

Année :2018

N° d'ordre : 82/D3C/2018

Série :09/Ele/2018



Université des Frères Mentouri Constantine  
Faculté des Sciences de la Technologie  
*Département Electronique*



## THESE

Présentée en vue d'obtention du diplôme de

**Doctorat troisième cycle En Electronique**

*Option : Systèmes, procédés et dispositifs pour l'électronique médicale*

L'intitulé de la thèse :

# Segmentation d'images de Résonance Magnétique de diffusion pour l'aide au diagnostic des pathologies cérébrales fœtales

Présentée par :

**ABDERREZAK Mohamed Zaki**

Soutenue publiquement le 04/07/2018, devant le jury composé de

**Jury d'examen :**

Président :	Mr. S. SAHLI	Prof. Université de Constantine 1
Rapporteur :	Mr. K. MANSOUR	Prof. Université de Constantine 3
Examineurs :	Mr. A. CHAABI	Prof. Université de Constantine 1
	Mr. N. BENOUDJIT	Prof. Université de Batna 2
	Mme. S. BENABDELKADER	Maitre de conférences Université Batna 2

# REMERCIEMENTS

*Je tiens à exprimer toute ma reconnaissance à mon promoteur Professeur Karim Mansour, pour qui je témoigne une profonde gratitude pour avoir dirigé ce travail. Son soutien, ses encouragements et conseils pertinents ainsi que son aide morale m'ont été précieux. Ce fût un honneur d'avoir été encadré par lui.*

*Je remercie les membres du jury d'avoir accepté de se pencher sur mes travaux et d'en apporter leurs avis en l'examinant. Je cite en premier lieu Monsieur SALAH SAHLI, professeur à l'université de Constantine 1 qui m'a fait l'honneur d'accepter de présider le jury de ma thèse.*

*Il m'est agréable de remercier Monsieur NABIL BENOUDJIT, Professeur à l'université de Batna 2, et SOUAD BENABDELKADER, Maître de conférences à l'université de Batna 2. Monsieur ABDELHAFID CHAABI professeur à l'université Constantine 1 pour avoir accepté d'examiner ce modeste travail.*

*J'associe à mes remerciements l'ensemble des membres du laboratoire Etude des matériaux électronique pour applications médicales, pour l'ambiance du travail et leur collaboration.*

*Je remercie également tous ceux qui ont contribué de près ou de loin à réaliser ce travail.*

*Enfin, j'exprime mon entière gratitude à ma famille pour leur patience, leurs encouragements et le soutien dont ils ont fait preuve tout au long de ces années.*

### **Titre : Segmentation d'images de Résonance Magnétique de diffusion pour l'aide au diagnostic des pathologies cérébrales fœtales.**

#### **Résumé :**

L'IRM fœtale est une modalité complémentaire à l'examen échographique. La segmentation des IRMs fœtales est une méthode récente, devenue rapidement une étape incontournable dans de nombreuses applications cliniques pour le suivi anténatal de la maturation ou d'une malformation cérébrales. Cependant, les artefacts inhérents à ce type d'images et la faible résolution de celles-ci, sont à l'origine des difficultés rencontrées dans la segmentation de ces images. Pour surmonter ces dernières, nous proposons dans ce mémoire deux méthodes de segmentation : (i) la première est basée sur les contours actifs géodésiques appliqués à des IRMs adultes pour la détection automatique des lésions cérébrales, (ii) la seconde basée sur la modification de la segmentation floue pour réaliser la classification des IRMs fœtales cérébrales. La première méthode est une combinaison de la fonction des contours actifs géodésiques et du gradient GVC (Gradient Vector Convolution) dans le but d'améliorer la détection des limites des objets à traiter. Le modèle a été testé sur des IRMs adultes qui contiennent des tumeurs cérébrales ou des lésions de sclérose en plaques. Ce modèle a donné satisfaction chez l'adulte mais pas dans le cas fœtal. Ce qui nous amènés à utiliser une classification non supervisée notamment avec des modèles de segmentation floue. Nous avons donc intégré la distance locale et non locale dans le terme d'attache aux données de la fonction d'énergie RFCM (Robust Fuzzy C-Means), et intégrer les moyennes non locales, dans le terme de régularisation. Un algorithme basé sur une segmentation couche par couche des régions cérébrales fœtales a donc été développé. Les résultats quantitatifs et qualitatifs sur des images fœtales cérébrales réelles ont montré l'efficacité et la robustesse de la méthode proposée par rapport aux méthodes décrites dans la littérature.

#### **Mots clés :**

IRM fœtale, Segmentation, Artefacts, Contour Active Géodésique, Gradient GVC, Tumeur, Sclérose En Plaque, Classification Non Supervisée, Segmentation Floue, Distance Local et Non Local, Moyenne Non Local.

### **Title: Segmentation of diffusion Magnetic Resonance images for the diagnosis of fetal brain diseases.**

#### **Abstract:**

Fetal MRI is a complementary modality to ultrasound examination. The segmentation of fetal MRIs is a recent method, quickly becoming an essential step in many clinical applications for antenatal monitoring of maturation or brain malformation. However, the artifacts inherent in this type of image and the low resolution of these images are at the origin of the difficulties encountered in the segmentation of these images. To overcome these, we propose in this memory, two methods of segmentation: (i) the first one is based on the geodesic active contours applied to adult MRIs for the automatic detection of the brain lesions, (ii) the second one is based on the modification of the fuzzy segmentation to achieve the classification of fetal brain MRIs. The first method is a combination of the geodesic active contours function and the Gradient Vector Convolution (GVC) in order to improve the detection of the boundaries of the objects to be segmented. The model has been tested on adult MRIs that contain brain tumors or multiple sclerosis lesions. This model has been satisfactory in adults but not in the fetal case. This led us to use an unsupervised classification especially with fuzzy segmentation models. We have therefore, integrated the local and non-local distance in the term of attachment to the data of the RFCM (Robust Fuzzy C-Means) energy function, and integrate non-local means in the regularization term. An algorithm based on layer-by-layer segmentation of fetal brain regions, has been developed. Quantitative and qualitative results on real cerebral fetal images showed the efficacy and robustness of the proposed method compared to the methods described in the literature.

#### **Keywords:**

Fetal MRI, Segmentation, Artifacts, Geodesic Active Contour, Gradient GVC, Tumor, Multiple Sclerosis, Classification Unsupervised, Fuzzy Segmentation, Local and Non-Local Distance, Non-Local Means.

### العنوان : تجزئة صور الرنين المغناطيسي المنشورة لتشخيص أمراض الدماغ الجنيني.

#### التلخيص :

الصور الرنين المغناطيسي للجنين هي طريقة مكتملة لفحص الموجات فوق الصوتية. إن تجزئة صور الرنين المغناطيسي للجنين هي طريقة حديثة ، وسرعان ما أصبحت خطوة أساسية في العديد من التطبيقات العيادة لرصد نضج أو تشوه الدماغ قبل الولادة. ومع ذلك فإن الاعطاب المتأصلة في هذا النوع من الصور ونفس دقتها ، هي في الأصل الصعوبات التي واجهتها في تجزئة هذه الصور.

للتغلب على هذه الصعوبات نقترح طريقتين للتجزئة في هذه الذاكرة: (1) الأولى تعتمد على الخطوط الجيوديسية النشطة المطبقة على الصور بالرنين المغناطيسي للكبار و ذلك للكشف التلقائي على آفات الدماغ ،(2) الثانية تعتمد على أساس تعديل تجزئة غامض لأداء تجزئة الصور بالرنين المغناطيسي للدماغ الجنين . تتمثل الطريقة الأولى في مجموعة من دالة المحيطات النشطة الجيوديسية و تحويل متجه التدرج (GVC) من أجل تحسين الكشف عن حدود المناطق مراد معالجتها . وقد تم اختبار هذا النموذج على الصور بالرنين المغناطيسي للكبار التي تحتوي على آفات ورم المخ أو التصلب المتعدد . كان هذا النموذج مرضياً لدى البالغين ولكن ليس مرضياً في حالة الجنين . الأمر الذي أدى بنا إلى استخدام تصنيف غير خاضع للرقابة و ذلك باستخدام نماذج التجزئة ضبابية . لذلك قمنا بدمج المسافة المحلية وغير المحلية في عبارة التعلق بالبيانات لدالة الطاقة (RFCM) ، ودمج المتوسطات غير المحلية في عبارة التسوية لدالة الطاقة .ولذلك ، تم تطوير خوارزم على أساس تجزئة مناطق الدماغ الجنينية طبقة بعد طبقة . أظهرت النتائج الكمية والنوعية على الصور حقيقية لدماغ الجنين فعالية و قوة الطريقة المقترحة مقارنة بالطرق الموضحة في الأدبيات .

#### الكلمات الرئيسية :

الصور بالرنين المغناطيسي للجنين ، التقطيع ، الاعطاب ، الخطوط الجيوديسية النشطة ، تحويل متجه التدرج (GVC) ، ورم ، التصلب المتعدد ، تصنيف غير خاضع للرقابة ، التجزئة غير واضحة ، المسافة المحلية وغير المحلية، المتوسط غير محلي.

<b>Introduction générale</b>	1
I. Contexte et motivation .....	1
II. Contribution et plan de manuscrit .....	2
<b>Chapitre 1. Principe de l’Imagerie par Résonance Magnétique</b>	4
I. Introduction .....	4
II. Principe de l’Imagerie par Résonance Magnétique .....	4
II.1. Polarisation avec un champ B0 .....	4
II.2. Excitation par un champ B1 .....	5
II.3. Phase de Relaxation .....	5
III. Création d’une image IRM .....	6
III.1. Imagerie par Spin-Warp .....	6
III.2. Sélection d’une coupe .....	7
III.3. Localisation dans le plan de coupe .....	7
IV. Paramètres d’une séquence .....	8
IV.1. Temps d’écho .....	9
IV.2. Temps de répétition .....	9
IV.3. Angle de basculement .....	9
V. Séquences d’une IRM .....	10
V.1. IRM chez l’adulte .....	10
V. 1.1. Image pondérée en densité de protons .....	10
V.1.2. Image pondérée en T2 .....	10
V.1.3. Image pondérée en T1 .....	11
V.2. IRM cérébrales fœtales .....	11
VI. Acquisition et lecture des images .....	12
VI.1. Lecture des images .....	12
VI.2. Reconstruction des images .....	13
VII. Artefacts en IRM .....	14
VII.1. Artefacts liés au patient (physiologique) .....	14
VII.1.1. Artefacts de mouvement (ghosting) .....	14
VII.1.2. Artefacts causés par des objets métalliques .....	15
VII.2. Artefacts liés à l’équipement .....	16

VII.2.1. Artefacts de déplacement chimique .....	16
VII.2.2. Artefacts de susceptibilité magnétique .....	17
VII.2.3. Les inhomogénéités d'intensité .....	18
VII.3. Artefact liés au système d'imagerie .....	18
VII.3.1. Artefact de repliement .....	18
VII.3.2. Artefact de troncature (Gibbs) .....	19
VII.3.3. Artefact du volume partiel .....	20
VIII. Anatomie et maturation cérébrales .....	20
VIII.1. Structure du système nerveux central .....	21
VIII.2. Maturation cérébrale .....	22
VIII.2.1. Mise en place du système nerveux .....	23
VIII.2.2. Formation du cerveau fœtale .....	24
IX. Conclusion .....	25
<b>Chapitre 2. Les différentes méthodes de segmentation</b> .....	<b>26</b>
I. Introduction .....	26
II. Définition .....	26
III. Différents approches de la segmentation .....	27
III.1. Approche basée contour .....	27
III.1.1. Méthode dérivative .....	27
III.1.2. Méthode par morphologie mathématique .....	28
III.1.3. Méthode déformable .....	29
III.2. Approche basée région .....	30
III.2.1. Approche par transformation de régions .....	30
III.2.1.1. Approche croissance de régions .....	31
III.2.1.2. Approche de partage de régions .....	32
III.2.1.3. Approche réunion de régions .....	32
III.2.2. Approche seuillage .....	32
III.2.3. Approche de classification .....	33
III.2.3.1. Classification déterministe supervisée .....	33
III.2.3.2. Classification déterministe non supervisée .....	37
III.2.3.3. Classification non paramétrique .....	38

III.3. Approche basée sur la forme .....	38
III.4. Approche hybride .....	39
IV. Utilisation des contours actifs pour la segmentation des IRMs .....	40
IV.1. Définition des contours actifs .....	40
IV.1.1. Les contours actifs paramétrique (snakes) .....	40
IV.1.2. Les contours actifs géométrique (Levels-Sets) .....	42
IV.2. Travaux effectués sur les contours actifs .....	44
V. Utilisation des C-Moyennes Floues dans la segmentation des IRMs ..	45
V.1. Théorie de la FCM .....	45
V.2. Travaux effectués sur la FCM .....	48
V.2.1. Mesure de la similarité .....	48
V.2.1.1. Distance Mahalabonis .....	48
V.2.1.2. Distance Manhattan .....	48
V.2.2. Ajout d'un terme pour la régularisation .....	49
V.2.3. Utilisation de la moyenne .....	50
V.2.3. Autre méthodes .....	51
VI. Conclusion .....	52
<b>Chapitre 3. Processus de segmentation proposée</b> .....	<b>53</b>
I. Introduction .....	53
II. L'approche hybride .....	53
II.1. Extraction de l'image du cerveau .....	53
II.1.1. Calcul de la variance .....	55
II.1.2. Rehaussement des contours .....	56
II.1.3. Binarisation de l'image .....	57
II.1.4. Outil morphologique .....	58
II.1.5. Remplissage des trous .....	60
II.1.6. Elimination des parties isolées .....	60
II.1.7. Superposition du masque à l'image .....	60
II.2. L'approche hybride de segmentation .....	61
II.3. Validation de la segmentation .....	64
III. L'approche de classification du cerveau .....	68
III.1. Modèle proposé .....	69

III.2. Validation de la méthode .....	72
III.2.1. Image de synthèse .....	73
III.2.2. Evaluation avec Brain Web .....	75
III.2.3. Evaluation avec des images IBSR .....	77
III.2.4. Validation clinique .....	81
IV. Conclusion .....	83
<b>Chapitre 4. La segmentation d'IRM fœtale cérébrale</b>	<b>84</b>
I. Introduction .....	84
II. Méthodologie .....	86
II.1. Processus de segmentation proposée .....	88
II.1.1. Séparation du liquide céphalo-rachidien du cerveau.....	88
II.1.1.1. Egalisation de l'histogramme .....	89
II.1.1.2. Initialisation des centroïdes .....	90
II.1.1.3. Application de la méthode proposée .....	91
II.1.2. Séparation de la MB et MG .....	92
II.1.2.1. Soustraction du LCR de l'image originale .....	92
II.1.2.2. Filtre Top-Hat .....	92
II.1.2.3. Adaptation de l'histogramme égalisé .....	94
II.1.2.4. Initialisation des centroïdes .....	95
II.1.2.5. Application de la méthode proposée .....	95
II.1.2.6. Reconstruction de l'image .....	96
III. Résultats et discussion .....	96
IV. Conclusion .....	102
<b>Conclusion générale</b>	<b>104</b>
I. Conclusion .....	104
II. Perspective .....	106
<b>Référence Bibliographique</b>	<b>107</b>
<b>Liste des publications</b>	<b>122</b>

<b>Liste des figures</b>		<b>page</b>
Figure 1.1	Principe de résonance magnétique nucléaire .....	6
Figure 1.2	Chronologie des impulsions en IRM .....	9
Figure 1.3	Quelques séquences IRM illustrées par des coupes du cerveau .....	11
Figure 1.4	IRM fœtale .....	12
Figure 1.5	La reconstruction d'une image 3D à partir des coupes 2D .....	14
Figure 1.6	Artefact de mouvement respiratoire dans les IRM fœtales .....	15
Figure 1.7	Artefact métallique .....	16
Figure 1.8	Artefact de déplacement .....	17
Figure 1.9	Susceptibilité magnétique .....	17
Figure 1.10	Coupe coronal en présence d'artefact lié aux inhomogénéités de l'intensité .....	18
Figure 1.11	Artefact de repliement .....	19
Figure 1.12	Artefact de troncature (gipps) .....	20
Figure 1.13	Artefact de volume partiel .....	20
Figure 1.14	Composition du cerveau .....	21
Figure 1.15	Anatomie du cortex cérébral .....	22
Figure 1.16	Coupe transversale de la gastrulation .....	23
Figure 1.17	Différentes étapes de la période de la neurulation .....	23
Figure 1.18	Les étapes de l'histogenèse .....	24
Figure 2.1	Segmentation par modèles dérivatif .....	28
Figure 2.2	Segmentation par croissance de régions .....	32
Figure 2.3	Les réseaux multicouches .....	34
Figure 2.4	Les réseaux à connexions locales .....	34
Figure 2.5	Les réseaux à connexion récurrentes .....	35
Figure 2.6	Réseaux à connexion complète .....	35
Figure 2.7	Structure d'un neurone artificiel .....	36
Figure 2.8	Méthode SVM .....	37
Figure 2.9	Représentation de la courbe Level-Sets .....	43
Figure 3.1	Schéma décrivant le système utilisé .....	55
Figure 3.2	Exemple de modèle de calcul de la variance .....	56
Figure 3.3	Image initiale filtrée par le filtre Pérona et Malik .....	57

Figure 3.4	Binarisation de l'image filtrée par la méthode Otsu .....	58
Figure 3.5	Ouverture morphologique .....	59
Figure 3.6	Fermeture morphologique .....	60
Figure 3.7	Superposition de l'image initiale avec le masque .....	61
Figure 3.8	Résultat de la segmentation de notre méthode sur l'image de synthèse	65
Figure 3.9	Comparaison entre notre modèle et le modèle Chan et Vese .....	66
Figure 3.10	Comparaison entre les résultats de la segmentation de la tumeur cérébrale .....	67
Figure 3.11	Segmentation d'une image de synthèse .....	74
Figure 3.12	Segmentation d'une image simulée sous BrainWeb .....	76
Figure 3.13	Segmentation sur une coupe T1 obtenue dans IBSR .....	78
Figure 3.14	Segmentation des images cliniques.....	81
Figure 4.1	Etude comparative entre L'IRM fœtale et L'IRM adulte .....	85
Figure 4.2	Distribution d'intensité de l'IRM adulte et fœtale .....	87
Figure 4.3	Segmentation d'une IRM fœtale axiale en utilisant différentes classes.	87
Figure 4.4	Schéma décrivant le système de segmentation utilisée .....	88
Figure 4.5	Image initiale après un prétraitement par le filtre Non Local Means ...	89
Figure 4.6	Image initiale après un prétraitement par égalisation d'histogramme...	90
Figure 4.7	Normalisation de l'image .....	91
Figure 4.8	Résultats de la segmentation par le modèle proposé .....	92
Figure 4.9	Soustraction du LCR de l'image principale pour segmenter la MG et la MB .....	92
Figure 4.10	Résultats du filtre morphologique Top-Hat .....	93
Figure 4.11	Résultats après adaptation de l'histogramme égalisé .....	94
Figure 4.12	Résultats de la segmentation de la MG et la MB.....	95
Figure 4.13	Résultats finaux de la segmentation par l'algorithme proposé .....	96
Figure 4.14	Résultats de la segmentation de l'IRM fœtale par l'algorithme proposé.....	100
Figure 4.15	Segmentation d'une IRM fœtale axiale pour l'étude quantitative .....	101

<b>Liste des Tableaux</b>		<b>page</b>
Tableau 3.1	Valeur de l'indice de similarité, du taux des faux positifs et celui des faux négatifs pour la segmentation de l'image de synthèse .....	75
Tableau 3.2	Valeurs de l'indice de similarité, du taux de faux positifs et celui des faux négatifs dans la segmentation de l'image BrainWeb .....	77
Tableau 3.3	Valeur de l'indice de similarité, du taux de faux positifs et celui des faux négatifs dans la segmentation de l'image IBSR .....	78
Tableau 4.1	Résultats de la segmentation d'IRM's fœtales par l'algorithme proposé .....	97
Tableau 4.2	de l'indice de similarité, du taux de faux positifs et celui des faux négatifs dans la segmentation d'une IRM fœtale par notre modèle .....	101

<b>Liste des Graphes</b>		<b>page</b>
Graphe 3.1	Influence de la taille du voisinage et l'intensité du bruit sur notre segmentation .....	80

## Liste des Symboles.

Symbole	Significations
$I$	Image originale
$\bar{I}$	Image moyenne
$\nabla I$	Gradient de l'image $I$
$p(R_i)$	Prédicat de la région $R_i$
$\delta$	Seuil de la segmentation
$\sigma$	Variance
$\emptyset(x, y)$	Contour Level-set
$k$	Fonction de courbure
$\delta(\emptyset)$	Fonction de Dirac
$u_{ji}$	Degré d'appartenance
$v_i$	Centroïde de la classe $i$
$N_R$	Nombre totale de voisinage
$N_j^R$	Nombre totale de voisinage du voxel $j$
$\text{div}$	Divergence
$g$	Fonction d'arrêt
$\varepsilon_B(I)$	Erosion de l'image $I$ par $B$
$\delta_B(I)$	Dilatation de l'image $I$ par $B$
$H_\epsilon(t)$	Heuriste
$G_\sigma$	Noyau Gaussien
$\lambda_j$	Multiplieur de Lagrange
$d_l$	Distance locale
$d_{nl}$	Distance Non Locale
$\rho$	Indice de similarité
$r_{fp}$	Faux positives
$r_{fn}$	Faux négatives

**Liste des abréviations.**

<b>Abréviations</b>	<b>Significations</b>
IRM	Image de Résonance Magnétique
SVM	Machine à Vecteur de Support
MB	Matière Blanche
MG	Matière Grise
LCR	Liquide Céphalo-Rachidien
$E_{int}$	Energie Interne
$E_{ext}$	Energie Externe
FCM	Fuzzy C-Means
RFCM	Robust Fuzzy C-Means
MFCM	Modified Fuzzy C-Means
BET	Brain Extraction Toll
CV	Chan et Vese
GVC	Gradient Vector Convolution

# **INTRODUCTION GENERALE**

### **I. Contexte et motivation.**

L'essor qu'a connu l'imagerie médicale ces dernières années par le développement de nouvelles modalités, permet une analyse détaillée des tissus et d'établir un diagnostic médical précis. Les techniques d'acquisition sont multiples, elles sont basées sur différents types de rayonnements (champ magnétique [1], ultrasons [2], rayon X [3], et rayon gamma [4],...).

L'Imagerie par Résonance Magnétique (IRM) est devenue rapidement une technique d'étude essentielle du crâne et de l'encéphale, grâce aux qualités de contraste et de caractérisation tissulaire qui facilitent la détection des différentes pathologies [5,6]. L'étude dans tous les plans, de la région d'intérêt, représente l'avantage de cette modalité qui a permis de l'adapter à l'étude cérébrale *in utero*.

L'IRM prénatale facilite l'étude des parties difficiles à observer lors d'un examen échographique réalisé par un gynécologue. Si le médecin remarque quelques indices qui peuvent générer des malformations cérébrales chez le fœtus (comme un retard du développement ou une anomalie cérébrale au niveau de la fosse postérieure,...etc), le médecin traitant prescrit un examen d'IRM pour compléter les observations échographiques et histologiques dans le but de confirmer l'anomalie trouvée. Grâce à un contraste élevé, ces régions cérébrales peuvent faire l'objet d'études précises, notamment en termes de biométrie par le biais d'une segmentation [7, 8, 9].

De nombreuses méthodes de segmentation automatique ont été développées dans un but d'aide au diagnostic cérébral dans le cas des IRM adultes [10, 11]. Parmi ces méthodes, on retrouve des méthodes qui permettent la détection automatique des malformations ou de pathologies telles que la sclérose en plaques et les tumeurs, ainsi que des méthodes qui peuvent être utilisées pour la quantification de différents tissus tels que la matière blanche (MB), la matière grise (MG) et le liquide céphalorachidien (LCR).

La segmentation automatique des images prénatale reste un défi majeur dans le diagnostic médical. Malgré la présence des artefacts dans ces images et la faible résolution de ces dernières, elle a tout de même suscité beaucoup d'intérêt dans la quantification ou dans la segmentation des images du cerveau fœtal [12,13]. Dans ce contexte, nous avons développé deux méthodes de segmentation automatique des IRMs cérébrales, (i) la première pour la segmentation des tissus pathologiques dans les IRMs adultes en présence du processus tumorale, et la sclérose en plaques, et (ii) la seconde permet la quantification de différentes

régions qui constituent le cerveau. Le modèle segmentation a été testé sur 14 cas d'IRMes d'adultes de différents âges, obtenues de la clinique El Hoceini de Constantine. Pour ce qui est de l'objectif de notre travail, ce modèle a été testé sur 5 cas des IRMs cérébrales fœtales entre 27 à 36 semaines d'aménorrhée.

### **II. Contribution et plan du manuscrit.**

Nous introduisons dans le premier chapitre, les principales modalités de la formation des images obtenues par résonance magnétique. Nous rappelons en particulier, dans un premier temps, le processus de formation de l'image, allant de l'acquisition jusqu'aux modes de visualisation des images en IRM chez l'adulte et du fœtus. Dans un second temps, nous décrivons les différents artefacts qui peuvent être présents dans les IRM adultes et fœtales, ainsi que les conséquences de ces derniers sur la qualité de la segmentation. Enfin nous terminons de chapitre par des rappels d'anatomie et par une description de la maturation cérébrale fœtale.

Le second chapitre contient un état de l'art sur les méthodes de segmentation des images cérébrales obtenues par IRM. En effet, après une présentation des principales approches proposées dans la littérature [14, 15, 16], nous présentons d'une manière plus détaillée, les méthodes basées sur les contours actifs (snake) et sur la méthode floue FCM. Nous terminons ce chapitre, par une description de l'utilisation de ces deux méthodes dans la segmentation des IRMs cérébrales chez l'adulte et le fœtus.

Le troisième chapitre, présente deux méthodes de segmentation d'IRMes cérébrales adultes. Dans la première segmentation, nous proposons un modèle hybride constitué par des contours actifs géodésiques en utilisant le GVC (Gradient Vector Convolution) pour améliorer la détection des limites du modèle, que nous avons ensuite testé pour la détection des tumeurs et la sclérose en plaques. Une étude comparative avec d'autres méthodes de segmentation a donné satisfaction au modèle qu'on a proposé. La seconde partie du chapitre contient une extension de l'algorithme RFCM par l'intégration d'une part, de la distance locale et non-locale dans le terme d'attache aux données et d'autre part, des moyennes non locales, dans le terme régulateur de la fonction pour réaliser le lissage simultanément que la segmentation et gagner dans le temps de calcul. Nous achevons ce chapitre par l'application de ce modèle à la segmentation des IRMs cérébrales obtenues par différentes bases : La base BrainWeb qui représente des IRMs simulées. La base IBSR qui représente des images

cliniques, et dont l'avantage consiste au fait qu'elle contient des IRMs segmentées par des experts qu'on a utilisés pour comparer nos résultats. Et enfin, nous avons appliqué notre modèle sur des images réelles obtenue par l'IRM Philips Intera 1.5 du centre de diagnostic El Hoceini de Constantine. Pour valider notre modèle, on a effectué une évaluation qualitative et quantitative avec d'autres méthodes et des segmentations manuelles d'experts.

Le quatrième chapitre décrit le processus de segmentation proposé dans le but de segmenter les IRM prénatales et quantifier les principaux tissus cérébraux (MB, MG, LCR). L'application de la segmentation hybride proposée sur cinq cas d'IRMs fœtales obtenues par le CHU Hautepierre de Strasbourg n'a pas donnée satisfaction. Dans ce chapitre, on a établie les différences entre les IRMs adultes et les IRMs fœtales, et on a proposé un algorithme qui permet une segmentation couche par couche des tissus cérébraux. Nous présentons dans un premier temps le processus de segmentation utilisé qui est principalement basé sur une double application du deuxième modèle présenté dans le chapitre précédent. Nous terminons ce chapitre par l'application du processus aux IRMs fœtales, des évaluations qualitatives et quantitatives des résultats obtenus et ceux obtenus par d'autres méthodes, ainsi que par des experts médicale prouve l'efficacité de ce dernier malgré la faible résolution de ces images.

# **CHAPITRE I**

## **Principe de l'IRM**

## **I. INTRODUCTION.**

Dans ce chapitre, nous présentons le principe de fonctionnement de l'Imagerie par Résonance Magnétique (IRM) cérébrale, et nous aborderons le phénomène de résonance magnétique. Seront présentées également, les différentes séquences en IRM, ainsi que les méthodes d'acquisition et de lecture des images. Nous discuterons ensuite des principaux artefacts, du bruit présent dans les IRMs ainsi que des solutions pour y remédier. De plus, nous développerons les méthodes de correction de ces artefacts. Enfin pour finir ce chapitre, nous décrirons l'anatomie et la maturation cérébrales.

## **II. PRINCIPE DE L'IMAGERIE PAR RESONANCE MAGNETIQUE.**

L'IRM est une technique non invasive et non irradiante utilisée pour la visualisation des organes et des tissus mous [17]. Elle exploite le phénomène physique de résonance magnétique et de relaxation mis en évidence par les deux équipes Bloch [18] et Purcell [19] en 1946. Elles ont obtenu le prix Nobel de physique en 1952. La première image par résonance magnétique date de 1973 ; elle fût réalisée par le chimiste P.Lauterbur [20] et le physicien P.Mansfield [21]. Ils ont reçu le prix Nobel de médecine en 2003. Aujourd'hui, après des années d'évolution, l'IRM est devenue une technique majeure de l'imagerie médicale moderne [22].

Le principe de l'IRM repose sur les propriétés magnétiques du noyau d'hydrogène présent dans la molécule d'eau qui représente entre 60 et 73% du corps humain [23]. Ces taux varient d'un tissu à un autre et peuvent varier dans le même tissu selon son état physiologique (présence de pathologies ou de tissus sains).

Un noyau à nombre atomique impair [24], possède un moment magnétique appelé spin nucléaire [25] (Otto Stern et Walter Gerlach, 1922). En absence d'un champ magnétique extérieur, ces spins ont une orientation aléatoire et la résultante magnétique globale  $M$  est nulle [26] (figure1.1-A).

### **II.1. Polarisation avec un champ $B_0$ .**

Lorsqu'un champ magnétique  $\vec{B}_0$  est appliqué aux noyaux, les spins nucléaires s'alignent soit dans la même direction (parallèle) du champ magnétique ou bien dans le sens inverse (antiparallèle). Les spins orientés dans la direction du champ magnétique sont plus nombreux. Il en résulte l'apparition d'un moment magnétique globale  $\vec{M}$  non nul (figure1.1-B). Les spins adoptent un mouvement de précession autour du champ appliqué

$\vec{B}_0$  avec une vitesse proportionnelle au champ magnétique, caractérisée par une fréquence angulaire  $\omega_0 = \gamma B_0$  (Précession de Larmor), où  $\gamma$  est le rapport gyromagnétique de l'atome considéré (pour l'hydrogène il est égal à 42,58 MHz/T).

## **II.2. Excitation par un champ $B_1$ .**

L'application dans un plan  $XY$  perpendiculaire à  $\vec{B}_0$ , d'un champ magnétique Radiofréquence (RF) à la même fréquence que celle de Larmor, perturbe le système. Cette perturbation est appelée phénomène de résonance. Au niveau quantique, il y'a absorption d'énergie, mais au niveau macroscopique la RF provoque un basculement de l'aimantation globale  $M$  dans le même sens que le champ  $\vec{B}_1$  (figure 1.1-C).

L'aimantation  $\vec{M}$  se décompose en une composante longitudinal  $\vec{M}_z$  selon l'axe de  $\vec{B}_0$ , et une composante transversal  $\vec{M}_{xy}$ . La phase d'excitation se traduit alors par une diminution de l'aimantation longitudinale qui passe par 0 pour remonter à son niveau haut. De plus, si la composante  $M_z$  diminue, la composante transversale augmente et vice et versa. Si le basculement est à  $180^\circ$ , la composante  $\vec{M}_{xy}$  est nulle ; par contre, la composante  $\vec{M}_z$  est maximale.

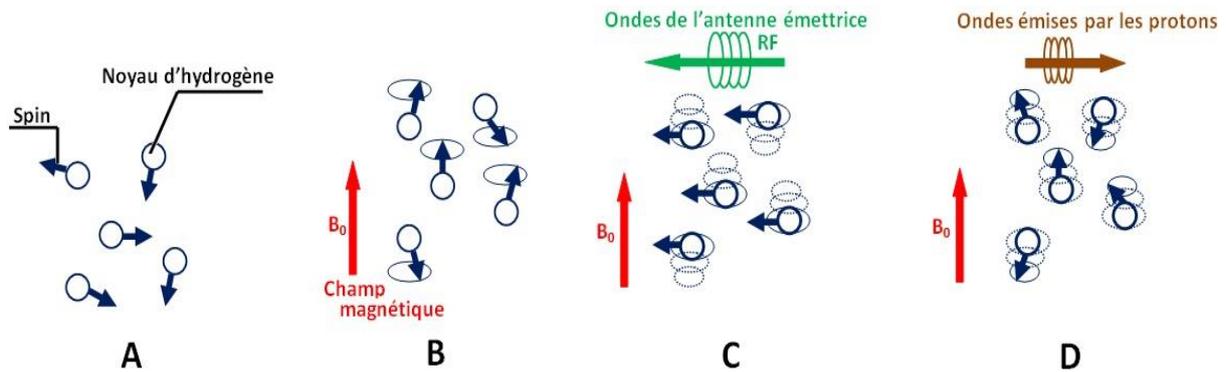
## **II.3. Phase de Relaxation.**

Lorsque le champ magnétique  $\vec{B}_1$ (RF) est coupé, le système perd l'énergie absorbée au cours de l'étape précédente, le moment magnétique  $\vec{M}$  retourne à son état d'équilibre et l'aimantation globale  $\vec{M}$  s'aligne sur le champ  $\vec{B}_0$  en décrivant une spirale (figure 1.1-D). La relaxation longitudinale  $M_L(t)$  croît exponentiellement avec une constante de relaxation spin-réseau [27]. Elle correspond à un transfert d'énergie d'un spin vers son environnement et peut être représentée par la fonction suivante (écrite par Bloch [18]) :

$$M_L(t) = M_0 - (M_0 - M_L(0))e^{-t/T_1} \quad (1.1.a)$$

Par contre, la relaxation transversale appelée  $M_t(t)$ , décroît exponentiellement selon une constante de relaxation spin-spin [28]. Elle correspond à des interactions entre spins, elle est décrite par l'équation de Bloch ci-dessous :

$$M_t(t) = M_t(0)e^{-\frac{t}{T_2}} \quad (1.1.b)$$



**Figure.1.1.** Principe de la résonance magnétique nucléaire.

Le retour de l'aimantation globale  $\vec{M}$  est accompagné par une émission d'énergie sous forme d'une onde RF [29]. Ce signal est collecté par une antenne réceptrice qui constitue le signal enregistré en IRM, qu'on appelle signal de précession libre [30], ou FID (Free Induction Decay).

Le FID passe par une transformation de Fourier [31] qui donne un signal avec trois paramètres qui caractérisent l'évolution de l'aimantation  $M$  qui sont la fréquence, l'amplitude et la durée du signal.

### **III. CREATION D'UNE IMAGE IRM.**

Différents noyaux présents dans le corps humain, possèdent des propriétés magnétiques, mais en IRM seul le noyau d'hydrogène qui se trouve dans la molécule d'eau est utilisé.

Plongés dans un champ magnétique, les protons d'un échantillon ou tissu homogène résonnent à la même fréquence de Larmor. Le principe de formation d'une image par résonance magnétique est d'induire une dépendance entre la position d'un proton et ses caractéristiques (fréquence de résonance et phase), en utilisant des gradients de champ magnétique.

#### **III.1. Imagerie par Spin-Warp.**

Trois gradients de champ magnétique sont appliqués successivement par l'intermédiaire de bobines de gradient dans le cadre de l'imagerie par Spin-Warp. Pour réaliser le codage de l'image, les gradients suivants sont utilisés : le gradient de coupe  $G_c$ , le gradient de phase  $G_p$  et le gradient de lecture  $G_L$ . Un gradient désigne un champ magnétique statique dont l'intensité varie linéairement dans une direction donnée appelée direction du gradient.

**III.2. Sélection d'une coupe.**

Pour sélectionner une coupe de l'échantillon qu'on souhaite représenté dans une image, on utilise un gradient de coupe. Ce dernier en un point  $P$  de l'espace orienté dans un repère  $(O, \vec{u}_x, \vec{u}_y, \vec{u}_z)$ , a pour expression :

$$G_c(P) = g_c(n_c \cdot OP)u_z \quad (1.2)$$

Où  $g_c$  et  $n_c$  sont l'intensité et la direction du gradient de coupe.

Sur tout point  $P$  d'un plan  $z$ , dans une direction  $n_c$ , la fréquence de Larmor reste constante et vaut :

$$f_0^z(p) = \gamma \frac{(B_0 + g_c z)}{2\pi} \quad (1.3)$$

Ainsi, avec l'application d'un champ électromagnétique  $\vec{B}_1$  de fréquence  $f_0^z$  et de bande passante  $2\delta f$ , seuls les protons qui ont une fréquence de résonance comprise entre  $(f_0^z - \delta f)$  et  $(f_0^z + \delta f)$  seront excités.

L'intensité du gradient et la bande passante déterminent donc l'épaisseur du plan  $\Pi_z$  de la coupe sélectionnée. Une fois le plan de coupe sélectionné, il reste à se repérer dans  $\Pi_z$  pour identifier chaque voxel de ce plan.

**III.3. Localisation dans le plan de coupe.**

Le gradient de lecture et de phase permet le codage spatial à l'intérieur du plan  $\Pi_z$ , avec des directions  $n_l$  et  $n_p$  orthogonales. On prend par un exemple, un point  $p$  dans le repère local  $(A, \vec{n}_l, \vec{n}_p, \vec{n}_c)$ , il a pour coordonnées  $(x_l, x_p, x_c)$ .

Le gradient de lecture  $G_l$  est utilisé pour créer une dépendance de la fréquence des différents signaux émis par les protons de la coupe  $\Pi_z$  par rapport à la position sur l'axe porté par  $\vec{n}_l$  dans ce plan. Il est appliqué au moment de l'enregistrement du signal et a pour expression :

$$G_l(p) = g_l x_l u_z \quad (1.4)$$

La fréquence du signal de résonance émis depuis un point  $P$  de  $\Pi_z$ , vaut donc d'après l'équation de précession Larmor :

$$f_0(p) = \gamma \frac{g_l x_l + B_0}{2\pi} \quad (1.5)$$

Ainsi, le gradient de lecture code la position d'un point  $x_1$  dans le plan  $\Pi_z$ , et le gradient de phase permet de trouver  $P$  de manière unique, lui aussi est utilisé pour coder la position  $x_p$  dans la direction  $n_p$  qui a l'expression suivante :

$$G_p(p) = g_p(n_p \cdot OP)u_z = g_p x_p u_z \quad (1.6)$$

Il s'écoule un court instant  $T_p$  avant de commencer l'enregistrement du signal, qui acquiert alors en  $P$  une phase égale à :

$$\varphi(p) = 2\pi f_0 T_p = \gamma(g_p x_p T_p + B_0) \quad (1.7)$$

Par le biais des gradients de lecture et de phase, il existe une dépendance entre la position des protons à l'intérieur du plan de coupe et le couple phase/fréquence du signal de résonance. Cette dépendance est donnée par les relations (1.5) et (1.7).

En imagerie Spin-Warp, le signal recueilli provenant de la mise en résonance des protons de  $\Pi_z$ , est un signal sinusoïdal. Si on néglige les phénomènes de relaxation, il est de la forme :

$$S(t_1, g_p) = k \iint_{\Pi_z} \rho(x_l, x_p) e^{2\pi i f_0(p)t_1} dx_l dx_p \quad (1.8)$$

Où  $\rho(x_l, x_p)$  est la densité de protons en  $(x_l, x_p)$  du plan de coupe.

En pratique, l'image IRM est construite en faisant varier  $G_p$  dans un intervalle  $[-G, +G]$ , par pas de  $2G/N_p$  où  $N_p$  est le pas d'encodage. Le signal recueilli est échantillonné sur  $N_l$  points pour obtenir une matrice  $N_l \times N_p$ . L'image IRM complexe est alors obtenue par double transformation de Fourier.

#### **IV. PARAMETRES D'UNE SEQUENCE.**

Les paramètres d'une séquence (figure 1.2) sont fixés par le manipulateur sur la console pour définir une séquence IRM. Ils permettent de contrôler l'influence des paramètres tissulaires  $T_1$ ,  $T_2$  et la densité de protons sur le signal et de moduler ainsi le contraste de l'image IRM.

#### IV.1. Temps d'écho.

Le temps d'écho, noté  $TE$ , représente le délai de mesure entre le basculement de  $90^\circ$  et le recueil de l'écho, qui est le signal provenant de l'aimantation transversale. Comme le signal de précession libre ne peut pas être enregistré directement après l'excitation (déphasage parasite induit par les gradients), il est acquis sous la forme d'un écho de spin ou de gradient.

Pour le cas de l'écho de spin, les hétérogénéités de  $B_0$  et les différentes aimantations des tissus sont compensées, alors qu'elles ne le sont pas dans l'écho de gradient. Cet état induit une différence entre le temps de relaxation, noté  $T_2$  pour l'écho de spin et  $T_2^*$  pour l'écho de gradient. D'une manière générale, le temps d'écho  $TE$  intervient pour refléter la relaxation  $T_2$ , il peut être lié directement au contraste des séquences résultantes.

#### IV.2. Temps de répétition.

Une image se constitue à partir de la répétition d'une même séquence mais avec différentes amplitudes du gradient de phase  $G_p$ , le temps entre deux impulsions de  $90^\circ$  est appelé temps de répétition  $TR$ , comme le  $TE$ , le  $TR$  est aussi un facteur qui favorise le contraste.

#### IV.3. Angle de basculement.

L'angle de basculement correspond à l'énergie délivrée par le champ  $B_1$  pour faire basculer l'aimantation  $\vec{M}$  selon un axe perpendiculaire au champ principal  $\vec{B}_0$ . Si  $\vec{M}$  est basculée d'un angle  $\alpha = 90^\circ$  (excitation par une impulsion  $\pi/2$ ), toute l'aimantation est dans le plan transversal et  $M_L$  est nulle.

En cas de basculement d'un angle inférieur à  $90^\circ$ , seule une partie de l'aimantation est convertie en signal ( $M_T$ ). Une aimantation  $M_T$  persiste, elle peut être utilisée pour une autre excitation. Le signal sera autant plus faible que l'angle de basculement sera petit. L'angle de basculement  $\alpha$  intervient dans le contraste de l'image, plus il est grand, plus le  $T_1$  gouverne le contraste.

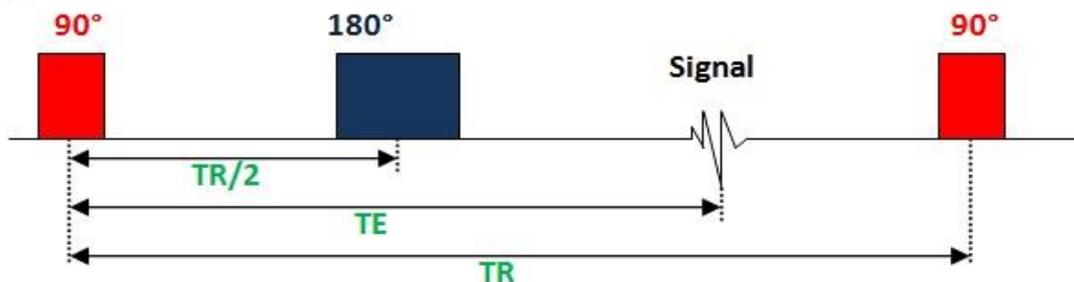


Figure 1.2. Chronologie des impulsions en IRM.

## **V. SEQUENCES D'UNE IRM.**

En modifiant les paramètres mentionnés précédemment, une grande diversité de volumes variant par le contraste, peut être acquise selon l'information que l'on cherche à mettre en valeur [32]. Dans ce travail nous décrivons les différentes techniques d'acquisition des images IRM cérébrales pour les cas adulte et fœtal.

### **V.1. IRM chez l'adulte.**

#### **V.1.1. Image pondérée en densité de protons.**

Pour un  $TR$  long de l'ordre de 2s et un  $TE$  court de l'ordre de 20 ms, on obtient une séquence pondérée en densité de proton  $\rho$ , qui reflète la différence de concentration des protons d'une structure à une autre, cette pondération s'exprime directement dans la phase de relaxation longitudinale  $M_z$ .

Les tissus sont ordonnés sur l'image par l'évolution de niveaux de gris en matière blanche (MB), matière grise (MG) et liquide cérébro-spinal (LCS) (figure 1.3-a).

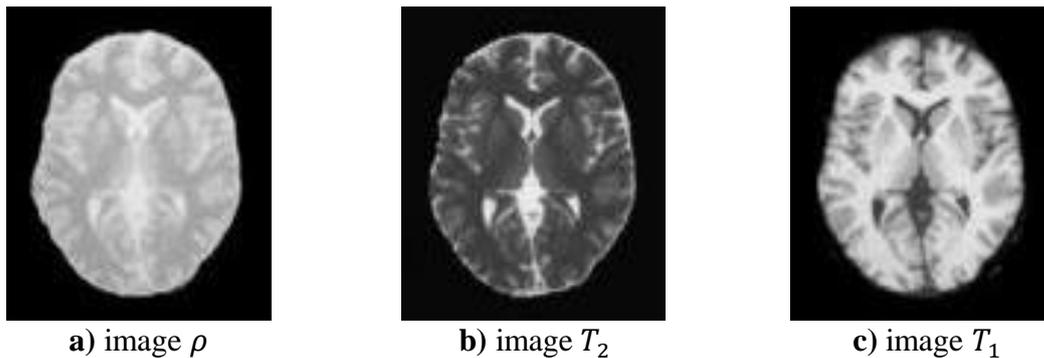
#### **V.1.2. Image pondérée en $T_2$ .**

Pour un  $TR$  long, de l'ordre de 2s, et des  $TE$  longs, environ 90 ms, la décroissance du signal domine la différence de densité protonique entre tissus. Le signal est suffisant pour réaliser une image dite pondérée en  $T_2$ , où les tissus sont ordonnés par niveaux de gris croissants en MB, MG et LCS (Figure 1.3-b).

Les séquences dites en pondération  $T_2$ , sont longues à cause du  $TR$  qui est principalement long. On utilise des paramètres  $TE$  et  $TR$  longs, respectivement pour faire du  $T_2$  et le second pour ne pas faire du  $T_1$ .

#### **V.1.3. Image pondérée en $T_1$ .**

Pour des  $TR$  courts de l'ordre de 600 ms, le contraste entre les tissus dépend essentiellement de  $T_1$ . Pour des  $TE$  courts (environ 20 ms), les différences de décroissance du signal entre les tissus n'ont pas le temps de s'exprimer, rendant le contraste indépendant de  $T_2$  : pour un  $TR$  court on obtient une image pondérée en  $T_1$ , où les tissus sont ordonnés par niveaux de gris croissants en LCS, MG et MB (Figure 1.3-c). Les séquences dites de pondération  $T_1$  sont rapides. On prend des paramètres  $TE$  et  $TR$  courts, respectivement pour ne pas pondérer en  $T_2$  et pour pondérer en  $T_1$ .



**Figure.1.3.** Quelques séquences IRM illustrées par des coupes du cerveau.

### **V.2. IRMs cérébrales fœtales.**

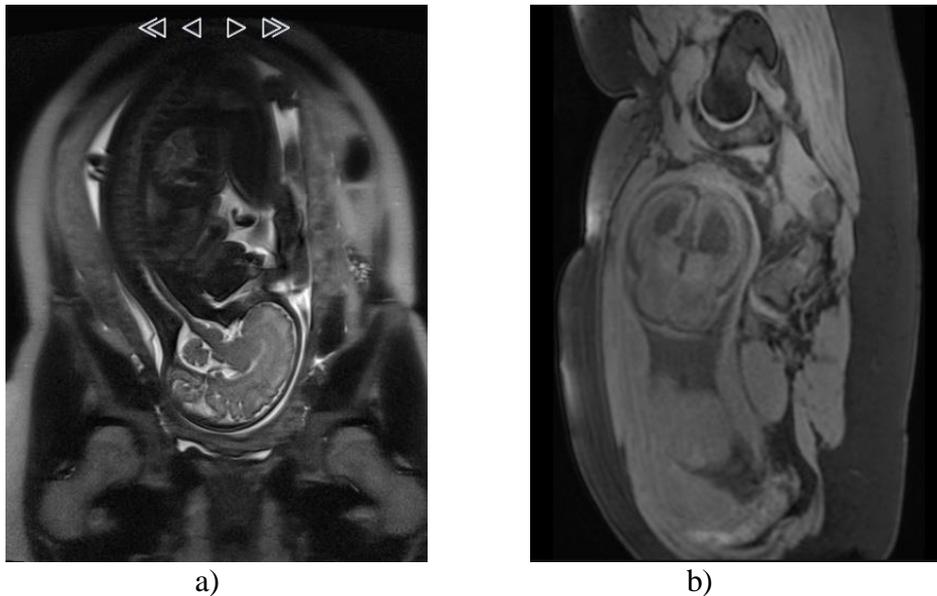
L'IRM cérébrale fœtale est un examen complémentaire réalisé pour confirmer ou infirmer les hypothèses échographiques [33]. Pendant l'examen, la parturiente est installée en position décubitus dorsal. Si une sensation d'inconfort de la patiente due à une compression de la veine cave antérieure est ressentie [34,35], elle peut être réinstallée en position décubitus latéral.

En IRM fœtale, les acquisitions reposent sur l'écho de spin ultra rapide [36] pour diminuer d'une part, les artefacts liés au mouvement fœtal et, d'autre part, les effets de la respiration maternelle. Grâce à ces séquences rapides on obtient en moins d'une seconde une coupe de 3 à 5 mm. La répétition des mêmes séquences d'acquisition peut s'avérer être une solution en présence des mouvements fœtaux.

L'examen de l'IRM fœtale commence par des acquisitions permettant un repérage du fœtus dans les trois axes, il permet à la fin d'obtenir des séquences pondérées en  $T_1$  et  $T_2$  dans les trois plans de l'espace. Les séquences pondérées en  $T_1$  et  $T_2$  ne contiennent pas les mêmes informations, chaque image obtenue par ces séquences, contient des informations spécifiques qui peuvent être utilisées par le médecin pour prévoir une malformation précise d'une région cérébrale.

Les séquences pondérées en  $T_2$  permettent d'étudier la giration, les phénomènes de migration neuronale et suivre l'évolution du cortex cérébral [37]. La figure 1.4-a représente une IRM fœtale pondérée en  $T_2$  sur laquelle on ne remarque que le cortex, la couche germinale et les cellules en migration sont noires et dites hypointenses. Par contre le LA (Liquide Amniotique) et le LCR sont en hypersignal ou hyperintenses (blanc).

La figure 1.4-b représente une IRM fœtale pondérée en  $T_1$  sur laquelle on peut voir le LCR et le LA (Liquide Amniotique) en hypointenses (noirs), le cortex, la graisse, l'hypophyse, les débuts de processus et les hématomes récents sont tous en hypersignal. Cette séquence est utilisée dans la recherche des processus hémorragiques et des lésions de sclérose tubéreuse de Bourneville [38].



**Figure.1.4.** IRM fœtale; a) séquence pondérée T<sub>2</sub>, b) séquence pondérée T<sub>1</sub>.

## **VI. ACQUISITION ET LECTURE DES IMAGES.**

### **VI.1. Lecture des images.**

L'encodage de l'image précédemment décrit fournit un signal discret dans le domaine fréquentiel (phase, fréquence) appelé espace K. Il existe plusieurs types de balayage de l'espace K, les plus utilisés en IRM sont : cartésien, spiral ou radial. Ils caractérisent en partie, l'acquisition et la qualité de l'image reconstruite (rapidité d'acquisition, sollicitation du système de gradient, sensibilité aux artefacts...). Pour passer du domaine fréquentiel au domaine spatial, on utilise la transformée de Fourier inverse. Les images d'IRM sont fournies sous la forme d'un ensemble d'images 2D qui peuvent être assemblées pour donner une image tridimensionnelle. Cependant, pour réaliser cette image, un ensemble de paramètres doit être disponible pour chaque coupe acquise sous forme DICOM (Digital Imaging and Communications in Medicine).

Pour réaliser la reconstruction 3D, il est nécessaire d'insérer un repère dans les images bidimensionnelles et effectuer le recalage de ces derniers. La reconstruction 3D est donc liée

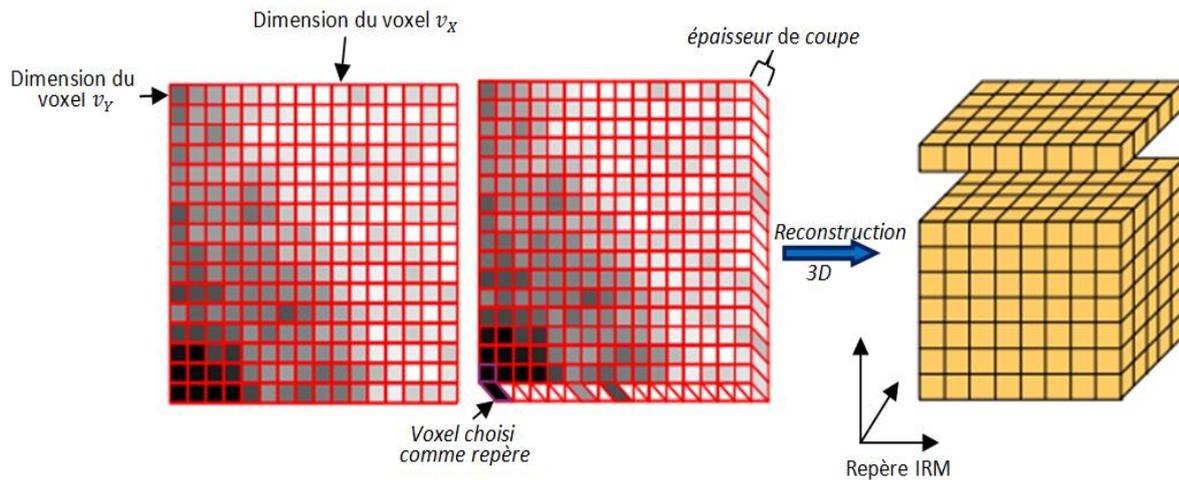
directement au bon positionnement des coupes successives. Le manque d'une coupe peut affecter la reconstruction. Il est également nécessaire de connaître six paramètres pour effectuer la reconstruction de l'image qui sont: l'orientation du repère 2D, la position de son origine, la taille des pixels, l'épaisseur des coupes, le champ de vue, et pour le nombre de coupe. Ces paramètres sont fournis par des champs DICOM qui permettent de calculer la taille du voxel (volumes unitaires) lors de l'acquisition. Les champs fournis par DICOM sont respectivement :

- **Image Position (Patient)** : permet de donner la position de l'origine de la coupe 2D par rapport au repère de l'IRM.
- **Image Orientation (Patient)** : permet de donner les deux vecteurs du repère de la coupe 2D, dans le repère de l'IRM.
- **Pixel Spacing** : permet de donner la taille des deux vecteurs du repère de la coupe 2D, toujours dans le repère de l'IRM.
- **Slice Thickness** : donne l'épaisseur de la coupe, ce qui permet de voir si les coupes sont jointives ou non.
- **Field of view (FOV)** : permet de connaître la taille de l'image.
- **Nombre de coupe** : il dépend de l'examen qu'on veut réaliser.

## **VI.2. Reconstruction des images.**

Les images d'IRM sont parfois fournies sous forme de coupes très fines (millimètre) non jointives, elles ne sont donc pas exploitables pour une reconstruction 3D, du fait que le paramètre du volume manque. Il faut donc s'assurer d'abord que les coupes sont bien jointives avant de commencer la reconstruction. En effet, pour avoir le volume d'une coupe, il faut que l'épaisseur des coupes soit compatible avec la distance inter-coupe.

Pour prendre une coupe d'une image IRM, il est nécessaire de placer le repère de la coupe sur un repère fixe (un voxel choisi) et de construire un volume de coupe d'épaisseur appelée *Slice thickness* (Figure 1.5). Cependant, on rencontre parfois des cas où l'axe de progression du repère de l'image 2D ne suit pas la direction donnée par la normale au plan de chaque coupe. La seule solution dans ces cas, est de faire un ré échantillonnage des images 2D.



**Figure.1.5.** la reconstruction d'une image 3D à partir des coupes 2D.

## **VII. ARTEFACTS EN IRM.**

Comme toute image issue d'un système d'acquisition, les sources d'artefacts en IRM sont nombreuses, ce qui cause la perte ou le rehaussement artificiel du signal [39]. La connaissance des artefacts nous permet de les minimiser, ou les réorienter, on peut aussi les corriger en post-traitement.

On distingue trois types d'artefacts dans les examens d'IRM.

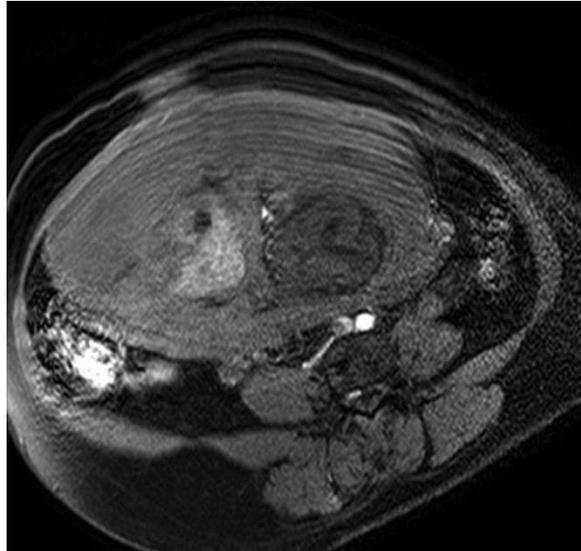
### **VII.1. Artéfacts liés au patient (physiologiques).**

#### **VII.1.1. Artéfacts de mouvement (ghosting).**

Artefact fréquent, à l'origine d'un déplacement d'une structure entre 2 TR ou au cours du codage de phase, les spins ne sont donc pas enregistrés à la même position à chaque répétition. Leur phase ne correspond pas à leur position, ce qui va conduire à une dégradation de la qualité des images qui se manifeste par un flou qui se propage selon la direction du codage de phase. La figure 1.6 montre une coupe frontale d'une IRM fœtale. Ils peuvent être la conséquence des mouvements maternels ou fœtaux, dans le cas maternel, on observe un flou dans la direction d'acquisition de la phase [40,42]. Si ces mouvements sont associés à la respiration maternelle, ils peuvent conduire à l'apparition de cet artefact [42]. Dans le cas d'une IRM chez l'adulte, elles peuvent être associées aux battements cardiaques, pulsations vasculaires.

Il existe deux types de mouvements fœtaux [43] : (i) les mouvements globaux qui sont les plus fréquents, ils sont associés à un mouvement de la tête, du tronc, ou des membres

et (ii) les mouvements internes décrits précédemment qui sont associés au fonctionnement des organes (battements cardiaques,...). Les artefacts de mouvement sont visibles dans le sens du codage en phase parce que celui-ci est plus lent (durée = seconde), par contre le codage en fréquence est plus rapide (durée = mseconde).



**Figure 1.6.** Artefacts de mouvement respiratoire dans les IRMs fœtales.

Pour résoudre ce problème, on a recours aux séquences rapides (< 30 sec) en apnée [41,43], et parfois à la sédation des patients agités. L'utilisation d'une synchronisation cardiaque ou respiratoire peut aussi inverser le sens de la phase et de la fréquence pour que l'artefact se projette ailleurs. Les nouvelles machines sont dotées de logiciels permettant de diminuer ce type d'artefacts.

### **VII.1.2. Artefacts causés par des objets métalliques.**

Avant chaque examen d'IRM, le manipulateur demande au patient s'il possède un corps étranger métallique, il peut s'agir d'un implant dentaire métallique, boucles d'oreilles,... etc. Ce n'est pas une contre indication absolue, mais pour des raisons préventives : prévention contre le risque d'échauffement local près de l'implant ou pour éviter l'apparition d'artefacts gênants pour l'interprétation médicale [44]. Les corps magnétiques purs entrant dans la composition d'un alliage, comme le fer, le chrome ou le nickel induisent les artefacts les plus importants. Par contre, les métaux non ferromagnétiques, comme l'aluminium ou l'argent, engendrent des artefacts très limités.



**Figure 1.7.** Artifacts métalliques.

L'artefact métallique se présente sous forme d'un vide de signal entouré d'un arc en hypersignal (figure 1.7), avec une déformation plus ou moins marquée des structures voisines. Pour corriger cet artefact, on a recours à des séquences SPIN ECHO, on diminue le TE et on utilise un bas champ magnétique.

## **VII.2. Artifacts liées à l'équipement.**

### **VII.2.1. Artefact de déplacement chimique.**

La fréquence de Larmor des noyaux d'hydrogène de l'eau est légèrement supérieure (3.25 ppm) à celle des noyaux d'hydrogène des lipides (graisse). La machine prend en compte cette différence pendant l'étape de transformation des différentes fréquences en positionnement spatial. Comme illustré dans la figure (1.8), l'artefact se traduit par un décalage des structures riches en eau et riches en graisse lors du codage par le gradient de fréquences.

D'après Mougin [45], pour corriger cet artefact, on doit inverser la direction du codage de fréquence et de phase (ce qui inverse simplement l'axe de projection de l'artefact). On peut également augmenter la bande passante et ajuster le TE en fonction de  $B_0$ . On peut enfin, utiliser les séquences Fat-Sat ou SPIR de suppression de la graisse, ce qui augmente la durée du temps d'acquisition.

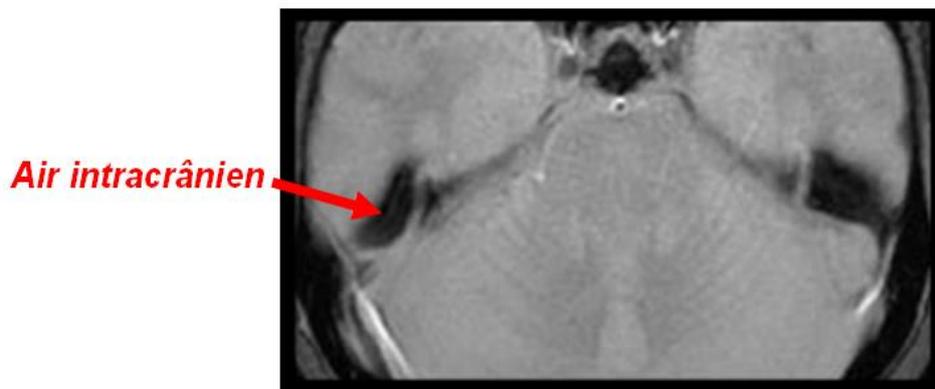


**Figure1.8.** Artifacts de déplacement chimique.

### **VII.2.2. Artéfact de susceptibilité magnétique.**

La susceptibilité magnétique est la propriété physique qui caractérise la façon dont un tissu ou une substance réagissent à la présence d'un champ magnétique externe. Au niveau macroscopique le champ est considéré comme homogène, mais en réalité si on le regarde au niveau microscopique on remarque qu'à l'interface de deux milieux présentant des différences de susceptibilité magnétique, un gradient de champ local se crée. Nous observons un vide de signal entouré d'un arc hypersignal (Figure 1.9). Ce type d'artefacts il se manifeste souvent dans les cavités contenant de l'air (par exemple la fosse nasale, les conduits auditifs et les poumons....etc) ou les zones anciennes de saignement.

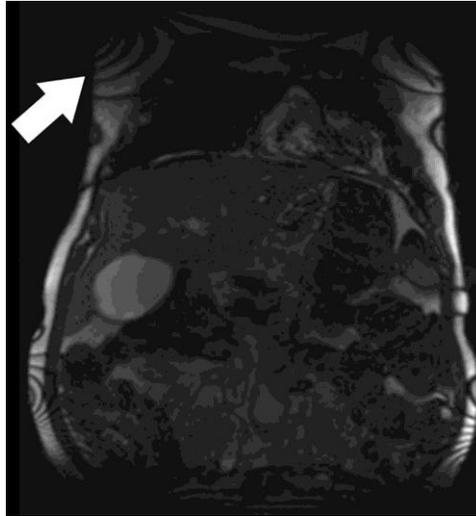
Pour la suppression de cet artefact, on peut réduire le TE [46], mais cela change la pondération de la séquence, ou utiliser des pixels plus petits, mais cela fait décroître le rapport signal sur bruit. Nous pouvons également utiliser des séquences Spin Echo avec des impulsions de 180° qui sont moins sensibles que les séquences Echo de gradient.



**Figure 1.9.**Susceptibilité magnétique.

### **VII.2.3. Les inhomogénéités d'intensité.**

Elles sont dues aux hétérogénéités du champ magnétique  $B_0$  et du champ d'excitation  $B_1$ , qui ne peuvent pas être uniformes, ce qui provoque l'apparition d'une bande sombre sur l'image IRM comme illustré par la flèche dans la figure 1.10.



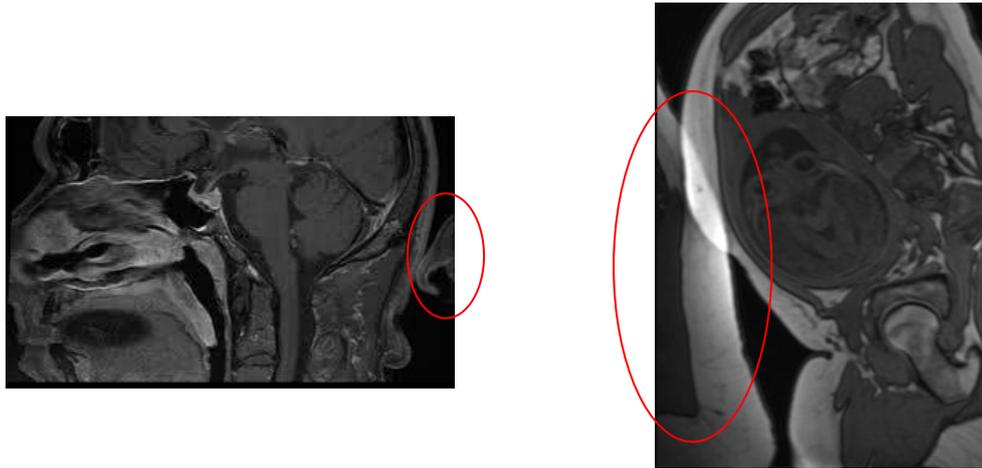
**Figure 1.10.** Coupe coronale en présence d'artefacts liés aux inhomogénéités de l'intensité.

La qualité des antennes de réception du signal doit être stable tout le long de l'examen. Il existe deux modes d'utilisation des antennes, on privilégie la plupart du temps, l'utilisation d'antennes avec une sensibilité spatialement stable pour l'IRM anatomique [47] et des antennes de surface pour l'IRM fonctionnelle, et ce pour une meilleure sensibilité dans une région très localisée. Ces sources d'inhomogénéités sont responsables de déphasages et de décalages de fréquences dans le volume étudié. Elles produisent de lentes variations spatiales d'intensité dans l'image reconstruite, nommées champ de biais (Bias Field).

### **VII.3. Artefacts liés au système d'imagerie.**

#### **VII.3.1. Artefact de repliement.**

C'est un artefact facile à identifier. Il existe dans le sens du codage de la phase et du codage en fréquence. Il apparaît lorsque le champ de vue (FOV) est plus petit que la zone à examiner ou décentré par rapport à celle-ci, et se manifeste par la projection d'une surface qui est hors du champ de vue sur l'image obtenue (Figure.1.11).



**Figure 1.11.** Artefacts de repliement.

Pour résoudre le problème des repliements dans le sens des fréquences [48], on utilise un filtre passe bas ou un sur-échantillonnage qui augmente le temps d'acquisition. Pour le cas des repliements dans le sens de la phase, on doit augmenter le FOV ou utiliser une antenne de surface très petite. On a parfois recours à un sur-échantillonnage en phase.

### **VII.3.2. Artefact de troncature (Gibbs).**

Il est responsable de l'apparition de lignes répétées parallèlement à des interfaces entre tissus ayant un contraste élevé (Figure 1.12) [49]. Il résulte de la reconstruction de l'image dans le plan de Fourier, par un nombre infini de sinusoides, de fréquences, de phases et d'amplitudes différentes.

Pour résoudre le problème de cet artefact, on choisit des directions de codage de phase et de fréquence de façon à ce que la direction du codage de phase corresponde à la plus petite dimension de la région anatomique qu'on étudie, ce qui conduit à l'augmentation de la matrice d'acquisition dans le sens de la phase (augmentation du temps). Une réduction du champ de vue (FOV) est alors nécessaire. L'inconvénient de cette manipulation est qu'elle peut retentir sur les autres artefacts (déplacement chimique, ou image fantômes liées aux mouvements).

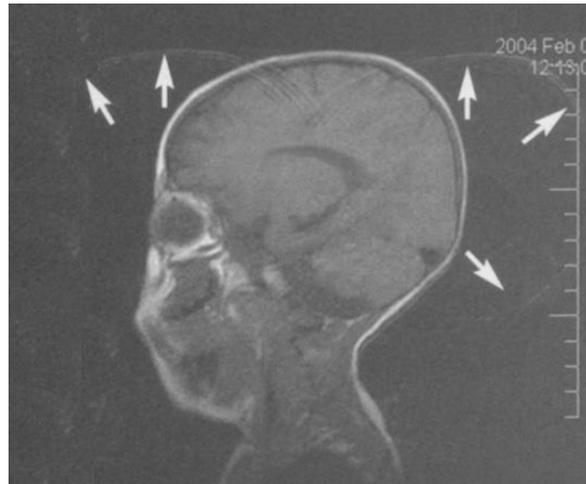


Figure 1.12. Artefacts de troncature (gipps).

### VII.3.3. Artéfact du volume partiel.

Appelé en anglais (PVE) pour Partial Volume Effect, il représente plusieurs objets se retrouvant dans le même élément de volume discret (Voxel). La mesure dans ce voxel est la résultante de différents objets qui l'occupent (Figure 1.13)

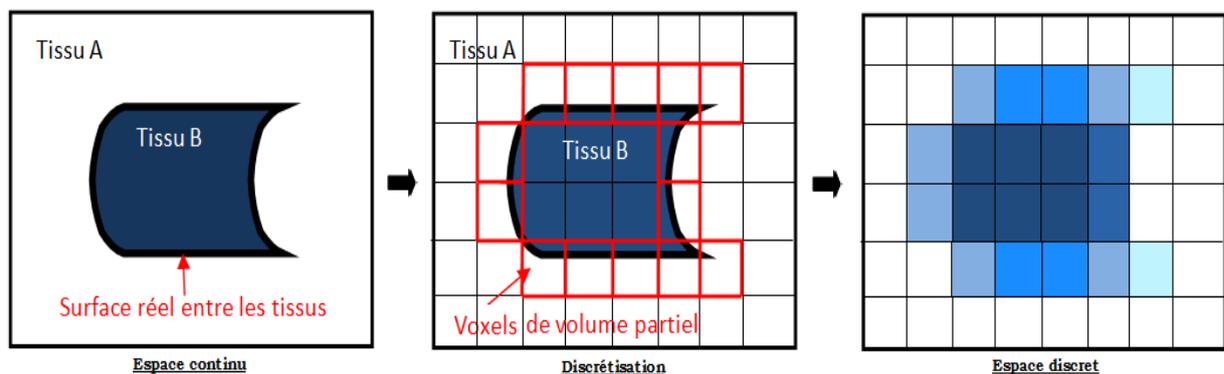


Figure.1.13. Artefacts du volume partiel.

Cet effet se manifeste à l'interface entre la matière grise et la matière blanche, la graisse ou l'Os. Il est particulièrement présent à l'interface LCR-MG dans les replis du cortex, car l'épaisseur des sillons corticaux est généralement inférieure à la résolution des images.

## VIII. ANATOMIE ET MATURATION CEREBRALES.

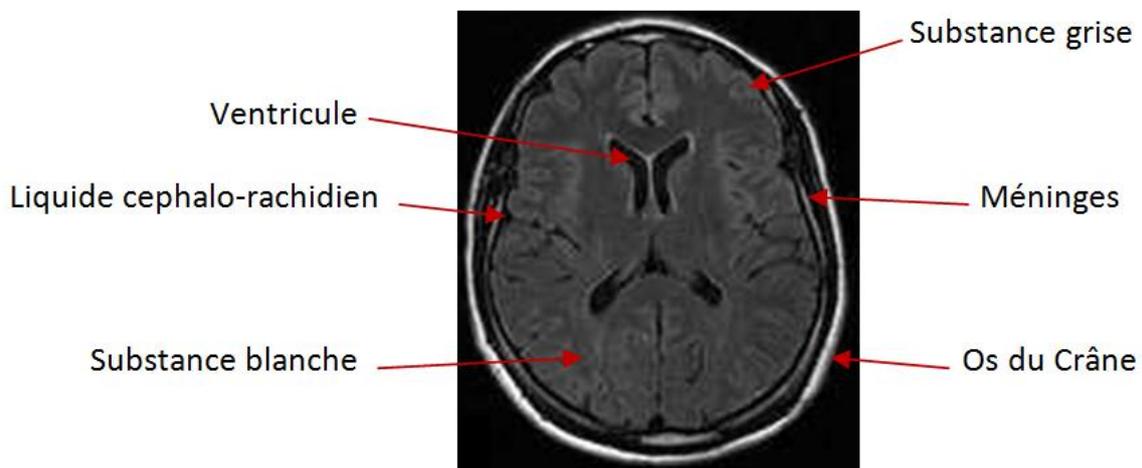
L'IRM est la modalité de référence dans l'exploration du système nerveux central chez l'adulte, et dans certain cas, un examen complémentaire à l'examen ultrasonore pour l'exploration des malformations cérébrales fœtales. Dans cette section, nous présentons

quelques notions fondamentales d'anatomie cérébrale de l'Homme adulte [50]. Pour mieux comprendre l'objectif de notre travail, nous discuterons de la maturation cérébrale fœtale.

### VIII.1. Structure du système nerveux central.

Le système nerveux assure les fonctions principales comme la sensorielle, l'intégrative et la motrice. Il est divisé en deux grandes parties : le système nerveux central (SNC) et le système nerveux périphérique (SNP). Le SNC est constitué d'une part de l'encéphale qui est composé du cerveau, de cervelet et du tronc cérébral, et d'autre part, de la moelle épinière. Ces organes permettent l'analyse et l'interprétation des informations sensorielles afin de donner des ordres aux organes du corps. Le SNP est composé des nerfs somatiques qui captent l'information sensorielle ou des sensations et la transporte au SNC, et des nerfs autonomes qui permettent le contrôle des organes intérieurs incontrôlable par l'humain (battements cardiaques, respiration,....., etc). Le SNP est constitué des nerfs crâniens qui se rattachent au tronc cérébral et des nerfs rachidiens qui se rattachent à la moelle épinière.

Dans cette thèse, nous ne nous sommes intéressés qu'à l'anatomie du système nerveux central et spécialement du cerveau qui présente une régionalisation des taches. Certaines zones gèrent des taches comme la parole, le mouvement et la mémoire.

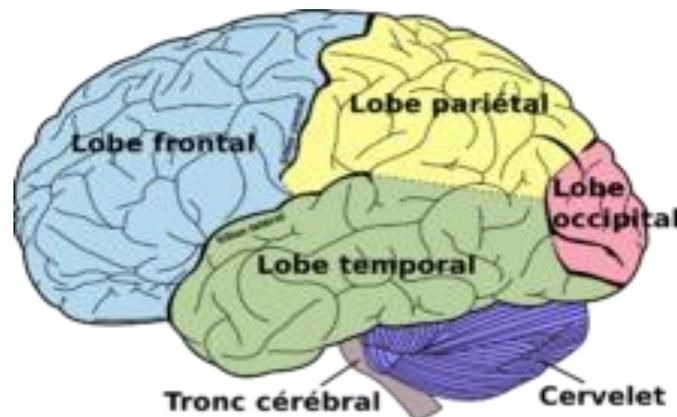


**Figure.1.14.** Composition du cerveau.

Le cerveau est constitué de trois parties principales qui sont : la matière grise (substance grise), la matière blanche (substance blanche) et du liquide céphalorachidien (LCR). La Figure 1.14 montre que lorsqu'on enlève la boîte crânienne (l'os) qui enveloppe le cerveau, ce dernier est composé essentiellement :

- de la substance blanche constituée par des fibres nerveuses qui ont pour rôle de connecter les différentes régions du cerveau pour permettre la transmission des informations.
- du LCR enveloppant le cerveau et remplissant le système ventriculaire. Il permet d'amortir les chocs et les mouvements qui pourraient endommager le cerveau.
- de la matière grise qui se compose essentiellement des neurones et des cellules gliales. Elle se répartie en deux grandes structures : les noyaux et le cortex.

Le cortex cérébral (Figure 1.15) recouvre les deux hémisphères du cerveau sur une épaisseur de 1 à 4.5 mm [51]. Bien qu'il soit plus complexe dans sa structure, on a tendance à le comparer à un ensemble de circuits électroniques. Il est délimités par des sillons appelés gyrus (ou circonvolutions cérébrales), les plus profonds d'entre eux délimitent les lobes du cerveau (lobe frontal, temporal, pariétal, lobe occipital). Pendant la grossesse le suivie des sillons permet de déterminer le degré de maturation du cerveau fœtal [52,53].



**Figure.1.15.** anatomie du cortex cérébral.

### **VIII.2. Maturation cérébrale.**

La maturation cérébrale est un processus important au cours de la vie prénatale et même après la naissance. Dans ce qui suit, nous décrivons les étapes principales de la maturation cérébrale.

Après la nidation, trois couches de cellules se forment dans l'utérus, on parle de la gastrulation. Ces cellules ont le même matériel génétique, mais certaines d'entre elles commencent à exprimer certains gènes plutôt que d'autres afin de développer différents

organes [54] (Figure 1.16) : (i) l'endoderme, couche qui produit les intestins, les poumons et le foie, (ii) le mésoderme, qui donne naissance aux reins, aux os, aux muscles et au système vasculaire, et (iii) l'ectoderme, qui produit l'épiderme et les systèmes nerveux central et périphérique.

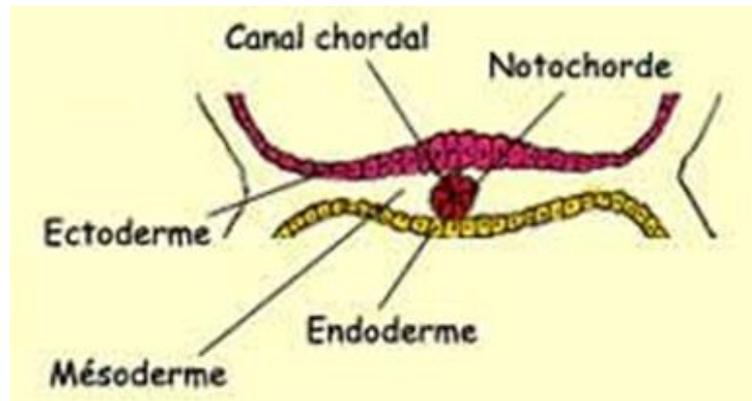


Figure 1.16. Coupe transversale de la gastrulation.

### VIII.2.1. Mise en place du système nerveux.

A environ trois semaines, le cerveau se trouve sous la forme d'une couche de cellules appelée plaque neurale. Un sillon se forme sur cette plaque pour former une gouttière neurale (figure 1.17.a).

Cette gouttière se ferme d'abord au milieu puis dans ses parties antérieure et postérieure pour former le tube neural (figure 1.17.b). Cette période est nommée neurulation, elle débute souvent avant que la mère sache qu'elle est enceinte, des cellules de ce tube deviendront la crête neurale, qui est la structure à l'origine de neurones du système nerveux (figure 1.17.c). À la fin de la troisième semaine du développement embryonnaire, les yeux et les oreilles auront aussi commencé à se former.

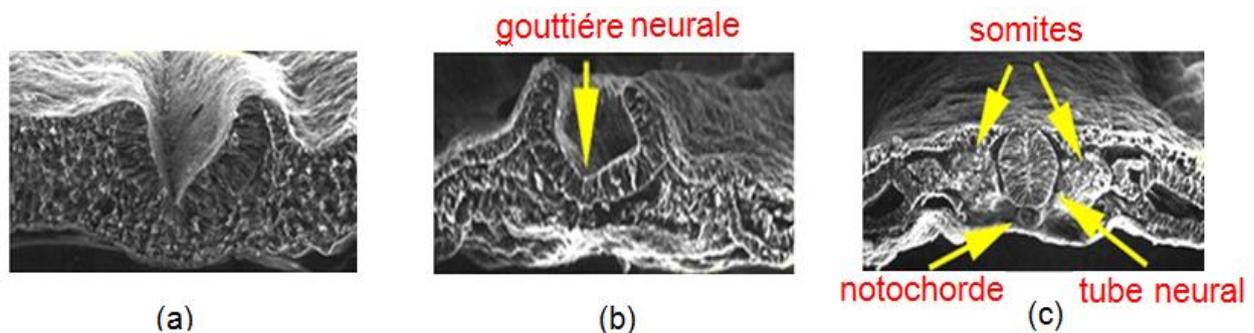
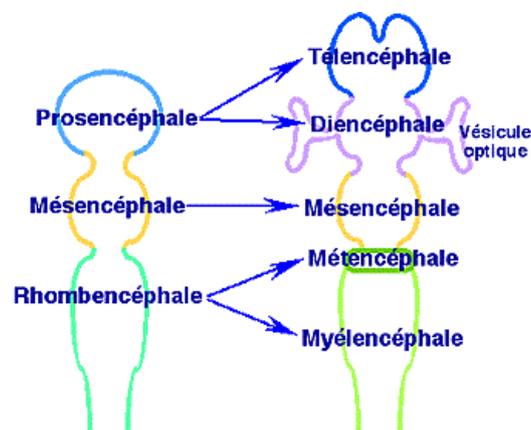


Figure.1.17. différentes étapes de la période de la neurulation.

### VIII.2.2. Formation du cerveau fœtale.

La première étape du développement du cerveau et de la moelle épinière s'achève avec la fermeture totale du tube neural (à la 4<sup>ème</sup> semaine du développement embryonnaire). Commence alors, une nouvelle étape appelée l'histogenèse qui mène à la formation des tissus nerveux et des grandes subdivisions du cerveau ainsi que le réarrangement des populations cellulaires.

Dans cette étape l'encéphale se constitue par la subdivision du tube neural (i) en trois vésicules primaires : prosencéphale, mésencéphale et rhombencéphale, et (ii) en cinq vésicules secondaires : télencéphale, diencéphale, mésencéphale, métencéphale et myélocéphale comme illustré dans la figure.1.18.



**Figure.1.18.** les étapes de l'histogenèse.

Le télencéphale voit deux bourgeonnements jaillir, prenant rapidement de l'ampleur pour former les deux hémisphères cérébraux. L'espace entre le télencéphale et le diencéphale donne naissance aux ventricules cérébraux, le diencéphale comprend les éléments qui formeront le thalamus, l'hypothalamus, l'hypophyse, la glande pinéale et la rétine.

Le mésencéphale, beaucoup plus lent pour se transformer, aboutit à la formation du tegmentum (un réseau de neurones) impliqué dans le contrôle des mouvements, et du colliculus (le colliculus supérieur qui reçoit les informations de l'œil, et le colliculus inférieur qui reçoit les informations provenant des oreilles).

Le métencéphale produira deux structures importantes, la première naît de l'épaississement du tissu qui tapisse les parois latérales du tube neurale on parle du cervelet, la seconde représente le pont (appelée le protubérance), c'est une voie de passage importante de l'information entre cerveau, cervelet et moelle épinière. Le renflement des régions

ventrales et latérales du myélocéphale donne naissance au bulbe rachidien. Le reste du tube neural formera la moelle épinière, le diamètre du tube neural diminue alors progressivement pour devenir le canal spinal.

A la huitième semaine, la formation du cortex va commencer par la multiplication des neurones et des cellules gliales autour des ventricules pour après migrer le long de cellules gliales radiales, la migration des neurones se poursuit généralement jusqu'à 20 semaines mais des fois peut s'étendre jusqu'à 24 semaines.

## **IX. CONCLUSION.**

Le domaine de l'imagerie par résonance magnétique (IRM) est passé progressivement de l'imagerie morphologique, à l'imagerie fonctionnelle et finalement à l'imagerie interventionnelle.

L'IRM est en effet une excellente modalité pour l'exploration du système nerveux central chez l'adulte et chez l'enfant. Grâce à l'excellent contraste des tissus mous, à l'absence de rayonnements ionisants et également grâce aux progrès enregistrés en électronique et en informatique, cette modalité a pu être adaptée aux études du cerveau fœtal.

Ces progrès ne s'arrêtent pas à la réalisation d'une bonne image pour que le médecin l'examine, mais interviennent également pour faciliter le diagnostic et faire gagner du temps dans l'interprétation des images. En effet, l'IRM est utilisée comme examen indispensable dans les centres de diagnostic prénataux pour l'étude du développement du système nerveux central du fœtus.

Le domaine du traitement d'image est une aide précieuse pour le médecin lorsque son objectif est de localiser une tumeur. Au lieu de faire des calculs de segmentation, les chirurgiens peuvent la réaliser en quelques secondes et donc faire une localisation de tous les tissus ou organes.

# **CHAPITRE II**

## **Les Différentes méthodes de Segmentation**

## **I. INTRODUCTION.**

Ces dernières années, l'imagerie par résonance magnétique (IRM) a connu un véritable essor. Les champs d'exploration offerts sont larges telle que l'observation avec une résolution fine, des tissus biologiques en particulier les tissus cérébraux de l'enfant et de l'adulte. Cette modalité d'imagerie permet d'explorer l'activité cérébrale en IRM fonctionnelle et d'obtenir la position, l'orientation et l'anisotropie des structures fibreuses. Le domaine de l'IRM a été étendu à l'étude du développement prénatal et de l'anatomie encéphalique au cours de son développement et sa maturation.

Actuellement, les recherches se tournent plutôt vers le traitement de l'image médicale, non seulement pour améliorer les performances de l'équipement mais pour le rendre plus efficace et plus rapide dans le diagnostic.

Dans ce chapitre, nous définissons la segmentation des images ainsi que ses différentes approches et présentons la segmentation hybride que nous avons utilisée dans les deux modèles développés dans ce travail.

## **II. DEFINITION DE LA SEGMENTATION.**

On retrouve dans la littérature plusieurs définitions de la segmentation [55]. La segmentation de l'image, est une opération de traitement d'images qui a pour but de rassembler des pixels entre eux suivant des critères prédéfinis.

La segmentation définie par Horowitz et Pavlidis [56], consiste à considérer un domaine  $\Omega$  de l'image  $I$  et une fonction  $f$  qui associe à chaque pixel une valeur  $f(i, j)$ . On définit alors le prédicat  $p$  sur l'ensemble des parties de  $\Omega$  qui permet de tester l'homogénéité des ensembles disjoints  $R_i$ .

La segmentation de l'image  $I$  est définie comme une partition de  $\Omega$  en  $n$  sous-ensembles  $\{R_1, R_2\}$  tel que :

- 1/  $I = \bigcup_{i=1}^n R_i$ .
- 2/  $\forall i \in \{1, \dots, n\} p(R_i)$  vraie. (2.1)
- 3/  $\forall i, j \in \{1, \dots, n\}^2 R_i$  est adjacent à  $R_j$  et  $i \neq j \Rightarrow p(R_i, R_j) = \text{Faux}$ .

Une segmentation est donc une décomposition de l'image en sous-ensembles de régions homogènes, chaque région correspond à un objet de l'image.

### **III. DIFFERENTES APPROCHES DE LA SEGMENTATION.**

Plusieurs approches peuvent différencier une segmentation d'une autre. On peut les grouper en fonction des résultats obtenus dans la pratique, ou selon l'approche qui les régit : approche basée contour, approche basée région, approche par la forme, et enfin approche hybride. Chacun de ces modèles est utilisé pour segmenter l'image, mais leurs domaines d'application sont différents.

#### **III.1. Approche basée contour.**

Cette approche considère que les primitives à extraire sont les lignes de contraste qui sépare les régions de différents niveaux de gris et relativement homogènes, ou bien les régions de différentes textures.

Dans la littérature on retrouve plusieurs approches basées contour [57], on ne citera que les approches utilisées dans la segmentation des IRM cérébrales.

##### **III.1.1. Méthode dérivative.**

Cette méthode permet de détecter les limites des régions dans les images de différentes dimensions (2D pour l'image naturelle, 2D et 3D pour les images médicales). Ces limites ou contours, représentent les points de forts gradients ou de dérivées secondes nulles.

Les méthodes les plus connues pour la détection des contours dans le traitement d'image sont les filtres de Roberts [58], Prewitt [59], le filtre Sobel [60] pour le gradient, et le Laplacien pour les dérivées secondes (Figure2.1).

On retrouve beaucoup de travaux sur la combinaison des filtres pour réaliser une partition de l'image, comme les travaux réalisé dans [61] où l'auteur combine le filtrage anisotropique. Les méthodes dérivatives sont rapides et ne nécessitent pas d'apport d'information, elles ne permettent cependant pas d'obtenir des contours fermés.

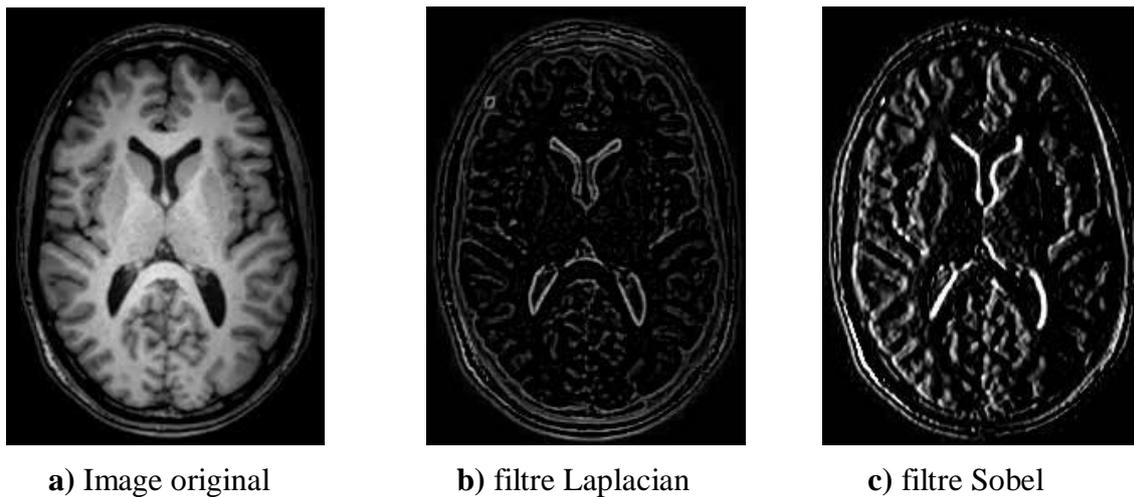


Figure. 2.1. Segmentation par modèle dérivatif.

### III.1.2. Méthode par morphologie mathématique.

Devenue une théorie fondamentale du traitement et de l'analyse en imagerie médicale, la morphologie mathématique a été introduite dans les années 60 par Matheron [62] et Serra [63]. Les opérateurs qu'elle propose permettent de fournir des outils pour le prétraitement, ainsi que pour la segmentation des images.

Ces opérateurs non linéaires permettent d'étudier les caractéristiques morphologiques (forme, taille, orientation,...) des objets et la conception des filtres pour le prétraitement du plus simple, au plus complexe comme le gradient morphologique pour la détection des contours des structures, utilisé dans la segmentation LPE (Ligne de Partage des Eaux) proposée par Digabel et Lantuéjoul [64].

Cette approche utilise la description des images en termes géographiques. L'image peut être vue comme un relief (chaque niveau de gris est associé à une altitude), il faut alors calculer la ligne de partage des eaux (les reliefs) et les bassins représentent la région à partitionner.

Dans le chapitre suivant, nous avons exploité les opérateurs morphologiques dans un algorithme pour extraire l'image du cerveau contenue dans des IRMs cérébrales. Les algorithmes qui utilisent la morphologie mathématique restent cependant sensibles au bruit présent dans les images, ce qui nécessite une étape de prétraitement.

**III.1.3. Méthode déformable.**

Le principe de base des méthodes déformables est l’adaptation d’un objet (contour) d’une position initiale sur l’image traitée à une position optimale sur le contour de la structure que l’on cherche à segmenter par la minimisation d’une fonction d’énergie. Dans la littérature, on retrouve plusieurs adaptations de la méthode déformable pour détecter les formes anatomiques que ce soit en échographie [65], en PET [66], ou en IRM [67]. Il existe deux types de méthodes déformables : les modèles explicites et les modèles implicites.

Les modèles explicites, appelés également contours actifs paramétriques (Snakes) [68], s’appuient sur la déformation du contour initial grâce à la minimisation de la fonction d’énergie représentée par la somme de deux termes : (i) Energie externe, un terme d’attache aux données lié au contenu de l’image, et (ii) Energie interne, un terme de régulateur qui prend en compte d’élasticité et la rigidité du contour. En générale la fonction s’écrit :

$$J(C) = \underbrace{\alpha \int \left| \frac{\partial C(q)}{\partial q} \right|^2 dq}_{\text{Elasticité}} + \underbrace{\beta \int \left| \frac{\partial^2 C(q)}{\partial q^2} \right|^2 dq}_{\text{Rigidité}} + \underbrace{\lambda \int g(|\nabla I(C(q))|) dq}_{\text{Energie externe}} \tag{2.2}$$

Energie interne

où  $C$  est l’hypersurface,  $q$  est la coordonnée relative à l’hypersurface,  $\nabla I$  représente le gradient de l’image  $I$ .  $\alpha, \beta$  et  $\lambda$  sont des coefficients positifs réels et  $g$  est une fonction strictement décroissance destinée à minimiser le terme d’énergie externe si l’hypersurface  $C$  est localisée sur les zones de plus fort gradient.

Ces modèles ont l’avantage d’une part, de permettre la segmentation des objets irréguliers et la prise en charge éventuelle des discontinuités des contours, et d’autre part, d’être robuste sur les images bruitées. L’emplacement du contour initial doit néanmoins être près de l’objet qu’on cherche à segmenter. La minimisation de la fonction dépend alors de l’initialisation du modèle : à chaque instant  $T$ , il est nécessaire de faire une réinitialisation de la courbe, ce qui est coûteux en temps. Plusieurs techniques ont été développées pour améliorer les contours paramétriques, telles que le GVF (Gradient Vector Flows) [69] ou récemment le FVF (Fluid Vector Flows) [70].

Les modèles implicites, connus aussi sous le nom de contours actifs géométriques (Level Sets) [71], permettent d’intégrer les changements topologiques complexes.

Contrairement aux modèles explicites qui dépendent des paramètres d'initialisation, ces modèles reposent sur l'évolution de la courbe en employant seulement des mesures géométriques. Leur paramétrisation n'est effectuée qu'après la déformation complète permettant l'adaptation topologique du contour sur l'objet. Les calculs numériques restent cependant lents.

La segmentation par contour dépend de la qualité de l'image à traiter. En effet, si par exemple on considère des IRMs cérébrales qui présentent un faible contraste [72], il est nécessaire de réaliser un filtrage et un rehaussement des contours avant la segmentation pour stopper l'évolution du contour sur les frontières des objets ciblés.

### III.2. Approche basée région.

Cette approche est utilisée pour l'identification et la localisation des pixels de même contraste ou des attributs communs. Les pixels similaires en homogénéité sont rassemblés en régions distinctes. Il existe plusieurs approches basées régions :

#### III.2.1 Approche par transformation de région.

Les approches par transformation de régions s'appuient sur la notion de la partition et du prédicat. La segmentation est basée sur la notion du prédicat  $p$  qui est une propriété logique que doit vérifier chaque région  $R_i$  de l'image pour appartenir à une autre région. Pour chaque région  $R_i$  de l'image, il existe deux prédicats possibles:

➤ Vérifier le prédicat "*la région  $R_i$  est homogène*" : parmi les arguments les plus utilisés pour vérifier que la région  $R_i$  est homogène [73,74], on distingue:

- Le contraste sur la région :

$$p(R_i) = \text{vrai} \Leftrightarrow \max_{R_i}[f(i, j)] - \min_{R_i}[f(i, j)] < \delta \quad (2.3)$$

$f(i, j)$  représente le niveau de gris du pixel et  $\delta$  un seuil donné.

- L'écart type de la région :

$$p(R_i) = \text{vrai} \Leftrightarrow \sqrt{\frac{1}{N} \sum_{R_i} (f(i, j) - m)^2} < \delta \quad (2.4)$$

$$\text{Où } N = \text{Card}(R_i) \quad \text{et} \quad m = \frac{1}{N} \sum_{R_i} n(i, j) \quad (2.5)$$

- Les différences limitées :

$$p(R_i) = \text{vrai} \Leftrightarrow \forall (k, j) \text{ voisins, } |f(k) - f(j)| < \delta \quad (2.6)$$

- L'entropie :

$$p(R_i) = \text{vrai} \Leftrightarrow -\sum_{R_i} p(f) \log(p(f)) < \delta \quad (2.7)$$

Ce prédicat est relié directement au choix du seuil  $\delta$ , si la valeur de ce dernier est élevée on obtient des régions grossières, par contre si la valeur est petite on obtient trop de régions dans l'image segmentée.

➤ Vérifier le prédicat "*la région  $R_i$  est distincte de ses voisines*" : on applique des arguments qui mettent en jeu les différences de valeurs moyennes, les distances inter-médianes, les contrastes moyens ou minima aux frontières.

$$\begin{cases} \forall i, j \ R_i \cap R_j = \emptyset \\ \cup_i R_i = \text{image} \\ \forall i R_i \neq \emptyset \end{cases} \quad (2.8)$$

Cette approche est basée sur l'approche ascendante (Bottom-up) qui fait partie de la classe d'algorithmes de segmentation dit « locaux ». Supposons une région de couleur homogène  $R$ . Avant de réaliser la segmentation  $R = 1$  (*un seul pixel*), celui-ci va s'étendre sur les régions dont la couleur est proche de  $R$ . Pour déterminer si une région a une couleur proche de  $R$ , on utilise les conditions des prédicats mentionnés précédemment. La variation doit être inférieure à un seuil donné  $\delta$ . Cette procédure est répétée jusqu'à ce qu'il n'y est plus de pixels de couleur assez proche sur la frontière. On aura à la fin, une région homogène qui caractérise la structure de l'objet qu'on souhaite traiter.

Dans cette approche, le résultat de la segmentation dépend d'une part du choix du seuil  $\delta$  ; une petite variation de ce seuil peut conduire à des modifications importantes de la segmentation. Et d'autre part de l'ordre dans lequel les pixels de la frontière sont examinés.

Dans la littérature on retrouve plusieurs approches qui suivent le principe de la transformation de régions [75] :

### **III.2.1.1. Approche de la croissance des régions (Region growing).**

Le principe de cette méthode est de prendre un ou plusieurs pixels qu'on appelle germe, comme initialisation de la partition, en collectionnant les pixels voisins qui répondent aux critères des prédicats mentionnés (Figure 2.2). Les voisins du germe sont examinés successivement, s'ils vérifient le critère du prédicat  $p$  mentionné précédemment, ils sont inclus à la région et deviennent à leur tour un germe, sinon ils sont rejetés. Ces approches

n'aboutissent pas à des partitions fiables, car la propriété  $\cup_i R_i = image$  n'est généralement pas satisfaite, d'où l'intérêt de les combiner à d'autres méthodes de segmentation, Schnach et al [76] les ont combinés avec des opérateurs de morphologie pour segmenter le système ventriculaire, et Richard et al [77] combinent la méthode avec une approche par mixture de gaussiennes pour segmenter les tissus.

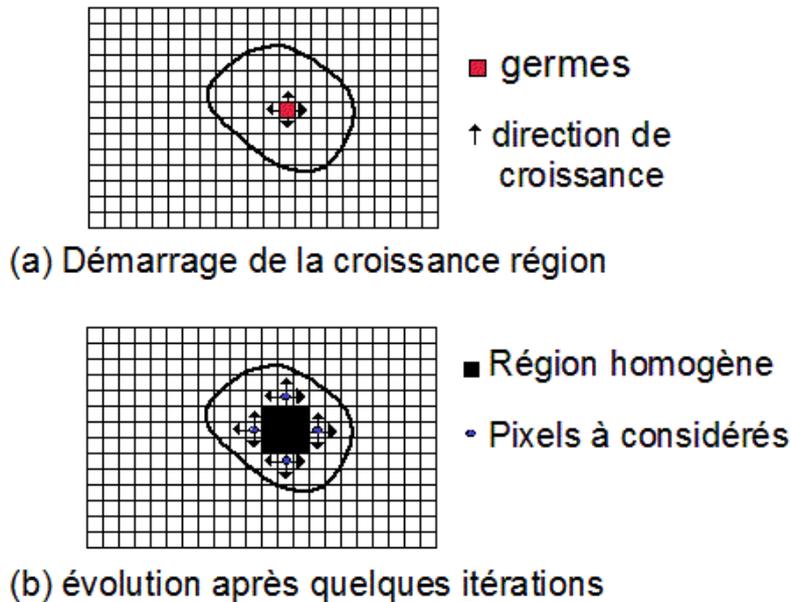


Figure.2.2. Segmentation par croissance de région.

**III.2.1.2. Approche de partage de régions (region splitting).**

Dans cette approche, on divise l'image I sur  $\eta$  parties, et on teste le prédicat  $p$  pour chaque sous régions  $\mathcal{R}_i^\eta$ , on retient la meilleure subdivision  $\eta$  qui conduit à des sous régions vérifiant le prédicat, ou qui donne le plus de sous régions vérifiant le prédicat. Cet algorithme est mal adapté à une mise en œuvre informatique.

**III.2.1.3. Approche de la réunion de régions.**

Si l'approche précédente permet de partager l'image grâce au prédicat  $p$ , celle-ci les regroupe, et pour chaque carré de  $(2 \times 2)$  pixels, le prédicat est testé. S'il est accepté, les pixels sont regroupés en une seule région, dans le cas contraire, ils sont séparés.

**III.2.2. Approche seuillage.**

Cette technique est souvent très proche des méthodes conventionnelles de classification, elle s'appuie sur l'analyse de la distribution des niveaux de gris dans l'histogramme. Chaque pic de l'histogramme est associé à une classe. Pour que le seuillage soit optimal, les pics

doivent être séparés dans l'histogramme, en général l'approche de seuillage est utilisée pour segmenter l'image en deux classes.

Théoriquement, l'histogramme est composé de  $n$  modal qui représentent la valeur la plus haute (les pics) d'une région, et aussi composé de  $(n - 1)$  seuils qui représentent la valeur qui permet de séparer l'image en  $n$  classes (régions),  $s_i$  correspond à un intervalle de niveau de gris du minimum de l'histogramme, la formule de la segmentation s'écrit alors :

$$h(s_i) = \min h(j), \quad \text{pour } j \in r_i \quad (2.9)$$

Différentes modifications sur cette approche ont été effectuées. Dans l'article [78], l'auteur a mis en œuvre une technique pour détecter le seuillage optimal. Cette approche est utile pour le passage à une image binaire (la segmentation d'une image sur deux classes). Les résultats de la segmentation par cette approche, sont directement liés à l'histogramme de l'image, donc à l'intensité des pixels.

### **III.2.3. Approche de classification.**

Les méthodes de classification font la partition de l'image en plusieurs parties. Par exemple, dans le cas des IRM cérébrales, elles portent sur la classification des tissus (MG, MB, LCF) en deux catégories : partie saine et partie pathologique. Plusieurs méthodes sont utilisées pour réaliser une classification, nous ne citerons que les plus connues d'entre elles et notamment celles que nous avons utilisées dans notre travail.

#### **III.2.3.1. Classification déterministe Supervisée.**

➤ **Réseaux de neurones** : les réseaux de neurones permettent le traitement d'image par intelligence artificielle. Haykin dans [79] définit le réseau de neurones comme un processus distribué de manière parallèle, qui a une propension naturelle à mémoriser des connaissances de façon expérimentale et de les rendre disponibles pour utilisation. Il ressemble au cerveau en deux points :

- La connaissance est acquise au travers d'un processus d'apprentissage.
- Les poids des connexions entre les neurones sont utilisés pour mémoriser la connaissance.

L'architecture d'un réseau est déterminée selon la façon dont les neurones sont reliés. Le réseau est organisé en plusieurs couches parallèles sur lesquels l'information circule de la

couche d'entrée vers la couche de sortie, en passant par une ou plusieurs couches intermédiaires (appelées couches cachées).

Plusieurs topologies des réseaux existent [80], elles déterminent la façon dont les neurones (les couches de la structure) sont reliés. Pour résoudre un problème donné on peut déterminer le nombre de neurones de la couche d'entrée et de sortie, mais il n'existe pas une méthode formelle pour déterminer le nombre de neurones intermédiaires ou les connexions nécessaires.

➤ **Réseau multicouche :** Illustrés dans la figure 2.3, les neurones sont arrangés en couches, et la liaison entre les couches se fait seulement avec les neurones des couches avales, et non sur des neurones de la même couches.

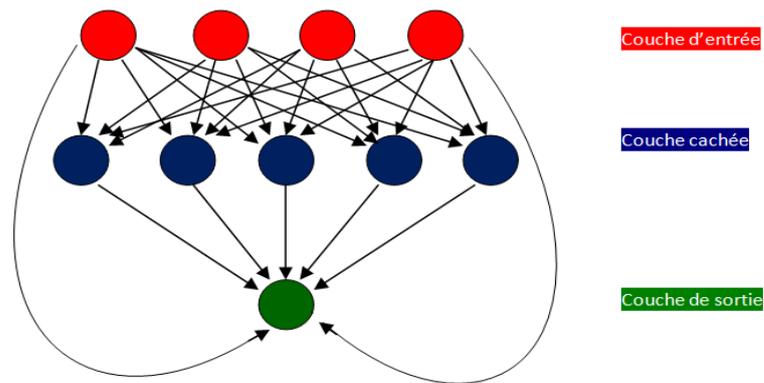


Figure 2.3. Les réseaux multicouches.

➤ **Réseau à connexions locales.** Comme le précédent, il est représenté par des multicouches, mais les liaisons entre neurones de différentes couches sont réduites. D'après la figure 2.4, on observe qu'elle a la forme d'une pyramide : le nombre des neurones est réduit d'une couche à une autre, ainsi que les liaisons entre chaque couche.

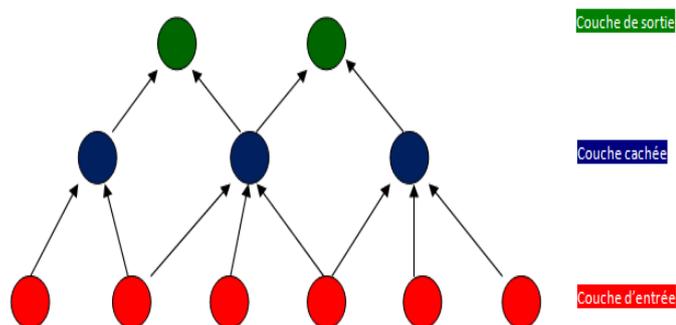


Figure 2.4. Les réseaux à connexions locales.

➤ **Réseau à connexion récurrentes.** Contrairement aux précédents réseaux, l'information passe dans les deux sens entre les couches (figure 2.5), elle est ramenée en arrière par des connexions qui sont souvent locales.

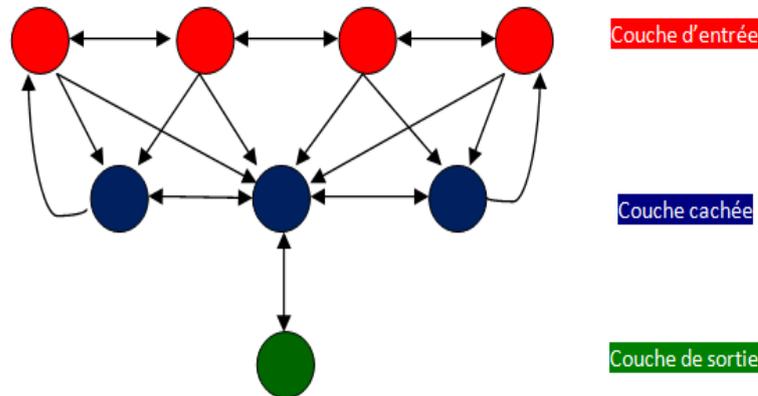


Figure 2.5. Réseaux à connexions récurrentes.

➤ **Réseau à connexion complète.** Chaque neurone est connecté à tous les neurones du réseau (Figure.2.6).

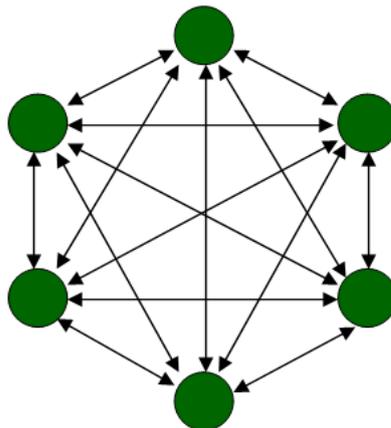
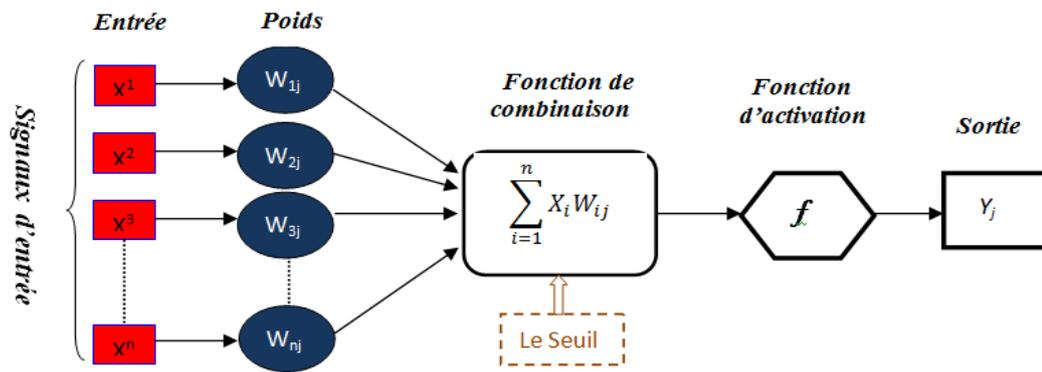


Figure 2.6. Réseaux à connexions complète.

La figure 2.7 représente la structure d'un neurone artificiel, les entrées de chaque neurone sont pondérées par des poids (synaptique) de sorte que les contributions de neurones des couches précédentes, soient multipliées chacune par ces poids synaptiques et additionnées pour donner une valeur globale qui sera affectée à un neurone donné.



**Figure.2.7.** Structure d'un neurone artificiel.

Dans le cadre de la segmentation d'IRM cérébrales, les réseaux de neurones sont utilisés dans la classification d'une région. Les poids synaptiques sont déterminés par apprentissage sur une base d'image, dont le résultat de segmentation est connu. Plusieurs modèles ont été proposés dans la littérature, dans l'article [81] par exemple, les auteurs ont choisi d'utiliser les réseaux de neurones pour la segmentation des tumeurs dans les IRM cérébrales.

L'inconvénient des réseaux de neurones dans le domaine de la segmentation cérébrale, est l'étape d'apprentissage : pour segmenter avec les réseaux de neurones nous avons besoin d'une segmentation manuelle pour calculer les poids synaptiques.

➤ **Machine à Vecteur de Support.** ou SVM (Support Vector Machine). C'est une généralisation des classificateurs supervisés [82]. Cette méthode ne peut être utilisée que dans le cas où l'espace de représentation des documents est linéairement séparable. Le principe de cette approche est de chercher la séparation maximale de la marge (figure.2.8). Cette dernière peut être définie comme la distance euclidienne entre la surface de séparation (hyperplan optimal) et le point le plus proche de l'ensemble d'apprentissage (les vecteurs de support). Cette approche n'est utilisée que dans le cas d'un problème séparable linéairement, de nombreux travaux ont été réalisés pour résoudre cet inconvénient [83, 84, 85].

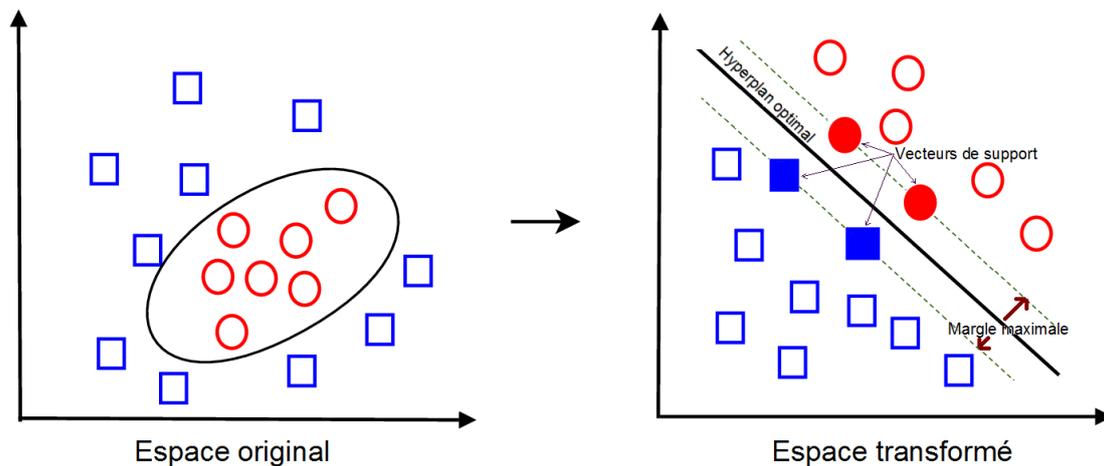


Figure.2.8. Méthode SVM.

Les méthodes par approche supervisée sont cependant, peu adaptées à la segmentation automatique des IRM cérébrales à partir de l'histogramme. En effet, les caractéristiques de l'image obtenue par IRM, diffèrent d'un patient à un autre et d'un jour d'acquisition à un autre (voir les artefacts du chapitre précédent), de ce fait ces approches nécessitent un bon choix de l'échantillon d'apprentissage.

### III.2.3.2. Classification déterministe Non Supervisée.

➤ **K-Moyennes.** Permettent de regrouper les voxels d'une image en  $K$  parties (appelées aussi classes) en fonction de leur intensité. Chaque classe est représentée par un centroïde (il existe plusieurs méthodes pour le choix des centroïdes) et chaque voxel est attribué à une classe dont le centroïde est le plus proche. L'algorithme K-moyennes revient à minimiser la fonction :

$$J_{K\text{-moyenne}} = \sum_{i=1}^c \sum_{j \in S_k} \|x_j - v_i\|_2^2 \quad (2.10)$$

Avec  $S_i$  l'ensemble des voxels classés comme éléments de la même classe,  $x_j$  définit l'intensité du voxel et  $v_i$  le centroïde de classe.

L'algorithme commence par attribuer aléatoirement chaque pixel à une région, puis calcule les nouveaux centroïdes de chaque ensemble et construit une nouvelle partition en attribuant chaque pixel au centroïde le plus proche ; le processus est répété par itération jusqu'à ce qu'une convergence soit atteinte (la carte des étiquettes n'est plus modifiée).

L'algorithme C-moyenne est très utilisé à cause de sa simplicité, sa facilité de mise en œuvre et sa rapidité. Il est donc intéressant de l'appliquer à la segmentation des IRM [86,87].

Néanmoins, les résultats de la segmentation dépendent du nombre de classes et de l'initialisation des centroïdes. Autre désavantage de cette approche, est qu'elle ne prend pas en considération le bruit présent dans les images qu'on veut traiter [88], ce qui a poussé à réaliser des améliorations dans beaucoup de travaux.

➤ **C-moyennes floues.** Dunn [89] reprend le même principe des K-moyennes mais s'appuie sur la notion d'ensembles flous. Très vite cet algorithme a trouvé sa place dans la segmentation en imagerie médicale comme en témoigne les travaux effectués par Bezdek [14] où la fonction à minimiser est :

$$L = J_q(u, v) = \sum_{j=1}^n \sum_{i=1}^c (u_{ji})^q \|x_j - v_i\|_a^2 \quad (2.11)$$

Où  $n$  est le nombre de pixels de l'image à traiter,  $c$  le nombre de classes,  $q \in [1, +\infty[$  est le poids de fuzzyfication,  $v_i$  avec  $i = (1, \dots, c)$ , le vecteur des centroïdes.

L'approche FCM (Fuzzy C-Means) sera détaillée dans ce qui suit car nous l'avons modifiée dans notre travail, pour l'adapter à la segmentation des IRM cérébrales.

### **III.2.3.3. Classification non paramétrique.**

➤ **Champs Aléatoires de Markov.** L'analyse de la texture d'une image est une étape primordiale dans la chaîne de traitement. Son application est étendue aux images médicales connues pour avoir un aspect de texture aléatoire, les champs de Markov sont un processus de segmentation géré par des paramètres calculés à partir de l'image [90]. L'approche MRF (Markov Random Fields) est très utilisée pour segmenter les IRM du cerveau [91], les résultats obtenus sont très prometteurs du fait que cette approche permet d'exprimer l'interaction spatiale présentée par les pixels (voxels dans le cas d'une image 3D), le champ est défini par son voisinage et sa fonction de potentiel.

Les Champs de Markov présentent des limites lorsqu'il s'agit de la classification des images IRM contenant les effets de volumes partiels, et peuvent mener à une mauvaise classification des voxels.

### **III.3. Approche basée sur la forme.**

Les approches basées sur la forme tendent à rechercher des régions qui dérivent d'une forme donnée comme à priori. Il existe trois méthodes pour cette approche :

➤ **Recalage d'atlas.** L'atlas anatomique est une représentation étiquetée de l'image anatomique d'un patient qu'on prend comme image de référence pour la

segmentation. L'utilisation d'un atlas consiste à apparier l'image de référence et l'image qu'on veut traiter. On superpose les informations contenues dans l'image atlas et l'image à traiter, les structures peuvent être ensuite recalées simultanément et permettent aussi d'obtenir une segmentation globale. La segmentation avec cette méthode permet de localiser les structures par alignement des deux images, mais ne permet pas de compenser l'élasticité des objets comme par exemple, la déformation de l'image causée par les mouvements du patient. Pour réaliser une segmentation précise d'une image médicale avec cette méthode, on doit considérer plusieurs atlas comme référence.

Les travaux effectués par Aljabar [92] par exemple, utilisent une base de 250 atlas pour son processus de traitement, mais un si grand nombre d'atlas est très coûteux en temps de calcul. Pour surmonter cette contrainte, l'auteur fait une sélection des atlas utilisés soit par comparaison de l'intensité des images, soit par comparaison de méta-données comme l'âge, la pathologie....etc.

Cependant, l'utilisation d'un grand nombre d'atlas repose sur leur recalage et augmente le volume des données à manipuler ainsi que le temps de traitement.

➤ **Transformation dans un sous-espace.** Un sous-espace est l'ensemble de toutes les approximations possibles d'un même signal à la résolution associée au sous-espace. A chaque étape de ces transformations, on élimine des détails et ainsi on se focalise sur la forme. L'une des méthodes les plus connues est la méthode des ondelettes (Wavelet). Gayatri [93] utilise cette approche pour la segmentation automatique des images IRM pour la détection des tumeurs cérébrales.

Les autres techniques qui utilisent cette approche sont l'harmonique sphérique, les modèles actifs de forme et enfin les modèles actifs d'apparence.

### **III.4. Approche hybride.**

L'approche hybride combine les approches mentionnées précédemment. Dans ce contexte, Yan et Kruggel [94] fusionnent des méthodes bayésiennes avec des algorithmes de type partage des eaux pour segmenter les sillons corticaux. Albert Huang [95] propose une combinaison entre l'approche par contours géodésiques et les statistiques pour régulariser la convergence du contour et extraire des structures anatomiques contenues dans les IRMs. Keyvan Kasiri dans [96] présente une méthode semi-automatique qui associe un atlas du cerveau et la méthode de classification SVM (Support Vector Machine) pour la segmentation

les tissus cérébraux. Enfin, Akshath [97] a combiné deux méthodes différentes de l'approche régions, pour la segmentation des régions du cerveau obtenues par IRM cérébrale.

#### **IV. UTILISATION DES CONTOURS ACTIFS POUR LA SEGMENTATION D'IRMs.**

La méthode des contours actifs est souvent utilisée pour la segmentation des IRMs. Etant donné que cette technique a été étudiée dans la première partie, nous discuterons donc dans ce qui suit, les différents modèles et leurs applications en imagerie médicale.

##### **IV.1. Définition des contours actifs.**

Les contours actifs ont beaucoup évolué ces dernières années en termes de détection des limites. Ils sont largement utilisés dans le traitement des images médicales, en robotique, en surveillance....etc.

On distingue deux types de modèles de contours actifs dans la littérature, les contours actifs paramétriques (Snakes), ou les contours actifs géométriques (Level-Sets).

##### **IV.1.1. Les contours actifs paramétriques (Snakes).**

Les Snakes tiennent leur nom de leur aptitude à se déformer comme des serpents. Ils tirent leur origine des modèles élastiques de Burr [98]. Ce modèle a ensuite été adapté par l'équipe Kass [99], il a très vite trouvé sa place dans le traitement des images. Plusieurs travaux utilisent cette technique sur les images pour la reconnaissance de formes, le suivi de scènes et la segmentation d'images. L'idée générale des contours actifs est de faire évoluer une courbe continue (fermée ou non) qui se déforme à partir d'une position initiale près de l'objet d'intérêt, jusqu'à ce qu'il converge vers les contours de ce dernier. Le contour est contrôlé par une énergie en fonction de sa position et dont le minimum est atteint lorsque l'on est sur les contours d'intérêt. Cette fonction d'énergie correspond à la somme de deux termes :

$$E_{total} = \int_0^1 E(C(s))ds = \int_0^1 \left( E_{int}(C(s)) + \lambda E_{ext}(C(s)) \right) ds \quad (2.12)$$

Où  $C$  est la courbe de déformation spatiale et temporelle, elle est définie et normalisée à  $[0,1]$ .  $s$  est un paramètre qui représente la position spatiale le long de la courbe.

$E_{int}$  est l'énergie interne,  $E_{ext}$  l'énergie externe,  $\lambda$  est le coefficient positif de pondération de l'influence extérieure.

➤ **L'énergie interne.** Elle gère la cohérence de la courbe, et impose des contraintes de continuité et d'élasticité au modèle. Elle est utilisée comme terme régulateur de la courbe. Elle est donnée par l'expression suivante :

$$E_{int} = \int_0^1 \left( \frac{\alpha}{2}(s) \|C'(s)\|^2 + \frac{\beta}{2}(s) \|C''(s)\|^2 \right) ds \quad (2.13)$$

$C'(s)$  et  $C''(s)$  sont les dérivées première et seconde de  $C$  par rapport à  $s$ .

$\alpha$  et  $\beta$  sont utilisés pour contrôler respectivement la force de tension et la rigidité du modèle.

Le premier terme prend une valeur importante quand la courbe se distend, et  $\alpha = 0$  si la courbe présente des discontinuités.

Le 2<sup>ème</sup> terme définit la courbure pour obtenir un coin. si  $\beta = 0$ , la courbe peut prendre une forte convexité. Si  $\beta$  est grand, il tendra vers un cercle lorsque la courbe est fermée, ou vers une ligne si elle est ouverte. Le choix de  $\alpha$  et  $\beta$  détermine donc la rigidité et la flexibilité du modèle.

➤ **L'énergie externe.** Cette énergie prend en considération les caractéristiques de l'image pour attirer le modèle vers les frontières de l'objet d'intérêt. Traditionnellement, l'énergie externe est basée uniquement sur l'information du gradient de l'image  $I$  ou de l'intensité de l'image.

- **Gradient de l'image.** Cette énergie représente la dérivée première de l'image, elle est utilisée dans différentes approches pour la recherche des zones de fort contraste dans l'image.

L'énergie externe en fonction du gradient s'écrit :

$$E_{ext} = - \int_0^1 \|\nabla I(v(s))\|^2 ds \quad (2.14)$$

$\nabla I(v(s))$  représente le gradient de luminance de l'image  $I$ . Habituellement définie comme étant une image filtrée par un filtre gaussien, la fonction de l'énergie devient :

$$E_{ext} = - \int_0^1 \|\nabla I(g_\sigma * I)(v(s))\|^2 ds \quad (2.15)$$

Où  $g_\sigma$  est la gaussienne bidimensionnelle,  $\sigma$  l'écart type qui permet le contrôle de la zone d'influence du contour, appelée aussi zone d'attractivité.

- **L'intensité de l'image.** contrairement au gradient cette énergie permet de sélectionner soit les zones sombres, soit les zones claires. L'énergie s'écrit alors sous la forme ci-dessous :

$$E_{intensité} = \pm \int_0^1 (I(v(s)) - i_0)^2 ds \quad (2.16)$$

$i_0$  est responsable du seuillage de l'image qu'on veut segmenter et favorise la position du contour dans une zone donnée.

Une segmentation avec les Snakes présente des avantages mais aussi quelques inconvénients. Le résultat de la segmentation dépend du choix des constantes et de l'initialisation du contour initial. La présence du bruit dans l'image ne permet pas de détecter les frontières des objets, le snake converge vers un minimum local.

Plusieurs améliorations ont été apportées, comme par exemple, l'utilisation de l'équation de diffusion des vecteurs gradients proposée par Xu et Prince [100], ou encore les fonctions introduites par le même auteur pour améliorer la convergence des contours [101]. Cependant, avec toutes les améliorations du Snake, le problème de gestion des changements de topologie reste posé.

**IV.1.2. Les contours actifs géométriques (Level-Sets).**

Cette méthode permet une représentation implicite des modèles comme un ensemble de niveaux d'une fonction scalaire de dimension supérieure. Contrairement au Snake, il permet une adaptation automatique à la topologie de ces modèles. Le modèle de base du contour actif géométrique est exprimé comme suit :

$$\begin{cases} \frac{\partial \phi(x, y, t)}{\partial t} = g(|\nabla I|)(k + v)|\nabla \phi(x, y, t)| \\ \phi(x, y, 0) = \phi_0(x, y) \end{cases} \quad (2.17)$$

$I$  représente l'image,  $\phi(x, y, t)$  la fonction Level-Set [102] basée sur un contour actif fermé  $S$  (figure 2.9), elle est définie par les paramètres suivants :

$$\begin{cases} \phi(x, y, t) > 0 & \text{si } S \text{ est à l'extérieur de la courbe} \\ \phi(x, y, t) < 0 & \text{si } S \text{ est à l'intérieur de la courbe} \\ \phi(x, y, t) = 0 & \text{si } S \text{ est sur la courbe} \end{cases}$$

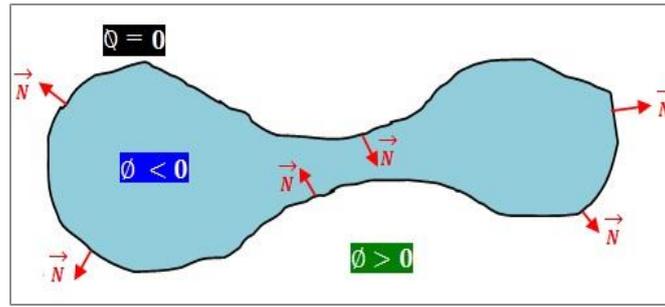


Figure 2.9. Représentation de la courbe Level-Sets.

$\nabla\phi$  est le gradient de la fonction level-set,  $v$  la constante positive chargée de forcer l'évolution du contour vers les limites de l'objet,  $k$  représente la fonction de courbure calculée par l'équation suivante :

$$k = \operatorname{div} \left( \frac{\nabla\phi}{|\nabla\phi|} \right) \tag{2.18}$$

$g$  est la fonction d'arrêt, définie par :

$$g(|\nabla I|) = \frac{1}{(1+|\nabla G_\sigma * I|)} \tag{2.19}$$

Ce type de contour actif présente plusieurs avantages, tels que la prise en compte des changements de topologie automatique. Pour l'extension à la 3D, il suffit d'ajouter une coordonnée à l'équation d'évolution, qui devient  $\phi(x, y, z, t)$ . Par ailleurs, on doit construire la fonction  $\phi(x, y, 0)$  de manière à ce que son niveau zéro corresponde à la position initiale du contour.

Cet algorithme nécessite un temps de calcul considérable. De plus, dans le cas réel, la fonction d'arrêt ne s'annule jamais puisqu'on ne rencontre jamais un contour idéal. Pour accélérer l'algorithme, on ne peut effectuer les calculs que sur une bande étroite et non sur la totalité de l'image [103]. Pour réduire le temps de calcul, Casselles *et al* [104] proposent un modèle appelé contours actifs géodésiques donné par l'expression suivante :

$$\frac{\partial\phi(x,y,t)}{\partial t} = g(|\nabla I|)(k + v)|\nabla\phi(x,y,t)| + \nabla g(\nabla I) \cdot \nabla\phi(x,y,t) \tag{2.20}$$

Ce modèle permet par l'ajout d'un terme de gradient, la détection des frontières d'objet, mais il reste inefficace lorsque ces frontières sont floues, ce qui est pris en charge par le modèle de Chan et Vese [105] :

$$\begin{cases} \frac{\partial \phi}{\partial t} = \delta(\phi(x, y))[\mu k - v - (\lambda_1(I(x, y) - c_1))^2 - (\lambda_2(I(x, y) - c_2))^2] \\ \phi(x, y, t) = \phi_0(x, y) \end{cases} \quad (2.21)$$

Où

$\delta(\phi)$  est la fonction de Dirac.

$\mu, v, \lambda_1, \lambda_2$  définissent la proportionnalité relative entre les différents termes.

$c_1, c_2$  représentent les moyennes intérieure et extérieure de la courbe.

#### **IV.2. Travaux effectués sur les contours actifs.**

Dans cette section, nous faisons une mise au point sur l'état de l'art de l'utilisation des contours actifs pour la segmentation des images cérébrales.

La force extérieure de la fonction de l'énergie permet d'attirer le contour initial vers l'objet, cette force représente la dérivée du gradient des niveaux d'intensité de l'image. Pour améliorer l'effet de la force, le contour initial doit être près de l'objet qu'on veut segmenter. Une solution est présentée dans les travaux effectués par Xu et Prince [100] qui permet une initialisation éloignée des objets. Ce modèle introduit un nouveau type de champ de force externe appelée GVF (Gradient Vector Flow), ce qui permet d'améliorer la qualité de la segmentation. Une utilisation du même principe a été effectuée par J.Tang [106] pour la segmentation du cancer de la peau.

Dans les travaux de Zhu [107], l'introduction d'un filtre non linéaire sur le champ GVF a permis une initialisation automatique grâce au GVF et une robustesse en présence du bruit de l'image. Ce modèle est utilisé pour la segmentation des parois des vaisseaux dans les images ultrasonores.

Pour augmenter la vitesse de la segmentation, Chan et Vese [105]. Ainsi que Wang Mingquan [108], incorporent l'information locale dans le modèle proposé et introduisent un nouveau critère d'arrêt pour s'assurer que la courbe s'arrête automatiquement, sur les limites des objets.

Une introduction des Smoothing B-Splines [109] permet aux contours, l'estimation automatique de la densité de probabilité du bruit présent dans la majorité des images médicales [110]. L'évolution du contour actif prend en considération le bruit présent dans les images et pas aveuglement comme c'est le cas pour la fonction initiale. Cette segmentation a

été testée sur des IRMs bruitées (bruit de type Ricien) et les résultats obtenues montrent que la méthode est beaucoup moins sensible au bruit d'acquisition.

Plusieurs approches hybrides combinent la segmentation contour actif à d'autres modèles. Dans [111], les auteurs ont mis en place une méthode qui combine deux modèles pour la segmentation du cerveau, la première est une segmentation avec l'approche MFCM (Modified Fuzzy Clustering Means) [112] pour partager l'image en 3 classes MB (Matière Blanche), MG (Matière Grise) et LC (Liquide Céphalorachidien). Cette étape représente une initialisation pour le contour actif du Level Set. En utilisant le même principe, l'auteur dans [113] a réalisé une segmentation des tumeurs cérébrales.

## **V. UTILISATION DE LA FCM DANS LA SEGMENTATION DES IRMs.**

A cause des limites des systèmes d'acquisition, les objets peuvent apparaître avec des frontières imprécises ou floues (l'effet du volume partiel). Comme mentionné dans le chapitre précédent, l'effet du volume partiel est souvent présent sur les IRM cérébrales, d'où la nécessité de choisir une méthode qui prend en considération cet artefact. L'une des approches qu'on retrouve fréquemment dans la littérature, est la segmentation par FCM (Fuzzy Clustering Means) où C-moyennes floues.

Nous avons utilisé cette technique dans notre travail, c'est pour cette raison que nous présentons cette approche et ses différentes améliorations. Enfin, nous présenterons également quelques applications dans le domaine médical notamment en IRM.

### **V.1. Théorie de la FCM.**

La méthode FCM est le premier algorithme qui s'appuie sur la notion d'ensembles flous, elle a été introduite par Zahed [114]. Très vite elle a trouvé sa place dans le traitement en imagerie médicale [115, 116]. L'approche permet enfin de regrouper les pixels ou les voxels de l'image selon un degré d'appartenance, et ce, pour réaliser la classification des tissus (attribuer chaque pixel à une région) ou la séparation des tissus sains et pathologiques.

L'approche FCM ne nécessite pas une base d'apprentissage (elle est une méthode non supervisée). Contrairement à la méthode C-Moyenne, la FCM permet de classer la donnée non seulement dans une classe en particulier, mais dans un ensemble de classes selon un degré d'appartenance. D'après Pham [117], le degré d'appartenance appelé aussi la fonction d'appartenance floue, représente le degré de similarité entre les niveaux de gris du voxel courant et le prototype associé à la classe appelé également centroïde.

Soit l'espace vectoriel  $X = \{x_j / x_j \in R, j \in \{1, \dots, n\}\}$  où  $n \in \mathbb{N}$  représente le nombre de pixels qui constituent l'image.

Soit l'espace vectoriel  $V = \{v_i / v_i \in R, i \in \{1, \dots, c\}\}$  qui représente les prototypes qui caractérisent les classes,  $c \in \mathbb{N}$  définit le nombre des classes avec  $(1 < c < n)$ .

Comme mentionné précédemment dans la méthode FCM, une donnée n'est pas attribuée à une classe en particulier, mais à un ensemble de classes avec un certain degré d'appartenance floue qu'on appelle  $u_{ji}$ . L'algorithme effectue une série d'itérations pour l'évaluation de la fonction d'appartenance et le calcul des centroïdes des classes  $v_i$ .

$U = \{u_{ji} / u_{ji} \in \mathbb{R}^{n \times c}, j \in \{1, \dots, n\}, i \in \{1, \dots, c\}\}$  représente la matrice de séparation floue qui satisfait les conditions suivantes :

$$0 \leq u_{ji} \leq 1 \quad \forall i \in [1, c], \forall j \in [1, n] \quad (2.22)$$

$$\sum_{i=1}^c u_{ji} = 1 \quad \forall j \in [1, n] \quad (2.23)$$

$$0 < \sum_{j=1}^n u_{ji} < n \quad \forall i \in [1, c] \quad (2.24)$$

La fonction d'énergie qui relie la fonction d'appartenance  $u_{ji}$  et les prototypes  $v_i$  est définie par :

$$J(u, v) = \sum_{j=1}^n \sum_{i=1}^c u_{ji}^q d^2(x_j, v_i) \quad (2.25)$$

où  $q > 1$  est le degré de flou de la segmentation, et  $d^2(x_j, v_i)$  représente une mesure de la distance entre l'intensité du voxel  $j$  et le centroïde de la classe  $i$ .

On effectue une minimisation de la fonction (2.25) pour retrouver la partition et le prototype optimal en suivant les étapes du théorème suivant :

**Théorème C- Moyenne Floue (FCM).** Pour effectuer la partition de l'image en plusieurs classes  $(c_1, c_2, \dots, c_n)$ , on doit minimiser la fonction d'énergie (2.25) en utilisant la fonction de Lagrange :

$$J_L = J(u, v) + \sum_{j=1}^n \lambda_j \left( 1 - \sum_{i=1}^c u_{ji} \right) \quad (2.26)$$

Avec les conditions suivantes :

$$\frac{\partial}{\partial u_{ji}} J_L = 0 \quad (2.27)$$

$$\frac{\partial}{\partial v_i} J_L = 0 \quad (2.28)$$

où  $\lambda_j$  représente le multiplicateur de Lagrange, calculé en utilisant les deux dérivées des équations précédentes. Le degré d'appartenance et le centroïde doivent satisfaire les conditions :

$$u_{ji} = \left[ \sum_{k=1}^c \left( \frac{d(x_j, v_i)}{d(x_j, v_k)} \right)^{2/(q-1)} \right]^{-1} \quad 1 \leq i \leq c, \quad x_i \in X \quad (2.29)$$

$$v_i = \frac{\sum_{j=1}^n u_{ji}^q x_j}{\sum_{j=1}^n u_{ji}^q} \quad 1 \leq i \leq c \quad (2.30)$$

Le terme  $d^2(x_j, v_i)$  permet de calculer la similarité entre l'intensité du voxel  $j$  et le centroïde de la classe  $i$ .

$$d^2(x_j, v_i) = \|x_j - v_i\|^2 \quad (2.31)$$

où  $\|.\|$  représente la distance Euclidienne.

L'algorithme FCM effectue une série d'itérations entre l'évaluation de la fonction d'appartenance floue  $u_{ji}$  et le calcul des centroïdes des classes  $v_i$ . Il suit le déroulement des procédures suivantes :

**Entrées :** L'image  $X = \{x_1, x_2, \dots, x_n\}$ , le nombre de classe  $c$ , la valeur de  $q$ , avec  $q > 1$ , valeur de convergence  $\varepsilon$ .

**Etape 1 :** initialisation de la matrice de partition  $U = [u_{ji}]$

**Etape 2 :** initialisation du compteur  $t = 0$ .

**Etape 3 :** calcul de la valeur des centroïdes  $v_i^t$  on utilisant l'équation 2.30.

**Etape 4 :** calcul des valeurs  $u_{ji}^{t+1}$  pour  $j = 1$  jusqu'à  $n$ .

**Etape 5 :** Si  $\|U^t - U^{t+1}\| < \varepsilon$  l'algorithme s'arrête. Sinon retour à l'étape 3 avec  $t = t + 1$ .

Les résultats de la classification par l'algorithme FCM dépend de l'étape de l'initialisation, cette étape se fait de façon aléatoire et ne prend pas en compte la présence du bruit sur les images ou la présence du volume partiel (présence de plusieurs tissus dans le même voxel) qu'on retrouve souvent sur les IRMs fœtales.

**V.2. Travaux effectués sur la FCM.**

Pour adapter la FCM aux images médicales, plusieurs approches ont été proposées. On ne citera que quelques modèles développés ces dernières années.

**V.2.1. Mesure de la similarité.**

Pour comparer la ressemblance entre deux pixels ou voxels, il faut pouvoir mesurer la similarité entre eux. Dans le traitement d'image, lorsqu'on parle de similarité, on désigne souvent une mesure de la distance entre deux points ou pixels de l'image.

Dans la méthode FCM conventionnelle, la distance Euclidienne permet de mesurer le degré de similarité entre l'intensité du voxel et celle du centroïde. Plusieurs travaux ont été développés pour modifier la distance.

**V.2.1.1. Distance Mahalabonis.**

Dans les travaux de He [118], la distance Euclidienne est remplacée par la distance Mahalabonis [119] pour prendre en compte la variance et la corrélation des classes, ce qui revient à utiliser la fonction suivante :

$$D^2(x_j, v_i) = (x_j - v_i)^T T_i (x_j - v_i) \tag{2.32}$$

La matrice  $T_i$  est calculée par la fonction  $T_i = \sqrt{|C_i|} C_i^{-1}$ ,  $|C_i|$  est le discriminant de la matrice de covariance floue  $C_i$ , cette dernière est calculée à l'aide de la fonction :

$$C_i = \frac{\sum_{j \in \Omega} u_{ji}^q (x_j - v_i)(x_j - v_i)^T}{\sum_{j \in \Omega} u_{ji}^q} \tag{2.33}$$

**V.2.1.2. Distance Manhattan.**

Récemment, une étude de comparaison entre l'utilisation de la distance Euclidienne et la distance Manhattan est présentée dans l'article [120]. Rappelons que la distance euclidienne appelée aussi distance à vol d'oiseau, représente la distance la plus courte entre deux pixels, par contre la distance Manhattan appelée taxi-distance, représente la distance entre deux pixels mais en effectuant un chemin en grille avec des déplacements horizontaux et verticaux des pixels. Cette distance calcule la somme des valeurs absolues des différences entre l'intensité du voxel  $j$  et le centroïde de la classe  $i$ . Il suit la fonction ci dessous :

$$D^2(x_j, v_i) = |x_j - v_i|^2 \tag{2.34}$$

D'après les résultats obtenus dans [120], l'utilisation de la distance Manhattan donne de meilleurs résultats dans la segmentation des tissus cérébraux en IRM.

### V.2.2. Ajout d'un terme pour la régularisation.

La qualité de la segmentation dépend de l'intensité du bruit présent dans l'image, or le modèle FCM est sensible aux artefacts dus aux inhomogénéités du champ. On retrouve dans la littérature, plusieurs modèles qui permettent de prendre en compte ces artefacts. Ces modèles sont régis par une fonction qui est la somme d'un terme d'attache aux données et d'un terme régulateur.

Pham [15], propose un modèle appelé RFCM (Robust Fuzzy C-Means) où la fonction d'énergie est constituée d'un terme d'attache aux données qui représente la fonction de la FCM classique et d'un terme inspiré du formalisme des champs de Markov qui permet la régularisation de la fonction d'énergie et la prise en compte de l'information spatiale de l'image (la relation entre le pixel et ses voisinages). Dans ce modèle la fonction s'écrit sous la forme suivante :

$$J_{RFCM} = \sum_{j \in \Omega} \sum_{k=1}^c u_{ji}^q \|x_j - v_i\|_2^2 + \frac{\beta}{2} \sum_{j \in \Omega} \sum_{k=1}^c u_{ji}^q \sum_{k \in N_j} \sum_{l \in L_i} u_{kl}^q \quad (2.35)$$

Le premier terme représente la méthode FCM standard, le second représente le terme de régularisation de la fonction.

$\beta$  est une constante qui contrôle le poids des deux termes et  $N_j$  un voisinage du  $j^{ème}$  voxel,  $L_i = [1, c] / \{1, \dots, i - 1, i + 1, \dots, c\}$ .

Dans le même contexte Ahmed *et al* [121] proposent le modèle MFCM (Modified FCM), qui définit la fonction d'énergie de la façon suivante :

$$J_{MFCM} = \sum_{j \in \Omega} \sum_{i=1}^c u_{ji}^q \|x_j - v_i\|_2^2 + \frac{\alpha}{|N_R|} \sum_{j \in \Omega} \sum_{i=1}^c u_{ji}^q \sum_{l \in N_j} \|x_l - v_i\|_2^2 \quad (2.36)$$

où  $N_R$  est le nombre total de voisinages, il est égal à 8 sur les images bidimensionnelles et 26 dans les images 3D.  $\alpha$  est une constante positive qui permet de contrôler le terme du voisinage.  $N_j$  est le voisinage du  $j^{ème}$  voxel, et  $x_l$  le voisinage de  $x_j$ .

Pour la mise à jour des centres de classes et des degrés d'appartenance, on utilise les multiplicateurs de Lagrange. La principale différence entre les algorithmes RFCM et MFCM est l'exploitation du voisinage. Dans le premier, la régularisation utilise principalement la fonction d'appartenance, par contre le second effectue la régularisation par rapport à la distance et donc la similarité entre l'intensité des voxels voisins et le centroïde de la classe courante. De nombreux travaux ont été effectués sur ces deux algorithmes pour mieux les adapter aux images qu'on veut traiter.

### V.2.3. Utilisation de la moyenne.

Il est nécessaire dans l'algorithme MFCM de calculer pour chaque pixel, l'ensemble des distances entre ses pixels voisins et les centres des classes. Cependant, l'exploration des différents voisinages est très couteuse en temps de calcul, des méthodes sont alors proposées pour accélérer le processus d'exécution. Chen et Zhang [16] proposent de calculer dans le terme de régulateur de la fonction la moyenne ou la médiane du voisinage plutôt que de la calculer sur la totalité de l'image. Cette version est appelée FCM\_S (FCM with Spatial constraints) et la fonction à minimiser devient :

$$J_{MFCM} = \sum_{j \in \Omega} \sum_{i=1}^c u_{ji}^q \|x_j - v_i\|_2^2 + \alpha \sum_{j \in \Omega} \sum_{i=1}^c u_{ji}^q \|\bar{x}_j - v_i\|_2^2 \quad (2.37)$$

Où  $\bar{x}_j$  est le  $j^{ème}$  pixel de l'image moyenne.

Comme dans le modèle traditionnel, la minimisation de la fonction d'énergie s'effectue en utilisant le multiplicateur de Lagrange, les degrés d'appartenance et les centres sont alors donnés par :

$$v_i = \frac{\sum_{j \in \Omega} u_{ji}^q (x_j + \alpha \bar{x}_j)}{(1 + \alpha) \sum_{j \in \Omega} (u_{ji})^q} \quad (2.38)$$

$$u_{ji} = \frac{\left( \|x_j - v_i\|_2^2 + \alpha \|\bar{x}_j - v_i\|_2^2 \right)^{\frac{1}{q-1}}}{\sum_{i=1}^c \left( \|x_j - v_i\|_2^2 + \alpha \|\bar{x}_j - v_i\|_2^2 \right)^{\frac{1}{q-1}}} \quad (2.39)$$

L'auteur utilise le même principe dans [117], mais il ajoute le noyau gaussien pour calculer la similarité de manière à ajouter à l'algorithme, une robustesse au bruit. Ce modèle est appelé KFCM\_S (Kernalised FCM with Spatial constraints). La fonction devient :

$$J_{KFCM\_S} = \sum_{j \in \Omega} \sum_{k=1}^c u_{ji}^q (1 - k(x_j, v_i)) + \beta \sum_{j \in \Omega} \sum_{k=1}^c u_{ji}^q (1 - k(\bar{x}_j, v_i)) \quad (2.40)$$

Les fonctions d'appartenance et des centres sont similaires à celles de Ahmed [121].

#### V.2.4. Autres méthodes.

Dans [122], Wang a présenté un modèle automatique pour la segmentation des images IRM. L'auteur applique plusieurs fois un filtre de diffusion sur l'image à traiter, on obtient alors une série d'images multi-échelles avec un niveau de détails de plus en plus réduit.

Par la suite, une segmentation par FCM est réalisée sur l'image la plus grossière et le résultat est utilisé dans la définition de la similarité pour réaliser une segmentation à un niveau de détails plus élevé jusqu'à l'image originale. L'image originale est segmentée par la FCM et la résultante est prise comme image de référence pour une image plus détaillée. Cet algorithme a le même principe qu'un atlas statistique sans les étapes de la construction d'un atlas et du recalage.

Yogita *et al* [123] ont effectué un changement dans la fonction MFCM de Ahmed [121], l'image obtenue par examen de l'IRM représente l'addition de l'image réelle et du bruit présent dans celle-ci. Cette fonction s'écrit sous la forme suivante :

$$Y_j = I_j + B_j \quad (2.41)$$

Avec  $Y_j$  l'image observée,  $I_j$  l'image réelle et  $B_j$  le bruit présent dans l'image.

L'objectif principal de la FCM est de réaliser la meilleure partition de l'image réelle  $\{I_j\}_{j=1}^N$  par différentes régions  $c$  définies par l'utilisateur. D'après [123], si on prend en considération le bruit présent sur les images, la formule à minimiser pour réaliser la segmentation devient :

$$J = \sum_{j \in \Omega} \sum_{i=1}^c u_{ji}^q \|Y_j - B_j - v_i\|_2^2 + \frac{\alpha}{|N_R|} \sum_{j \in \Omega} \sum_{i=1}^c u_{ji}^q \sum_{l \in N_j} \|Y_l - B_l - v_i\|_2^2 \quad (2.42)$$

L'auteur a testé l'algorithme sur des images de cerveau obtenues en IRM. Les résultats obtenus montrent l'efficacité de ce dernier pour la correction de l'inhomogénéité de l'intensité de l'image et la robustesse en présence de bruit.

**VI. CONCLUSION.**

Dans ce chapitre, nous avons présenté quelques méthodes proposées dans la littérature pour la segmentation des IRM. Deux méthodes nous ont particulièrement intéressés :

- Les approches par contours actifs géodésiques, en particulier le modèle de Casselles *et al* [104]. Ce modèle a l'avantage de prendre automatiquement en compte les changements de topologie et la détection des frontières même en présence du bruit dans l'image grâce au terme de gradient.
- Les approches par classification, en particulier le modèle modifié de la FCM de Ahmed [121] qui s'est révélé être une bonne méthode pour réaliser la partition des images cérébrales caractérisées par la présence du volume partiel.

Notre travail s'articule autour de deux points majeurs. Le premier point est d'utiliser la méthode proposée par Casselles [104] dans une segmentation hybride d'images cérébrales (chez l'adulte) pour la détection des tumeurs et la sclérose en plaques. Le second est de réaliser des modifications sur l'algorithme FCM pour le rendre plus robuste au bruit et plus rapide, et de l'utiliser pour la partition des images cérébrales.

# **CHAPITRE III**

## **Processus de Segmentation proposée**

**I. INTRODUCTION.**

La segmentation est l'une des tâches les plus importantes dans l'analyse en imagerie médicale. Elle est souvent la première étape dans de nombreuses applications cliniques. Dans l'IRM cérébrale, la segmentation est couramment utilisée pour calculer le volume des structures anatomiques du cerveau et suivre la croissance et le développement de ces derniers, ou pour délimiter les régions pathologiques.

Au cours de ces dernières années, beaucoup de méthodes mettant en évidence la segmentation cérébrale, sont rapportées dans la littérature. Dans ce chapitre, nous présenterons et discuterons les résultats que nous avons obtenus dans la segmentation des IRM cérébrales. Deux nouvelles approches sont présentées : (i) la première est basée sur une segmentation hybride utilisée pour délimiter les frontières de la tumeur et la sclérose en plaques, (ii) la seconde est basée sur la méthode RFCM qui permet la classification des différents tissus du cerveau et donc de réaliser une quantification de celui-ci.

**II. L'APPROCHE HYBRIDE.**

L'approche que nous proposons dans notre travail pour la segmentation des IRMs cérébrales, est basée essentiellement sur des méthodes du contour actif géodésique (voir chapitre précédent). Notre méthode a été testée sur des images cérébrales brutes contenant des tumeurs ou une sclérose en plaques.

Une série de prétraitement des images a été réalisée avant la segmentation: (i) extraction de la région intracrânienne du reste de l'image, (ii) segmentation proposée. Ces différents étapes sont détaillés dans ce qui suit.

**II.1. Extraction de l'image du cerveau.**

Dans le présent travail nous nous sommes limités à l'étude des tissus cérébraux. Cependant, les images cérébrales obtenues par l'IRM contiennent la tête entière. De ce fait, il est nécessaire d'extraire l'image du parenchyme cérébral (matière grise, matière blanche et liquide céphalo-rachidien) du reste de l'image pour réduire le nombre de pixels à traiter pendant la segmentation, et ce dans le but de réduire le temps de traitement. Néanmoins, cette opération reste difficile à réaliser car elle dépend de l'intensité de différents tissus qui constituent le cerveau.

Plusieurs algorithmes sont proposés dans la littérature pour faire l'extraction de l'image du parenchyme cérébral. Parmi les plus intéressants, nous citerons :

- L'algorithme **BET** [124] (*Brain Extraction Toll*), qui traite l'histogramme pour retrouver l'intensité du seuil entre les tissus du parenchyme cérébral et le reste de l'image. Il détermine par la suite, le centre de gravité, ainsi que la taille approximative du cerveau, et définit une sphère déformable initiale basée au centre de gravité. Enfin, la sphère est poussée vers l'extérieur par des forces d'adaptation locales jusqu'à atteindre la surface du cerveau.
- L'algorithme **BSE** [125] (*Brain Surface Extractor*), qui effectue l'extraction de l'image du cerveau à l'aide d'une séquence de filtres de diffusion anisotrope, détecteur de bordure Marr-Hildreth [126] et du traitement morphologique.
- L'algorithme **HWA** [127] (*The Hybrid Watershed Algorithm*), est une méthode hybride qui combine l'algorithme des **LPE** (Lignes de Partage des Eaux) [128]. Pour obtenir un volume initial du cerveau, ce volume est utilisé comme masque initial à l'extraction. Ce masque se déforme pour atteindre la partie supérieure du cerveau en utilisant les modèles déformables.

Les résultats de l'extraction dépendent de la qualité de l'image obtenue, plusieurs régions peuvent être difficiles à gérer à cause des similitudes entre la peau, l'os et le cerveau. Pour notre part, nous proposons un algorithme simple et facile à utiliser pour éliminer juste les parties non désirables dans les IRM cérébrales, même dans le cas où le niveau de gris peut être similaire aux parties à éliminer.

Dans cette partie de prétraitement, notre objectif est d'éliminer les parties non utilisées dans l'interprétation, comme le crâne et la peau de la tête. Pour cela, nous proposons un algorithme combinant les méthodes statistiques et les outils morphologiques pour prendre en considération la différence de niveaux de gris entre les tissus et la connexion entre différentes parties du cerveau.

Le schéma suivant fournit une description globale de notre système.

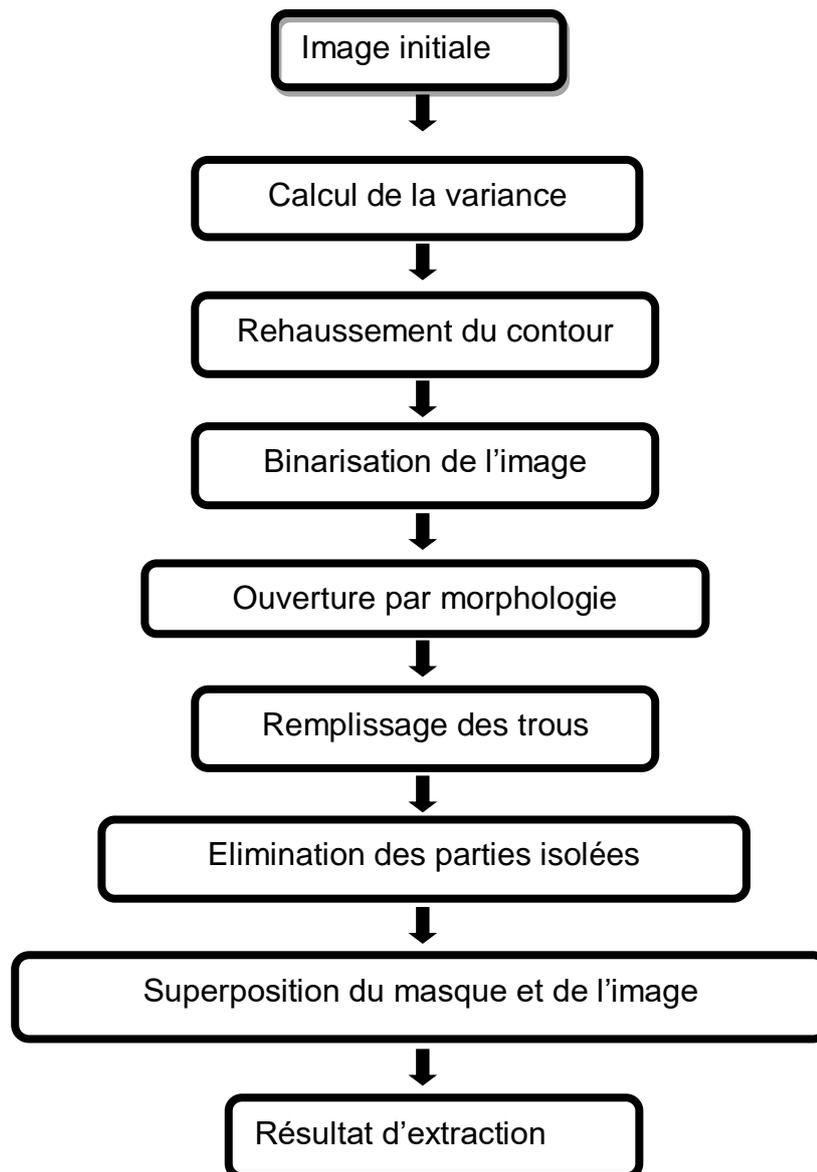


Figure 3.1. Schéma décrivant le système utilisé.

#### II.1.1. Calcul de la variance.

Le calcul de la variance locale d'un pixel, dans différentes échelles et différentes directions, est appliqué dans le cadre de notre travail, pour extraire l'ensemble des caractéristiques de l'image. Nous calculons la variance locale pour mesurer la répartition des niveaux de gris autour d'un pixel avec une fenêtre choisie et de différentes orientations. La figure 3.2, illustre l'utilisation d'une fenêtre de 3x3 (8 voisins) et de 5x5 (24 voisins) avec des orientations de 0°, 45°, 90°, et 135°.

L'équation de la variance s'écrit sous la forme :

$$var(x) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \tag{3.1}$$

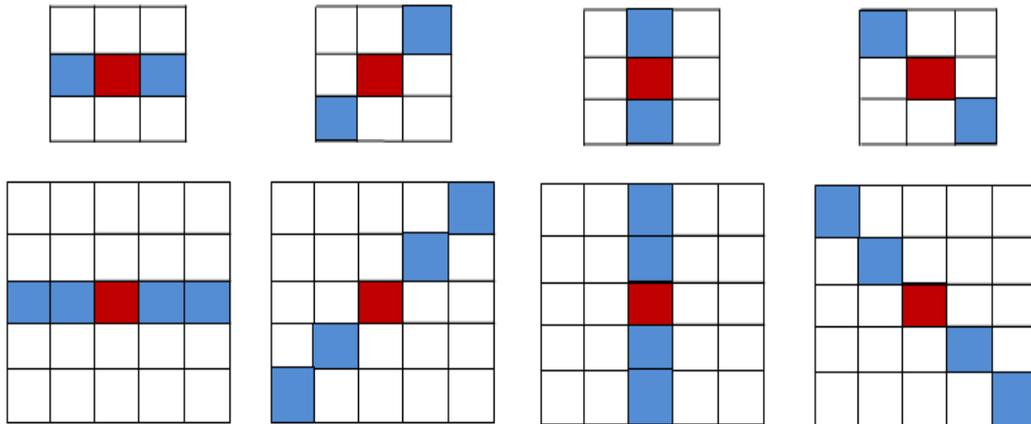


Figure 3.2. Exemple de modèle de calcul de la variance.

**II.1.2. Rehaussement des contours.**

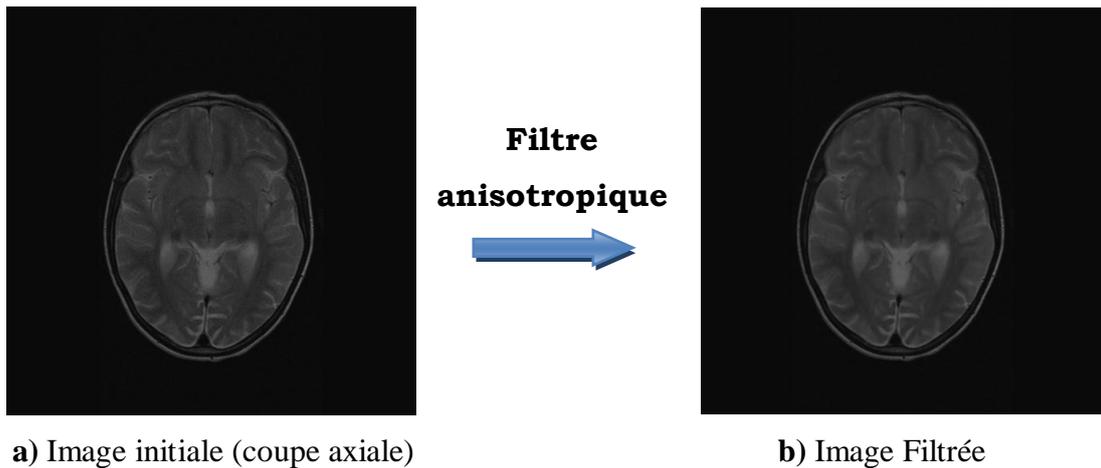
La segmentation des IRMs est directement liée à la phase du prétraitement. Cette phase permet d’éliminer le bruit inhérent au principe physique de l’acquisition et la variation d’intensité des voxels au sein d’un même tissu. Plusieurs algorithmes sont appliqués dans le domaine médical, pour diminuer ou éliminer cet artefact de l’image. Dans cette partie de la thèse, nous avons utilisé le filtre de diffusion anisotrope défini par Pérona et Malik [129] pour le prétraitement des images. Ce filtre permet d’éliminer le bruit tout en préservant le contraste sur les contours. La fonction de diffusion s’écrit comme suit :

$$\frac{\partial I_t}{\partial t} = div [g(\|\vec{\nabla}I\|) \vec{\nabla}I] \tag{3.2}$$

Où :

- *div* représente l’opérateur divergence.
- $\vec{\nabla}I$  est l’opérateur gradient appliqué à l’image *I*.
- *g* est la fonction d’arrêt qui contrôle le processus de diffusion.

La figure 3.3 (image de gauche) représente une coupe axiale d’un patient de la clinique El Hoceini (Constantine). En utilisant le filtre de diffusion sur cette image, on obtient l’image de droite, qui montre que le filtre nous permet de rehausser les contours des tissus dans les IRM.



**Figure 3.3.** Image initiale filtrée par le filtre Pérona et Malik.

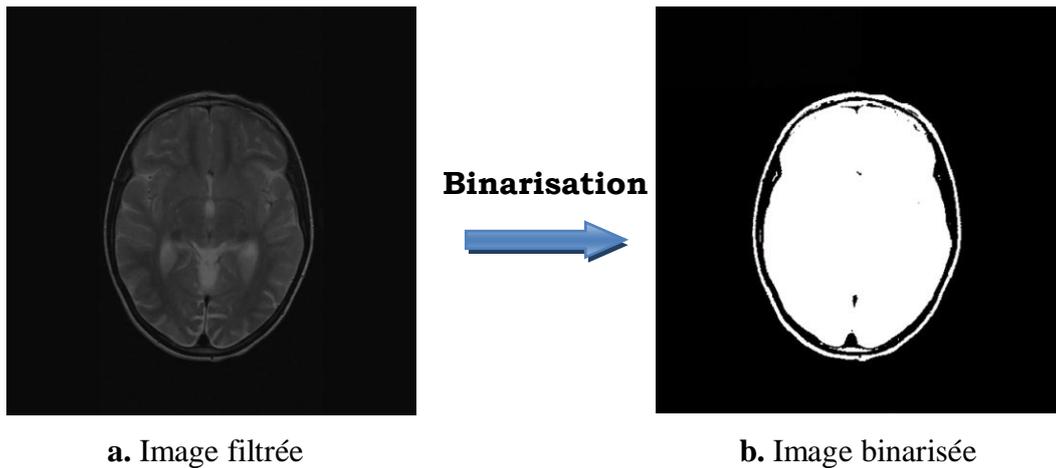
### **II.1.3. Binarisation de l'image.**

La binarisation de l'image, appelée aussi seuillage de l'image, permet de transformer à partir d'une valeur choisie (un seuil), une image de niveaux de gris en une image binaire. Tous les pixels qui ont une valeur inférieure à ce seuil, de la valeur zéro (0 : noir) leur sera affectée, et tous les pixels ayant une valeur supérieure au seuil la valeur un (01 ou 255 : blanc) leur sera affectée. L'équation qui décrit cette étape est la suivante :

$$g(x) = \begin{cases} 0 & \text{si } f(x) \leq S \\ 1 & \text{si } f(x) \geq S \end{cases} \quad (3.3)$$

Afin d'éviter le choix du seuil qui n'est pas le même pour toutes les images, nous avons utilisé le seuillage automatique proposé par Otsu dans [130]. Ce qui permet de tirer profit du niveau de gris du crâne qui est plus sombre que le liquide céphalorachidien qui entoure le cerveau. Cet algorithme utilise l'histogramme de l'image, pour calculer la valeur du seuil optimal qui sépare les régions : crâne - LCR, crâne- peau afin que leur variance intra-classe soit minimale.

La figure 3.4 représente un seuillage par la méthode d'Otsu, on remarque que l'image à niveaux de gris est réduite en une image binaire qui ne contient que deux classes de pixels. On obtient une image avec le crâne en noir et le cerveau et la peau en blanc.



**Figure 3.4.** Binarisation de l'image filtrée par méthode Otsu.

### III.1.4. Outil morphologique.

La morphologie mathématique [131] est une théorie de traitement non linéaire de l'information utilisée, qui a pour but d'étudier les objets en fonction de leur forme, leur relation avec leur voisinage, leurs couleurs où les niveaux de gris.

Ces méthodes sont largement utilisées dans le traitement d'image dans le cadre du prétraitement (filtrage) ou la segmentation (pour la quantification des tissus). Les opérateurs qu'on utilise dans notre travail sont : l'érosion, la dilatation, l'ouverture et la fermeture.

#### ➤ Erosion :

Soit  $p$  l'ensemble des pixels de l'image  $I$  et  $B_p$  une fenêtre obtenue en positionnant l'élément structurant  $B$  sur le pixel  $p$ . L'érosion de  $I$  par  $B$  est l'ensemble des pixels  $p$  tels que la fenêtre  $B_p$  est incluse dans  $I$ . L'équation de l'érosion de  $I$  par  $B$  s'écrit :

$$\varepsilon_B(I) = \inf\{p / B_p \leq I\} \quad (3.4)$$

L'effet de l'érosion est d'abord de rétrécir l'image en déplaçant l'élément structurant  $B$  dans l'image et en remplaçant la valeur du pixel du milieu de l'élément structurant par la valeur minimale des pixels de ce dernier. L'érosion a pour rôle la réduction des objets clairs de l'image.

#### ➤ Dilatation :

Contrairement à l'érosion, l'image  $I$  est dilatée par l'élément structurant  $B$ . On remplace la valeur de chaque pixel  $p$  de l'image  $I$  par la fenêtre  $B_p$  obtenue en positionnant  $B$  sur le pixel  $p$ . La dilatation est représentée par la fonction suivante :

$$\delta_B(I) = \sup\{B_p / p \in I\} \quad (3.5)$$

L'effet de la dilation est un élargissement de l'image. Elle a pour rôle d'augmenter les objets les plus clairs des images.

➤ **Ouverture morphologique :**

On définit l'ouverture d'une image  $I$  par un élément structurant  $B$  comme la composition de l'érosion de l'image  $I$  par l'élément  $B$ , suivi d'une dilatation par le même élément structurant. Dans ce cas la fonction s'écrit comme suit :

$$I_B = \delta_B[\varepsilon_B(I, B), \check{B}] \tag{3.6}$$

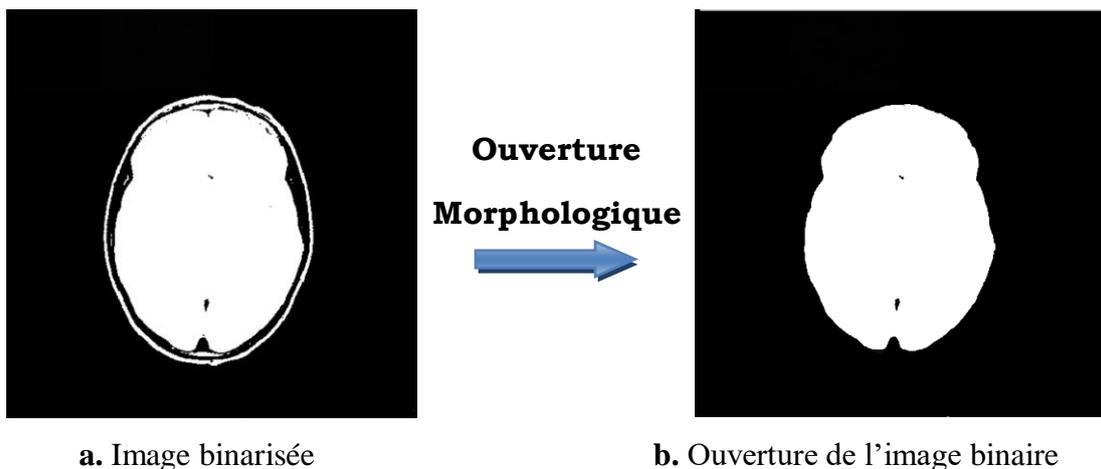


Figure 3.5. Ouverture morphologique.

Nous avons utilisé une ouverture morphologique « imopen » sous Matlab avec un disque d'un rayon de 5 pixels sur l'image binaire obtenue par la méthode d'Otsu [130]. La Figure 3.5 montre le résultat de l'ouverture morphologique sur l'image, on remarque que l'ouverture nous permet d'éliminer les objets connexes plus petits que l'élément structurant et n'affecte en aucun cas les objets connexes plus gros que l'élément structurant. Dans notre cas, l'ouverture nous a permis d'éliminer la partie extérieure du crâne, c'est-à-dire la peau.

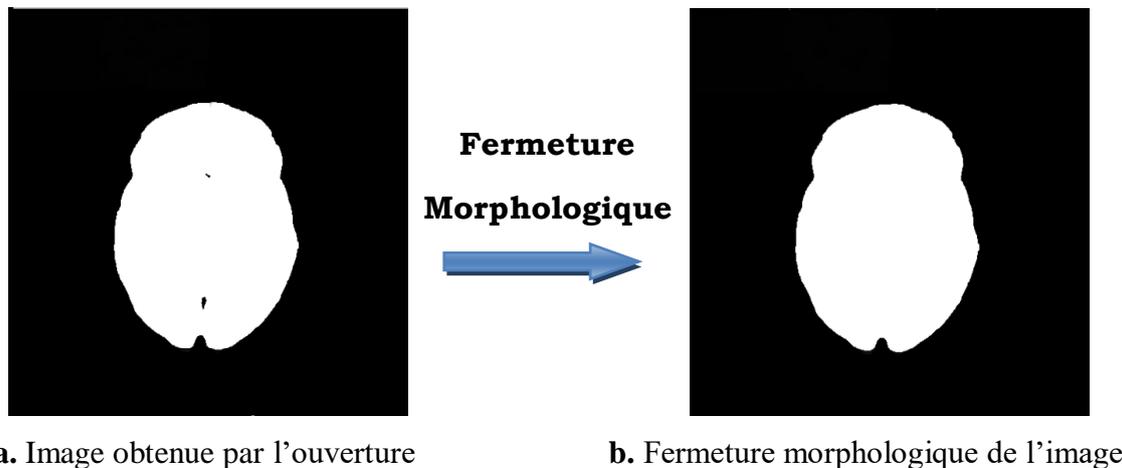
➤ **Fermeture morphologique :**

La fermeture morphologique d'une image  $I$  par un élément structurant  $B$  est définie comme la composition d'une dilatation suivie d'une érosion. Elle s'écrit sous la forme suivante :

$$I_B = \varepsilon_B[\delta_B(I, B), \check{B}] \tag{3.7}$$

Dans notre algorithme d'extraction, l'ouverture morphologique, a été suivie d'un remplissage des trous par la commande de Matlab « imclose », qui permet d'effectuer une

fermeture morphologique. La Figure 3.6 montre que cette étape a permis de remplir les trous les plus petits de l'élément structurant, et les formes les plus proches deviennent soudées.



**Figure 3.6.** Fermeture morphologique.

#### **III.1.5. Remplissage des trous.**

Après l'étape précédente, dans le cas où il subsiste quelques parties non remplies à l'intérieur du cerveau, on réalise une opération de remplissage (ou d'inondation) sur les pixels qui se trouvent à l'intérieur du cerveau. Pour effectuer cette manipulation nous avons utilisé la commande «*imfill*» de Matlab qui est une fonction morphologique qui permet de combler les trous dans une image binaire. Après cette étape, l'intérieur du cerveau devient homogène.

#### **III.1.6. Elimination des parties isolées.**

Les parties isolées sont celles qui n'ont pas été éliminées par l'ouverture morphologique. On utilise alors la commande «*bwareaopen*» de Matlab qui est basée sur une analyse en composantes connexes, qui permet d'éliminer les régions de petites tailles dans l'image binaire.

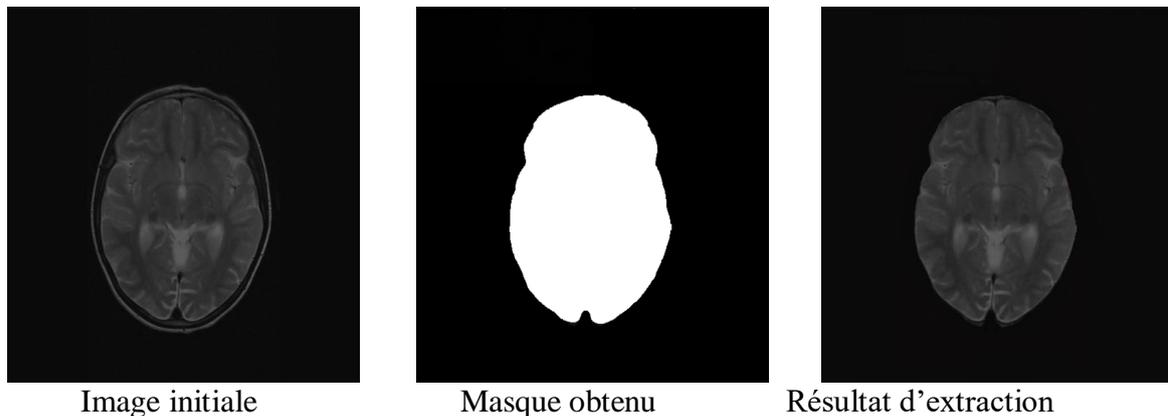
#### **III.1.7. Superposition du masque à l'image.**

Dans la dernière étape de l'extraction, on superpose l'image initiale avec le masque (l'image binaire) obtenu précédemment. La figure 3.7 représente le résultat de l'extraction du parenchyme cérébral (matière grise, matière blanche et liquide céphalorachidien).

Cependant, on retrouve quelques difficultés d'extraction sur quelques images lorsque la peau ou le crâne ont le même niveau de gris que le cerveau. De ce fait, même si notre l'algorithme n'a pas permis de supprimer la totalité des couches du crâne et de la peau nous

avons admis les résultats obtenus. En effet, il vaut mieux accepter le fait que la peau et/ou le crâne ne soient pas entièrement enlevés que de perdre une portion de volume cérébral.

Cependant, les résultats obtenus par notre algorithme avec la plupart des images obtenues par différentes coupes, sont bons même en présence de pathologies cérébrales.



**Figure 3.7 :** Superposition de l'image initiale avec le masque.

## **II.2. L'approche Hybride de segmentation.**

Une fois l'extraction du parenchyme cérébral effectuée, nous avons utilisé une nouvelle approche de segmentation automatique des images IRM cérébrales, dans le but de quantifier et de détecter les différents types de pathologies cérébrales (processus tumoral ou sclérose en plaques).

Notre approche repose sur le modèle des contours géodésiques proposé par Casselles *et al* [104], donné par l'expression suivante :

$$\frac{\partial \phi(x, y, t)}{\partial t} = g(|\nabla I|)(k + v)|\nabla \phi(x, y, t)| + \nabla g(\nabla I) \cdot \nabla \phi(x, y, t) \quad (3.8)$$

Pour réaliser la segmentation des objets, la fonction 3.8 doit être minimisée. Dans le modèle proposé par Casselles *et al* [104], le terme du gradient permet de détecter efficacement les frontières des objets, mais il a des limites lorsque les frontières sont floues. D'autre part, Chan et Vese [132] proposent un nouveau modèle de segmentation géométrique ACM (Active Contour Model) (voir chapitre II), basé sur l'approche de Mumford et Sahn [133]. Ce modèle se résume à l'introduction d'un contour fermé sur le plan de l'image qui évolue et s'arrête aux frontières des objets. La fonction à minimiser dans le modèle Chan et Vese, s'écrit :

$I : (i, j) \in \Omega / \Omega \rightarrow \mathbb{R}$

$E_{cv}(C, c_1, c_2) = \mu \cdot \text{lenght}(c)$

$$+ v \cdot \text{area}(\text{inside}(c)) \lambda_1 \int_{in(c)} |I - c_1|^2 di + \lambda_2 \int_{out(c)} |I - c_2|^2 di \quad (3.9)$$

Où :  $\mu \geq 0, v \geq 0, \text{et } \lambda_1, \lambda_2 > 0$  sont des constantes positives.

$c_1$  et  $c_2$  Représentent deux constantes qui définissent l'approximation de l'intensité à l'intérieur et à l'extérieur du contour  $C$ .

Après minimisation, on obtient la fonction suivante :

$$\frac{\partial \phi}{\partial t} = \delta(\phi) \cdot [\mu \cdot k - v - \lambda_1(I - c_1)^2 + \lambda_2(I - c_2)^2] \quad (3.10)$$

Où :

$\delta(\phi) = H'_\epsilon(i) = \frac{1}{\pi} \frac{\epsilon}{\epsilon^2 + i^2}$  Représente une fonction Dirac.

$k$  définit la fonction de courbure, calculée par l'équation suivante :  $k = \text{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right)$

$\mu, v, \lambda_1$  et  $\lambda_2$ , définissent la proportionnalité relative entre les différents termes de la fonction d'énergie.

$c_1$  et  $c_2$  sont les moyennes intérieure et extérieure de la courbe calculées respectivement par :

$$c_1(\phi) = \frac{\int_{\Omega} I \cdot H(\Phi) d\Phi}{\int_{\Omega} H(\Phi) d\Phi} \quad (3.11)$$

$$c_2(\Phi) = \frac{\int_{\Omega} I(1 - H(\Phi)) d\Phi}{\int_{\Omega} (1 - H(\Phi)) d\Phi} \quad (3.12)$$

Avec  $H_\epsilon(t) = \frac{1}{2} \left( 1 + \frac{2}{\pi} \arctan \left( \frac{t}{\epsilon} \right) \right)$

Le terme  $-\lambda_1(I - c_1)^2 + \lambda_2(I - c_2)^2$  joue un rôle important dans l'évolution du contour initial.

Dans le modèle que nous proposons, nous avons remplacé la fonction de Dirac  $\delta(\phi)$  utilisée dans le modèle C-V du terme régulateur de la fonction, par le terme du gradient  $|\nabla \phi(i, j)|$ , afin d'élargir la plage de capture. La nouvelle fonction s'écrit alors :

$$\frac{\partial \phi}{\partial t} = |\nabla \phi|. [\mu \cdot k - v - \lambda_1(I - c_1)^2 + \lambda_2(I - c_2)^2] \quad (3.13)$$

Dans le modèle proposé, nous avons supposé que :  $\lambda_1 = \lambda_2 = \lambda_0$ , et fait la somme du résultat obtenu et de la fonction 3.8 du modèle géodésique, et ce pour avoir une méthode hybride et les avantages des deux méthodes. La fonction d'énergie devient alors :

$$\frac{\partial \phi}{\partial t} = |\nabla \phi|. \left[ g(k + v) + \gamma(c_1 + c_2) \left( I + \frac{c_1 + c_2}{2} \right) \right] + \nabla g \cdot \nabla \phi \quad (3.14)$$

$\gamma$  est une constante qui assure la proportionnalité entre le terme des forces régions et celui des forces contours (gradient).

$g$  est la fonction d'arrêt, représentée par la formule décroissante de la norme du gradient de  $I$  à une échelle  $\sigma$ , la fonction s'écrit :

$$g = \frac{1}{1 + |\nabla G_\sigma * I|^p} \quad \text{Avec } p \geq 1 \quad (3.15)$$

Où  $G_\sigma$  est un noyau gaussien, le deuxième terme de l'équation 3.14 a été remplacé par  $(W_g \cdot W_\phi)$ , qui représente le GVC (*Gradient Vector Convolution*) [134]. Ce gradient a l'avantage de gérer le problème de la dépendance à l'initialisation du contour, et d'obtenir un contour qui arrive à se mouvoir jusqu'aux frontières des régions d'intérêt.

L'approximation de l'équation proposée s'écrit sous la forme suivante :

$$\phi_{i,j}^{n+1} = \phi_{i,j}^n + \Delta t. \left[ |\nabla(\phi_i)| \left( g \cdot \nabla I \cdot (k + v) + \gamma(c_1 - c_2) \left( u + \frac{c_1 + c_2}{2} \right) \right) + W_g \cdot W_\phi \right] \quad (3.16)$$

$c_1$  et  $c_2$  sont calculés par la fonction 3.11 et la fonction 3.12 respectivement,  $\gamma$  est une constante positive et  $\Delta t$  le pas entre deux itérations successives.

Pour effectuer une segmentation avec le modèle proposé, nous avons suivi les étapes suivantes :

**Etape 1 :** Soit l'image  $I(i, j)$  à segmenter, et  $\phi_0(i, j)$  le contour initial.

**Etape 2 :** Calcul de la taille de l'image  $[ln, cn]$ .

**Etape 3 :** Affectation de valeurs aux constantes positives  $\gamma, \Delta t, \sigma$ .

**Etape 4 :** Initialisation de la fonction level set :  $\phi_0(i, j) = \phi(i, j)$ .

**Etape 5 :** Calcul du gradient  $g$  :

$$\begin{aligned} & \text{pour } i = 1 \text{ jusqu'à } ln \text{ faire} \\ & \text{pour } j = 1 \text{ jusqu'à } cn \text{ faire} \\ & g(|\nabla I(i, j)|) = \frac{1}{1 + |\nabla G(i, j) * I(i, j)|} \end{aligned}$$

**Etape 6 :** Calcul de la fonction de courbure  $k$

$$\begin{aligned} & \text{pour } i = 1 \text{ jusqu'à } ln \text{ faire} \\ & \text{pour } j = 1 \text{ jusqu'à } cn \text{ faire} \\ & k(i, j) = \text{div} \left( \frac{\nabla \phi(i, j)}{|\nabla \phi(i, j)|} \right) \end{aligned}$$

**Etape 7 :** Calcul des valeurs de  $c_1$  et  $c_2$  avec les fonctions (3.11 et 3.12)

**Etape 8 :** Calcul du GVC (*Gradient Vector Convolution*)

**Etape 9 :** Calcul de la fonction  $\phi^{t+1}(i, j)$

$$\phi_{i,j}^{n+1} + \Delta t. \left[ |\nabla(\phi(i, j))| (g.(k) + \gamma(c_1 - c_2) \left( u(i, j) + \frac{c_1 + c_2}{2} \right)) + W_g . W_\phi \right] + \phi^t(i, j)$$

**Etape 10 :** Répéter jusqu'à la minimisation de la fonction d'énergie.

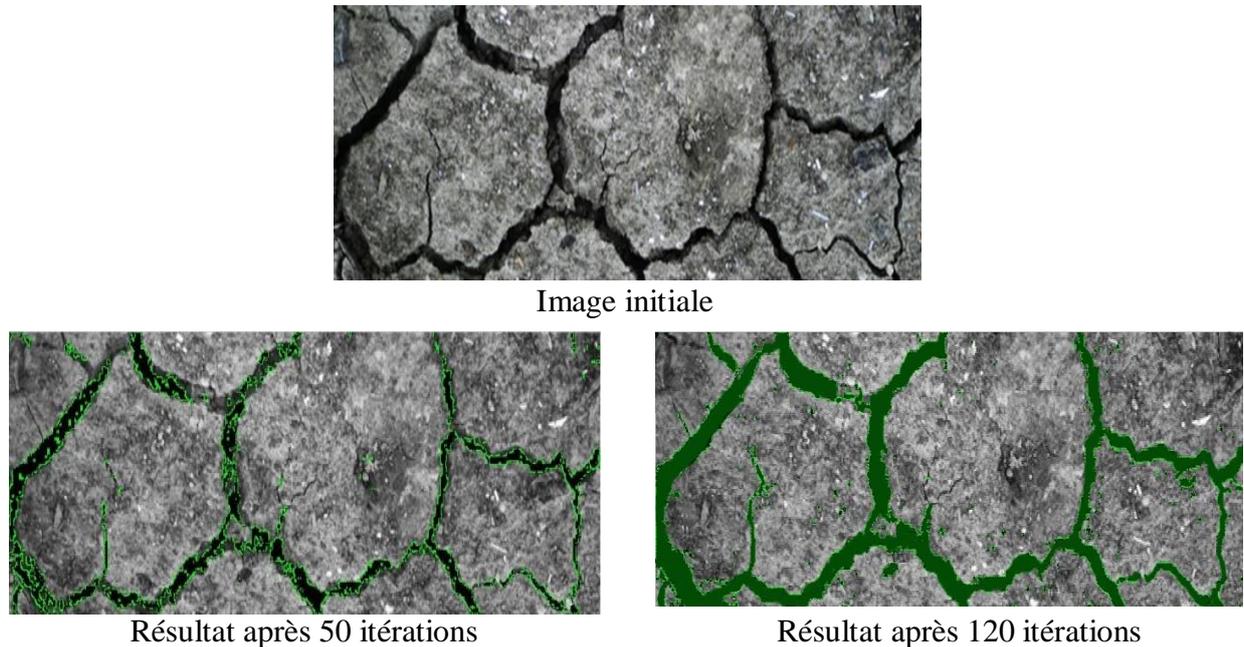
La donnée d'entrée de l'algorithme représente l'image prétraitée précédemment, les paramètres déterminants sont : le contour initial de la segmentation  $\phi_0$ ,  $\gamma$  qui contrôle le rapport entre les deux forces régions et contours,  $\Delta t$  le pas entre deux itérations successives,  $\sigma$  l'échelle du noyau gaussien.

### **II.3. Validation de la segmentation.**

Le modèle proposé a été implémenté sur une plateforme Matlab R2013a. Le programme est simulé au départ sur des images texturées, après une étape de prétraitement avec un filtre Non Local Means pour réaliser un filtrage de l'image. Nous avons fixé le pas entre chaque itération  $\Delta t = 0.01$ , et fait varier la constante de proportionnalité  $\gamma$  jusqu'à ce qu'on retrouve l'équilibre entre forces internes et forces externes, le but étant d'avoir une bonne évolution de la courbure. Après plusieurs essais, nous avons fixé  $\gamma = 0.5$  et  $\sigma = 1$ , ses paramètres ont été choisis pour leurs performances de segmentation et un temps de calcul de l'algorithme favorable.

La figure 3.8 montre l'évolution de la segmentation avec ce modèle, sur une image de texture après 50 et 120 itérations. D'après cette image, on peut dire que le modèle proposé a détecté les détails de l'image et que les contours sont bien fermés. Le temps de segmentation des images que nous avons testées varie selon la taille de l'image. Pour une image

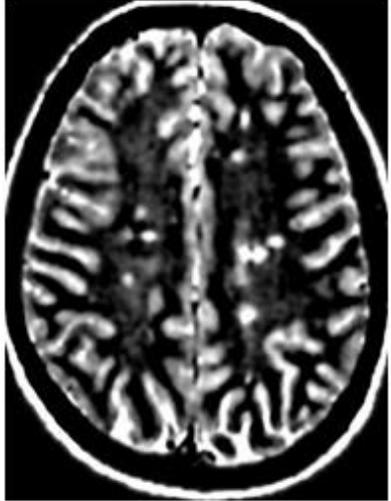
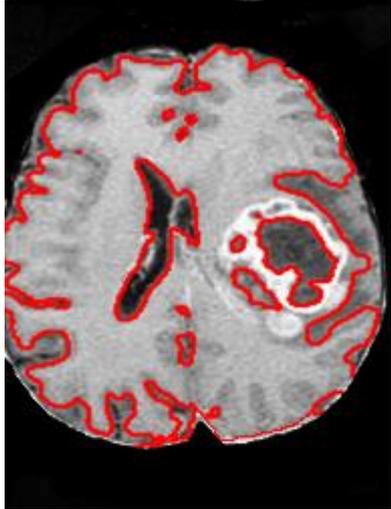
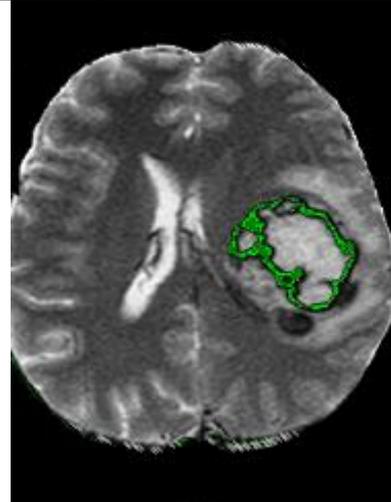
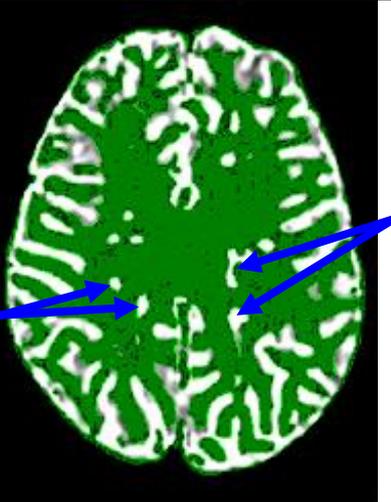
( $256 \times 256$ ), le temps de réalisation d'une segmentation de 120 itérations est de 90 secondes.



**Figure 3.8.** Résultats de la segmentation de notre modèle sur des images texturées.

Sur la figure 3.8 nous pouvons observer que notre segmentation donne un contour lisse qui ne s'accroche pas au bruit grâce à l'implémentation du terme de gradient. La nouvelle fonction permet d'avoir une segmentation finale précise même aux endroits courbés, on peut donc affirmer que l'ajout du GVC permet d'ajouter de la flexibilité au modèle.

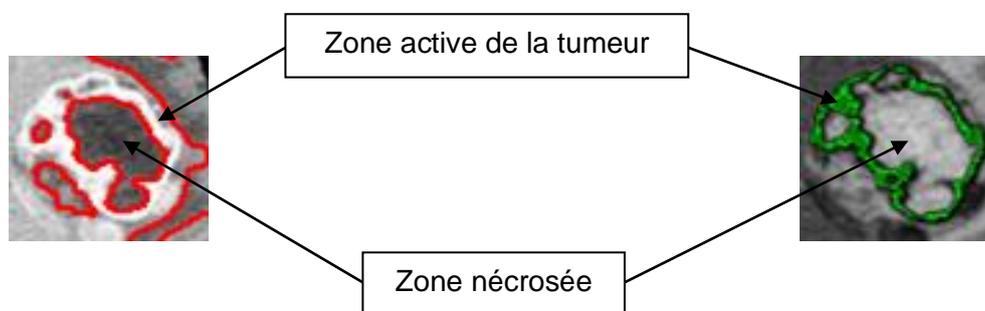
L'approche proposée a été testée sur des images d'IRM pour la détection de deux pathologies cérébrales : (i) processus tumoral cérébral, une masse de cellules anormales qui se multiplient dans le cerveau de façon incontrôlée et (ii) sclérose en plaques, c'est une maladie qui touche le système nerveux central, en particulier le cerveau, les nerfs optiques et la moelle épinière. Après un prétraitement des images d'IRM avec l'algorithme d'extraction proposé précédemment, nous avons réalisé la segmentation de ces images. La figure 3.9 montre les résultats obtenus avec le modèle proposé et ceux obtenus avec le modèle de Chan et Vese [132].

	Cas 1 (Tumeur)	Cas 2 (Sclérose)
IRM cérébrale avant segmentation		
Segmentation avec le modèle Chan et Vase	 <p>Après 200 itérations</p>	 <p>Après 300 itérations</p>
IRM après segmentation avec notre modèle	 <p>(<math>\Delta t = 0.02</math>, <math>\gamma = 0.01</math> et <math>\sigma = 1.5</math>)</p>	 <p>(<math>\Delta t = 0.02</math>, <math>\gamma = 0.01</math> et <math>\sigma = 0.5</math>)</p>

**Figure 3.9.** Résultat de la segmentation proposée et une comparaison entre notre modèle et le modèle de Chan et Vase [149].

Les résultats de la figure 3.9 obtenus dans le premier cas étudié – patient présentant un processus tumoral cérébral visible sur une coupe axiale pondérée en T<sub>1</sub> avec injection de produit de contraste (gadolinium) – montrent que le modèle de Chan et Vese [132] a échoué dans la segmentation de la tumeur après 200 itérations. En revanche, avec le même nombre d'itérations notre modèle détecte bien la zone active de la tumeur après 80s.

D'après la figure 3.10, la différence entre les résultats de notre modèle et ceux obtenus par le modèle de Chan et Vese, apparait clairement. En effet, ce dernier n'a permis la segmentation que de la partie nécrosée de la tumeur, alors que notre modèle a bien détecté les limites de la zone active de la tumeur (couleur verte dans notre modèle). De plus, ce dernier entoure bien la partie nécrosée de la tumeur cérébrale.



**Figure 3.10** Comparaison entre les résultats de la segmentation de la tumeur cérébrale.

Les résultats obtenus sur 12 coupes pondérée en T<sub>1</sub> avec injection de produit de contraste, montrent que la qualité de notre segmentation est bonne pour la détection de la tumeur. En effet, les parties actives de la tumeur sont détectées et les parties nécrosées sont circonscrites.

Le second cas de la figure 3.9, est une coupe axiale pondérée en T<sub>2</sub> avec quelque hypersignaux bilatéraux de la substance blanche montrant la présence d'une sclérose en plaque. Après 300 itérations avec l'approche de Chan et Vese, les limites des taches affectant la sclérose en plaques ont été partiellement détectées. Le contour de cette méthode n'a pas réussi à séparer les plaques les plus proches. Par contre, le modèle proposée permet de détecter les lésions avec une bonne précision et avec le même nombre d'itérations.

La comparaison de notre modèle à l'approche de Chan et Vese montre l'efficacité de notre fonction d'énergie pour la détection des limites des tissus pathologiques cérébraux.

Ainsi, le GVC (*Gradient Vector Convolution*) [134] a apporté plus de robustesse dans le modèle proposé dans le cas où, les forts gradients correspondent aux frontières de l'élément recherché, et il reste insensible à l'initialisation de la fonction d'énergie. En effet, la méthode de Chan et Vese ne permet pas de trouver les frontières des pathologies cérébrales avec précision. Ainsi, notre modèle est plus adapté au traitement des images avec un temps d'exécution très court.

Les résultats expérimentaux sur les images d'IRM cérébrale montrent l'efficacité et la robustesse de notre fonction d'énergie, par l'ajout du terme de gradient dans l'expression de celle-ci. Ce terme améliore la robustesse aux hétérogénéités de gradient le long de la frontière, il réduit la nécessité d'utiliser une force de type ballon pour contrer la rétraction du contour et permet ainsi, de réduire le temps de segmentation. Tous ces avantages permettent au modèle proposé de trouver sa place dans les applications cliniques.

### **III. L'APPROCHE DE CLASSIFICATION DU CERVEAU.**

Il existe dans la littérature de nombreuses méthodes pour la classification ou la segmentation des tissus. Ils peuvent être regroupés en deux catégories [135] : les modèles non supervisés [136] qui visent à séparer les régions sans connaissance préalable des classes et les modèles supervisés [137] qui ont besoin d'une étape d'apprentissage pour réaliser la partition de l'image. Parmi ces modèles, on retrouve la segmentation de Markov [90] et les réseaux de neurones [79,80].

Dans notre travail, nous nous sommes intéressés au modèle RFCM (*Robust Fuzzy C-Means*) représentant la segmentation introduite par Pham et al [15] qui est basée sur les modèles non supervisés flous, pour classifier l'image en deux ou plusieurs classes. Selon Pham, chaque pixel peut appartenir à une ou à plusieurs classes selon un certain degré d'appartenance.

L'algorithme FCM a vite trouvé une place dans la pratique médicale. En effet, Weijie [139] et Singh [140] l'ont adapté à la segmentation d'images IRM, et Brandt [141], a utilisé cet algorithme pour mesurer le volume des différents tissus cérébraux dans les IRM pédiatriques.

Le but de cette partie de la thèse est de réaliser une classification des différents tissus du cerveau (matière blanche, matière grise, liquide céphalo-rachidien) à partir des images de

l'IRM. Dans le chapitre I, nous avons présenté les artefacts présents sur ces images notamment l'effet du volume partiel qui peut altérer le résultat de la segmentation. Ce qui nous a conduits à choisir la méthode de classification FCM qui prend en considération cet artefact.

Cependant, l'algorithme FCM standard ne compense pas les inhomogénéités d'intensité présentes dans les IRM cérébrales [142]. Des solutions ont été proposées dans [143]. Parmi ces méthodes, Pham a proposé dans [144] une nouvelle approche robuste, qui par l'ajout d'un terme régulateur à la fonction standard, prend en considération les fonctions d'appartenance des voxels voisins.

De nombreuses études ont été réalisées sur le changement du terme régulateur. Sahbi et Nozha [145] utilisent un terme basé sur l'entropie. Ahmed et al [121], Wang et al [138] incorporent les informations spatiales dans le terme. Néanmoins, ces modèles restent sensibles au bruit. Les limites de ces méthodes nous ont amenés à la mise en œuvre d'une approche robuste au bruit de l'image qui prend en compte les informations spatiales des pixels.

### III.1. Modèle proposé.

La classification FCM est fréquemment utilisée dans le domaine du traitement d'image, de nombreuses améliorations ont été effectuées sur le modèle pour mieux l'adapter aux images qu'on veut traiter. Parmi ces modèles on retrouve le modèle de Pham [144], RFCM (Robust Fuzzy C-Means), qui propose une extension de l'équation initiale FCM.

On considère l'espace vectoriel  $X = \{x_j/x_j \in \mathcal{R}, j \in \{1, \dots, n\}\}$  où  $n \in \mathbb{N}$  représente le nombre de pixels qui constituent l'image  $I$ ,  $V = \{v_i/v_i \in \mathcal{R}, i \in \{1, \dots, c\}\}$  est l'espace vectoriel représentant les classes et  $c \in \mathbb{N}$  le nombre des classes  $1 < c < n$ .

Dans la FCM,  $x_j$  n'est pas attribuée à une seule classe mais à différentes classes selon le degré d'appartenance  $u_{ji}$  avec  $U = \{u_{ji}/u_{ji} \in \mathcal{R}^{n \times c}, j \in \{1, \dots, n\}, i \in \{1, \dots, c\}\}$ , ce dernier doit satisfaire les conditions suivantes :

$$0 \leq u_{ji} \leq 1 \quad \forall i \in [1, c], \forall j \in [1, n] \quad (3.17)$$

$$\sum_{i=1}^c u_{ji} = 1, \quad \forall j \in [1, n] \quad (3.18)$$

$$0 < \sum_{j=1}^n u_{ji} < n \quad \forall i \in [1, c] \quad (3.19)$$

La fonction d'énergie définie par Pham [15] pour faire la liaison entre les centroides des classes et la fonction d'appartenance s'écrit :

$$J = \left( \sum_{j=1}^n \left( \sum_{i=1}^c u_{ji} \|x_j - v_i\|_2^2 \right) \right) + \frac{\beta}{2} \left( \sum_{j=1}^n \sum_{i=1}^c u_{ji}^q \left( \sum_{k \in N_j^R} \sum_{l \in L_i} u_{kl}^q \right) \right) \quad (3.20)$$

Le premier terme est le terme initial du modèle FCM appelé aussi terme d'attache aux données et le second est un terme régulateur.

$\|x_j - v_i\|_2^2$  représente la distance euclidienne,  $N_j^R$  le voisinage du voxel,  $\beta$  une constante qui contrôle le poids entre les deux termes de la fonction,  $q > 1$  représente le degré de la segmentation.  $L_i = [1, c] / \{i\} = \{1, \dots, i-1, i+1, \dots, c\}$ .

Notre travail s'est basé sur le modèle proposé par Caldaïrou et al [146] pour la segmentation des IRM cérébrales. L'auteur utilise le poids non local  $W_{ni}(k, j)$  dans le second terme de la fonction pour un meilleur lissage des régions. Dans notre travail, nous avons remplacé la distance euclidienne par la distance locale et non locale proposée par Wang et al [138] pour ajouter l'information spatiale à la fonction d'énergie et avons également rajouté le poids non local proposé par Caldaïrou pour rendre la segmentation lisse même en présence de bruit dans les images.

La fonction d'énergie que nous proposons s'écrit alors :

$$J = J_{FCM} + J_{Reg} \quad (3.21)$$

$$J = \sum_{j=1}^n \left( \sum_{i=1}^c u_{ji} \left( \sum_{k \in N_j} W_{kj} D^2(x_j, v_i) \right) \right) + \frac{\beta}{2} \left( \sum_{j=1}^n \left( \sum_{i=1}^c u_{ji}^q \right) \sum_{k \in N_j^R} W_{kj} \left( \sum_{l \in L_i} \sum_{k \in N_j} u_{kl}^q \right) \right) \quad (3.22)$$

Pour minimiser cette équation on utilise la fonction de Lagrange (chapitre 2, théorème de la FCM), où  $\lambda_j$  représente le multiplicateur de Lagrange :

$$J_L = J(u, v) + \sum_{j=1}^n \lambda_j \left( 1 - \sum_{i=1}^c u_{ji} \right) \quad (3.23)$$

$$\frac{\partial}{\partial u_{ji}} J_L = 0 \quad (3.24)$$

$$\frac{\partial}{\partial v_i} J_L = 0 \quad (3.25)$$

D'après l'équation 3.24, on peut écrire :

$$\frac{\partial J}{\partial u_{ji}} = q u_{ji}^{q-1} \left( \sum_{k \in N_j} (W_{kj} \cdot D^2(x_j, v_i)) + \beta \left( \sum_{k \in N_j} W_{kj} \right) \left( \sum_{l \in L_i} \sum_{k \in N_j} u_{kl}^q \right) \right) - \lambda_j \quad (3.26)$$

On obtient :

$$u_{ji} = \frac{\left( \sum_{k \in N_j} D^2(x_j, v_i) + \beta \sum_{k \in N_j} W_{kj} \sum_{k \in N_j} \sum_{l \in L_i} u_{kl}^q \right)^{-\frac{1}{q-1}}}{\sum_{i=1}^c \left( \sum_{k \in N_j} W_{kj} D^2(x_j, v_i) + \beta \sum_{k \in N_j} W_{kj} \sum_{k \in N_j} \sum_{l \in L_i} u_{kl}^q \right)^{-\frac{1}{q-1}}} \quad (3.27)$$

$D^2(x_j, v_i)$  est la distance entre l'intensité  $x_j$  du voxel  $j$  et le centroïde  $v_i$  de la classe  $i$ , présenté dans l'article de Wang et al [138], c'est la combinaison entre la distance locale et distance non locale calculée par la fonction :

$$D^2(x_j, v_i) = (1 - \varphi_j) d_l^2(x_j, v_i) + \varphi_j d_{nl}^2(x_j, v_i) \quad (3.28)$$

Où  $\varphi_j$  contrôle la liaison entre les distances locale  $d_l$  et non locale  $d_{nl}$ . La distance locale est calculée par la fonction :

$$d_l^2(x_j, v_i) = \frac{\sum_{x_k \in N_j} W_l(x_k, v_i) d^2(x_k, v_i)}{\sum_{x_k \in N_i} W_l(x_k, x_j)} \quad (3.29)$$

avec  $N_j$  le voisinage centré autour du voxel  $j$ , et  $d^2(x_k, v_i)$  représente la distance euclidienne.  $W_l$  est le poids local défini par :

$$W_l(x_k, x_j) = e^{-\frac{|x_k - x_j|^2}{\sigma^2}} \quad (3.30)$$

$\sigma^2$  est la variance de  $N_i$  et  $d_{nl}$  est la distance non locale de tous les voxels de l'image  $I$  qui se calcule par :

$$d_{nl}^2(x_j, v_i) = \sum_{x_k \in I} W_{nl}(x_k, x_j) d^2(x_k, v_i) \quad (3.31)$$

$$W_{nl}(x_k, x_j) = \frac{1}{Z(x_j)} U(x_k, x_j) \quad (3.32)$$

$$U(x_k, x_j) = e^{-\frac{\|V(N_k) - V(N_j)\|_{2,\alpha}^2}{h^2}} \quad (3.33)$$

La similarité entre les deux pixels  $x_k$  et  $x_j$  est calculée par la distance euclidienne  $\|V(N_k) - V(N_j)\|_{2,\alpha}^2$ , où  $V(N_k)$  et  $V(N_j)$  sont les intensités des pixels  $k$  et  $j$  respectivement. Le paramètre  $h$  contrôle le degré du filtre non local, et  $Z(x_j)$  est la constante de normalisation calculée par :

$$Z(x_j) = \sum_{x_k \in I} e^{-\frac{\|V(N_k) - V(N_j)\|_{2,\alpha}^2}{h^2}} \quad (3.34)$$

$$\varphi_j = \frac{1}{q} \sum_{i=1}^q U_i(x_k, x_j) \quad (3.35)$$

Les différentes étapes permettant de minimiser la fonction d'énergie proposée sont les suivantes:

**Les entrées :** Image,  $X = \{x_1, x_2, \dots, x_n\}$ ,  $c$  est le nombre de classe,  $q$  permet de le degré de floue de la segmentation, et choisir le seuil  $\varepsilon > 0$ .

**Etape 1 :** Calcul du poids  $W_{kj}$  quelque soit  $(kj) \in \Omega^2$ .

**Etape 2 :** Initialisation des centroides  $V = [v_1, v_2, \dots, v_c]$ .

**Etape 3 :** Calcul de la nouvelle distance grâce à l'équation (Eq.3.28).

**Etape 4 :** Mise à jour des valeurs de  $u_{ji}$  en utilisant la fonction 3.27.

**Etape 5 :** Mise à jour des centroides  $v_i$  en utilisant la fonction suivante :

$$v_i = \frac{\sum_{j=1}^n u_{ji}^q x_j}{\sum_{j=1}^n u_{ji}^q}$$

**Etape 6 :** répéter les étapes 3 - 5 jusqu'à  $\|v_{new} - v_{old}\| < \varepsilon$ .

### III.2. Validation de la méthode.

Nous avons évalué notre algorithme sur des images de synthèse, sur des IRM simulées réalisées par le site BrainWeb<sup>1</sup> et sur des cas cliniques d'IRM obtenues par IBSR<sup>2</sup> (*Internet Brain Segmentation Repository*) ces images ont été traitées par le centre d'analyses morphologiques de l'hôpital du Massachusetts.

<sup>1</sup> <http://www.bic.mni.mcgill.ca/brainweb/>

<sup>2</sup> <http://www.cma.mgh.harvard.edu/ibsr/>

Enfin, pour terminer nous avons testé notre algorithme sur des IRM de différentes séquences réalisées au Centre de Diagnostic El Hoceini de Constantine en 2016. Les résultats de la segmentation sont comparés à ceux obtenus par les méthodes FCM standard, FCMS proposée par Ahmed et al [121] et par la segmentation RFCM de Pham et al [15].

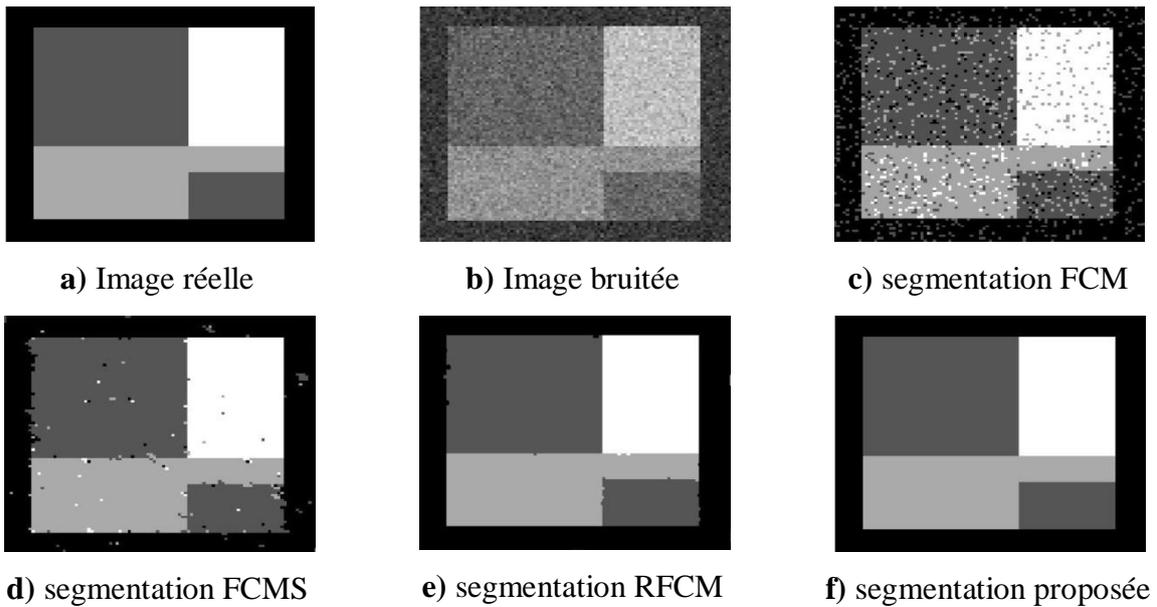
### III.2.1. Image de synthèse.

Notre algorithme a été testé sur une image 2D de synthèse d'une taille  $(435 \times 335)$  pixels, en présence d'un bruit gaussien. Nous avons fixé les paramètres d'entrées  $q = 2, c = 3$ . Plusieurs approches ont été adoptées pour automatiser le calcul du paramètre  $h$ . Cependant, l'objectif de notre thèse, nous a poussés à utiliser les travaux de Coupé [147], qui propose une méthode qui ne dépend pas seulement de la variance du bruit  $\sigma^2$  mais aussi de la taille du patch  $|P_j^I|$ .

La fonction qui permet de calculer le degré de lissage non local, s'écrit alors  $h = 2\alpha\sigma^2|P_j^I|$ ,  $\alpha$  est un paramètre contrôlé manuellement par l'utilisateur. Nous avons fixé  $\alpha = 2$  et le critère d'arrêt du programme est  $\varepsilon = 1e^{-5}$  dans toutes les manipulations réalisées avec cet algorithme.

La Figure 3.11 contient les résultats obtenus par la segmentation de l'image avec différentes méthodes. Parmi elles, on retrouve la segmentation classique FCM, la FCMS proposée par Ahmed [121] avec  $\alpha = 2$ , la segmentation RFCM [15], et pour finir la segmentation avec l'approche proposée.

Après plusieurs manipulations nous avons choisi d'utiliser  $\beta = 500$  convenable pour garder l'équilibre entre les deux termes de la fonction avec une fenêtre de  $(3 \times 3)$  ce choix est motivé par la performance des résultats obtenus. D'après la Figure 3.11.f, on observe clairement, qu'en présence du bruit gaussien, notre approche est plus efficace pour effectuer une classification.



**Figure 3.11.** Segmentation d'une image de synthèse [150].

Pour évaluer le modèle proposé, nous avons calculé trois indices : indice de similarité  $\rho$ , le nombre de faux positive  $r_{fp}$ , le nombre des faux négative  $f_{fn}$ . Le calcul de la similarité s'effectue en utilisant la formule suivante :

$$\rho = \frac{2|A_i \cap B_i|}{|A_i| + |B_i|} \quad / \quad \rho > 0 \quad (3.36)$$

$A_i$  et  $B_i$  représentent les ensembles des pixels qui appartiennent à la classe  $i$  pendant la segmentation manuelle et la segmentation avec notre modèle.  $|A_i|$  est le nombre de pixels qui constituent la région  $A_i$ ,  $|B_i|$  est le nombre de pixels constituant la région  $B_i$ .  $B_i$  représentent les pixels

L'indice de similarité représente la correspondance des pixels de la région  $i$  dans les deux images A (segmentation de référence) et B (résultat de la segmentation avec notre approche). D'après la définition de la similarité, plus sa valeur est grande, plus les deux segmentations se rapprochent. D'après [148], on peut qualifier une segmentation de bonne si  $\rho > 70\%$ . Pour calculer le nombre de faux positifs et de faux négatifs, on utilise ces deux fonctions :

$$r_{fp} = \frac{|B_i| - |A_i \cap B_i|}{|A_i|} \quad (3.37)$$

$$r_{fn} = \frac{|A_i| - |A_i \cap B_i|}{|A_i|} \quad (3.38)$$

La première fonction (faux positifs), calcule la sur-segmentation. C'est-à-dire que des pixels sont inclus dans la segmentation proposée et non dans la segmentation de référence. Par contre, les faux négatifs rendent compte de la sous-segmentation et expriment le nombre de pixels exclus de l'image segmentée mais présents dans l'image de référence.

Pour évaluer notre approche, nous avons utilisé les indices ( $\rho$ ,  $r_{fp}$ ,  $r_{fn}$ ) et les avons comparés aux valeurs calculées par les segmentations mentionnées précédemment. Ces résultats sont regroupés dans le tableau 3.1

**Tableau 3.1.** Valeurs de l'indice de similarité, du taux des faux positifs et celui des faux négatifs pour la segmentation de l'image de synthèse [150].

méthode	$\Delta t$	$\rho$	$r_{fp}$	$r_{fn}$
<b>FCM</b>	16.42	77.43	23.40	17.35
<b>FCMS</b>	22	92.33	3.40	1.90
<b>RFCM</b>	36.59	99.86	0.51	3.09
<b>Notre modèle</b>	47.39	99.91	0.23	1.61

Ce tableau confirme que les résultats obtenus par notre méthode est plus fiable pour la classification des images de synthèse en présence d'un bruit gaussien.

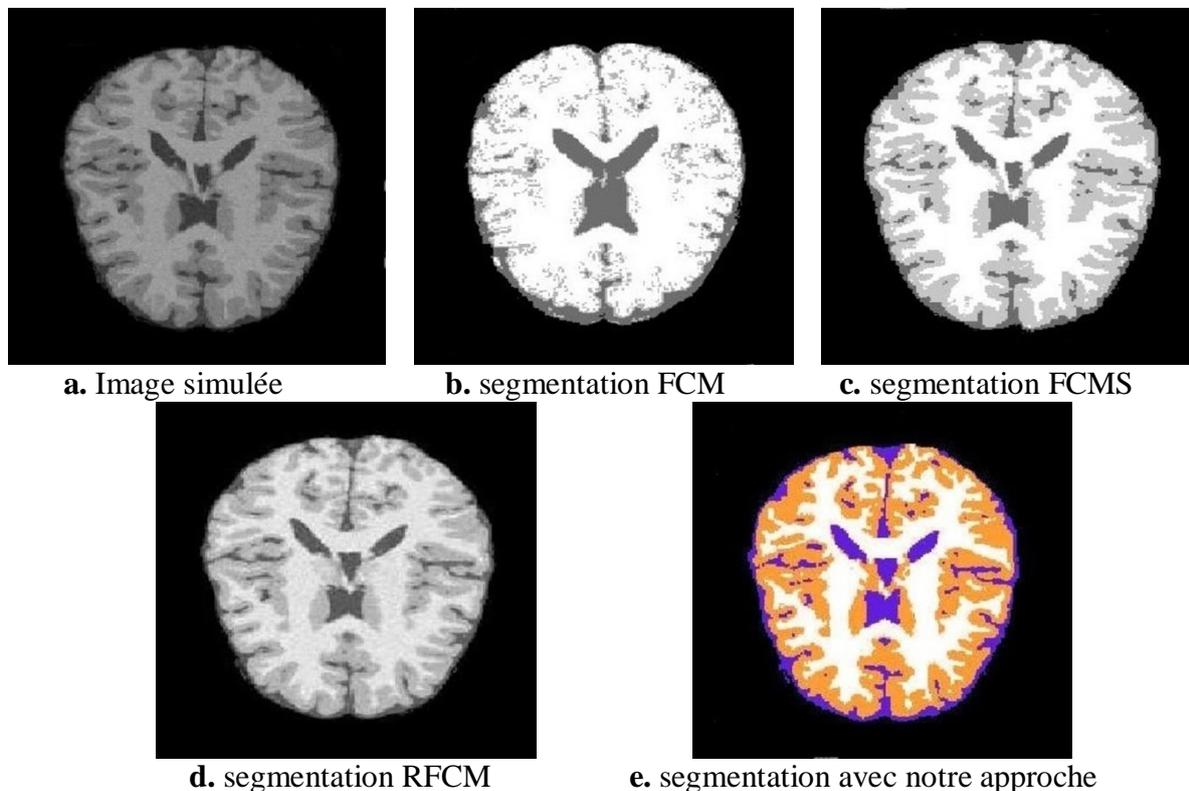
### III.2.2. Evaluation avec BrainWeb.

La base BrainWeb fournit des images simulées du cerveau SBD (*Simulated Brain Database*). Elle contient un ensemble de volumes de données d'IRM produites par un simulateur. Ces données peuvent être utilisées par la communauté de la neuro-imagerie pour évaluer la performance des différentes méthodes d'analyse de l'image dans un milieu de nature connue.

L'algorithme développé est appliqué à une coupe simulée pondérée en  $T_1$  représentée par l'image (a) de la figure 3.12. Cette image a une taille de  $(256 \times 256 \times 3)$  avec 20% d'inhomogénéité à laquelle a été ajouté un bruit Rician de 10%. Avant de classifier les tissus du cerveau, nous les avons extraits de l'image à l'aide du logiciel BET (*Brain Extract Tool*) [124].

Nous avons ensuite, appliqué une segmentation en trois (03) classes qui représente respectivement la MB (Matière Blanche), la MG (Matière Grise) et le LCR (Liquide

Céphalorachidien). La figure 3.12 montre, (b) la segmentation par la méthode FCM, (c) la segmentation FCMS, (d) la segmentation avec le modèle RFCM et (e) la segmentation avec l'approche proposée. Pour les IRM cérébrales nous avons fixé le nombre de voisinages à  $(5 \times 5)$  pixels.



**Figure 3.12.** Segmentation d'une Image simulée sous BrainWeb [150].

D'après les résultats obtenus de la figure 3.12, nous observons nettement l'influence du bruit Ricien sur la segmentation pour les méthodes FCM, FCMS et RFCM. Le modèle proposé montre son efficacité pour la classification du cerveau même en présence de bruit. Nous avons effectué une évaluation qualitative et quantitative complète sur tous les modèles de segmentation utilisés pour évaluer la précision de notre segmentation en présence du bruit Ricien.

Pour l'évaluation quantitative nous avons choisie de calculer les valeurs de l'indice de similarité, les faux positifs ainsi que les faux négatifs pour tous les modèles de segmentation utilisés sur les trois régions du cerveau. Les résultats sont présentés dans le tableau 3.2. On constate que le modèle proposé avec  $\rho > 89\%$  est plus efficace que les autres modèles.

**Tableau 3.2.** Valeurs de l'indice de similarité, du taux de faux positifs et celui de faux négatifs dans la segmentation de l'image BrainWeb [150].

méthode	LCF			MB			MG		
	$\rho$	$r_{fp}$	$r_{fn}$	$\rho$	$r_{fp}$	$r_{fn}$	$\rho$	$r_{fp}$	$r_{fn}$
<b>FCM</b>	79.20	30.10	20.20	70.20	35.63	22.84	49.10	5.95	31.15
<b>FCMS</b>	83.20	23.16	10.09	87.96	14.25	5.91	87.73	7.26	16.20
<b>RFCM</b>	84.23	21.33	12.03	91.98	13.30	6.35	88.96	6.94	17.29
<b>Notre modèle</b>	89.75	10.95	9.02	89.97	10.29	3.48	90.78	6.18	10.76

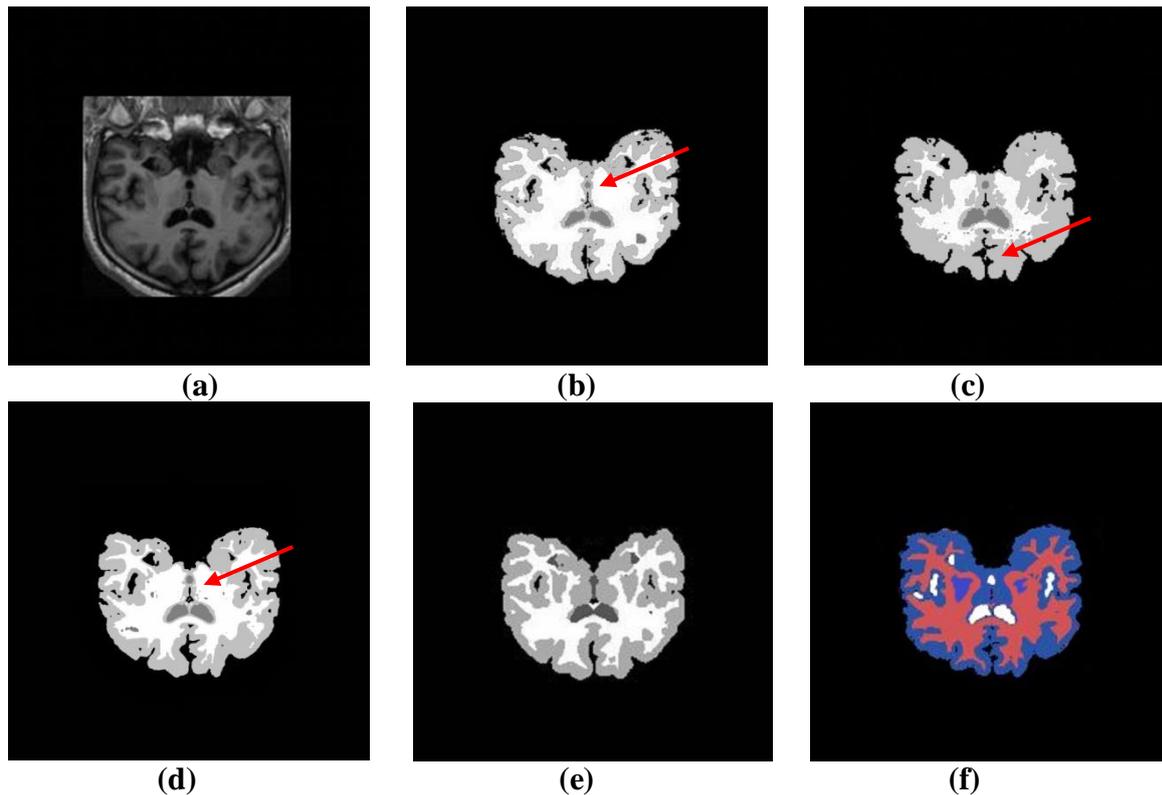
### III.2.3. Evaluation avec des images IBSR.

La base IBSR (Internet Brain Segmentation Repository) contient des résultats de segmentation traités manuellement par des experts, ainsi que des données d'images cérébrales IRM. Ces résultats sont utilisés pour l'évaluation de nouvelles méthodes de segmentation. La base est composée de 18 volumes pondérés en  $T_1$  d'une taille de  $(128 \times 256 \times 256)$  et chaque image dispose d'une vérité terrain segmentée par un expert, sur laquelle la classification a été réalisée sur la matière blanche (MB), la matière grise (MG) et le liquide céphalo-rachidien (LCR).

Nous avons utilisé l'algorithme BET [124] sur des cas réels de la base IBSR, pour séparer l'image du cerveau de celle des tissus qui ne présentent pas d'intérêt pour notre étude. La figure 3.13 représente une séquence d'une IRM pondérée en  $T_1$  d'un volume du cerveau du 8<sup>ème</sup> cas de la base IBSR. Les images ont pour dimension  $(256 \times 256 \times 128)$  voxels, la résolution des voxels est de  $(10 \times 10 \times 15)$ .

Dans cette session, nous avons utilisé, pour tous les algorithmes, une segmentation sur trois classes pour représenter les tissus cérébraux. La figure 3.13 présente une illustration des résultats obtenus par les mêmes approches que précédemment. Les résultats de la segmentation sont comparés à ceux obtenus par la segmentation manuelle de l'expert (IBSR).

On remarque que la classification avec notre approche est beaucoup plus proche de la réalité que celle des autres méthodes, on remarque une sous-segmentation de la MG (illustré par une flèche dans l'image 3.13.b) pendant la segmentation FCM et une non homogénéité des régions, une sur-segmentation de même région a été observé dans la segmentation avec la FCMS, et enfin malgré l'homogénéité des régions on observe une sous-segmentation de la MG dans la segmentation RFCM.



**Figure 3.13.** Segmentation sur une coupe T1 obtenue dans IBSR (*Internet Brain Segmentation Repository*) [150]. a) coupe d'IRM à segmenter, b) segmentation effectuée avec la FCM standard, c) segmentation avec la méthode FCMS avec  $\alpha = 2$ , d) segmentation RFCM, e) segmentation manuelle, f) segmentation avec notre méthode.

Cependant, on ne peut pas se contenter d'une simple comparaison visuelle (étude qualitative de la segmentation). En effet, comme nous sommes en présence d'une image de référence de la classification idéale du cerveau, on peut donc calculer pour chaque région, les indices de similarité, les faux négatifs et les faux positifs décrits dans le tableau 3.3 (étude quantitatives de la segmentation).

**Tableau 3.3.** Valeurs de l'indice de similarité, du taux des faux positifs et celui des faux négatifs dans la segmentation de l'image IBSR [150].

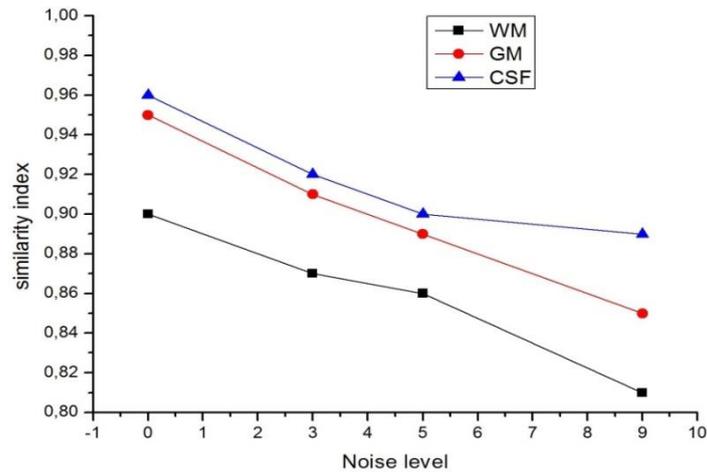
méthode	MB (Matière Blanche)			MG (Matière Grise)		
	$\rho$ %	$r_{fp}$ %	$r_{fn}$ %	$\rho$ %	$r_{fp}$ %	$r_{fn}$ %
<b>FCM</b>	75.18	20.15	9.87	74.69	8.20	20.98
<b>FCMS</b>	88.6	17.65	7.59	85.12	6.07	19.35
<b>RFCM</b>	90.03	14.98	6.44	86.57	5.63	17.25
<b>Notre modèle</b>	93.12	8.36	4.68	90.37	3.67	12.03

D'après le tableau 3.3, on remarque que la similitude des deux régions, matière grise et matière blanche, sont classifiées par notre approche avec plus de 90% . Notre modèle est donc plus proche de la vérité terrain comparé aux images obtenues par les autres modèles. Ce constat confirme que notre algorithme est plus adapté dans la classification du cerveau pour les IRMs cérébrales par rapport à la segmentation FCM ou la RFCM, en présence du bruit et sans effectuer une étape de prétraitement des images qu'on veut traiter.

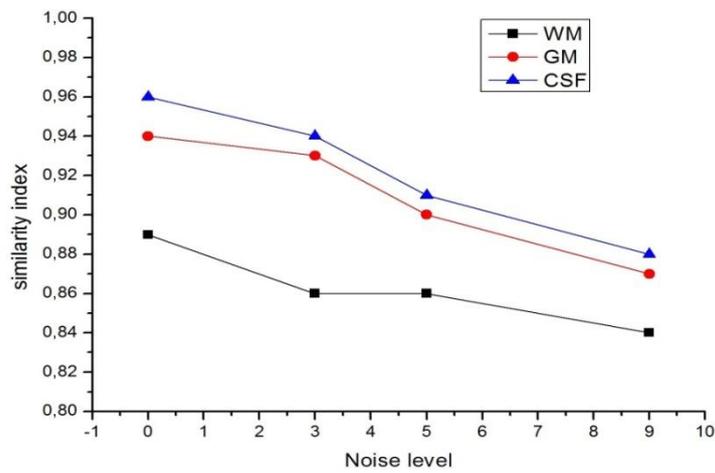
Nous avons utilisé une fenêtre de voisinage ( $7 \times 7$ ), avec un temps d'exécution du programme de l'ordre de 18 *min*. Le temps excessif se justifie par le calcul du poids non local pour toute l'image 3.13.a dans le terme de régularisation pendant chaque itération.

Dans ce qui suit, nous présentons l'influence du bruit ajouté sur des images prises de la base IBSR et le choix de la fenêtre du voisinage pour la classification des trois régions du cerveau (MG, MB, LCR). Dans le graphe 3.1, nous avons utilisé une fenêtre de voisins ( $3 \times 3$ ) dans le graphe 3.1.a, ( $5 \times 5$ ) dans graphe 3.1.b et enfin ( $7 \times 7$ ) dans le graphe 3.1.c. D'après ces courbes, l'indice de similarité diminue lorsque le niveau du bruit augmente. Si on compare les trois choix, on peut affirmer que :

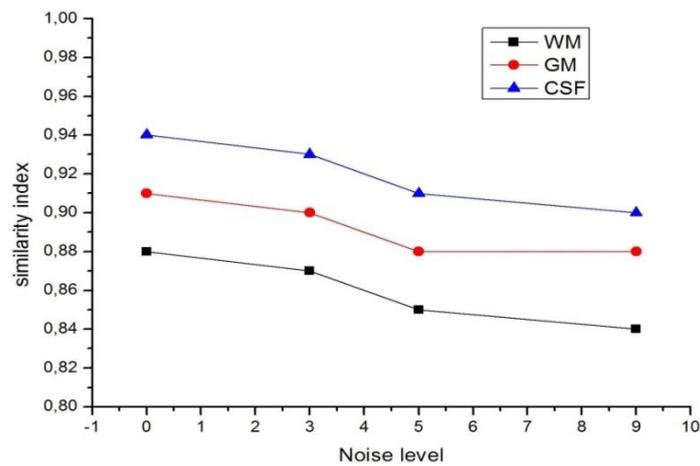
- Pour la région LCR : le choix du meilleur indice de similarité entre l'image segmentée manuellement par un expert et l'image obtenue par notre segmentation, est acquis lorsqu'on a utilisé un voisinage ( $3 \times 3$ ).
- Pour la région MB : de meilleurs résultats sont obtenus lorsqu'on a pris une fenêtre de voisins ( $5 \times 5$ ) et l'indice de similarité est dans l'intervalle 87 – 94 %.
- Pour la région MG : le meilleur choix dans ce cas, est une grande fenêtre du voisinage ( $7 \times 7$ ).



a. voisinage (3 × 3)



b. voisinage (5 × 5)



c. voisinage (7 × 7)

**Graphes 3.1.** Influence de la taille du voisinage et l'intensité du bruit sur notre segmentation [150], a) segmentation avec (3 × 3) voisins, b) segmentation avec (5 × 5), c) segmentation avec (7 × 7) voisins.

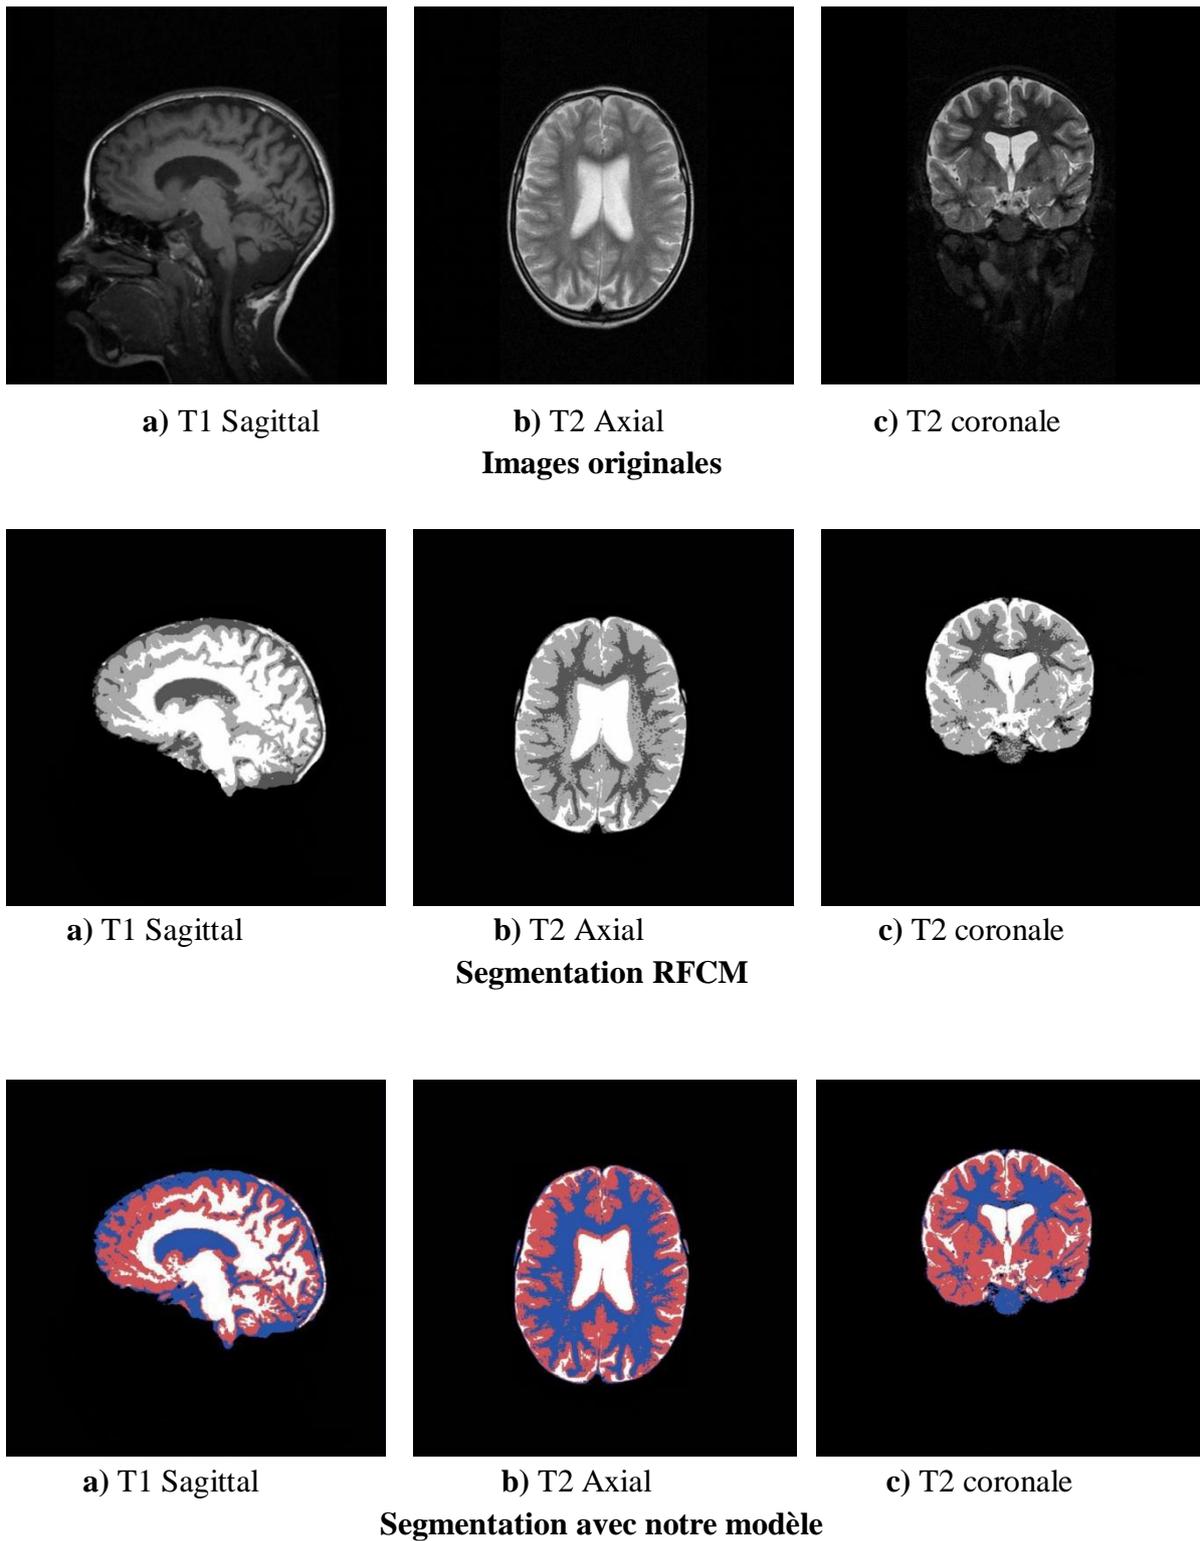
### III.2.4. Validation clinique.

Le but de notre étude est la mise en œuvre d'un modèle de segmentation des différents tissus constituant le cerveau pour différentes séquences d'acquisitions pondérées en  $T_1$  ou en  $T_2$  d'IRM. Nous avons testé notre méthode sur 14 volumes obtenus en IRM (IRM philips Intera 1.5 Teslas du Centre de Diagnostic El Hoceini de Constantine).

Les volumes choisis diffèrent par l'âge des patients et les séquences utilisées pendant l'examen. Les coupes constituant les volumes ont pour taille  $(512 \times 512 \times 128)$  avec une résolution de  $(0.5 \times 0.5 \times 3)$ . Aucun prétraitement n'a été utilisé sur ces images à l'exception de l'extraction par l'algorithme BET pour supprimer les parties non désirées. La figure 3.14 regroupent trois coupes : (figure 3.14a) une coupe sagittale obtenue par une séquence pondérée en  $T_1$ , (figure 3.14b) une coupe axiale obtenue par une séquence pondérée en  $T_2$  et (figure 3.14c) une coupe coronale obtenue par une séquence pondérée en  $T_2$ . Nous avons réalisé le même prétraitement sur ces coupes avec l'algorithme d'extraction. Les résultats obtenus avec la segmentation RFCM et avec notre modèle sont présentés dans la figure 3.14.

Dans les deux méthodes nous avons choisi de segmenter en trois régions (on ignore le fond noir de l'image IRM). On remarque d'après les résultats obtenus que la segmentation avec notre modèle est plus précise qu'avec le modèle RFCM (Robust Fuzzy C-Means). Par exemple, sur la coupe axiale pondérée en  $T_1$ , on note clairement que la taille du corps calleux a été réduite dans la segmentation RFCM, par contre notre algorithme a bien délimité cette région. Pour le cas des coupes sagittale et coronale pondérées en  $T_2$ , on remarque que les résultats de segmentation montrent qu'avec la méthode RFCM, les régions ne sont pas lisses, alors que notre modèle donne une bonne classification des régions.

Ces résultats confirment les autres évaluations, notre approche donne une meilleure segmentation dans les zones étroites et sinueuses, telles que les zones entre le LCF et MB, et également la région entre MG et MB.



**Figure 3.14.** Segmentation des images clinique [150].

**IV. CONCLUSION.**

Nous avons présenté dans ce chapitre, deux nouvelles méthodes de segmentation. La première est fondée sur le modèle géodésique et la seconde sur la RFCM. Dans le premier modèle nous avons remplacé la fonction de Dirac par le gradient de level-set pour réaliser un rehaussement des contours des tissus à segmenter et intégré le GVC (*Gradient Vector Convolution*) pour gérer le problème de la dépendance à l'initialisation du contour et d'obtenir ainsi un contour qui arrive à se mouvoir jusqu'aux frontières des régions d'intérêt. Les expériences menées afin d'évaluer le modèle proposé ont montré qu'il fournissait de meilleurs résultats que les autres méthodes testées.

La seconde approche fondée sur la segmentation RFCM, intègre les distances locale et non-locale dans le terme d'attache aux données. Ce qui a pour but d'ajouter l'information spéciale dans notre modèle et d'intégrer des moyennes non-locales dans le terme régulateur de la fonction pour un lissage plus pertinent de la segmentation et une amélioration de la qualité de la segmentation du modèle initial dans un environnement bruité. Les expériences menées pour une évaluation quantitative et qualitative du modèle proposé, montrent l'efficacité par rapport aux autres méthodes testées dans ce chapitre.

# **CHAPITRE IV**

## **La segmentation d'IRM Foetale cérébrale**

**I. Introduction.**

Dans ce chapitre, nous nous intéressons à la réalisation d'une technique de segmentation des images fœtales obtenues par des examens IRM au cours de la grossesse. Les différences entre les images d'IRM fœtales et IRM adultes ne nous permettent pas d'appliquer les méthodes de segmentation développées dans le chapitre précédent, l'utilisation de ces méthodes ne donne pas une segmentation complète du cerveau anténatale.

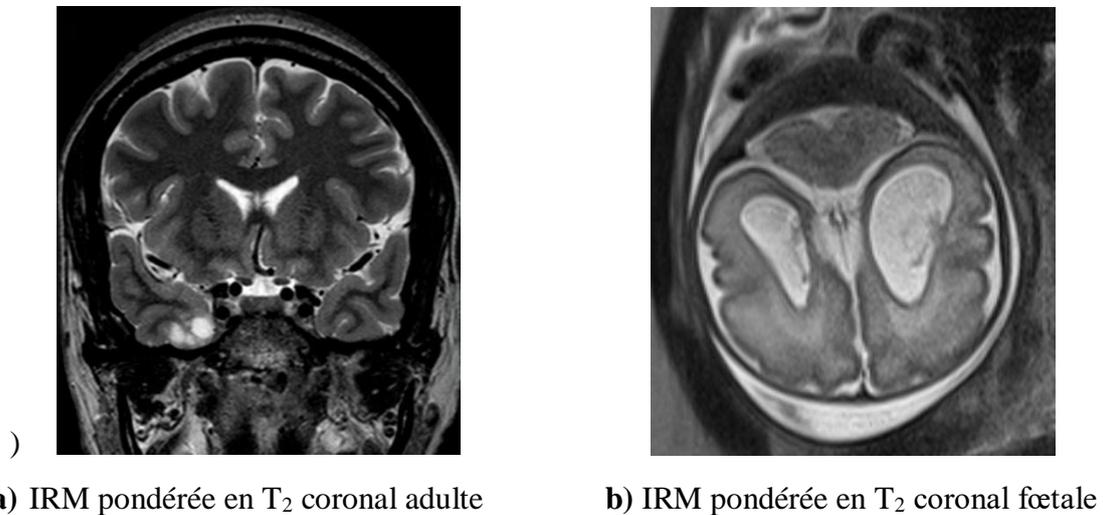
Dans le premier chapitre, nous avons présenté la différence entre les deux examens d'IRM et avons proposé des solutions pour résoudre le problème des artefacts dans le cas de l'IRM fœtale. Nous avons alors pris comme exemple, la réduction du temps d'acquisition qui peut résoudre le problème des artefacts créés par les mouvements de la parturiente et du fœtus. Dans le même chapitre, nous avons détaillé les étapes de maturation cérébrale anténatale, en faisant remarquer que le cerveau fœtal n'a pas la même anatomie que le cerveau d'un adulte. La classification des tissus cérébraux des adultes se limite souvent à trois régions selon les niveaux de gris de l'image : la matière grise, la matière blanche et le LCR.

La segmentation des tissus du fœtus est beaucoup plus complexe que celle des IRM de l'adulte à cause des faibles contrastes apparaissant sur l'image. En effet, dans l'IRM de l'adulte, le cortex est circonvolé et la matière blanche est complètement myélinisée. Par contre, dans le cas anténatal, le cortex est lisse à 24 semaines et devient peu à peu circonvolé (formations de sillons) à 36 semaines.

La myélinisation de la matière blanche, ne s'effectue qu'entre la 25<sup>ème</sup> et la 28<sup>ème</sup> semaine en passant par un temps de repos jusqu'à la 40<sup>ème</sup> semaine. La MB ne cesse alors de se propager pour devenir totalement myélinisée à la vie prénatale de l'enfant. Avant la maturation, la matière blanche est principalement composée d'eau, ce qui entraîne un temps de relaxation  $T_2$  plus important et un signal plus élevé.

Dans la figure 4.1, on peut observer la différence de contraste entre l'IRM adultes et l'IRM prénatale. D'après la figure 4.1.a, les tissus cérébraux (MG, MB, LCR) d'un adulte sont bien définis et les classes semblent plus faciles à discerner. En effet, elles sont mieux individualisées contrairement au cas fœtal (Figure 4.1.b). Nous pouvons donc conclure qu'une augmentation du contraste de l'image fœtale est nécessaire. Cependant, ce traitement ne sera pas unique pour toutes les images à traiter (le cerveau fœtal se développe et la myélinisation de la matière blanche s'effectue au cours des semaines). De plus, la méthode développée

devra permettre de réaliser une segmentation souple et robuste pour toutes les images obtenues au cours de la grossesse.



**Figure 4.1.** Etude comparative entre l'IRM fœtale et l'IRM adulte.

L'image 4.1 montre une inversion des contrastes entre la matière blanche et la matière grise par rapport aux images de l'adulte. La différence entre ces deux modalités d'imagerie ne permet pas d'utiliser directement les mêmes méthodes de segmentation présentées dans les chapitres précédents. De ce fait, un algorithme de traitement spécifique aux caractéristiques des images fœtales a été développé.

Le domaine de la segmentation des IRMs anténatales est récent. Quelques méthodes qui permettent une segmentation complète des tissus cérébraux sont décrites dans la littérature [151, 152]. Elles utilisent un atlas pour la segmentation du cerveau fœtal. Cependant, cette étape est difficile à mettre en œuvre car elle nécessite une construction d'un atlas et un recalage sur l'image qu'on veut segmenter (voir le chapitre 2).

Caldairou [146], propose un algorithme pour ne segmenter que la partie du cortex fœtal qui est l'indicateur du degré de maturité cérébrale. L'auteur a repris le principe d'une segmentation en plusieurs étapes décrite dans [153] pour le cas de l'adulte et dans [154, 155] pour le cas des IRMs fœtales. Enfin, pour parvenir à une segmentation du cortex, Caldairou utilise deux fois de suite l'algorithme des K-means [86].

Dans le présent travail, nous avons utilisé le modèle proposé dans [150], car l'approche que nous avons proposée donne de meilleurs résultats que les modèles FCM, RFCM, et K-Means. Nous avons donc développé un nouveau algorithme et avons repris le principe

d'une segmentation en plusieurs étapes décrite dans [153] et [156], l'auteur propose une segmentation en plusieurs étapes d'image IRM adulte, ainsi que Ferario [155], Bach cudra [154], Caldaïrou [146] dans le cas des IRMs fœtales.

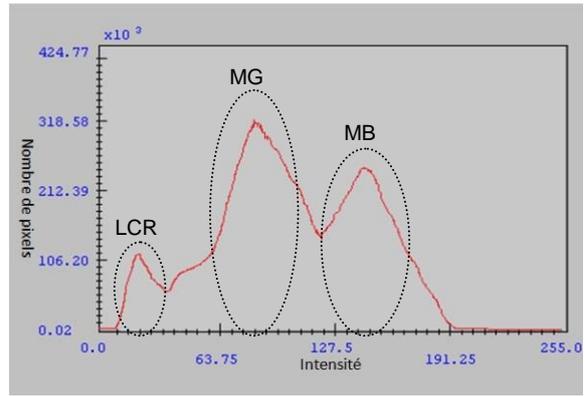
Notre algorithme utilise deux fois de suite le modèle de classification proposé dans le chapitre précédent, l'objectif étant d'arriver à une segmentation des IRMs fœtales cérébrales.

## **II. Méthodologie.**

La figure 4.2, nous permet de voir la différence entre les distributions d'intensité des IRM adultes et anténatales. D'après l'histogramme de l'IRM adulte (figure 4.2.a) on observe trois pics distincts qui correspondent au LCR, MG et MB. Par contre, dans l'IRM fœtale (figure 4.2.b), on observe un important recouvrement du LCR et de la MB dans le cerveau fœtal.

Dans cette modalité, il est difficile de distinguer les classes en se basant uniquement sur la répartition des intensités : d'après l'histogramme, on observe que la MG est presque entièrement incluse dans la MB, ce qui explique le fait que l'utilisation de la méthode proposée sur l'image fœtale, pour une segmentation cérébrale, ne donne pas un résultat fiable pour séparer la MB de la MG (voir Figure 4.3).

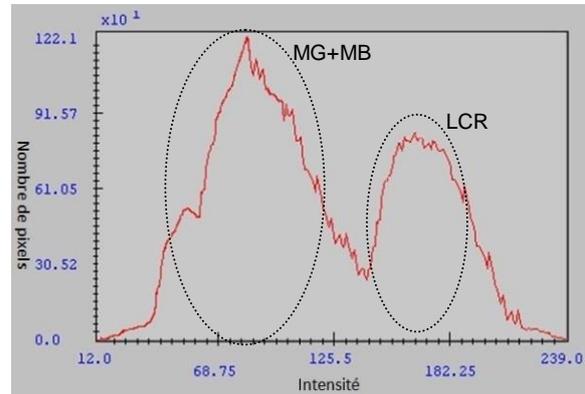
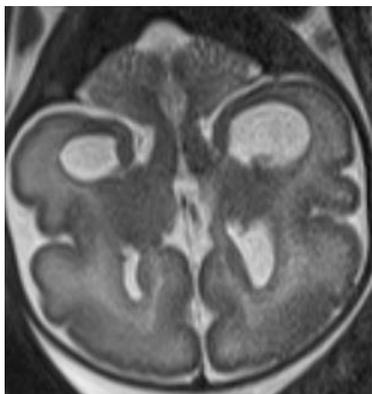
Les résultats obtenus avec l'algorithme proposé dans le chapitre précédent, ne sont pas satisfaisants, et ce, même dans le cas d'une classification en trois ou plusieurs classes. Ce constat nous a amenés à la mise au point d'un processus de segmentation qui permet l'extraction des régions une par une, en utilisant l'approche proposée [150].



IRM cas adulte.

Histogramme de l'IRM adulte.

a) Histogramme dans le Cas adulte.

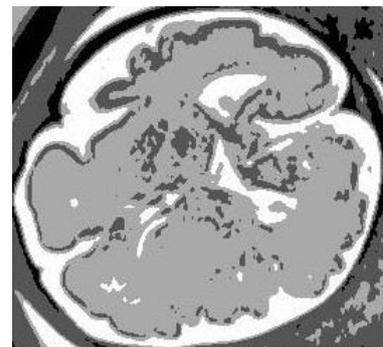
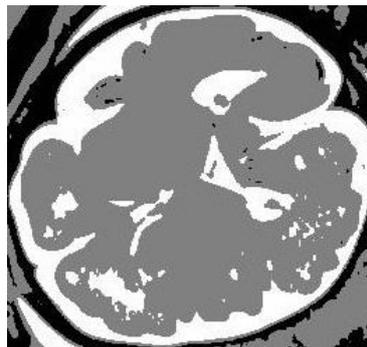
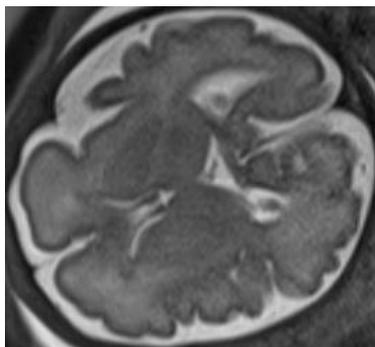


IRM cas fœtale.

Histogramme de l'IRM fœtale.

b) Histogramme dans le Cas anténatale.

Figure 4.2. Distribution d'intensité de l'IRM adulte et fœtale.



a) Image original

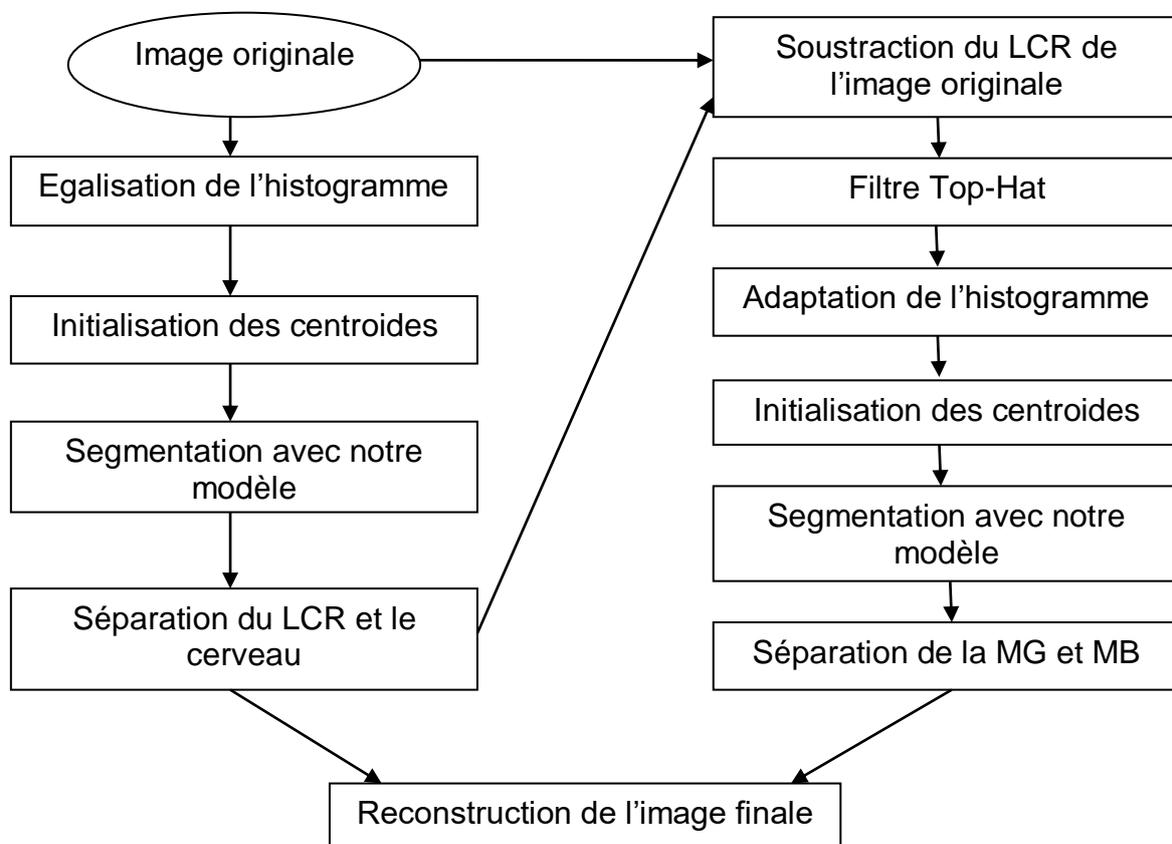
b) segmentation 3 régions

c) segmentation 4 régions

Figure 4.3. Segmentation d'une IRM fœtale axiale en utilisant différentes classes.

**II.1. Processus de la segmentation proposée.**

Comme le montre l'histogramme des IRMs fœtales (Figure 4.2.b), une classification sur trois régions ne donne pas des résultats fiables, ce qui nous a amenés à réaliser un modèle de segmentation adapté aux images à traiter. Nous proposons donc, un modèle de segmentation des tissus cérébraux fœtaux, composé de deux parties (schéma de la Figure 4.4). La première étape permet de séparer le LCR et le cerveau fœtal, la seconde consiste à segmenter la matière blanche et la matière grise (cortex). Enfin, les deux images obtenues sont superposées pour construire une image qui constitue les régions à segmenter.

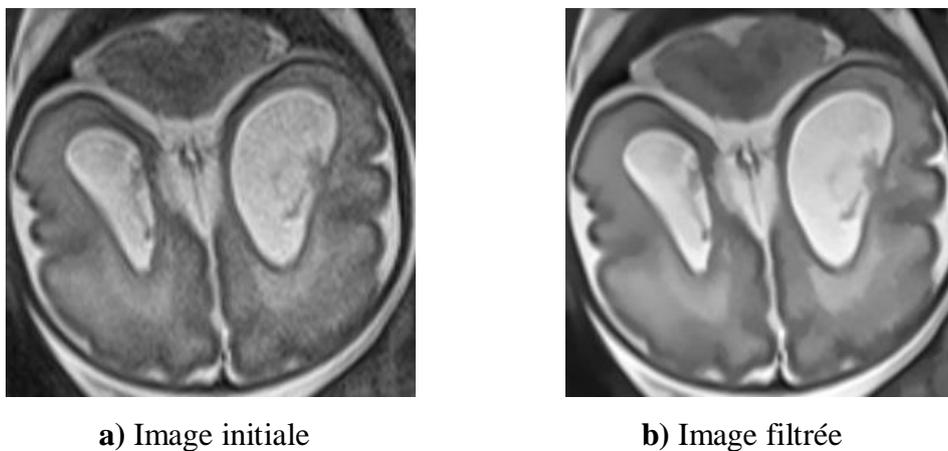


**Figure 4.4.** Schéma décrivant le système de segmentation utilisée.

**II.1.1. Séparation du Liquide céphalo-rachidien du cerveau.**

Dans cette étape, l'algorithme proposé permet de séparer le LCR du reste de l'image qu'on veut traiter. En nous basant sur l'histogramme de la figure 4.2.b, nous avons créé deux régions, la première représente le LCR et la seconde est composée de la MG et de la MB.

L'utilisation d'un filtre Non Local Means [157] sur l'image initiale, est une étape primordiale dans la segmentation, pour réduire le bruit contenu dans les images obtenues d'une part et, le rehaussement des contours d'autre part. La figure 4.5 représente une IRM fœtale pondérée en  $T_2$  et le résultat obtenu par le filtre. Après l'étape du lissage, l'histogramme de l'image prétraitée est établi afin de déterminer le nombre de pixels de l'image en fonction de l'intensité de l'image IRM, l'intensité d'une région peut différer d'une coupe à une autre, ce qui complique la classification des régions cérébrales. Pour résoudre ce problème, nous avons choisi d'utiliser l'égalisation de l'histogramme de l'image filtrée précédemment pour distribuer uniformément les niveaux de gris.

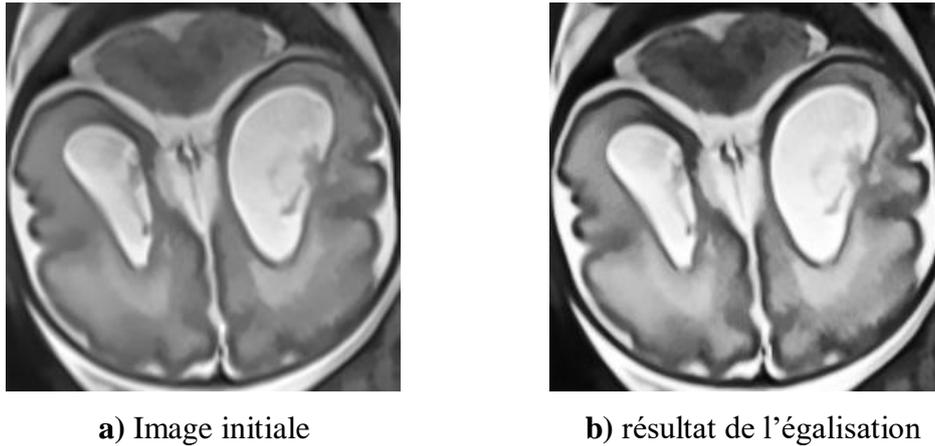


**Figure 4.5.** Image initiale après un prétraitement par le filtre Non Local Means.

#### **II.1.1.1. Egalisation de l'histogramme.**

La forme de l'histogramme donne une idée sur la qualité de l'image. Un histogramme concentré vers des valeurs faibles (proche de 0), correspond à une image sombre, par contre un histogramme concentré vers des valeurs grandes, correspond à une image claire.

L'une des méthodes largement utilisées dans le traitement d'images pour améliorer le contraste d'une image en niveaux de gris, est d'uniformiser la répartition des niveaux d'intensité de l'image avec l'égalisation de l'histogramme. Cette méthode permet d'élargir les niveaux de gris tout au long de l'intervalle dans lequel l'intensité de l'image varie selon la fréquence d'apparition dans l'image. L'avantage d'utiliser cette méthode, dans la première partie de la segmentation, est que les régions claires de l'image comme le LCR ainsi que les ventricules, deviennent plus claires. Après adaptation de l'histogramme, on obtient l'image de la figure 4.6.



**Figure 4.6.** Image initiale après un prétraitement par égalisation d'histogrammes.

### II.1.1.2. Initialisation des centroides.

Pour initialiser les centroides la méthode proposée par Jian [158], a été utilisée. Dans cet article, l'auteur utilise la segmentation K-means pour effectuer une segmentation des IRMs cérébrales. Les résultats de la segmentation K-means (chapitre 2) sont reliés directement à l'initialisation des centroides (un mauvais choix des centroides donne une fausse segmentation).

Malgré les difficultés du choix des centroides initiaux de la méthode K-means, l'auteur a cependant obtenu de bons résultats en utilisant la méthode de la normalisation de la matrice des niveaux de gris. De ce fait, nous avons intégré cette initialisation, à notre modèle, pour séparer le LCR et le cerveau dans un premier temps.

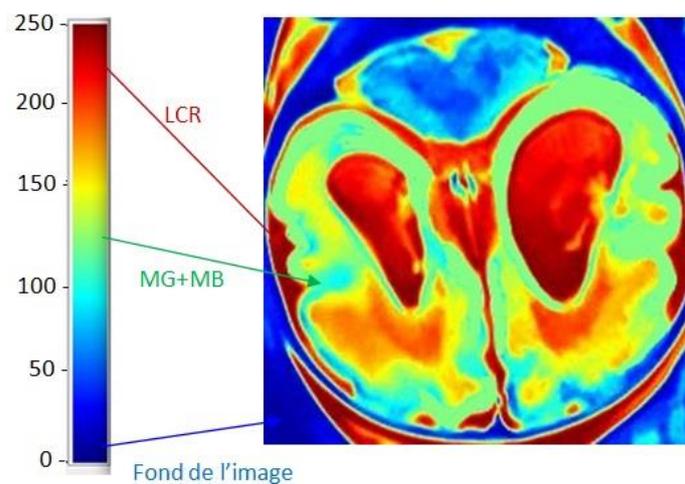
Comme toutes les images d'IRM, l'IRM fœtale est représentée par des niveaux de gris allant du noir au blanc en passant par toutes les nuances de gris. Pour le calcul de l'image normalisée, la fonction  $g(i, j)$  proposée par Jian [158] a été utilisée, elle est donnée par :

$$g(i, j) = \text{round} \left( \frac{f(i, j)}{\max(f(i, j))} \times 255 \right) \quad (4.1)$$

où  $f(i, j)$  représente les niveaux de gris de l'image initiale,  $i$  et  $j$  sont respectivement le nombre de lignes et le nombre de colonnes de l'image.  $\max(f(i, j))$  représente le maximum du niveau de gris de l'image,  $g(i, j)$  est l'image obtenue après normalisation dans une marge de  $[0, 255]$  de niveaux de gris.

L'image de la figure 4.7 illustre le résultat obtenu pour la normalisation d'une IRM fœtale. Globalement on observe que l'image est divisée en 3 régions : l'arrière plan de l'image (couleur bleu), le cerveau (couleur vert) et le LCR (couleur rouge).

En se basant sur la palette de couleurs et l'image, il est possible de choisir la valeur approximative que représente chaque couleur des trois régions choisies. Nous pouvons donc attribuer à chaque région, les valeurs 0, 130 ou 220 que l'on prend comme centroides initiaux pour la segmentation.

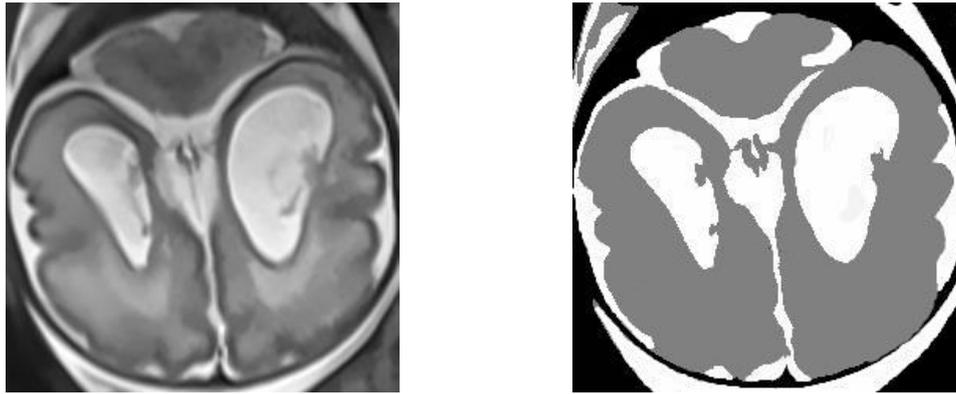


**Figure 4.7.** Normalisation de l'image.

### **II.1.1.3. Application de la méthode proposée.**

Dans cette étape, la méthode proposée dans le chapitre précédent [150] est appliquée à des IRMs fœtales cérébrales. Ce modèle évolue suivant la méthode de segmentation décrite dans le chapitre III. Comme entrée à notre algorithme, on prend l'image obtenue par l'égalisation de l'histogramme (figure 4.6.b), et les valeurs obtenue par la normalisation pour l'initialisation des centroides. Le résultat qu'on cherche à obtenir dans cette étape, est la segmentation de l'image sur trois classes qui représentent le fond de l'image, le LCR, et le cerveau.

La Figure 4.8 représente l'image qui résulte de la segmentation par notre modèle, nous pouvons y observer qu'à ce stade du traitement, l'apparition de deux régions séparées. La première est constituée du liquide céphalorachidien ainsi que les ventricules (couleur blanche dans l'image 4.8) et la seconde est constituée de l'ensemble la MG et de la MB (couleur grise).



a) Image initiale

b) séparation LCF et le cerveau

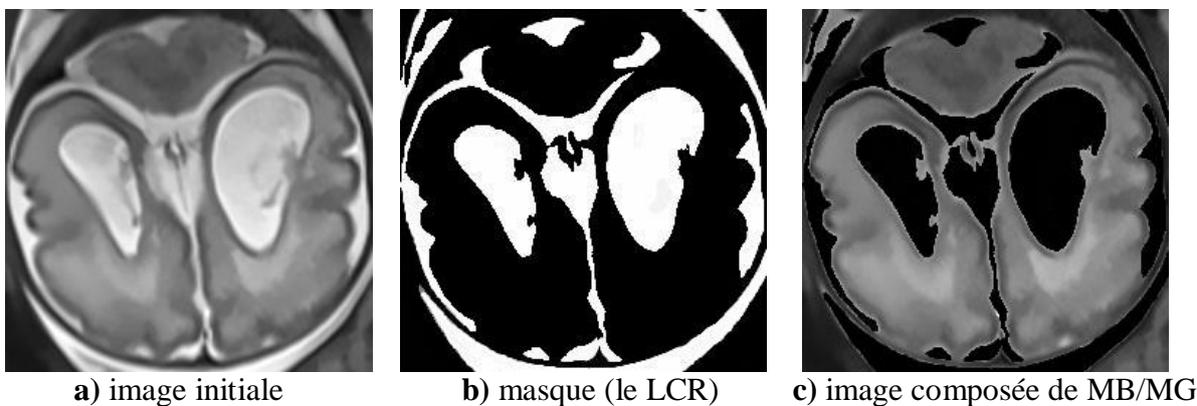
**Figure 4.8.** Résultats de la segmentation par le modèle proposé.

### II.1.2. séparation de la MB et de la MG.

L'intérêt principal de cette étape, est de séparer la matière grise et la matière blanche à partir des résultats obtenus par la chaîne précédente de traitement (segmentation du LCR et du cerveau).

#### II.1.2.1. Soustraction du LCR de l'image originale.

Pour une partition idéale de la MB et de la MG, nous devons éliminer le LCR déjà segmenté par l'étape précédente. Pour réaliser cette étape, nous avons utilisé un algorithme qui crée un masque du LCR et permet par la suite, de soustraire ce dernier de l'image originale. La Figure 4.9b montre le masque créé on utilisant la segmentation du liquide céphalorachidien. La Figure 4.9c montre l'image lorsqu'on élimine la partie du LCR, donc l'image qui résulte de la soustraction. Dans cette partie du programme, l'image est utilisée comme image initiale à la segmentation.



a) image initiale

b) masque (le LCR)

c) image composée de MB/MG

**Figure 4.9.** Soustraction du LCR de l'image principale pour segmenter la MG et MB.

### II.1.2.2. Filtre Top- Hat.

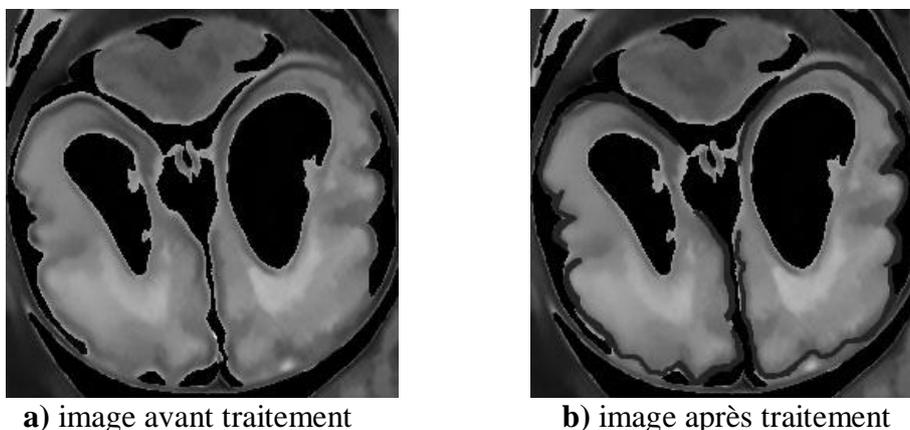
Le filtre Top-Hat, appelé aussi chapeau haut de forme, représente une transformation morphologique de l'image. Les données de la littérature [159] distinguent deux types de chapeaux haut de forme : (i) le chapeau haut de forme blanc, qui est la différence entre l'image originale et l'ouvert morphologique de cette image. Cette différence permet de détecter ce que l'ouverture morphologique a fait disparaître c'est-à-dire les parties claires de l'image initiale. (ii) Le chapeau haut de forme noir, qui représente la différence entre l'image originale et la fermeture morphologique de cette image. Cette différence permet de détecter ce que la fermeture morphologique a fait disparaître c'est-à-dire les parties sombres de l'image traitée.

Dans notre cas, nous souhaitons faire apparaître le cortex cérébral (la matière grise) dans une IRM fœtale. D'après Fischl [160], le cortex prénatal est une fine bande d'une épaisseur comprise entre 1 et 4 millimètres selon l'évolution de la grossesse, il se situe entre le LCR et la matière blanche. Le filtre chapeau haut de forme noir permet d'ajouter du contraste au cortex, il est défini par la fonction suivante :

$$I_{top-hat} = \varphi_B(I) - I_{initial} \quad (4.2)$$

où  $I_{top-hat}$  est l'image résultante du filtre Top-Hat,  $\varphi_B$  la fermeture morphologique de l'image  $I$  par un élément structurant  $B$ .

Afin de pouvoir appliquer l'opérateur des morphologies mathématiques de fermeture, nous avons utilisé un disque de taille  $(9 \times 9 \times 1)9$ . La Figure 4.10 montre le résultat obtenu pour une IRM pondérée en T2 après prétraitement par le filtre Top-Hat. Nous remarquons que ce filtre permet de révéler les zones sombres de l'image, donc le cortex.



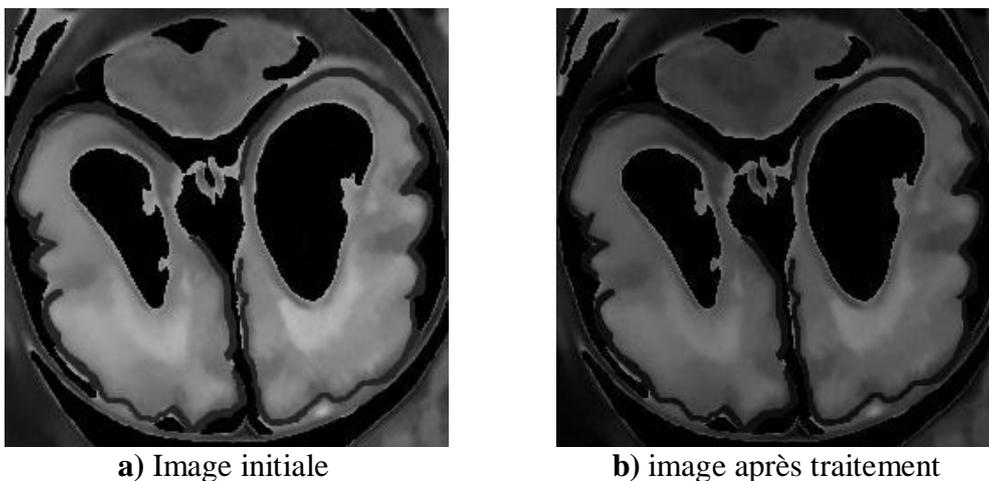
**Figure 4.10.** Résultat du filtre morphologique Top-Hat.

### II.1.2.2. Adaptation de l'histogramme égalisé.

Dans cette partie du traitement, nous rajoutons du contraste à l'image qu'on veut segmenter pour rendre le cortex plus sombre par rapport à ce qu'il était dans l'image initiale. Nous proposons donc d'utiliser un histogramme adaptatif de contraste CLAHE (Contrast Limited Adaptive Histogram Equalization) [161] qui permet de mieux distinguer le cortex. La différence entre l'égalisation utilisée dans cette partie et l'égalisation utilisée dans la section II.1.1.1, est que la première est appliquée à quelques régions de l'image qu'on appelle tuiles, alors que la seconde est utilisée à l'image intégrale. L'image est donc partitionnée en tuiles après que le contraste de chaque tuile ait été amélioré par l'égalisation de l'histogramme. Une interpolation bilinéaire est alors utilisée pour combiner les tuiles voisines et reconstruire l'image.

La fonction « adapthisteq » de Matlab a été utilisée pour réaliser l'égalisation. Plusieurs paramètres d'entrée tels que la forme et le nombre de tuiles (NumTiles) pour diviser l'image ainsi que le facteur de contraste (clipLimit) doivent être introduits. Après plusieurs tentatives, nous avons opté pour une forme rectangulaire de taille (8 x 8) l'image ce divise en ce nombre de régions et le contraste se fasse par région, ce choix c'est fait pour favoriser le temps de calcul, nous avons utilisé  $\text{clipLimit} = 0.005$  ce choix est motivé par la qualité des images obtenues comparé à d'autres valeurs.

La figure 4.11 représente le résultat de l'image obtenu après un prétraitement par la méthode CLAHE. On remarque que cette dernière permet d'ajouter du contraste à notre image, en particulier à la matière grise.



**Figure 4.11.** Résultat après adaptation de l'histogramme égalisé.

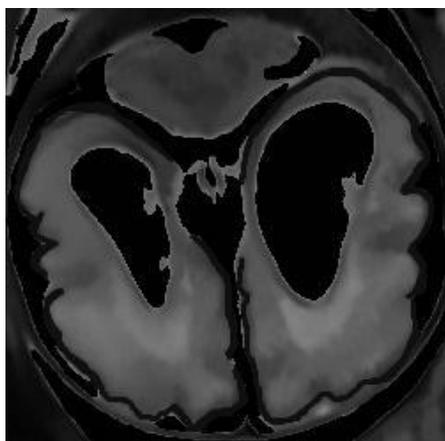
### II.1.2.3. Initialisation des centroides.

Pour l'initialiser les centroides, nous avons utilisé la méthode mentionnée précédemment dans la première étape de notre processus. Nous avons donc affecté une valeur à chaque région à segmenter. Après avoir appliqué la méthode de normalisation proposée par Jian dans [158], nous avons choisi les valeurs à même d'initialiser les centroides. Les trois régions qu'on veut séparer dans cette étape sont le fond de l'image, la MG et la MB. Sur la base des résultats obtenus nous avons choisi les valeurs 0, 80 et 180 pour initialiser respectivement les valeurs des centres du fond de l'image, la MG et la MB. Le choix des centroides peut être réalisé de manière aléatoire comme dans le chapitre précédent, la seule différence réside dans le temps d'exécution, avec cette initialisation nous avons réduit le temps de calcul.

### II.1.2.4. Application de la méthode proposée [150].

Dans cette étape, la segmentation de l'IRM fœtale est effectuée en exécutant l'algorithme proposée dans le chapitre précédent avec deux entrées, qui sont l'image résultante par l'adaptation de l'égalisation de l'histogramme ainsi que trois paramètres pour l'initialisation des centroides. L'objectif dans cette partie, est de séparer la matière grise et la matière blanche, l'initialisation des centroides pouvant être réalisée aléatoirement comme dans le cas d'une segmentation adulte (chapitre III).

Néanmoins, pour réduire le temps de calcul, nous avons utilisé les valeurs mentionnées dans l'étape précédente. La figure 4.12 montre le résultat obtenu lors de la segmentation, nous constatons que la MG et la MB sont clairement séparées. Ces deux régions ont été exploitées dans la dernière étape de l'algorithme pour la recomposition de l'image finale.



a) image initiale

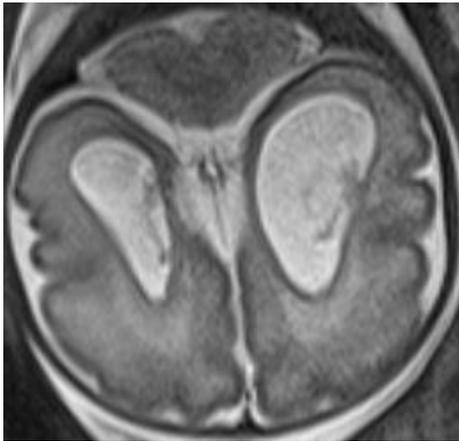


b) image segmenter par notre modèle

**Figure 4.12.** Résultat de la segmentation de la MG et de la MB.

### II.1.2.5. Reconstruction de l'image finale.

Après avoir réalisé la segmentation du liquide céphalo-rachidien dans la première partie, et la segmentation de la matière blanche et de la matière grise dans la seconde partie, nous avons reconstruit les deux images précédentes pour reconstruire qu'une seule image représentant la segmentation de l'IRM fœtale initiale (Figure 4.13a). Pour arriver au résultat final (Figure 4.13b), nous avons superposé les deux images correspondant aux résultats des différentes segmentations.



a) image initiale (IRM fœtale)



b) Résultat de la segmentation

**Figure 4.13.** Résultats finaux de la segmentation par l'algorithme proposée.

### III. Résultats et discussion.

Dans cette section, nous testons les performances de la méthode proposée sur des images réelles d'IRMs du cerveau fœtal acquis avec un imageur IRM de 1.5 Tesla du CHU Hautepierre (Strasbourg) utilisant des séquences ultra-rapides pour la réduction des artefacts du mouvement fœtal dans différentes directions (axiale, coronale et sagittale).

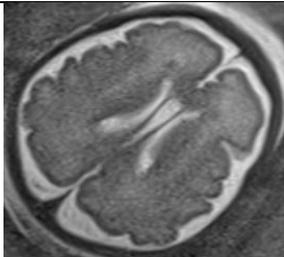
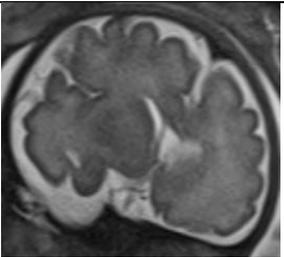
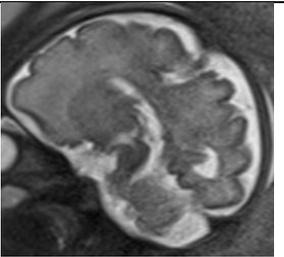
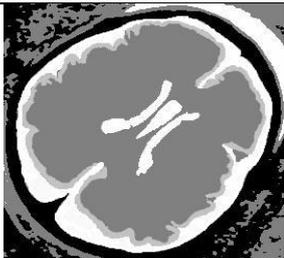
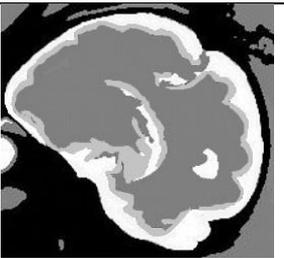
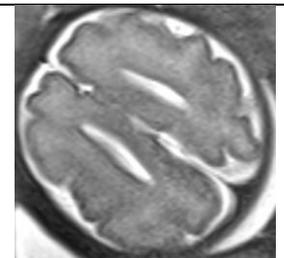
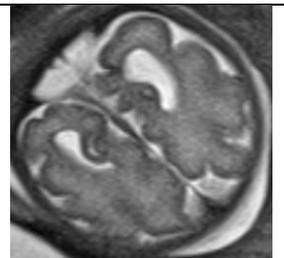
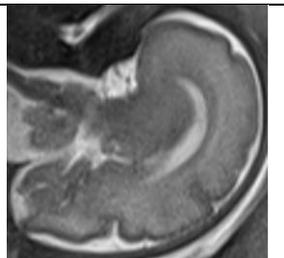
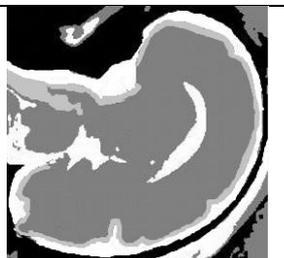
Les images utilisées sont des images non reconstruite de 5 cas d'IRM cérébrale fœtale. Toutes les coupes utilisées ont la même épaisseur (4mm), la seule différence entre elles, réside dans la taille de l'image et principalement l'âge du fœtus qui détermine le degré de maturité cérébrale, leurs âge s'étend de 27 à 36 semaine d'aménorrhée (SA).

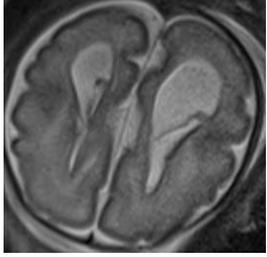
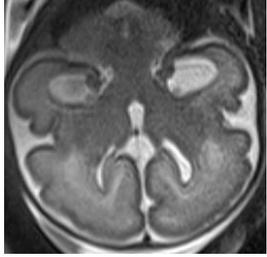
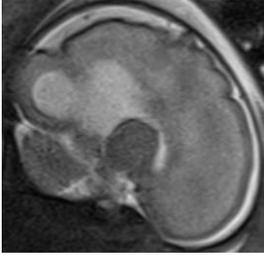
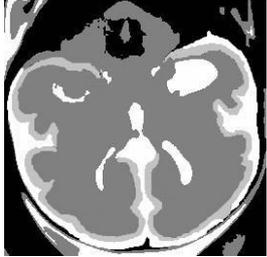
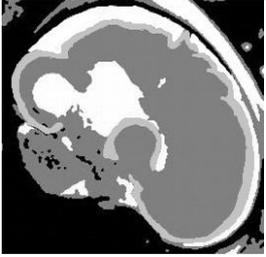
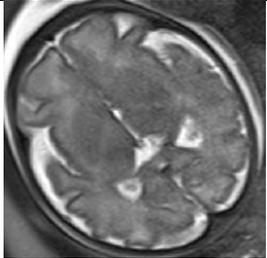
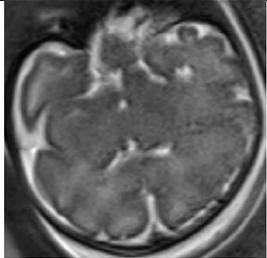
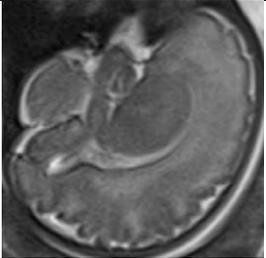
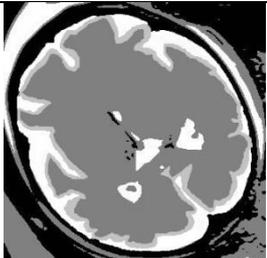
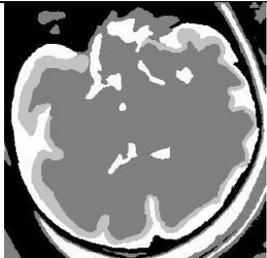
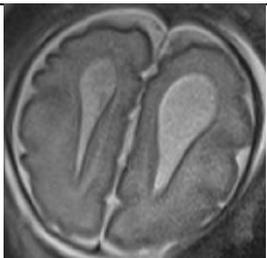
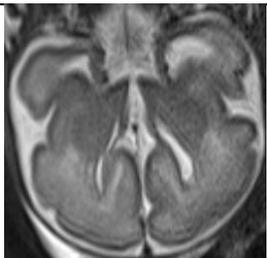
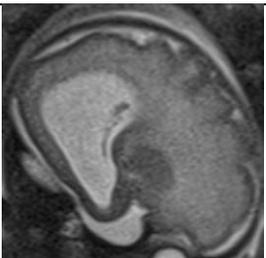
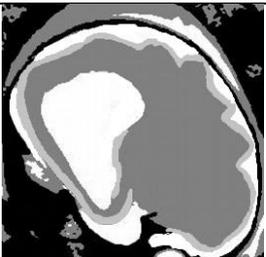
L'évaluation de notre approche a été effectuée sur la segmentation de tissus cérébraux, c'est-à-dire la matière blanche, la matière grise et le LCR. Les résultats issus des segmentations effectuées par notre algorithme ont ensuite été comparés à ceux obtenus par d'autres méthodes de segmentation.

L'évaluation quantitative de notre segmentation sur des volumes réels est une tâche impossible car nous ne possédons pas une référence en matière de segmentation manuelle

permettant de définir, de façon objective, un critère de validation comme c'est le cas dans la segmentation des IRM adultes ou enfants. Le tableau 4.1 présente quelques coupes de différentes séquences que nous avons traitées avec la méthode proposée pour la séparation de différents tissus cérébraux.

**Tableau 4.1.** Résultats de la segmentation de l'IRMs fœtales par l'algorithme proposé.

Cas		Séquences		
		Axiale	Coronale	Sagittale
N° 1 27 SA	Image originale			
	Image segmentée			
N° 2 36 SA	Image originale			
	Image segmentée			

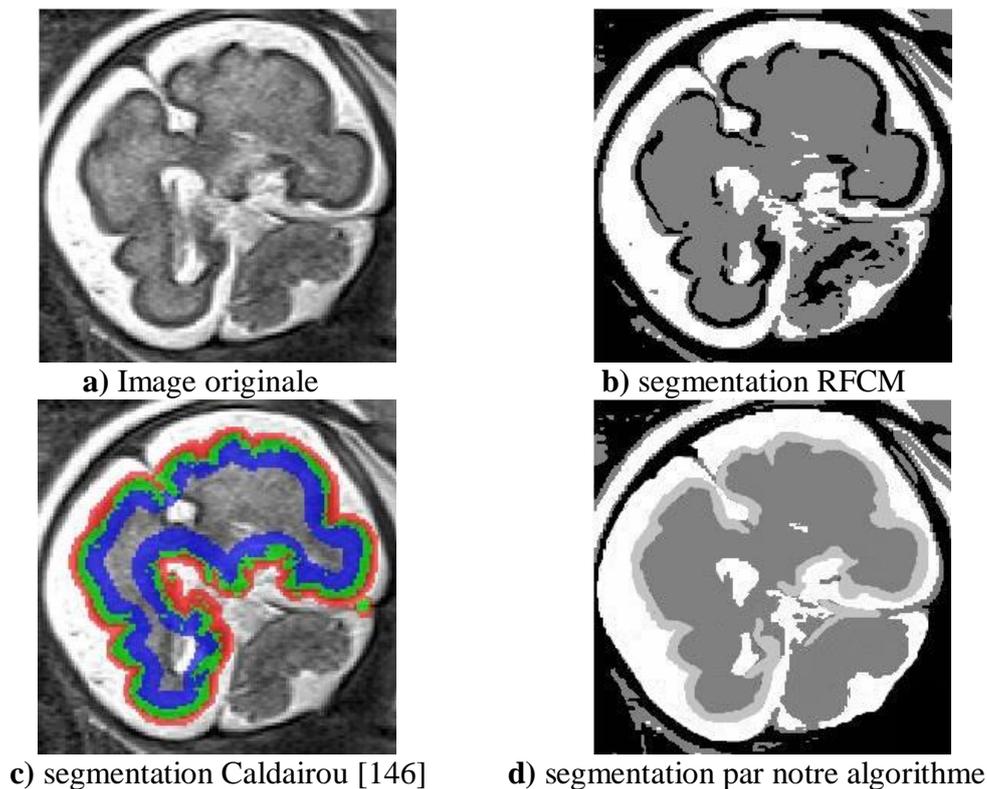
N° 3 32 SA	Image originale			
	Image segmentée			
N° 4 28 SA	Image originale			
	Image segmentée			
N° 5 32 SA	Image originale			
	Image segmentée			

Cependant, les résultats obtenus sont satisfaisants pour la classification des différents tissus cérébraux fœtaux. Dans le cas des coupes axiale et coronale, nous remarquons une bonne segmentation qui fait apparaître trois parties représentant la matière blanche, la matière grise et le LCR. Dans notre cas, les ventricules sont représentés par le même tissu que le LCR et les deux régions (MB et MG) sont bien séparées malgré la complexité de l'image initiale. Ces deux régions ont quasiment la même intensité. Nous remarquons néanmoins, l'apparition de faux positifs dans quelques coupes coronales dans la région du cervelet.

Dans le cas d'une segmentation de coupes sagittales, nous observons sur les images résultantes, l'apparition de faux négatifs dans la segmentation de la matière grise, causée par la qualité de ces images. Cette qualité est à lier essentiellement aux mouvements fœtaux lors de l'acquisition et à la difficulté d'appliquer le filtre morphologique Top-Hat pour séparer la matière grise de la matière blanche dont les intensités respectives sont quasiment identiques.

Pour étudier l'efficacité de l'algorithme proposée, nous avons effectué une comparaison entre des résultats obtenus avec notre approche et ceux d'autres méthodes de classification décrites dans la littérature.

La Figure 4.14 montre les résultats de la segmentation d'une IRM fœtale pondérée en  $T_2$  d'une coupe coronale en utilisant notre méthode et celle proposée par Caldairou dans [146] ainsi que la méthode RFCM proposée par Pham dans [15]. Les résultats obtenus confirment l'efficacité de la méthode mise en œuvre par rapport aux autres méthodes.



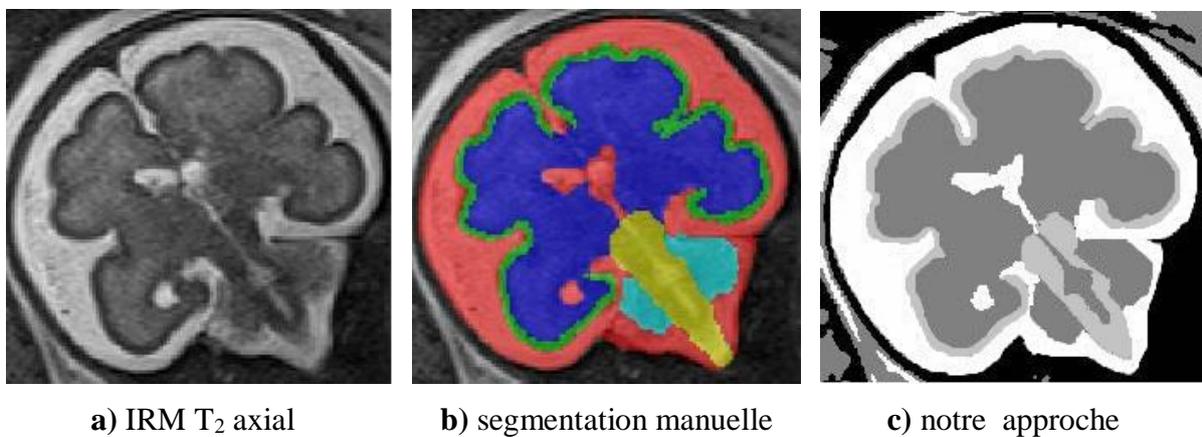
**Figure 4.14.** Résultats de la segmentation de l'IRM fœtale par l'algorithme proposé.

Dans la figure 4.14.b, la méthode proposée par Pham n'a pas détecté la matière grise, le cortex et la matière blanche étant regroupés dans la même région. Dans la figure 4.14.c, le résultat obtenu par Caldaïrou dans [146] montre l'efficacité à détecter le cortex, mais le ventricule gauche a été classé comme LCR après la segmentation. Par contre dans la figure 4.14.d (résultat de notre méthode), on observe clairement que le cortex est bien détecté, ce qui permet de matérialiser une frontière entre le LCR et la matière blanche. Nous remarquons également que les ventricules sont bien séparés du LCR par la matière blanche, ce qui suppose que notre algorithme a effectivement détecté les frontières entre les trois régions qui constituent le cerveau fœtal. Cependant, le seul inconvénient de notre approche, est la présence des faux positifs du cortex dans le cervelet et le tronc cérébral.

Après l'évaluation qualitative de notre approche, nous pouvons affirmer que notre méthode est bien adaptée à la segmentation des trois régions qui constituent le cerveau fœtal et ce, malgré la qualité des images obtenues lors des examens.

Pour réaliser une évaluation quantitative de notre modèle, nous avons eu des difficultés à trouver des références dans la littérature qui représentent des segmentations du cerveau fœtal. Nous avons donc utilisé une image présentée dans les travaux de Caldaïrou [146].

La figure 4.15 (a et b) montre une IRM en coupe axiale du cerveau fœtal et une segmentation manuelle de la même image, effectuée par des experts [162]. Nous avons donc segmenté cette image à l'aide de l'algorithme proposé. Le résultat obtenu est montré par la figure 4.15.c. Nous remarquons sur cette image segmentée, que les régions d'intérêt du cerveau (LCR, MB et MG) sont bien détectées et qu'une partie du cervelet et le tronc cérébral sont inclus dans la MG et la MB. Pour évaluer le résultat cette segmentation, nous avons calculé les paramètres d'évaluation mentionnés dans le chapitre III (les faux positifs, les faux négatifs et l'indice de similarité). L'évaluation est réalisée en comparant l'image retrouvée par notre segmentation et l'image segmentée manuellement par des experts. Les résultats de cette étude sont résumés par le tableau 4.2.



**Figure 4.15.** Segmentation d'une IRM fœtale axiale pour l'étude quantitative.

**Tableau 4.2.** Valeurs de l'indice de similarité, du taux de faux positifs et celui des faux négatifs dans la segmentation par notre approche, d'une IRM fœtale.

	Indices de validation		
	$\rho$	$r_{fp}$	$r_{fn}$
<b>LCR</b>	76.20	0.93	1.86
<b>MB</b>	71.60	14.75	3.57
<b>MG</b>	70.57	19.3	2.86

On remarque dans le tableau 4.2 que l'indice de similarité entre l'image segmentée par notre algorithme et l'image segmentée manuellement par l'expert est supérieur à 70% pour les trois régions du cerveau. Ce qui signifie que notre méthode semble être bien adaptée à la segmentation des IRMs fœtales.

Dans la segmentation du LCR, nous observons que l'indice de similarité donne satisfaction ainsi que les faux positifs et les faux négatifs. D'après les résultats calculés, il est possible d'affirmer que les limites du LCR sont bien détectées.

Pour le cas de la MB, nous observons des taux de similarité comparables entre les deux images. Par contre, la valeur des faux positifs fait apparaître une sur-segmentation de cette région, ce qui est dû au fait que le cervelet a été confondu à la matière blanche car ils ont des intensités quasi-identiques. Enfin, en comparant les régions de la MB de la figure 4.15 et si la partie du cervelet est ignorée, nous pouvons affirmer que la région de la MB est bien détectée par notre algorithme.

Pour le cas de la MG, nous remarquons que le taux de similarité entre les deux images est normal et la valeur des faux positifs, montre une sur-segmentation de cette région, dû au fait que le tronc cérébral a été considéré comme matière grise (intensité similaire). Cependant, en comparant les régions de la MG obtenue dans la figure 4.15 sans prendre en considération le tronc cérébral, la classification de la MG est bien détectée par notre algorithme.

#### **IV. Conclusion.**

Les méthodes que nous proposons dans ce chapitre, semble prometteuse. Elles permettent de segmenter les tissus cérébraux d'une manière non-supervisée. La méthode hybride que nous avons développée dans le premier chapitre, est basée sur l'approche des contours actifs géodésiques, elle nous permet de segmenter des tissus pathologiques telle qu'une tumeur ou une sclérose en plaques. L'ajout du gradient GVF dans la fonction d'énergie donne un véritable changement dans les résultats comme en témoigne les comparaisons effectuées avec d'autre modèles. En effet, notre modèle permet, grâce au gradient, de mieux guider le contour initial vers les frontières des tissus anormaux.

Le deuxième modèle proposé dans ce chapitre, est basé sur les méthodes floues qui permettent de corriger la segmentation malgré la présence du volume partiel. Cette méthode est largement utilisée dans la quantification des tissus du cerveau. Le modèle proposé a d'abord été testé sur des IRMs adultes. Il a donné des résultats prometteurs d'où notre intérêt à l'utiliser sur des IRMs fœtales pour la quantification des tissus cérébraux, étape qui reste essentielle dans le suivi de la grossesse. Cependant, pour arriver à de bons résultats, nous avons utilisé un processus basé sur deux segmentations successives, la première permet d'extraire le LCR du reste du cerveau et la seconde pour segmenter la MG et la MB. Les

résultats obtenus montrent la pertinence de l'algorithme proposé et sa robustesse pour la classification du cerveau fœtal malgré la mauvaise qualité des images obtenues dans ce type d'examens. De plus, les contraintes géométriques du modèle introduisent des faux positifs dans la détection du cortex, remarqués sur quelques coupes sagittales.

# **Conclusion Générale**

### **I. Conclusion.**

Dans cette thèse, nous nous sommes intéressés à la réalisation d'une nouvelle approche de segmentation d'IRM fœtale. Ce travail de recherche est divisé en trois parties distinctes qui ont permis d'aborder différentes problématiques liées à la segmentation des IRM cérébrales.

Dans un premier temps, nous avons proposé une méthode hybride pour la segmentation des tissus cérébraux qui est basée sur l'algorithme des contours actifs géodésiques. Afin de rehausser les contours de la région d'intérêt, nous avons remplacé la fonction de Dirac de la fonction initiale de la segmentation par le gradient de la fonction level-set. D'autre part, pour permettre à notre modèle de gérer le problème de la dépendance à l'initialisation du contour et d'obtenir un contour qui arrive à se mouvoir jusqu'aux frontières, nous avons intégré le GVC (Gradient Vector Convolution) dans la fonction d'énergie proposée. Les expériences menées, au départ sur des images de synthèse et ensuite sur des IRMs réelles contenant des pathologies cérébrales (tumeur cérébrale, sclérose en plaques), ont démontré l'efficacité de l'approche proposée. Une étude comparative des résultats que nous avons obtenus avec ceux de la littérature, a permis de confirmer que le modèle proposé est plus robuste que les autres méthodes, et ce, même en présence de bruit dans l'image. Cette robustesse est due au fait que notre approche bénéficie des caractéristiques intrinsèques et les avantages de chacun des outils cités précédemment.

Dans un second temps, nous avons élaboré une nouvelle approche dans le cadre de la segmentation floue par l'amélioration de la méthode RFCM. Cette dernière est représentée par la somme d'un terme d'attache aux données et d'un terme régulateur. Dans ce travail, les distances locale et non locale ont été introduites dans le terme d'attache aux données à la place de la distance Euclidienne pour permettre de prendre en compte le biais en intensité souvent présent dans les IRM. Par ailleurs, le concept des moyennes non locales a été introduit dans le terme régulateur pour une meilleure prise en charge du bruit présent dans les images à traiter.

Les expériences ont été menées sur des images obtenues de la base BrainWeb pour évaluer l'apport de la prise en compte de l'information apportée par notre méthode de segmentation. Cette méthode a ensuite été testée sur des images réelles obtenues de la base IBSR pour pouvoir comparer les résultats de la segmentation du modèle proposé à des segmentations manuelles réalisées par des experts médicaux. Enfin les résultats sur des

images réelles ont donné une segmentation prometteuse dans le cas des IRM adultes. L'application de l'approche proposée sur des IRM fœtales, n'a pas donné de bons résultats à cause des différences qui existent entre ces deux modalités d'imagerie (IRM adulte et IRM anténatale).

Pour réussir la segmentation des IRMs fœtales, un processus de segmentation a été proposé dans la dernière partie de cette thèse. Ce processus permet de segmenter l'image couche par couche en utilisant deux fois de suite la méthode proposée. L'application de l'algorithme donne des résultats prometteurs pour la classification du cerveau fœtal qui reste une étape primordiale dans le suivi de la grossesse et la vie anténatale. La méthode proposée a permis de segmenter les régions du cerveau (MG, MB, LCR) malgré la faible résolution des images obtenues. L'étude quantitative et qualitative de notre modèle avec d'autres approches de segmentation a prouvé la performance de celui-ci et ce, malgré la présence du volume partiel et des artefacts dans les images traitées.

### **II. Perspectives.**

Les perspectives que nous envisageons dans le prolongement de ce travail s'articulent autour des points suivants :

➤ En ce qui concerne le modèle, la segmentation étant basée sur les contours actifs géodésiques, il ne dépend donc pas de l'initialisation du contour, mais la fonction d'énergie doit être améliorée pour la rendre moins sensible aux choix du paramètre  $\gamma$  et  $g$  qui représentent respectivement la constante qui assure la proportionnalité entre le terme de la force région et de la force gradient et la fonction d'arrêt de l'algorithme.

➤ En ce qui concerne la segmentation des IRMs chez l'adulte, les résultats obtenus donnent satisfaction, mais l'algorithme proposé est couteux en temps de calcul car nous devons calculer à chaque itération, les moyennes locale et non locale de toute l'image, pour déterminer la distance. Pour la performance de l'algorithme, nous pourrions envisager de diviser l'image à traiter, en plusieurs parties et réaliser le calcul de toutes les parties en même temps, puis réduire le nombre de parties pour reconstruire l'image finale segmentée. Dans le cas d'une segmentation des IRMs fœtales, nous avons remarqué l'apparition de faux positifs dans le tronc cérébral au niveau du thalamus et de l'hypothalamus. Pour la performance de l'algorithme sous cet angle, nous pourrions d'abord segmenter cette région en utilisant par exemple, les algorithmes des contours actifs pour délimiter la région du tronc cérébral et la

séparer de l'image initiale, pour ensuite utiliser notre approche pour segmenter les autres régions constituant le cerveau fœtal.

**REFERENCES**  
**BIBLIOGRAPHIQUES**

- [1] I. Peretti. Evolution of magnetic resonance imaging. *Innovation and Research in Biomedical Engineering*, vol. 30 (2), pages. 53-59, 2009.
- [2] F. Tranquart, P. Marcy. Nouveautés en ultrasons et échographie de contraste. *Journal de Radiologie*, vol. 88 (10), pages. 1298, 2007.
- [3] C. Aubé, A. Bouvier, J. Lebigot, et al. Traitement radiologique de CHU : la radiologie interventionnelle au centre de la prise en charge. *Journal de Radiologie Diagnostique et interventionnelle*, vol. 96 (2), pages. 180-191, 2015.
- [4] L. Yenumula, R.V. Acharya, U. Kumar. Ring artifact correction in gamma-ray process tomography imaging. *Applied Radiation and Isotopes*, vol. 124, pages. 75-82, 2017.
- [5] T.S. Nogueira, M.D. Silva, A.A. Sousa, B.S. Costa, J.G. Fernandes. NR9 Interet des sequences IRM non morphologiques dans l'exploration des lesions expansives intracraniennes. *Journal de Radiologie*, vol. 87 (10), page. 1488, 2006.
- [6] D. Sabri, R. Ossuly, E. Letard, P. Fernandez, E. Schouman. Interet des sequences de diffusion en IRM prostatique. *Journal de Radiologie*, vol. 90 (10), page. 1465, 2009.
- [7] C. Adamsbaum, L. Mezzetta, P. Hornoy. Current events in fetal magnetic resonance. *Archives de Pédiatrie*, vol. 17 (12), pages. 1749-1760, 2010.
- [8] J.L. Daire, I. Claude, G. Sebag, J.F. Lerallut. Segmentation de la fosse postérieure en IRM fœtale : application biométrique. *ITBM-RBM*, vol. 23 (1), pages. 14-22, 2002.
- [9] N.A. Kasbi, H. Allani, I. Bellagha, A. Hammou. Le dysraphisme spiral. Apport de l'imagerie dans le diagnostic anténatal. *Journal de pédiatrie et de Puériculture*, vol. 17 (1), pages. 20-23, 2004.
- [10] N. Hata, Y. Muragaki, T. Inomata, et al. Intraoperative tumor segmentation and volume measurement in MRI. *Academic Radiology*, vol. 12 (1), pages. 116-122, 2005.
- [11] O. Charron, A. Lallement, D. Jarnet, V. Noblet, et al. Automatic detection and segmentation of brain metastases on multimodal MR images with a deep convolutional neural network. *Computers in Biology and Medicine*, vol. 95, pages. 43-54, 2018.
- [12] A. Maknopoulos, S.J. Counsell, D. Rueckert. A review on automatic fetal and neonatal brain MRI segmentation. *NeuroImage*, vol. 170, pages. 213-248, 2018.

- [13]K. Keraudren, M.K. Murgasova, V. Kyriakopoulou, et al. Automaed fetal brain segmentation from 2D MRI slices for motion correction. *NeuroImage*, vol. 101, pages. 633-643, 2014.
- [14]J. Bezdek, J. Keller, N. Pal, R. Krisnapuram. *Fuzzy Models and Algorithms for pattern recognition and image rocessing*. Springer science & business Media, vol. 4, 2006.
- [15]D.L. Pham. *Spacial Models for Fuzzy Clustering*. *Computer Vision and Image Understanding*, vol. 84 (2), pages. 285-297, 2001.
- [16]S. Chen, D. Zhang. Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure. *IEEE Transactions on systems, Man and Cybernetics- part B: Cybernetics*, vol. 34 (4), pages. 1907-1916, 2004.
- [17]M. Zins. Imagerie des canaux pancréatiques: CPRE ou IRM?. *Hépto Gastro & oncologie Digestive*, vol. 11 (1), pages. 27-30, 2004.
- [18]F. Bloch, W. Hansen, M. Packard. The nuclear induction experiment. *Physical Review*, vol. 70, pages. 474-485, 1946.
- [19]E.M. Purcell, H.C. Torrey, R.V. Pound. Resonance absorption by nuclear magnetic moments in a solid. *Physical Review*, vol. 69, pages.37-38, 1946.
- [20]P.C. Lauterbur. Image formation by induced local interactions: examples employing nuclear magnetic resonance. *Nature*, vol. 242, p. 190-191, 1973.
- [21]P. Mansfield. Multi planar image formation using NMR spin echoes. *Journal of Physic C Solid State Physics*, vol. 10 (3), pages. 55-58, 1977.
- [22] H. Pannier, M. Noulhiane, J. Dubois, C. Chiron. Mieux comprendre le développement cérébral grâce aux nouvelles techniques d'IRM anatomique et fonctionnelle. *Mt pédiatrie*, vol. 16 (3), pages. 167-78, 2013.
- [23]M. Ferry, P. Ritz. Besoin en eau et en énergie. *Nutrition de la personne agée*, vol. 4, pages. 47-50, 2012.
- [24]J.M. Idée, N. Fretellier, M.M. Thurnher, B. Bonnemain, C. Corot. Physico chemical and toxicological profil of gadolinium chelates as contrast agents for magnetic resonance imaging. *Annales Pharmaceutiques Française*, vol. 73 (4), pages. 266-276, 2015.

- [25] Otto Stern, Walter Gerlach. The experimental proof of the directional quantization in the magnetic field. *Journal of Physics*, vol. 9 (1), pages. 349-352, 1922.
- [26] Y. Chung, C. Hsied et al. Magnetic moment quantifications of small spherical objects in MRI. *Magnetic Resonance Imaging*, vol. 33(6), pages. 829-839, 2015.
- [27] H. Malcolm. Spin dynamics basics of nuclear magnetic resonance. John Wiley et Sons Chichester, vol. 40. Page.686, 2001.
- [28] Ray Freeman. Basic steps in high resolution NMR. Spin Choregraphy, Oxford University Press, Oxford, Chapitres 1-3, 1998.
- [29] J. Felblinger. Gestion de la radiofréquence en IRM. *Journal de Radiologie*, vol. 88 (10), page. 1293, 2007.
- [30] F. A. Hopf, R. F. Shea, M. O. Scully. Theory of Optical Free-Induction Decay and Two Photon Superradiance. *Physical Review A*, vol. 7 (6), pages. 2105–2110, 1973.
- [31] Z.H. Cho, O. Nalcioglu, H.W. Park. Methods and algorithms for Fourier transform nuclear magnetic resonance tomography. *Journal of the Optical Society of America*, vol. 4 (5), pages. 923-932, 1987.
- [32] H. Zaouini, T. Guertin, C. Oppenheim, J.F. Méder. Intérêts des nouvelles séquences IRM pour le diagnostic de la thrombose veineuse cérébrale. *Journal de Radiologie*, vol. 98 (10), pages. 1509, 2008.
- [33] H. Marret, F. Tranquart. Echographie et IRM perviennes, ou la surenchère est-elle justifiée?. *Gynécologie Obstétrique & Fertilité*, vol. 38 (3), pages. 163-165, 2010.
- [34] C. Malamateniou, S.J. Malik, S.J. Counsell, J.M. Allsop, A.K. McGuinness, T. Hayat, et al. Motion-compensation techniques in neonatal and fetal MR imaging. *American Journal of Neuroradiology*, vol. 34 (6), pages. 1124–1136, 2013.
- [35] Y. Patenaude, D. Pugash, K. Lim, L. Morin. Utilisation de l'imagerie par résonance magnétique en obstétrique. *Journal d'obstétrique et gynécologie du canada*, vol. 38(12), pages 418-425. 2016.
- [36] Y. Yamashita, T. Namimoto, Y. Abe, et al. MR imaging of the fetus by a HASTE sequence. *American Journal of Roentgenology*, vol. 168(2), pages. 513-519, 1997.

- [37] M. Brasseur, V. Ickowicz. IRM fœtale : indication, limites et dangers. *Gynécologie Obstétrique & Fertilité*, vol. 36 (1), pages. 120-121, 2008.
- [38] M. Chipaux, C. Chiron, R. touraine, L. ouss, et al . Sclérose tubéreuse de Bourneville : mise au maint et actualités. *Journal of Epilepsies*, vol. 35, pages. 678-683, 2007.
- [39] B. Belaroussi. Correction par traitement d'images de l'artéfact de susceptibilité magnétique dans les images IRM. Thèse de doctorat, Institut national des sciences appliquées de Lyon, 2005.
- [40] B. Boulet, C. Caramella, D. Couanet, et al. Approche diagnostique de la moelle osseuse en IRMV. *Journal de Radiologie*, vol 90 (10), page. 1207, 2009.
- [41] N. Girard, C. Raybaud. Imagerie cérébrale par résonance magnétique nucléaire pendant la période prénatale. *Archive de Pédiatrie*, vol. 5, pages. 171-174, 1998.
- [42] E.A. Larue. Diagnostic anténatal des dysgénésies du corps calleux et devenir neurologique : expérience nantaise de 2002 à 2010. Thèse doctorat, Faculté de médecine Nantes, 2012.
- [43] M. Malamateniou, S.J. Malik, S.J. Counsell, et al. Motion Compensation techniques in Neonatal and Fetal MR Imaging. *American Journal Of NeuroRadiology*, vol. 34(6), pages. 1124-1136, 2013.
- [44] G. Malik. Optimizing the MRI protocol to overcome artifacts from metallic orthopedic implants and hardware. *European Society of Radiology*, pages. 1-18, 2014 .
- [45] P. Mougin. L. Beguiristain, et al. IRM de la region hypophysaire : de 1,5 à 3 Tesla. *Journal de Radiologie*, vol. 88 (10), pages. 1315-1320, 2007.
- [46] C. Losif, C. Rodriguez, et al. 19 Imagerie de susceptibilité magnétique : quelle séquence pour quelle indication ?. *Journal de Radiologie*, vol. 90(10), pages. 1543-1548, 2009.
- [47] S.Y. Huang, R.T. Seethamraju, et al. Body MR Imaging: Artifacts, K-Space, and solutions. *Journal of Radiological Society of North America*, vol. 35(5), pages. 1439-1460, 2015.
- [48] L. Brunereau, V. Bousson, et al. Artercats en angiographie par résonance magnétique. *Journal de radiologie*, Vol. 79 (9), pages. 849-859, 1998.

- [49]L.J. Erasmus, D. Hurter, et al. A short overview of MRI artefacts. SA Journal of radiology, pages. 13-17, 2004.
- [50]S. Cantin, C. Mendoza, et al. MRI of normal brain in the coronal sagittal and axial planes. Feuille de Radiologie, vol 45 (3), pages.147-167, 2014.
- [51]B. Fischl, A.M. Dale. Measuring the thickness of the human cerebral cortex from magnetic resonance images. Proceedings of the National Academy of sciences of the United States of America, vol. 97 (20), pages. 11050-1055, 2000.
- [52]D. Levine , P.D. Barnes. Cortical maturation in normal and abnormal fetuses as assessed with prenatal MR imaging. Journal of Radiology, vol 210 (3), pages. 751-758, 1999.
- [53]C. Garel, E. Chantrel, H. Brisse, M. Elmaleh, D. Luton, et al, Fetal cerebral cortex : normal gestational landmarks identified using prenatal MR imaging. American Journal of Neuroradiology, vol. 22 (1), pages. 184-189, 2001.
- [54]A. Broca. Développement et maturation cérébrale. Le développement de l'enfant, vol. 6, pages. 19-23, 2017.
- [55]S. Horowitz, T. Pavlidis. Picture segmentation by a directed split-and-merge procedure. Rapport de Recherche, Departement of Electrical Engineering, Princeton University, 1975.
- [56]S. Horowitz, T. Pavlidis. Picture segmentation by a tree traversal algorithm. Journal of The Association for Computing Machinery, vol. 23(3), pages. 368–388, 1976.
- [57]H. Mallouche, J. D. Guise, Y. Goussard. Model-based multiple active contours matching for radiographic images. Engineering in Medicine and Biology Society, IEEE 17th Annual Conference, 20-23 septembre, 1995.
- [58]L.G. Roberts. Machine perception of three dimensional solids. Optical and Electro-optical Information Processing, vol. 9, pages. 159-197, 1965.
- [59]J.M.S. Prewitt. Object enhancement and extraction. Picture Processing and Psychopictorics, New York Academic Press, pages. 75-149, 1970.
- [60] I. Sobel, G. Feldman. A 3x3 Isotropic Gradient Operator for Image Processing. Pattern Classification and Scene Analysis, pages. 271-272, 1973.

- [61]Z.K. Xiong, H. Li. A combined approach to medical image segmentation using anisotropic diffusion and wavelet packet decomposition. *Bioinformatics and Biomedical Engineering, 2nd International Conference on BBE*, 16-18 may, 2008.
- [62]G. Matheron. *Eléments pour une théorie des milieu poreux*. Masson, vol. 1, page. 146, 1967.
- [63]J. Serra. *Les fonctions aléatoires de dilution*. Centre de Morphologie Mathématique. ENSMP France, note interne, 1968.
- [64]H. Digabel, C. Lantujoul. Iterative algorithm. *Quantitative analysis of micro structures in materials sciences*, vol.1, pages. 85–99, 1978.
- [65]H.A. Nugroho, A. Nugroho, L. Choridah. Thyroid nodule segmentation active contour bilateral filtering on ultrasound images. *International conference on Quality in Research*, pages. 43-46, 2015.
- [66]X.M. Pardo, M.J. Carreira, A. Mosquera, D. Cabello. A Snake for CT Image Segmentation Integrating Region and Edge Information. *Image and vision computing*, vol. 19, pages. 461-475, 2001.
- [67]N. Duta, M. Sonka. Segmentation and Interpretation of MR Brain Images: An Improved Active Shape Model. *IEEE Transactions on medical imaging*, vol. 17, pages. 1049-1062, 1998.
- [68]T. McInerney, D. Terzopoulos. Deformable models in medical image analysis: a survey. *Medical Image Analysis*, vol. 1(2), pages. 91–108, 1996.
- [69]C. Xu, J.L. Prince. Snakes shapes and gradient vector flow. *IEEE Transactions on Image Pocessing*, vol. 7 (3), pages. 359-369, 1998.
- [70]T. Wang, I. Cheng. Fluid Flow and applications in Brain Tumor Segmentation. *IEEE Transactions on biomedical engineering*, vol. 56 (3), Pages. 781-789, 2009.
- [71]A. Rabhi, M. Adel, S. Bourenane. Segmentation d’images ultrasonores par les régions actives géodésiques. *ITBM-RBM*, vol. 27 (1), pages. 8-18, 2006.
- O. Colliot, O. Camara, I. Bloch. Integration of fuzzy spatial relations in deformable models Application to brain MRI segmentation. *Pattern Recognition*, vol. 39 (8), pages.1401–1414, 2006.

- [73] S. Zucher. Region growing: childhood and adolescence. *Computer Graphics and image processing*, vol. 5, pages. 382-399, 1976.
- [74] B. Fan, P. Zhang. Spatially enabled customer segmentation using a data classification method with uncertain predicates. *Decision Support Systems*, vol. 47 (4), pages. 343-353, 2009.
- [75] I. Bloch, Y. Gousseau, H. Maitre, D. Matigon, et al. Le traitement des images, Polycopié du cours ANIM Département TSI Télécom Paris, vol.2, pages. 243-254, 2005.
- [76] H.G. Schnack, P.H. Hulshoff, W. Baaré, M. Viergever, R. Kahn. Automatic segmentation of the ventricular system from MR images of the human brain. *NeuroImage*, vol. 14 (1), pages. 95–104, 2001.
- [77] N. Richard, M. Dojat, C. Garbay. Automated segmentation of human brain MR images using a multi agent approach. *Artificial Intelligence in Médecine*, vol. 30, pages. 153–175, 2004.
- [78] K. Miroslav. Neural networks: A comprehensive foundation by simon haykin, Macmillan, 1994. *Journal The Knowledge Engineering Review*, vol. 13(4), pages. 409-412, 1999.
- [79] H. Abdi. Les reseaux de neurones. Presses universitaire de Grenoble, 1994.
- [80] V.N. Vapnik. The nature of statistical learning theory. Springer, 1995.
- [81] J. Yeh, J. Fu. A hierarchical genetic algorithm for segmentation of multi spectral human brain MRI. *Expert Systems with Applications*, vol. 34, pages. 1285- 1295, 2008.
- [82] X. Wang, S. Wang, Y. Zhu. Image segmentation based on Support Vector Machine, *Computer Science and Network Technology*, 2<sup>nd</sup> International Conference, 29-31 decembre 2012.
- [83] Xin. Zhang, Xiu. Zhang. WITHDRAWN :Adaptive multiclass support verctor machine for multimodal data analysis. *Pattern Recogntition*, vol. 70, pages. 177-184, 2017.
- [84] Z. Yu, H.S. Wong, G. Wen. A modified support vector mahine and its application to image segmentation. *Image and Vision Computing*, vol. 29(1), pages. 29-40, 2011.

- [85] N. Abdul Rahim, M.P. Paulraj, A.H. Adom. Adaptive Boosting with SVM Classifier for Moving Vehicle Classification, vol. 53, pages. 411-419, 2013.
- [86] J.B. MacQueen. Some Methods for classification and Analysis of Multivariate Observations, Proceedings of 5 th Berkeley Symposium on Mathematical Statistics and Probability. Berkeley, University of California Press, vol. 1, pages. 281-297, 1967.
- [87] J. Liu, L. Guo. An improved K-means Algorithm for brain MRI image segmentation. 3<sup>rd</sup> International Conference on Mechatronics, Robotic and Automation, pages. 1087- 1090, 2015.
- [88] Z. Chen, H. Yu, H. Chen. Research on K-means clustering segmentation method for MRI brain image based on selectiong multi-peaks in gray histogram. Journal of Biomedical, vol. 30 (6), pages. 1164-1170, 2013.
- [89] J. Dunn. A fuzzy relative of the ISODATA process and its use in detecting compact wellseparated cluster. Journal of Cybernetics, vol. 3, pages. 32–57, 1973.
- [90] Z. Liang, S. Wang. An EM approach to MAP solution of segmenting tissue mixtures: a numerical analysis. IEEE T Med Imaging, vol. 28, pages. 297-310, 2009.
- [91] J. Xue, S. Ruan, B. Moretti, M. Revenu, D. Bloyet. Knowledge-based segmentation and labeling of brain structures from MRI images. Pattern Recognition Letters, vol. 22, pages. 3-4, 2001.
- [92] J. Aljabar, B.A. Heckemann, A. Hammers, J.V. Hajnal, D. Rueckert. Multi-atlas based segmentation of brain images : atlas selection and its effects on accuracy. NeuroImage, vol. 46 (3), pages. 726-738, 2009.
- [93] G. Mirajkar, B. Barbabekar. Automatic segmentation of brain tumors from MR images using undecimated wavelet transform and gabor wavelets. Electronics Circuits and Systems (ICECS), 17th IEEE International Conference on Electronics Cirucuits ans systems, 12-15 decembre 2010.
- [94] F. Yang, F. Kruggel. Automatic segmentation of human brain sulci. Medical Image Analysis. vol. 12 (4), pages. 442–451, 2008.

- [95] A. Huang. A Hybrid Geometric–Statistical Deformable Model for Automated 3-D Segmentation in Brain MRI, *IEEE Transactions on Biomedical Engineering*, vol. 56 (7), pages. 1938-1848, 2009.
- [96] K. Kasiri, K. Kazemi, & al. A Hybrid Hierarchical Approach for Brain Tissue Segmentation by Combining Brain Atlas and Least Square Support Vector Machine, *Journal Med Signals Sens*, vol. 3 (4), pages. 232–243, 2013.
- [97] M.J. kshath, H.S. Sheshadri. Hybrid edge detection techniques for MR image analysis. *International Research Journal of Advanced Engineering and Science*, vol. 2 (1), pages. 79-83, 2017.
- [98] D.J. Burr. Elastic Matching of line drawings. *IEEE transaction on Pattern analysis and machine intelligence*, vol. 3 (6), pages. 708-713, 1981.
- [99] M. Kass, A. Witkin, D. Terzopoulos. Snakes : Active contour models. *International Journal of Computer Vision*, vol. 1(4), pages. 321-331, 1987.
- [100] C. Xu, J. Prince. Gradient vector : a new external force for snakes. *International Conférence on Computer Vision and Pattern Recognition*, pages 66- 71, 1997.
- [101] C. Xu, J. Prince. Snakes, shapes, and gradient vector. *IEEE Transactions on Image Processing*, vol. 7(3), pages. 359-369, 1998.
- [102] S. Osher, J. Sethian. Fronts propagating with curvature dependent speed: Algorithms based on Hamilton Jacobi formulations. *Journal of computer Physic*, vol. ,pages. 12-49, 1988.
- [103] O. Chilali, M. Diaf. Segmentation d’Images à Bases de Modèles Déformables. 3 émes Journées Internationales sur l’Informatique Graphique, Constantine, Algérie, 2007.
- [104] V. Caselles, R. Kimmel, G. Sapiro. Geodesic active contours. *International Journal of Computer Vision*, vol. 22(1), pages. 61-79, 1997.
- [105] T. Chan, L. Vese. Activates contours without edges. *IEEE Transaction one Processing image*, vol. 10 (2), pages. 266-277, 2001.

- [106] J. Tang, S. Guo. Segmentation of skin cancer using external force filtering snake based on wavelet diffusion. Multi modality of the art medical image segmentation and registration methodologie, vol. 1, pages. 129-142, 2011.
- [107] X. Zhu, P. Zhang, J. Shao, et al. A snake based method for segmentation of intravascular ultrasound images and its in vivo validation. Ultrasonics, vol. 51 (2), pages. 181-189, 2011.
- [108] M. Wang, J. Liang, J. Liu, X. Feng. Medical Image segmentation Based on Improved Level Set. 4<sup>th</sup> International Conference on Biomedical Engineering and Information (BMEI) 2011.
- [109] F. Precioso, M. Barlaud, T. Blu, M. Unser. Robust real-time segmentation of images and videos using a smooth spline snake based algorithm. IEEE Transactions on Image Processing, vol. 14 (7), pages. 910-924, 2005.
- [110] P. Gravel, G. Beaudoin, J.A. Guise. A Method for Modeling Noise in Medical Images. IEEE Transactions on Medical Imaging, vol. 23 (10), pages. 1221-1232, 2004.
- [111] B.S. Anami, P.H. Unki. A combined fuzzy and level sets based approach for brain MRI image segmentation. Fourth National Conference on Computer Vision, Pattern Recognition Image Processing and Graphics (NCVPRIPG), 2013.
- [112] S. Ramathilagam, R. Pandiyarajan, A. Sathya ,R. Devi, D.R. Kannan. Modified Fuzzy C-Means algorithm for segmentation of T1-T2-Weighted brain MRI. Journal of computational and applied mathématiques, vol. 235 (6), pages. 1578-1586, 2011.
- [113] B. BEDDAD, K. HACHEMI. Brain Tumor Detection by using a Modified FCM and Level Set Algorithms. 4th International Conference on Control Engineering & Information Technology (CEIT -2016), 16-18 December, Tunisia, 2016.
- [114] L. A. Zadeh. Fuzzy sets. Information and Control, vol. 8 (3), pages. 338-353, 1965.
- [115] W. Adey. Organization of brain tissue: is the brain a noisy processor. International Journal of Neuroscience, vol. 3 (6), pages. 271-284, 1972.
- [116] J.C. Bezdek. Feature selection for brain data-medical diagnosis with fuzzy sets. AFIPS 76 proceeding National Computer Conference and exposition, pages. 1057-1068, 1976.

- [117] D.L. Pham, J.L. Prince, A.P. Dagher, C. Xu. An automated technique for statistical characterization of brain tissues in magnetic resonance imaging. *International Journal of Pattern Recognition and Artificial Intelligence*, vol. 11 (8), pages. 1198-1211, 1996.
- [118] R. He, S. Datta, B.R. Sajja, P.A. Narayana. Generalized fuzzy clustering for segmentation of multi spectral magnetic resonance images. *Computerized Medical Imaging and Graphics*, vol. 32 (5), pages. 353-366, 2008.
- [119] P.C. Mahalanobis. On the Generalized Distance in Statistics. *Journal of Genetics*, vol. 41, pages. 159-193, 1936.
- [120] S. Madhukumar, N. Santhyakumari. Evaluation of K Means and Fuzzy C means segmentation on MR images of brain. *The Egyptian Journal of Radiology and Nuclear Medicine*, vol. 46 (2), pages. 475-479, 2015.
- [121] M.N. Ahmed, S.M. Yamany, N. Mohamed, A.A. Farag, T. Moriarty. A modified fuzzy c-means algorithm for bias fields estimation and segmentation of MRI data. *IEEE Transactions on Medical Imaging*, vol. 21 (3), pages. 993-999, 2002.
- [122] H. Wang, B. Fei. A modified fuzzy c-means classification method using a multiscale diffusion filtering scheme. *Medical Image Analysis*, vol. 13 (2), pages. 193-202, 2009.
- [123] Y.K. Dubey, M.M. Mushrif. FCM Clustering Algorithms for Segmentation of Brain MR Images. *Advances in Fuzzy Systems*, pages. 1-14. 2016.
- [124] S.M. Smith. Fast robust automated brain extraction. *Human Brain Mapping*, vol. 17(3), pages. 143-155, 2002.
- [125] D.W. Shattuck, S.R. Sandor-Leahy, K.A. Schaper, D.A. Rottenberg, R.M. Leahy. Magnetic resonance image tissue classification using a partial volume model. *NeuroImage*, vol. 13 (5), pages. 856-876, 2001.
- [126] D. Marr, E. Hildreth, Theory of Edge Detection. *Proceeding of the royal society of london*. Vol. 207(1167), pages. 187–217, 1980.
- [127] F. Ségonne, A.M. Dale, B.E. Busa, B.M. Glessner, B.D. Salat, B.K. Hahn, B. Fischl. A hybrid approach to the skull stripping problem in MRI. *NeuroImage*, vol. 22, pages. 1060-1075, 2004.

- [128] H.K. Horst, H.O. Peitgen. The Skull Stripping Problem in MRI Solved by a Single 3D Watershed Transform. International conference on medical image computing and computer assisted intervention, pages. 134-143, Pennsylvania, USA, 2000.
- [129] P. Perona, J. Malik. Scale space and edge detection using anisotropic diffusion. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 12(7), pages. 629–639, 1990.
- [130] N. OTSU. A Threshold Selection Method from Gray-Level Histograms. IEEE transactions on Systems Man and Cybernetics, vol. 9(1), pages. 62-66, 1979.
- [131] F. Meyer, S. Beucher. Morphological segmentation. Journal of visual communication and Image Representation, vol. 1 (1), pages. 21-46, 1990.
- [132] L. Vese, T. Chan. A multiphase level set framework for image segmentation using the Mumford and Shah model. International Journal of Computer Vision, vol. 50 (3), pages. 271-293. 2002.
- [133] D. Mumford, J. Shah. Optimal approximations by piecewise smooth functions and associated variational problems. Pure Communication on Applied Mathematics, vol. 42(5), pages. 577-685. 1989.
- [134] Y. Wang, Y. Jia. External force for active contours: Gradient Vector Convolution. International conference on artificial intelligence, vol. 5351, pages. 466-472. 2008.
- [135] L. Guerra, L.M. McGarry, V. Robles, C. Bielza, P. Larranaga, R. Yuste. Comparison between supervised and unsupervised classifications of neuronal cell types: a case study. Developmental Neurobiology, vol. 71(1), pages. 71-82, 2011.
- [136] S. Chabrier, B. Emile, H. Laurent, C. Rosenberger. Unsupervised performance evaluation of image segmentation. EURASIP Journal on Advances in Signal Processing, vol. 18, pages. 217-217, 2006.
- [137] M. Vasconcelos, N. Vasconcelos, G. Carneiro. Weakly supervised top down image segmentation. IEEE Computer Vision and Pattern Recognition Conference, pages. 1001-1006, New York, NY, USA. New York, NY, USA, 17-22 June 2006.

- [138] J. Wang, J. Kong, Y. Lu, M. Qi, B. Zhang. A modified FCM algorithm for MRI brain image segmentation using both local and non-local spatial constraints. *Computerized Medical Imaging Graphics*, vol. 32(8), pages. 685-698, 2008.
- [139] W. Chen, M.L. Giger. A Fuzzy C-Means (FCM) based algorithm for intensity inhomogeneity correction and segmentation of MR images. 2<sup>nd</sup> IEEE international symposium Biomedical Imaging: nano to macro, pages. 1307-1310, Arlington, VA, USA. New York, NY, USA, 15-18 April 2004.
- [140] P. Singh, H.S. Bhadauria, A. Singh. Automatic brain MRI image segmentation using FCM and LSM. *IEEE Reliability Infocom Technologies and Optimization Conference*, pages. 1-6, Noida, India. New York, NY, USA, 8-10 October 2014.
- [141] M.E. Brandt, J.M. Fletcher, L.A. Kramer. Brain tissue volumes estimated from magnetic resonance scans in pediatric hydrocephalus. *IEEE Biomedical Engineering Society Conference*, pages. 1122-1123, Houston, TX, USA. New York, NY, USA, 23-26 October 2002.
- [142] R. He, S. Datta, B.R. Sajja, M. Mehta, P. Narayana. Adaptive FCM with contextual constrains for segmentation of multi-spectral MRI. *IEEE Engineering in Medicine and Biology Society Conference*, pages. 1660-1663, Los Alamitos, CA, USA. New York, NY, USA, 1-5 September 2004.
- [143] J.H. Xue, W. Philips, A. Pizurica, I. Lemahieu. A novel method for adaptive enhancement and unsupervised segmentation of MRI brain image. *IEEE Acoustics Speech and Signal Processing Conference*, pages. 2013-2016, Salt Lake City, UT, USA. New York, NY, USA, 7-11 May 2001.
- [144] P.L. Bazin, D.L. Pham. Topologypreserving tissue classification of magnetic resonance brain images. *IEEE T Med Imaging*, vol. 26, pages. 487-496, 2007.
- [145] H. Sahbi, B. Nozha. Validity of fuzzy clustering using entropy regularization. *IEEE Fuzzy Systems Conference*, pages. 177-182, Reno, NV, USA. New York, NY, USA, 22-25 May 2005.
- [146] B. Caldairou, F. Rousseau, N. Passat, P.A. Habas, C. Studholme, C. Heinrich. A non local fuzzy segmentation method: application to brain MRI. *Pattern Recognition*, vol. 44(9), pages. 1916-1927, 2011.

- [147] P. Coupe, P. Yger, S. Prima, P. Hellier, C. Kervrann, C. Barillot. An optimized blockwise nonlocal means denoising filter for 3-D magnetic resonance images. *IEEE T Med Imaging*, vol. 27, pages. 425-441, 2008.
- [148] A.P. Zijdenbos, B.M. Dawant. Brain segmentation and white matter lesion detection in MR images. *Crit Rev Biomed Eng*, vol. 22, pages. 401-465, 1994.
- [149] M.Z. Abderrezak, M.B. Chibane, K. Mansour. A New Hybrid Method for the segmentation of the brain MRIs. *Signal & Image processing : An international Journal*, Vol. 5 (4), pages. 77-84, 2014.
- [150] M.Z. Abderrezak, M.B. Chibane, K. Mansour. A new segmentation method of cerebral MRI images based on the fuzzy c-means algorithm. *Turk J Elec Eng & Comp Sci*, vol. 25, pages. 3215-3226, 2017.
- [151] P.A. Habas, K. Kim, D. Chandramohan, F. Rousseau, et al. Statistical model of laminar structure for atlas based segmentation of the fetal brain from in utero MR images. *Medical Imaginig*, vol. 7256, pages. 17-24, 2009.
- [152] P.A. Habas, K. Kim, J.M. Detig et al. A spatiotemporal atlas of MRI intensity tissue probability and shape of the fetal brain with application to segmentation. *NeuroImage*, vol. 53(2), pages. 460-470, 2010.
- [153] P. Dokladal, I. Bloch, et al. Topologically controlled segmentation of 3 D magnetic resonance images of the head by using morphological operators. *Pattern Recognition*, vol. 36(10), pages. 2463-2478, 2003.
- [154] M.B. Cuedra, M. Schaer, et al. Brain Tissue segmentation of fetal MR Images. *Image analysis for the developing Brain, Workshop in MICCAI*, 2009.
- [155] D. Ferrario, M.B. Cuedra, et al. Brain surface segmentation of magnetic resonance images of the fetus. *EUSIPCO European Signal Processing Conference*, 2008.
- [156] X. Tang, D. Crocetto, K. Kuttan, C. Ceritoglu, M.S. Albert, et al. Segmentation of brain magnetic resonance images based on multi-atlas likelihood fusion: testing using data with a broad range of anatomical and photometric profiles. *Front Neuroscience*, vol. 9 (61), pages. 1-13, 2015

- [157] A. Buades, B. Coll, J.M. Morel. A non local algorithm for images denoising. Computer vision and pattern recognition, 2005, CVPR. IEEE Computer Society Conference. 2005.
- [158] J. Weiliu, L. Gue. Selection of initial parameters of K-Means clustering algorithm for MRI brain image segmentation. International conference on machine learning and cybernetics, 2015.
- [159] F. Bidault, J.Stawiaski, E. Decenciére, et al. INF-WS-2 Segmentation interactive d'images medicales a 4 dimensions par hierarchie de partition. Vol. 88(10), pages. 1545, 2007.
- [160] B. Fischl, A.M. Dale. measuring the thickness of the human cerebral cortex from magnetic resonance images. Proceedings of the national academy of sciences of the united states of America, vol. 97(20), pages. 11050-11055, 2000.
- [161] K. Zuiderveld. Contrast Limited Adaptive Histogram Equalization. Graphic Gems IV San Diego Academic Press Professional, vol.4, pages. 474-485, 1994.
- [162] B. Caldairou. Contributions à la segmentation des structures cérébrales en IRM Fœtale. Thèse université de Strasbourg, Chapitre 4, page. 73, 2012.

# Liste des Publications

## **Liste des publications**

### **Articles dans des revues internationales avec comités de lecture (2)**

1. M.Z. Abderrezak, M.B. Chibane, K. Mansour. A New hybrid method for the segmentation of the Brain MRIs, *Signal & Image Processing : International journal*, vol.5 (4), pages. 77-84, 2014.
2. M.Z. Abderrezak, M.B. Chibane, K. Mansour. A new segmentation method of cerebral MRI images based on the fuzzy c-means algorithm, *Turkish Journal of Electrical Engineering & Computer Sciences*, vol. 25, pages. 3215-3226, 2017.