

UNIVERSITE BLIDA 1

Faculté de Technologie
Département d'Electronique

MEMOIRE DE MAGISTER

en Electronique
Option : Signaux et Systèmes

SEGMENTATION AUTOMATIQUE DE TUMEUR CEREBRALE PAR CONTOURS
ACTIFS COTRAINTS PAR DES RELATIONS SPATIALES

Par

Samia BENSALEM

Devant le jury composé de :

Mr A.AISSAT	Professeur, (USDB)	Président
Mr A.MEZIANE	Directeur de recherche	Examineur
Mr M.DJENDI	Maître de conférences (A),(USDB)	Examineur
Mr Y.CHERFA	Maître de conférences (A),(USDB)	Promoteur

Blida, 25 juin 2014

ملخص

الموضوع الرئيسي لهذه الأطروحة هو تجزئة أورام المخ ومكوناته (وذمة و نخر) . للقيام بذلك، فإننا نقترح وسيلة تمزج بين التجزأة الى مناطق و التجزأة الى المحيط ، قبل ذلك نقوم بتصفية الصور من أي تشويش لتحسين المعلومات المقدمة لعملية التجزئة.

طريقة التجزأة الى مناطق، تتم إما على أساس التصنيف الغامض، للكشف عن الفئة الناتجة عن الورم ، إما بالتحليل المتناظر للرسم البياني للصورة، الذي يقوم على الفرضية أن المخ متناظر و أن الورم يمكن تغيير هذا التناظر. لتحسين طريقة التجزئة الأولى القائمة على التجزأة الى مناطق، اخترنا طريقة المحيط المتحرك الذي يستعمل تدفق الأشعة المنحدرة للصورة، القائمة على الحواف. و أخيراً، لتوجيه أفضل للمحيط المتحرك، و جعل وسيلة التجزئة قابلة للتطبيق على أي نوع أو شكل للورم، أضفنا قوة خارجية للمحيط من العلاقات الفضائية التي استوحيناها من التجزئة الأولية للورم (القائمة على المناطق) و للأنسجة المحيطة به.

الإطار المقترح لا يتطلب سوى صورة بالرنين المغناطيسي المرجحة ب ت1 أو فلار. قمنا بتطبيق هذه الطريقة على أزيد من 20 صورة ثنائية الأبعاد ذات اشكال و أنواع مختلفة للأورام.

الكلمات الجوهرية : التجزئة الثنائية الأبعاد ، التصوير بالرنين المغناطيسي، ورم في الدماغ ، مرشح متباين الخواص ، تحويل هوغ ، تصنيف غامض ، النموذج المشوه البرامتري ، تدفق الأشعة المنحدرة ، العلاقات الفضائية .

RESUME

Le sujet principal de ce mémoire est la segmentation 2D de tumeurs cérébrales ainsi que ses composantes (œdème et nécrose). Pour ce faire, nous proposons une méthode de segmentation coopérative, entre approches régions et approches contours, précédée d'une étape de prétraitement, permettant d'améliorer les informations fournies à la segmentation.

L'approche région employée est une classification floue, basée sur la détection d'une classe d'intensité qui correspond à la tumeur, ou bien sur l'analyse de symétrie, qui s'appuie sur l'hypothèse que le cerveau est symétrique, et que la tumeur peut changer cette symétrie. Afin d'affiner la segmentation région, nous avons choisi de tirer avantage des contours actifs guidés par les GVF, qui produisent une bonne délimitation des frontières de l'objet. Pour mieux guider l'évolution du snake, et rendre l'outil de segmentation plus généralisable sur plusieurs types et formes de tumeurs, nous avons ajouté de nouvelles forces au modèle, issues des relations spatiales, présentant les connaissances a priori de la détection initiale de la tumeur et ses tissus avoisinants.

Ce travail a nécessité seulement des IRM pondérées en T1 ou en Flair. Nous avons évalué cette méthode sur une base de données de plus de 20 images 2D, avec différents types et formes de tumeur.

Mots clés : *Segmentation 2D, IRM, tumeurs cérébrales, Filtre anisotrope, transformée de Hough, Classification Floue, Snakes, GVF, Relations spatiales.*

ABSTRACT

The main topic of this thesis is the 2D segmentation of brain tumors and its components (edema and necrosis). To do this, we propose a cooperative method of segmentation based on regions approaches and contours approaches, after using preprocessing step, which improve the information provided to the segmentation.

The region approach used is a fuzzy clustering, based on the detection of a new class of intensity corresponding to the tumor, or the symmetry analysis, which is based on the assumption that the brain is symmetrical and tumor can change this symmetry. To refine the segmentation region we choose to take advantage of the Snake guided by GVF which produces a good delimitation of boundaries of the object. And finally, to better guide the evolution of the snake and make the segmentation more generalizable to many types and forms of tumors, we have added a new external force to the model from spatial relations presented by a priori knowledge of the initial detection of the tumor and its surrounding tissues.

The proposed framework requires only a T1-weighted MRI image or Flair. We evaluated this method on a set of more than 20 images of two dimensions with different types and forms of tumor.

Keywords: 2D segmentation, MRI, brain tumor, anisotropic filter, Hough transforms, Fuzzy Classification, Snake, GVF, Spatial Relations.

REMERCIEMENT

Je tiens à remercier tout d'abord ALLAH qui m'a donné le courage et la patience jusqu'au bout de mes études, et qui m'a permis de réaliser mon travail.

C'est avec un immense plaisir d'exprimer mes remerciements les plus sincères à MR. YAZID CHERFA et madame ASSIA CHERFA qui m'ont donné l'opportunité de découvrir le domaine de l'imagerie médicale à travers un projet dans leurs intégralité, qui, en tant que promoteur et promotrice de mémoire, se sont toujours montré à l'écoute et sont très disponible tout au long de la réalisation de ce mémoire, ainsi que pour l'inspiration, l'aide et le temps qu'ils ont bien voulu me consacrer et sans qui ce mémoire n'aurait jamais vu le jour

Un grand merci aux membres du jury, qui ont accepté d'évaluer mon travail de magister.

Je remercie également mes chers parents, ma source de courage, de soutien et de bonheur, merci pour tous ce que vous avez fait pour moi. A mes sœurs ainsi que toute ma famille, pour leur soutien moral compréhension et aide continu.

*J'*aimerai aussi présenter un grand merci à mes collègues du laboratoire de recherche en imagerie médicale " LARIM ", pour le partage des connaissances et la collaboration, particulièrement à MAOUIA, MOUDACHE, BELADGHEM, MESBAHI, BOUGUETTAYA, KHADIDJA et SEG HOUR. A tous mes amis, et à toute personne, qui de près ou de loin ont rendu ce travail possible.

Je tiens à remercier également le centre d'imagerie médicale d'ALGER (professeur YAKER) et le laboratoire LABHUMAN de l'université polytechnique de Valence, de m'avoir fourni les images IRM qui m'ont facilité la partie expérimentale de mon étude.

TABLE DES MATIERES

RESUME

REMERCIEMENTS

TABLE DES MATIERES

LISTE DES ILLUSTRATIONS, GRAPHIQUES ET TABLEAUX

GLOSSAIRE

INTRODUCTION	12
1. GENERALITES	15
1.1 anatomie du cerveau.....	16
1.1.1 Organisation générale du système nerveux.....	16
1.1.2 Les différentes parties du cerveau et leurs fonctions	16
1.1.2.1 Les hémisphères cérébraux.....	16
1.1.2.2 Le cervelet	17
1.1.2.3 Le tronc cérébral	18
1.1.2.4 Les méninges	18
1.1.2.5 Le liquide céphalo-rachidien.....	18
1.1.3 Les tissus du cerveau	19
1.2 Imagerie par résonance magnétique	20
1.2.1 Principe de l'IRM.....	20
1.2.2 Modalités d'images IRM	21
1.2.3 Observation des tissus dans des images pondérées en T1 & T2	22
1.3 Les tumeurs du cerveau	23
1.3.1 Qu'est-ce que le cancer?.....	23
1.3.2 Qu'est-ce qu'une tumeur cérébrale.....	23
1.3.3 Les différents types de tumeurs cérébrales	23
1.3.4 Tumeurs cérébrales primaires et secondaires (métastatiques)	24
1.3.5 Gradation selon l'OMS.....	24
1.3.6 Classification des tumeurs cérébrales selon la localisation, le type et l'agressivité.....	25
1.3.7 Classification des tumeurs selon leurs apparences radiologiques	26
1.3.7.1 Tumeurs non contrastées (NCON)	26
1.3.7.2 Tumeurs contrastées sans œdème (CONSO).....	26
1.3.7.3 Tumeurs contrastées avec œdème (CONAO)	27
1.3.7.4 Tumeurs partiellement contrastées (PCON)	27
1.3.8 Causes des tumeurs cérébrales.....	28
1.3.9 Signes et symptômes associés à la présence de tumeurs cérébrales.....	29
1.3.10 Diagnostic d'une tumeur du cerveau	30
1.3.11 Traitements envisageables	32
2. ETAT DE L'ART	35
2.1 Qu'est ce que la segmentation	37
2.1.1 Définition littéraire de la segmentation.....	37
2.1.2 Définition formelle	37
2.1.3 Objectifs de la segmentation	38

2.2	Les différentes approches de segmentation	39
2.2.1	Segmentation par approche région	39
2.2.1.1	Approche par division, fusion et fusion division (split & merge).....	40
2.2.1.2	Segmentation par croissance de région	42
2.2.1.3	Segmentation par classification	43
2.2.2	Segmentation par approche contour.....	50
2.2.2.1	Modèles déformables paramétriques.....	51
2.2.2.2	Modèles déformables géométriques.....	52
2.2.3	Segmentation par Théorie des graphes	52
2.2.4	Approches Régions-Contours	53
3.	PRETRAITEMENT ET SEGMENTATION INITIALE	55
3.1	Prétraitement.....	56
3.1.1	Filtrage du bruit dans les IRM	57
3.1.1.1	Filtrage anisotrope.....	57
3.1.1.2	Résultat et comparaison	60
3.1.2	Isolation du cerveau.....	60
3.1.2.1	Principe	60
3.1.2.2	Etapas de la méthode.....	61
3.1.3	Calcul du plan de symétrie	66
3.1.3.1	Calcul du plan de symétrie par la transformée de Hough	67
3.1.3.2	Fondements théoriques de la TH.....	67
3.1.3.3	Principe de la méthode par TH	70
3.2	Segmentation initiale	73
3.2.1	Segmentation par classification.....	73
3.2.1.1	La famille des c-moyennes.....	74
3.2.1.2	Classification c-moyenne floue (FCM).....	74
3.2.2	Segmentation par analyse de symétrie.....	78
3.2.2.1	Tumeurs non contrastées (NCON).....	79
3.2.2.2	Tumeur contrastée et sans œdème (CONSA)	81
3.2.2.3	Tumeur partiellement contrastée (CONP) et contrastée avec œdème (CONAO)	82
4.	MODELES DEFORMABLES ET RELATIONS SPATIALES	84
4.1	Aperçu de la méthode générale	85
4.2	Relations spatiales	86
4.2.1	Introduction	86
4.2.2	Description de l'anatomie cérébrale par des relations spatiales	87
4.2.3	Représentation des relations spatiales	88
4.2.4	Types de relations spatiales	89
4.2.4.1	Relations topologiques : intérieur, extérieur et frontières	90
4.2.4.2	Relations de direction	90
4.2.4.3	Relations de distance	91
4.3	Modèles déformables	93
4.3.1	Types de modèles déformables	94
4.3.2	Modèles déformables paramétriques.....	94
4.3.2.1	Définition	94
4.3.2.2	Inconvénients des Snakes	96
4.3.3	Forces externes	97
4.3.3.1	Force du gradient	97

4.3.3.2 Le flux du vecteur gradient (GVF).....	98
4.3.3.3 Contraintes issues des relations spatiales	99
4.3.4 Initialisation automatique du Snake.....	100
4.3.4.1 Initialisation du Snake en utilisant le GVF.....	100
4.3.4.2 Méthode proposée d'initialisation automatique du Snake	100
4.4 Méthode proposée : Modèle déformable, contraint par des relations spatiales.....	102
5. RESULTATS ET DISCUSSIONS	106
5.1 Présentation de l'interface et Implémentation	107
5.1.1 Environnement logiciel	107
5.1.2 Langage adopté pour la programmation	107
5.1.3 Structure du logiciel	108
5.2 Images utilisées	109
5.3 Résultats, interprétations et discussions	111
5.3.1 Résultats du prétraitement	111
5.3.1.1 Résultats du filtrage anisotrope.....	111
5.3.1.2 Résultats de l'isolation du cerveau.....	113
5.3.1.3 Résultats de la détection du plan de symétrie	114
5.3.2 Résultats de Segmentation initiale (FCM et Analyse de Symétrie).....	115
5.3.2.1 Segmentation par C-moyennes flous.....	115
5.3.2.2 Segmentation par analyse de symétrie	116
5.3.3 Résultats du raffinement de la Segmentation	119
5.3.3.1 Contours actifs paramétriques (Snake) et Snake guidé par GVF.....	119
5.3.3.2 Coopération entre FCM/Analyse de symétrie et Snake guidé par GVF.....	121
5.3.3.3 Méthode proposée : Coopération entre FCM et Snake guidée par GVF	124
contraint par les relations spatiales	
5.3.4 Evaluation des résultats de la méthode.....	129
CONCLUSIONS ET PERSPECTIVES.....	131
Annexe A : Types de tumeurs cérébrales	134
Annexe B : Manuel utilisateur	143

BIBLIOGRAPHIE

LISTE DES ILLUSTRATIONS, GRAPHIQUES ET TABLEAUX

Figure 1.1	Les deux hémisphères cérébraux	16
Figure 1.2	Les différents lobes d'un cerveau humain.....	17
Figure 1.3	Les méninges.....	18
Figure 1.4	Les ventricules cérébraux. Vue sagittale.....	19
Figure 1.5	Le cerveau comporte deux types de tissus : MG et MB.....	20
Figure 1.6	Appareil IRM.....	21
Figure 1.7	Exemples de modalités d'images IRM.....	22
Figure 1.8	Tumeur non contrastée	26
Figure 1.9	Tumeur contrastée sans œdème.....	27
Figure 1.10	Tumeurs contrastées avec œdème.....	27
Figure 1.11	Tumeurs partiellement contrastées.....	28
Figure 1.12	Scanner.....	31
Figure 1.13	Examen d'IRM.....	32
Figure 2.1	Chaine d'analyse d'images.....	36
Figure 2.2	Segmentation d'une image en 5 régions.....	38
Figure 2.3	Classification des différentes approches de segmentation.....	39
Figure 2.4	Les différentes méthodes de segmentation par approche région.....	40
Figure 2.5	Exemple de la division.....	40
Figure 2.6	Illustration du concept pyramidal de l'image pour la segmentation par fusion et division de régions.....	41
Figure 2.7	Décomposition en 4, faire apparaître des blocs similaires.....	41
Figure 2.8	Agrégation itérative des blocs similaires au bloc 1.....	41
Figure 2.9	Segmentation de tumeur cérébrale.....	48
Figure 2.10	Segmentation par Mean Shift.....	48
Figure 2.11	Segmentation de tumeur cérébrale par FCM.....	49
Figure 2.12	Exemple de segmentation par Classification.....	49
Figure 2.13	Principe des trois types de coopération.....	53
Figure 3.1	Organigramme global de la méthode proposée.....	56
Figure 3.2	Organigramme du processus de prétraitement.....	56
Figure 3.3	Bruit sur la matière blanche.....	57
Figure 3.4	Résultat et comparaison du filtrage d'image.....	60
Figure 3.5	Isolation du cerveau.....	61
Figure 3.6	Organigramme d'isolation du cerveau	62
Figure 3.7	Filtrage par diffusion anisotrope.....	63
Figure 3.8	Binarisation.....	63
Figure 3.9	Erosion.....	64
Figure 3.10	Dilatation.....	64
Figure 3.11	Etiquetage en composantes connexes.....	65
Figure 3.12	Opération de remplissage des trous.....	65
Figure 3.13	Opérations d'isolation du cerveau.....	66
Figure 3.14	Représentation d'une droite.....	68
Figure 3.15	Représentation d'un point dans l'espace ab.....	68
Figure 3.16	Représentation d'une droite dans l'espace ab.....	69
Figure 3.17	Représentation dans l'espace (ρ, θ)	69
Figure 3.18	Accumulateur.....	69

Figure 3.19	Organigramme de la détection du plan de symétrie par la TH.....	70
Figure 3.20	Carte contour obtenue avec le détecteur de Canny, $S=0.7$	71
Figure 3.21	Calcul de médiatrices.....	71
Figure 3.22	Accumulation.....	72
Figure 3.23	Détermination de l'axe de symétrie.....	73
Figure 3.24	Exemple de segmentation d'une image synthétique du cerveau par FCM	77
Figure 3.25	Exemple de segmentation d'une image réelle pathologique du cerveau par FCM.....	78
Figure 3.26	Analyse de symétrie pour une tumeur non contrastée.....	80
Figure 3.27	Détection initiale de la tumeur et des tissus environnants par analyse de symétrie.....	81
Figure 3.28	Segmentation d'une tumeur par analyse de symétrie, (CON)	81
Figure 3.29	Segmentation d'une tumeur par analyse de symétrie, Tumeur contrastée avec œdème et partiellement contrastée avec œdème.....	82
Figure 4.1	Aperçu général de la méthode proposée.....	85
Figure 4.2	Une partie d'un niveau de graphe hiérarchique synthétique, décrivant l'agencement des structures cérébrales.....	87
Figure 4.3	Exemples de coupes d'ensembles flous représentant les relations de distance et de direction.....	89
Figure 4.4	Types de relations spatiales sens des flèches	90
Figure 4.5	Représentation de la relation de distance par des ensembles flous.....	92
Figure 4.6	Principe du modèle déformable.....	93
Figure 4.7	Force externe calculée par le gradient de l'image.....	97
Figure 4.8	Zone d'attraction.....	98
Figure 4.9	Convergence aux concavités.....	98
Figure 4.10	Importance de l'initialisation pour l'utilisation du Snake guidé par GVF	100
Figure 4.11	Centre de forte divergence des vecteurs GVF.....	101
Figure 4.13	Etapes d'initialisation automatique du Snake.....	101
Figure 4.12	Initialisation manuelle du Snake.....	102
Figure 4.14	RS utilisées pour la segmentation de la tumeur détectée.....	103
Figure 4.15	Force externe F_R à partir de μ_R , correspond à une relation R.....	103
Figure 4.16	Résultat de la segmentation par modèle déformable, intégrant des relations spatiales.....	104
Figure 4.17	Aperçu général de la méthode proposée.....	104
Figure 5.1	Présentation de l'interface de développement graphique.....	107
Figure 5.2	Interface de prétraitement.....	108
Figure 5.3	Interface de la segmentation.....	109
Figure 5.4	Images utilisées.....	110
Figure 5.5	Résultats du filtrage anisotrope sur des images IRM, avec différentes modalités.....	112
Figure 5.6	Isolation du cerveau sur une séquence de 16 images	113
Figure 5.7	Résultats de la détection du plan de symétrie.....	114
Figure 5.8	Segmentation par FCM et détection de la tumeur.....	115
Figure 5.9	L'histogramme avant et après filtrage anisotrope.....	117
Figure 5.10	Comparaison d'histogrammes avant et après filtrage.....	117
Figure 5.11	Détection de la tumeur par analyse de symétrie de l'image «Image 3»	118
Figure 5.12	Détection de la tumeur par analyse de symétrie d'une image1 IRM Flair	118
Figure 5.13	Détection de la tumeur par analyse de symétrie de l'image « Image7»	119
Figure 5.14	Comparaison de la segmentation d'une image synthétique, par Snake	

	et par Snake guidé par GVF.....	120
Figure 5.15	Comparaison de la segmentation d'une IRM réelle par Snake et par Snake guidé par GVF.....	120
Figure 5.16	Etapes de la coopération FCM et Snake guidé par GVF.....	121
Figure 5.17	Opérations morphologiques et obtention du masque de la tumeur.....	122
Figure 5.18	Segmentation par Coopération entre FCM et Snake guidé par GVF ...	123
Figure 5.19	Segmentation par Coopération entre Analyse de symétrie et Snake guidé par GVF.....	123
Figure 5.20	Etapes de la coopération entre FCM et Snake guidé par GVF contraint par des RS.....	124
Figure 5.21	Résultats de la segmentation de la méthode proposée sur une séquence de 24 IRM.....	126
Figure 5.22	Comparaison de la segmentation entre un modèle intégrant des relations spatiales et un modèle sans relations spatiales (« image2 »)...	127
Figure 5.23	Comparaison de la segmentation entre un modèle intégrant des relations spatiales et un modèle sans relations spatiales (« image8 »)...	128
Figure 5.24	Comparaison avec une segmentation manuelle.....	129
Figure A.1	Tumeur astrocytaire.....	136
Figure A.2	Oligodendrogliomes.....	137
Figure A.3	Ependymome.....	138
Figure A.4	IRM T2+gado : médulloblastome.....	139
Figure A.5	Neurinome.....	140
Figure A.6	Méningiome.....	140
Figure A.7	Adénome hypophysaire.....	141
Figure A.8	IRM T1 + gado : métastases cérébrales d'origine pulmonaire.....	142
Figure B.1	Interface Principale.....	145
Figure B.2	Interface secondaire.....	145
Figure B.3	Description globale des modules de l'interface « Prétraitement ».....	146
Figure B.4	Description globale des modules de l'interface « Segmentation ».....	147
Figure B.5	Choix de différents types d'image.....	148
Figure B.6	Utilisation du Filtrage par l'interface « Prétraitement ».....	149
Figure B.7	Utilisation du programme d'isolation du cerveau.....	150
Figure B.8	Utilisation du programme de détection de l'axe de symétrie.....	150
Figure B.9	Interface secondaire « A propos ».....	151
Figure B.10	Utilisation du programme de segmentation coopérative.....	153
Figure B.11	Palette de paramètres de l'interface principale.....	154
Figure B.12	Palette de paramètres de l'interface secondaire.....	155
Figure B.13	Les boutons de l'interface principale.....	155
Figure B.14	Les boutons de l'interface secondaire.....	156
Tableau 1.1	Principales fonctions des lobes du cerveau.....	17
Tableau 1.2	Pondération T1 et pondération T2.....	22
Tableau 1.3	Classification des tumeurs cérébrales selon l'OMS.....	25
Tableau A.1	Différents types de tumeurs du cerveau.....	134
Tableau A.2	Types de tumeurs astrocytaires.....	137
Tableau B.1	Liste des raccourcis de l'interface	153

GLOSSAIRE

CNR	Rapport contraste sur bruit, 57
CONAO	Contrasté avec œdème, 27
CONSO	Contrasté sans œdème, 26
EM	Expectation maximisation, 45
FCM	Fuzzy c means, 49
FLICM	Fuzzy Local Information C-Means, 50
GVF	Gradient vector flow, 98
HCM	Hard c means, 74
IRM	Imagerie par résonance magnétique, 20
ISFCM	Improved Spatial Fuzzy C-Means, 50
Kpp (KNN)	K-plus proches voisins (K-nearest neighbor), 43
LCR	Liquide céphalo-rachidien, 18
MB	Matière blanche, 19
MG	Matière grise, 19
MRGM	Modified region growing methode, 42
NCON	Non contrasté, 26
NFCM	Novel Fuzzy C-Means, 50
OMS	Organisation mondiale de la santé, 24
PCON	Partiellement contrasté, 28
RS	Relations spatiales, 108
SEP	Sclérose en plaque, 46
SNC	Système nerveux central, 18
SNR	Rapport signal sur bruit, 57
SVM	Support vector machine, 46
SWA	Sliding Window Algorithm, 44
TE	Temps d'écho, 21
TH	Transformée de Hough, 66
TR	Temps de répétition, 21

INTRODUCTION

Depuis longtemps, le médecin n'a eu à sa disposition que des signes extérieurs et indirects pour se représenter les atteintes d'une maladie. L'expérience indispensable du praticien permettait alors de relier l'état du patient à une maladie particulière. La représentation qu'il pouvait avoir des organes atteints n'émanait que de timides suppositions, fondées sur de précédentes autopsies. Mais, tout ceci ne permettait pas au médecin de voir l'intérieur du corps du patient, bien vivant, afin de se représenter l'état réel des organes malades, et de suivre l'évolution de la maladie. L'invention du stéthoscope au XVIIIème siècle par R. Laennec fut une véritable révolution : il était désormais possible d'entendre, avec précision, les bruits de certains organes, et de les associer à un état sain ou pathologique de l'organe. Le stéthoscope a été le premier véritable instrument de diagnostic médical, et reste encore le plus utilisé à l'heure actuelle.

Au fil des années, d'autres techniques furent mises au point, dans le but d'observer cette fois-ci les organes malades, relativement à telle ou telle maladie. La découverte des rayons X en 1895 par W.C. Roentgen a permis d'examiner les parties dures du corps. La découverte de la radioactivité naturelle en 1898 par A. Becquerel et M. Curie, de la radioactivité artificielle par F. et I. Joliot-Curie en 1934, de la Résonance Magnétique Nucléaire (RMN) en 1946 par F. Bloch, l'amélioration des techniques de la physique, puis finalement, dans ces dernières années, l'apparition de méthodes de traitement et de reconstruction d'images, ont contribué à la création de scanners, permettant de visualiser tout organe. Le médecin de cette décennie ne se contente plus de déduire l'état d'un organe, il peut le voir en image, localiser ses anomalies, observer son comportement au cours du temps, et apprécier l'effet d'une thérapie. L'ensemble de ces techniques récentes a ainsi donné naissance à *l'imagerie médicale*. L'une de ces techniques est l'Imagerie par Résonance Magnétique (IRM), que nous présenterons brièvement au premier chapitre. Il s'agit d'une technique d'imagerie médicale, non invasive et indolore, qui permet d'observer l'anatomie d'un organe, par une représentation 2D ou 3D. En 1971 aux Etats-Unis, R. Damadian, découvrait que des tissus sains et des tissus tumoraux donnaient des spectres de RMN différents ; cette différence est corrélée à la teneur en eau des tissus. C'est en 1973, toujours aux Etats-Unis, que P. Lauterbur obtint les premières images du corps humain en IRM. Mais il fallut attendre 1980 pour pouvoir observer les premières images IRM in vivo de l'encéphale humain, fournies par Hawkes.

En général, le but le plus important de l'analyse des images IRM du cerveau, est l'extraction de l'information clinique, qui permet le diagnostic et le traitement de la maladie ; cette tâche peut être réalisée par la segmentation. La littérature en traitement d'images est riche en méthodes de segmentation, mais peu de méthodes concernent les pathologies. D'une part, ces méthodes conçues initialement pour les structures saines, trouvent leurs limites dès qu'une pathologie vient désorganiser l'agencement structurel, et altérer les valeurs radiométriques des tissus cérébraux. D'autre part, lorsqu'il s'agit de tumeurs du cerveau, d'autres problèmes se posent, ce qui rend leur segmentation plus difficile : Il existe une large

classe de types de tumeurs, qui ont une grande variété de formes et de tailles, et qui peuvent donc apparaître à n'importe quel endroit, et dans différentes intensités de l'image ; certaines d'entre elles peuvent également déformer les structures environnantes, ou être associées à un œdème ou à une nécrose.

Les méthodes dédiées à la détection de tumeurs cérébrales sont encore à un stade exploratoire, et les quelques techniques publiées à ce jour souffrent d'un manque de robustesse, de précision, et nécessitent dans leur majorité une interaction manuelle.

Problématique

La segmentation des structures anatomiques cérébrales est un problème ardu, et reste un sujet de recherche de forte actualité dans le domaine médical. La difficulté à segmenter une image est due à la complexité structurelle des images IRM, et du contraste souvent insuffisant pour extraire la structure d'intérêt, sans aucune connaissance a priori sur sa forme et sa localisation.

Le travail que nous nous proposons de faire est de développer une méthode de segmentation robuste et précise, d'une grande classe de tumeurs, à partir d'images IRM cérébrales, en vue de fournir des informations utiles aux praticiens, afin de poser le diagnostic et de mener un traitement thérapeutique.

Objectif et travaux réalisés

Les méthodes traitant la segmentation de tumeurs cérébrales se divisent en trois classes : l'approche contours, l'approche régions et l'approche combinant les deux approches précédentes. Chacune des deux premières méthodes a ses avantages et ses défauts. Pour cela, nous avons choisi de faire coopérer ces deux approches, afin de tirer profit des avantages de l'une et de l'autre, et de diminuer leurs défauts.

Le cadre général de la segmentation de tumeurs du cerveau que nous avons développé comprend deux composantes principales : le prétraitement et la segmentation. L'étape de prétraitement comporte les opérations de réduction d'hétérogénéité d'intensité, de segmentation du cerveau, et du calcul du plan de symétrie inter-hémisphérique.

L'étape de segmentation, fondée sur les informations fournies à l'issue du prétraitement, est subdivisée en deux axes : initialisation et raffinement. Dans la première phase, une segmentation et une détection initiale de la tumeur sont fournies, en employant deux types de méthodes : la classification floue FCM, ou l'analyse de symétrie, suivie par quelques opérations morphologiques. L'algorithme FCM introduit la notion d'ensembles flous dans la définition des classes, afin de prendre en compte des données imprécises et incertaines. Il s'appuie sur l'hypothèse que la tumeur apparaît avec des niveaux de gris spécifiques dans l'image, correspondant à une classe supplémentaire. Le deuxième algorithme s'appuie sur l'hypothèse que la forme du cerveau est approximativement symétrique, et que la tumeur peut

changer cette symétrie. Cette première étape fournit une détection initiale de la tumeur, et des tissus environnants ; elles seront considérées comme étant une initialisation de la deuxième segmentation, qui utilise un contour actif paramétrique, guidé par GVF, contraint par des relations spatiales. L'idée est que les contours de la tumeur doivent être situés entre la frontière de la détection initiale de la tumeur et la frontière des tissus avoisinants.

Organisation du manuscrit

Ce document est organisé en cinq chapitres :

- ❖ Le premier chapitre est consacré à la définition des notions de base sur l'anatomie cérébrale humaine, ainsi qu'à la description des principaux composants du cerveau, nécessaires à la compréhension du mémoire. Un aperçu sur les tumeurs cérébrales, leurs caractéristiques et leurs classifications est donné dans ce chapitre.
- ❖ Dans le deuxième chapitre, nous présentons un état de l'art sur les méthodes de segmentation, afin d'en choisir celles qui sont adaptées au cas de notre étude.
- ❖ Le troisième chapitre est dédié à la présentation de l'étape de prétraitement, ainsi que l'étape initiale de segmentation de la tumeur, basée sur l'approche région.
- ❖ Une nouvelle approche de segmentation, basée sur une coopération régions-contours, intégrant des contraintes, issues de relations spatiales, est exposée au quatrième chapitre.
- ❖ Le cinquième chapitre est le miroir qui reflète la qualité du travail réalisé, et est destiné aux résultats obtenus, par chaque méthode seule, puis par les coopérations proposées, ainsi que les interprétations qui en découlent. Une brève présentation de l'interface utilisateur développée, et de son manuel, sera ajoutée en annexe.
- ❖ Enfin, une conclusion générale et des perspectives concernant le travail présenté achèvent ce document.

CHAPITRE 1

GENERALITES

L'objectif de ce chapitre est de fixer le cadre applicatif que nous avons envisagé. Il contient les notions nécessaires à la compréhension de notre mémoire.

Au début, nous allons présenter quelques éléments d'anatomie du système nerveux central afin de préciser le vocabulaire et les notions nécessaires qui serviront de base pour la compréhension de ce qui se passe à l'intérieure du cerveau humain.

Puis, nous explicitons brièvement L'IRM qui est la technique utilisée par excellence pour la visualisation du corps humain (en particulier le cerveau).

Enfin, nous étudions en détaille les tumeurs qui est parmi les maladies neurodégénératives qui peuvent atteindre le cerveau.

1.1 Anatomie du cerveau

1.1.1 Organisation générale du système nerveux

On appelle système nerveux l'ensemble constitué par le cerveau, la moelle épinière et les nerfs. Le cerveau est l'organe central supervisant le système nerveux, on subdivise le système nerveux en deux: le système nerveux central et le système nerveux périphérique. [S2]

- Le système nerveux central comprend :
 - l'encéphale constitué par : le cerveau, le tronc cérébral et le cervelet ;
 - la moelle épinière.

Le cerveau et la moelle épinière sont enveloppés par les méninges. Elles comprennent trois feuillets, entre lesquels circule le liquide céphalorachidien. Nous donnerons plus de détails par la suite.

- Le système nerveux périphérique est composé de racines nerveuses rachidiennes, de plexus, de ganglions nerveux, et de nerfs. On distingue deux types de nerfs :
 - Les nerfs crâniens et spinaux ;
 - Les nerfs végétatifs ou autonomes, constituants du système nerveux végétatif ou autonome. Ils sont subdivisés en deux systèmes qui s'opposent la plupart du temps : les systèmes sympathique et parasympathique.

1.1.2 Les différentes parties du cerveau et leurs fonctions

Le cerveau est très bien organisé, il est composé de plusieurs parties qui ont chacune des rôles spécifiques, tout en étant complémentaires les unes des autres.

1.1.2.1 Les hémisphères cérébraux

Les hémisphères cérébraux forment les parties les plus volumineuses du cerveau. Il y a un hémisphère droit et un hémisphère gauche (Figure 1.1).

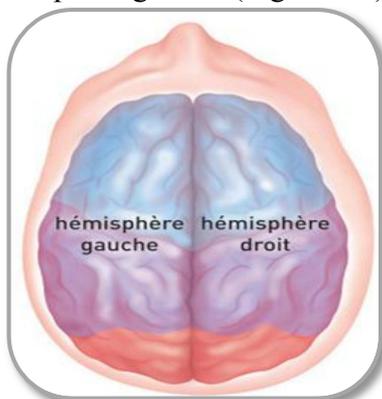


Figure 1.1 : Les deux hémisphères cérébraux

On parle souvent de cerveau droit et de cerveau gauche. Les hémisphères contrôlent l'ensemble de nos fonctions mentales supérieures : mouvements volontaires, pensées, apprentissage, mémoire, etc. [3]. Chaque hémisphère est partagé en quatre zones appelées lobes (Figure 1.2), dans lesquelles ces différentes fonctions sont gérées : le lobe frontal, le lobe pariétal, le lobe temporal et le lobe occipital.

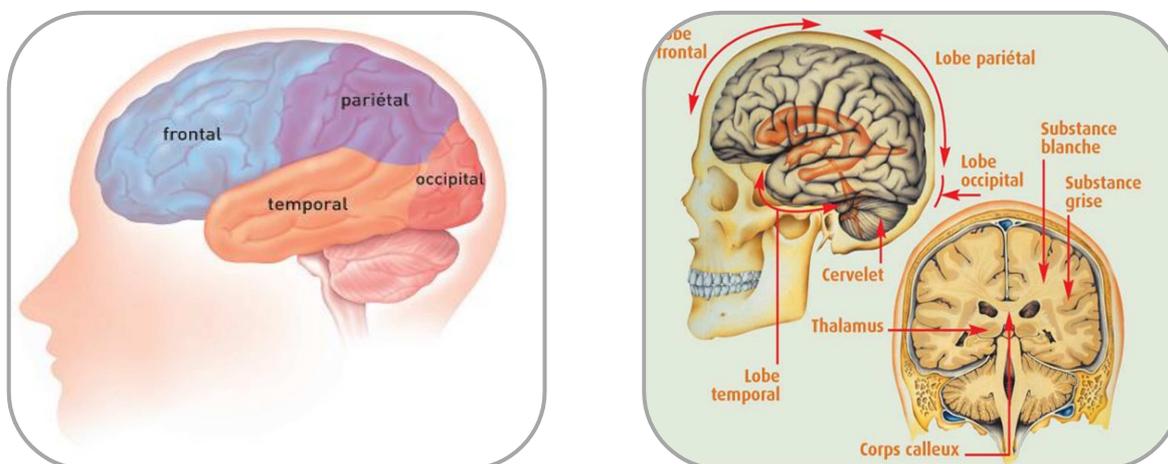


Figure 1.2 : Les différents lobes d'un cerveau humain

Le tableau ci-dessous présente les principales fonctions de chaque lobe : [2], [3]

Lobes	Principales fonctions
Lobe frontal	Il est situé dans la partie antérieure (avant) des hémisphères cérébraux, c'est-à-dire juste derrière le front. Il abrite les centres chargés du contrôle musculaire, de la pensée, de la mémoire, du raisonnement et des associations. Selon certains chercheurs il serait également le siège de la personnalité
Lobe pariétal	Il est situé dans la partie moyenne du cerveau. Il reçoit les informations relatives au toucher et à l'orientation spatiale
Lobe occipital	Il est situé à l'arrière des hémisphères, près de l'os occipital du crâne. Il abrite les centres responsables de la vision.
Lobe temporal	Il est situé sur le côté, près des tempes. Il abrite les centres de l'audition, du goût et de la mémoire.

Tableau 1.1 : Principales fonctions des lobes du cerveau

1.1.2.2 Le cervelet

Le cervelet est situé à l'arrière du tronc cérébral, sous les lobes occipitaux. Il nous permet d'avoir des réflexes, de coordonner nos mouvements et de garder l'équilibre. [3]

1.1.2.3 Le tronc cérébral

Le tronc cérébral relie le cerveau et la moelle épinière. Il contient **les** centres nerveux chargés de la régulation des fonctions fondamentales involontaires, comme le rythme cardiaque, la respiration, la digestion ou la température corporelle. Il joue un rôle essentiel dans la transmission des influx nerveux entre la moelle épinière et les hémisphères cérébraux.

Il est également le siège de l'hypophyse. Cette glande produit des hormones qui gèrent une large gamme de fonctions corporelles, et, à leur tour, stimulent d'autres glandes (thyroïde, ovaires, testicules, etc). [2]

1.1.2.4 Les méninges [4]

L'encéphale est entouré de couches protectrices appelées méninges. Elles sont constituées de trois membranes successives (Figure 1.3) :

- la plus interne de ces membranes est la pie-mère, fine, compacte, qui contient les structures veineuses qui ramènent le sang du cerveau vers le cœur ;
- la membrane intermédiaire est l'arachnoïde, ainsi appelée en raison de sa ressemblance avec une toile d'araignée. Entre celle-ci et la pie-mère circule un liquide appelé liquide céphalo-rachidien (LCR) ;
- la membrane la plus externe est la dure-mère, dure et résistante, formée de tissu conjonctif qui protège les couches sous-jacentes des os les entourant.

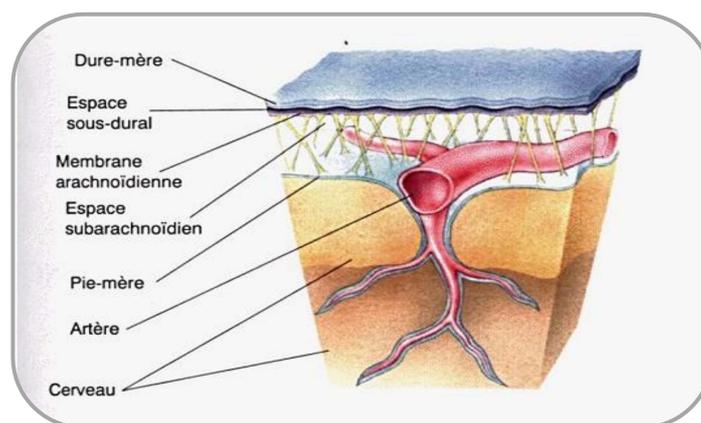


Figure 1.3 : Les méninges

1.1.2.5 Le liquide céphalo-rachidien

Le liquide céphalo-rachidien (LCR) est une substance transparente constituée de 99% d'eau. Il forme un coussin protecteur pour le système nerveux central (SNC) et le nourrit. Le LCR est contenu dans le SNC, dans deux zones anatomiques bien distinctes :

- le système interne : constitué par les ventricules cérébraux (Figure 1.4), qui sont au nombre de quatre : les ventricules latéraux, un dans chaque hémisphère cérébral, le troisième ventricule entre les deux thalamus (Figure 1.2), et le quatrième ventricule en arrière du tronc cérébral. Les ventricules latéraux communiquent avec le troisième ventricule via le trou de Monro (Figure 1.4), et le quatrième ventricule avec le troisième ventricule par l'intermédiaire de l'aqueduc de Sylvius (Figure 1.3). Ce sont les plexus choroïdes contenus dans les ventricules cérébraux qui sécrètent le liquide céphalorachidien ;
- le système externe : appelé également système de résorption. Il s'agit des cavités situées en dessous de l'arachnoïde (Figure 1.2) (cette cavité est plus précisément située entre la pie-mère et l'arachnoïde). [4]

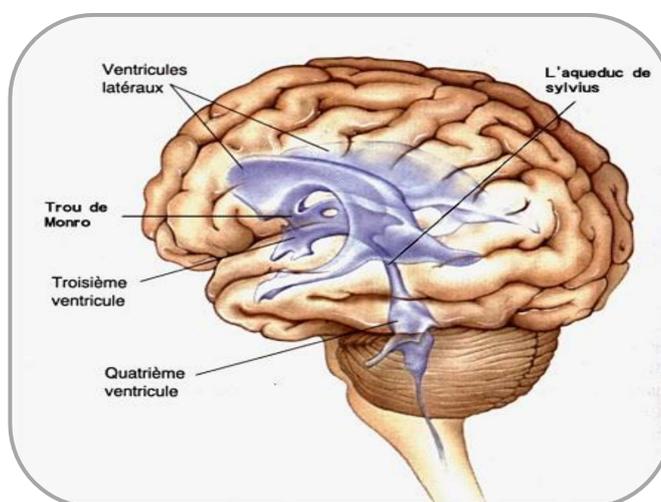


Figure 1.4 : Les ventricules cérébraux. Vue sagittale

Le compartiment ventriculaire et le compartiment de résorption communiquent entre eux au niveau de la partie inférieure du cervelet par un foramen ventriculaire, appelé trou de Magendie.

1.1.3 Les tissus du cerveau

Lorsque l'on observe le cerveau, on remarque que ce dernier est principalement constitué d'une matière blanchâtre à laquelle on donne le nom de **Matière blanche (MB)** (Figure 1.3). A la surface du cerveau se trouve une fine pellicule de matière grisâtre : le **cortex cérébral**, ou **matière grise (MG)**. Cette différence de couleur provient du fait que le cortex contient principalement les corps cellulaires des **neurones** [4], et peut être vu comme le lieu de traitement des données [6]. Alors que la substance blanche est constituée d'un agglomérat d'axones qui relie les différentes aires corticales les unes aux autres, les axones sont responsables de la transmission du flux nerveux, et sont entourés de gaines de myéline de couleur blanchâtre (Figure 1.5). [6]

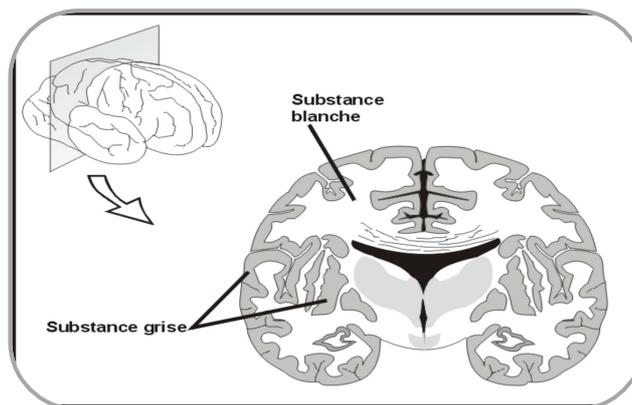


Figure 1.5 : Le cerveau comporte deux types de tissus : MG et MB

Après avoir vu l'anatomie cérébrale, nous verrons par la suite la technique qui permet la bonne visualisation des différentes structures cérébrales.

1.2 Imagerie par résonance magnétique (IRM)

L'IRM est une technique d'imagerie médicale permettant d'obtenir des images numériques en 3D, d'une précision inférieure au millimètre, des tissus cérébraux sains et pathologiques. Initialement développé pour l'aide au diagnostic en milieu médical, ce type d'acquisition permet d'effectuer une analyse neuroanatomique individuelle, de très haute précision.

Le sigle IRM regroupe en fait un ensemble de techniques d'imagerie : outre des images anatomiques et fonctionnelles, l'IRM permet d'obtenir des images de l'organisation spatiale des vaisseaux cérébraux (angiographie IRM), de l'orientation des principaux faisceaux de fibres blanches (IRM de diffusion), de la distribution de sang (IRM de perfusion), ainsi que de la concentration locale de certains métabolites énergétiques et peut-être, bientôt, de certains neurotransmetteurs (spectroscopie IRM). [7]

1.2.1 Principe de l'IRM

Le principe de l'IRM consiste à mesurer l'aimantation des tissus biologiques et à reconstruire une image à partir de ces aimantations (Figure 1.6). En pratique, l'aimantation mesurée est surtout induite par l'hydrogène car :

- l'hydrogène possède des propriétés magnétiques (contrairement à d'autres atomes) ;
- on le trouve en abondance dans le corps humain, principalement dans l'eau et la graisse.

Le champ magnétique produit en IRM permet d'orienter l'aimantation des atomes d'hydrogène (spins) dans une même direction. Les aimantations sont ensuite écartées de cette direction grâce à l'énergie fournie par une onde radiofréquence (RF) générée par une antenne.

L'émission de l'antenne s'interrompant, les spins retournent à leur position (phase de relaxation) en émettant un signal radiofréquence, qui peut être lu par la même antenne. Le signal RMN ne permet pas directement de localiser les sources de ces ondes. En effet, les dimensions de l'objet d'intérêt sont petites devant sa longueur d'onde qui est de l'ordre de quelque mètre à 1.5T ou 3T. On peut en revanche connaître avec une grande précision les fréquences qui lui sont associées. En codant l'espace en fréquence et en phase des signaux émis, il devient possible de reconstruire une image par application d'une transformée de Fourier inverse. L'IRM permet l'acquisition d'un volume complet, soit par acquisition de coupes 2D successives, soit par l'acquisition d'un volume 3D. [5]



Figure 1.6 : Appareil IRM

1.2.2 Modalités d'images IRM

En modifiant les paramètres d'acquisition IRM, notamment le temps de répétition (TR) entre deux excitations et le temps d'écho (TE), temps entre le signal d'excitation et la réception de l'écho, l'utilisateur peut modifier la pondération de l'image, c'est-à-dire faire apparaître les différences de temps T1 et de temps T2 des différents tissus d'un organisme.

➤ **Pondération T1**

En utilisant un temps de répétition court ($TR = 400$ à 600 ms) et un temps d'écho court ($TE = 10$ à 20 ms), on obtient un contraste d'image pondérée en T1, pondération dite « anatomique » (Figure 1.7(a))

➤ **Pondération T2**

En utilisant un temps de répétition long ($TR > 2\,000$ ms) et un temps d'écho long ($TE > 80$ ms), on obtient un contraste d'image dite pondérée en T2, dite aussi pondération « tissulaire » (Figure 1.7 (b))

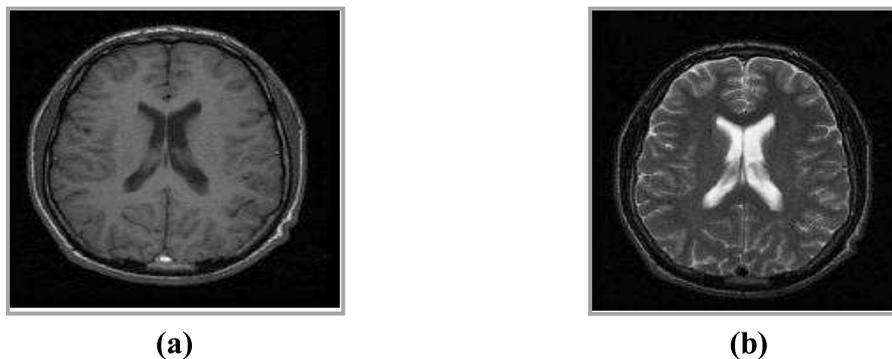


Figure 1.7 : Exemples de modalités d'images IRM
 (a) : Image pondérée en T1, (b) : Image pondérée en T2

➤ Séquence Flair ou Flair T2

L'acronyme FLAIR provient de l'anglais " Fluid Attenuated Inversion Recovery ". C'est une séquence qui supprime le signal provenant du liquide céphalo-rachidien, Le contraste est celui d'un T2 et les lésions apparaissent généralement hyperintenses. Cette séquence est bien adaptée à l'exploitation cérébrale (notamment du cortex et des parois ventriculaires), l'œdème, la nécrose ou encore la gliose.

Les images IRM qu'on va utiliser dans notre étude sont de pondération T1 et T2 en plus d'une séquence Flair.

1.2.3 Observation des tissus dans des images pondérées en T1 & T2 [8]

Dans le tableau suivant on montre la différence entre les tissus observés dans les images pondérées en T1 et les images pondérées en T2, comme on peut la voir aussi sur l'image de la Figure 1.7 :

Tissus en pondération T1 (Du plus foncés au plus claires)	Tissus en pondération T2 (Du plus foncés au plus claires)
l'air, les yeux, l'os et le liquide céphalo-rachidien	l'air, l'os et le sang
les muscles, la peau et la substance grise	les muscles et la peau
la substance blanche	la substance blanche
la graisse et le sang	la substance grise
	la graisse, les yeux et le liquide céphalo-rachidien

Tableau 1.2 : Pondération T1 et pondération T2

La technique de l'imagerie par résonance magnétique a été jugée excellente en termes de visualisation du corps humain (en particulier le cerveau), et nous allons voir dans la partie qui suit son intérêt majeur dans le diagnostic des tumeurs cérébrales. [S7], [9], [8]

1.3 Les tumeurs du cerveau

1.3.1 Qu'est-ce que le cancer?

Le mot «cancer» est utilisé pour désigner de nombreuses maladies différentes, ayant pour point commun la présence de cellules cancéreuses. La plupart du temps, ces cellules cancéreuses forment des tumeurs dites «malignes», qui ont tendance à s'accroître et à se disséminer. Les tumeurs sont des excroissances «anormales» présentes dans les tissus pathologiques). [2]

1.3.2 Qu'est-ce qu'une tumeur cérébrale

Une tumeur est toute masse qui résulte d'une multiplication (division) accrue (prolifération) de cellules anormales dans le cerveau et la moelle épinière. Elle peut être également appelée un néoplasme ou une excroissance (masse). Elle peut se développer dans n'importe quelle zone du cerveau : les hémisphères, le cervelet, le tronc cérébral, l'hypophyse. [S2]. Les tumeurs cérébrales malignes représentent 1 à 2% de l'ensemble des cancers. Chez les enfants, elles occupent le second rang, juste après les leucémies (20–40% de toutes les tumeurs malignes). Ce sont les tumeurs solides les plus fréquentes chez les enfants. [2]

1.3.3 Les différents types de tumeurs cérébrales

Il existe différents types de tumeurs cérébrales : bénignes, malignes ou intermédiaires.

➤ Les tumeurs bénignes (non cancéreuses)

Les tumeurs dites bénignes, sont constituées de cellules qui croissent lentement. Comme elles n'envahissent pas les tissus avoisinants, elles ne sont pas cancéreuses. Elles peuvent comprimer des tissus ou des organes, mais elles demeurent localisées dans une partie du corps et ne mettent généralement pas la vie en danger. Toutefois, elles peuvent être très dangereuses, car en raison du volume non extensible de la boîte crânienne, elles peuvent comprimer des zones vitales du cerveau, et causer des troubles importants. Il peut également arriver qu'une tumeur bénigne s'aggrave et se transforme en cancer, mais généralement ce processus est lent. [2], [S2], [S5]

➤ Tumeurs malignes (cancéreuses)

Les tumeurs malignes, par contre, peuvent détruire des tissus proches par leur croissance rapide et leur caractère envahissant. De plus, les cellules cancéreuses des tumeurs malignes peuvent se mettre à circuler dans le sang ou le système lymphatique

et envahir des ganglions (nodules¹ répartis dans tout l'organisme et ayant une fonction immunitaire). Les cellules cancéreuses, ainsi disséminées, peuvent également former de nouvelles tumeurs à distance du tissu d'origine: les métastases. Le cerveau est souvent le siège de métastases provenant d'autres organes, mais il n'est lui-même que très rarement à l'origine de métastases. [3], [S2], [S5]

➤ Les tumeurs intermédiaires

Ce sont des tumeurs dites atypiques ou évolutives, qui, bénignes au début, peuvent se transformer en cancer dans un laps de temps variable. [3]

1.3.4 Tumeurs cérébrales primaires et secondaires (métastatiques) [3], [S2]

Les tumeurs cérébrales peuvent être primaires ou secondaires.

➤ Les tumeurs cérébrales primaires (primitives)

Les tumeurs cérébrales dites «primaires» sont celles qui se développent directement à partir des cellules du cerveau et de son enveloppe (à l'intérieur du crâne). Elles peuvent être bénignes ou malignes.

➤ Les tumeurs cérébrales secondaires

Ce sont des tumeurs constituées de cellules provenant d'un autre organe, le plus souvent des poumons, des seins, des reins ou de la peau (mélanome). Des cellules tumorales de ces organes peuvent migrer vers le cerveau en empruntant le plus souvent la voie sanguine. Les métastases représentent entre 30 et 40% de toutes les tumeurs intracrâniennes. Les tumeurs cérébrales métastatiques sont toujours malignes.

Note : Contrairement aux autres cancers, les tumeurs cancéreuses du cerveau n'entraînent pas de métastases à l'extérieur du cerveau. Elles ne s'étendent pas à d'autres organes.

1.3.5 Gradation selon l'OMS [S6]

La classification officielle des tumeurs cérébrales, proposée par l'Organisation Mondiale de la santé (OMS), s'effectue selon des critères d'origine cellulaire et de leur degré de malignité. Cette classification est présentée dans le tableau 1.3

¹ En médecine, un **nodule** est une formation anormale, arrondie, palpable dans ou sous la peau, qui peut être une tumeur bénigne ou maligne.

Anaplasie :	
Terme désignant le phénomène au cours duquel certaines cellules, entrant dans la composition des tissus, perdent leurs caractères propres et changent anormalement de structure	
Grade I Tumeurs bénignes	Tumeurs à croissance lente et circonscrites (limites bien définies)
Grade II Tumeurs bénignes	Tumeurs à croissance lente, mais, contrairement aux tumeurs de grade I, leurs limites sont imprécises
Grade III Tumeurs malignes	Tumeurs anaplasiques. Un ou plusieurs foyers « anaplasiques » se sont développés au sein d'une tumeur préexistante de bas grade (I ou II). Leurs croissances est plus rapide que celles des tumeurs de bas grade.
Grade IV Tumeurs malignes	Les tumeurs de grade IV présentent une anaplasie trop prononcée. Leurs croissances est plus rapide que celles des tumeurs de bas grade.

Tableau 1.3 : Classification des tumeurs cérébrales selon l'OMS

1.3.6 Classification des tumeurs cérébrales selon la localisation, le type et l'agressivité

Les tumeurs cérébrales peuvent être classées selon trois caractéristiques [3] :

➤ Leur localisation dans le cerveau

La tumeur cérébrale peut entraîner des troubles très différents, selon la zone dans laquelle elle se développe dans le cerveau. Par conséquent, sa localisation permet un choix adéquat du traitement à appliquer. Une tumeur située à la surface du cerveau par exemple, est généralement plus facile à extraire qu'une tumeur située au centre du cerveau.

➤ Leur type

Les tumeurs cérébrales varient selon le type des cellules du cerveau à partir desquelles elles se développent, et portent généralement le nom de ces cellules. Les gliomes se développent à partir des cellules gliales, qui nourrissent et soutiennent les neurones ; les méningiomes se développent à partir des cellules composant les méninges (enveloppe du cerveau) ... etc. Et selon leur type, les tumeurs ne se comportent pas de la même manière. Certaines se développent plus vite que d'autres, ou ont un risque accru de récurrence, par exemple.

➤ Leur degré d'agressivité

Plus la tumeur se développe rapidement, plus elle est jugée agressive. Les tumeurs du cerveau sont classées en différents grades, selon leur agressivité, du haut, au bas grade. Ce dernier peut être exprimé par un chiffre romain variant entre I et IV. Le grade I correspond aux tumeurs non cancéreuses, ce sont les moins agressives. Le grade IV correspond aux tumeurs les plus agressives. Connaître le grade d'une tumeur est déterminant dans le choix des traitements et dans le pronostic. Plus le grade est bas, plus le pronostic est favorable.

Il existe plusieurs types de tumeurs selon ces trois caractéristiques, ils sont présentés en détail sur l'annexe A.

1.3.7 Classification des tumeurs selon leurs apparences radiologiques

En se basant sur l'apparence radiologique du contraste des tumeurs contrastée en T1, et sans considérer l'histologie des tumeurs, on peut classifier les tumeurs cérébrales en 4 classes : non contrastée, contrastée sans œdème, contrastée avec œdème et partiellement contrastée. [1]

1.3.7.1 Tumeurs non contrastées (NCON)

Pour ce type de tumeur on ne fait pas l'injection du produit de contraste donc on nomme ce type de tumeur « tumeur non contrastée », (NCON). Ici, la tumeur apparaît en hypo-intense dans les images pondérées en T1 (Figure 1.8(a)), et les images pondérées en T1 avec contraste rehaussé, elle apparaît plus foncée que la MG (Figure 1.8(b)). Dans les images pondérées en T2 et flair, elle apparaît en hyper-intense (Figure 18(c)). Les astrocytomes de bas grade, les gangliogliomes et les oligodendrogliomes sont les tumeurs les plus fréquentes pour cette catégorie.

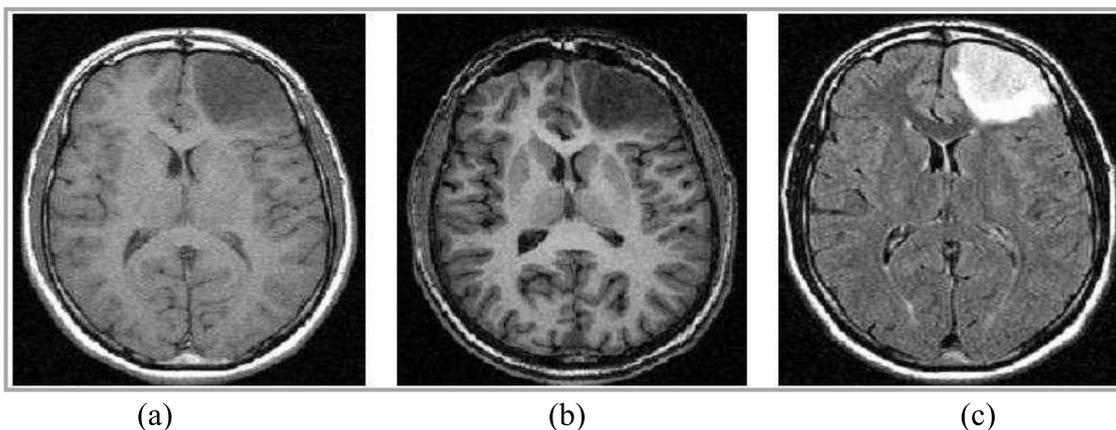


Figure 1.8 : Tumeur non contrastée

(a) : Coupe axiale d'une image pondérée en T1, (b) : Image (a) avec rehaussement de contraste, (c) : Image flair

1.3.7.2 Tumeurs contrastées sans œdème (CONSO)

Ces tumeurs sont contrastées grâce à l'injection du gadolinium (produit de contraste), mais elles ne contiennent pas d'œdème, donc on a intitulé ce type « Contrastée sans œdème », (CONSO). Dans les images pondérées en T1 avec contraste rehaussé, approximativement tous les pixels (ou voxels) de la tumeur apparaissent en hyper-intense (Figure 1.9(b)). Ces tumeurs sont sans œdème et apparaissent en hypo-intense dans les images pondérées en T1 et hyper-intense dans les images T2 et flairs. Dont on peut citer quelques types les méningiomes, les épépendymomes, lymphomes...etc. [1]

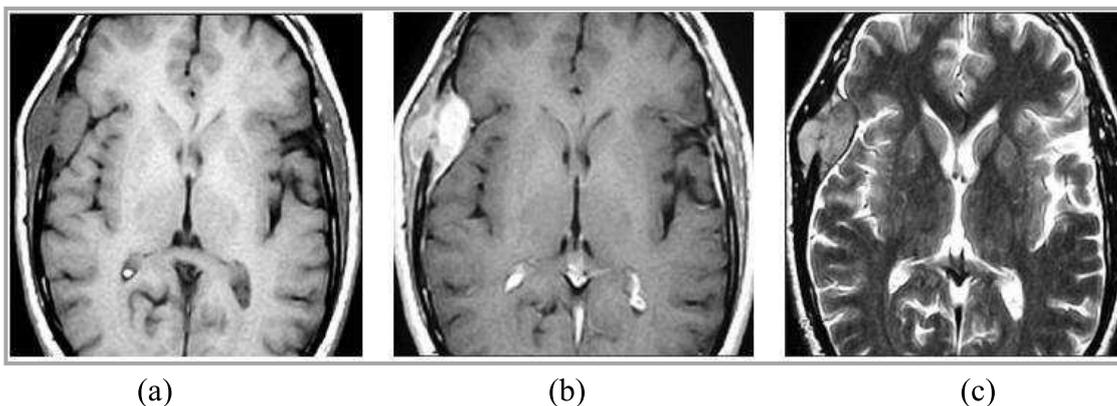


Figure 1.9 : Tumeur contrastée sans œdème

(a) : Coupe axiale d'une image pondérée en T1, (b) : Image (a) avec contraste rehaussé, (c) : Image (a) pondérée en T2.

1.3.7.3 Tumeurs contrastées avec œdème (CONAO)

Ces tumeurs ont deux sections : la section solide et l'œdème. Avec l'injection du produit de contraste, la section solide devient contrastée et apparaît en hyper-intense, dans les images pondérées en T1 avec rehaussement de contraste (Figure 1.10(b)), et en hypo-intense dans les images pondérées en T1 (Figure 1.10(a)). Pour les images pondérées en T2 et en flair, les deux sections apparaissent en hyper-intense (Figure 1.10(c)). Les astrocytomes anaplastiques (haut grade), les oligodendrogliomes (haut grade), et quelques types de méningiomes peuvent être incluses dans cette catégorie. [1]

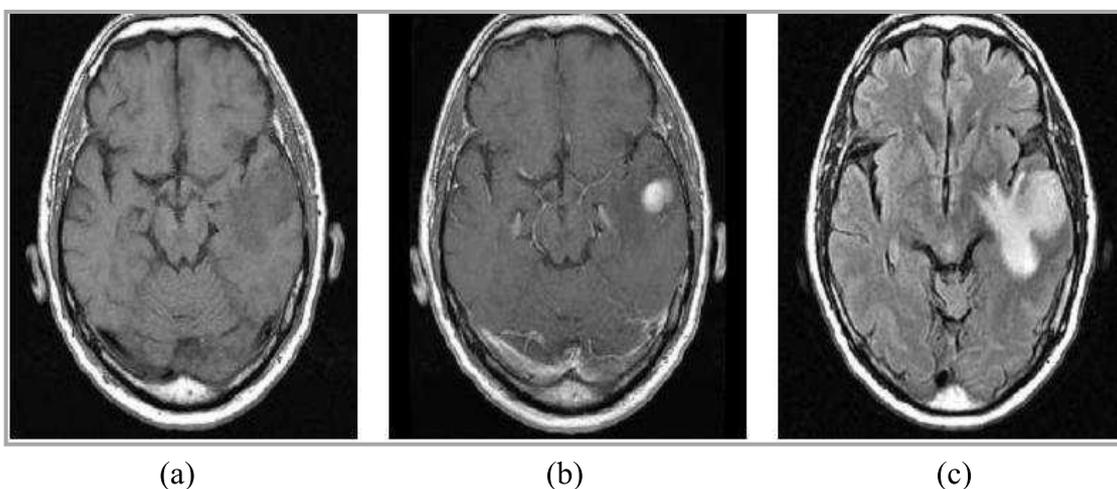


Figure 1. 10 : Tumeurs contrastées avec œdème

(a) : Coupe axiale d'une image pondérée en T1, (b) : Image (a) avec contraste rehaussé, (c) : Image Flair.

1.3.7.4 Tumeurs partiellement contrastées (PCON)

Ces tumeurs présentent trois sections, la section centrale qui est la nécrose, la section solide entourant la nécrose, et la troisième section est l'œdème, qui entoure la section solide.

Dans les images pondérées en T1, les trois sections apparaissent en hypo-intense, alors que la nécrose est la plus foncée. Dans les images pondérées en T1 avec contraste rehaussé, la nécrose et l'œdème apparaissent en hypo-intense, alors que la partie solide, en présence du produit de contraste, devient contrastée et apparaît en hyper-intense. Pour les images pondérées en flair, l'œdème et la section solide apparaissent en hyper-intense, alors que la nécrose apparaît hypo-intense. Les glioblastomes de haut grade et les oligodendrogliomes présentent ces caractéristiques (Figure 1.11). [1]

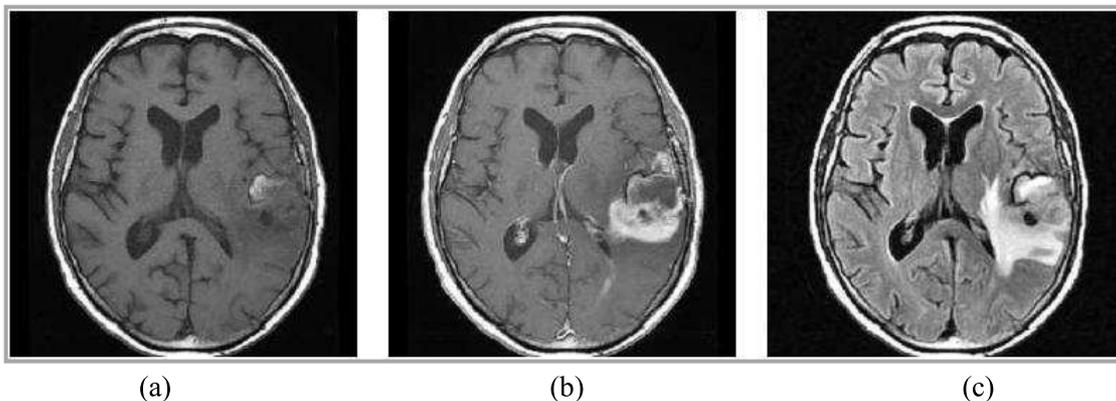


Figure 1.11 : Tumeurs partiellement contrastées

(a) : Coupe axiale d'une image pondérée en T1, (b) : Image (a) avec contraste rehaussé, (c) : Image Flair.

1.3.8 Causes des tumeurs cérébrales

Aucun conseil de prévention ne peut être proposé afin de prévenir l'apparition de tumeur cérébrale primaire. Par ailleurs, les risques de développer une tumeur secondaire ou métastatique peuvent être diminués si la tumeur initiale (poumon, sein ou rein), est dépistée et soignée à temps. [S2]

De nombreuses études scientifiques ont été menées, ou sont en cours, pour tenter de déterminer les facteurs qui favorisent l'apparition d'une tumeur au niveau du cerveau. On parle de facteurs de risques. Trois types de facteurs de risques sont étudiés : les risques liés à l'environnement, à l'hérédité et aux virus.

Un facteur de risque n'explique pas à lui seul pourquoi une tumeur est apparue ; en effet, pour deux personnes confrontées au même risque, l'une peut développer une tumeur et l'autre non. À l'inverse, une personne peut être atteinte d'une tumeur, alors qu'elle n'est concernée par aucun facteur de risque. [3], [2]

➤ Les risques liés à l'environnement

Les études scientifiques cherchent depuis plusieurs années à déterminer l'influence de l'environnement dans l'apparition des tumeurs du cerveau. Ces études portent sur :

- l'influence de certaines substances chimiques

Plusieurs substances chimiques sont reconnues comme cancérogènes² pour le cerveau. Il s'agit de substances chimiques utilisées dans différentes activités professionnelles, telles que la fabrication de caoutchouc synthétique et de certains médicaments, la production de polyvinyle, de pétrole brut et de ses produits dérivés, l'industrie nucléaire et l'armement, et enfin la manipulation de pesticides. Ces substances représentent un risque pour les personnes qui y sont exposées à des doses élevées et pendant une longue durée.

- Les conséquences de l'exposition à des champs électromagnétiques

Le risque lié à l'exposition régulière à des champs électromagnétiques, comme les téléphones portables, les lignes à haute tension ou certains appareils électroménagers, est encore en cours d'évaluation. Les spécialistes n'ont pas clairement déterminé si cette exposition peut entraîner des tumeurs du cerveau.

Quant à l'utilisation de téléphones portables, un principe de précaution s'impose. Les études n'ont pas définitivement tranchées, mais elles vont dans le sens d'un risque possible, en particulier chez l'enfant et l'adolescent. Par précaution, il est donc conseillé de limiter l'utilisation du téléphone portable, et de ne pas le garder sur soi. Pendant les communications, l'utilisation d'une oreillette est recommandée.

➤ Les risques liés à l'hérédité

La grande majorité des tumeurs du cerveau n'ont aucun lien héréditaire. Ce n'est pas parce qu'une personne a une tumeur du cerveau que les autres membres de sa famille ont un risque accru de développer le même type de tumeur. Un risque héréditaire existe néanmoins pour deux types de tumeurs du cerveau : Le neurinome et le neurofibrome. Ces tumeurs représentent moins de 5% de l'ensemble des tumeurs cérébrales. Ce sont des tumeurs bénignes, qui se développent sur le nerf auditif, reliant le cerveau et l'oreille. Ces tumeurs sont souvent liées à une maladie génétique, appelée neurofibromatose. La neurofibromatose n'entraîne pas systématiquement une tumeur du cerveau.

➤ Le risque lié à des virus

Selon les études scientifiques actuelles, il n'y a pas de lien entre les virus et l'apparition d'une tumeur. Seul le virus du Sida (le VIH), qui affaiblit les défenses de l'organisme, peut favoriser, de façon indirecte, l'apparition d'une tumeur, appelée lymphome du cerveau.

1.3.9 Signes et symptômes associés à la présence de tumeurs cérébrales

Il existe un grand nombre de tumeurs différentes du cerveau. Selon leur localisation, la vitesse à laquelle elles se développent et leur agressivité, les tumeurs n'entraînent pas les mêmes symptômes, et n'ont pas la même gravité. Les symptômes des tumeurs du cerveau ne sont pas systématiques. Il s'agit de maux de tête persistants, de crises d'épilepsie ou de

² C'est-à-dire pouvant favoriser la survenue d'une tumeur cancéreuse du cerveau

troubles plus ou moins importants des fonctions gérées par le cerveau : changement de personnalité et d'humeur, déficits moteurs, troubles de la vue ou du langage, perte de sensibilité, nausées matinales/vomissements, vertige/étourdissement...

Ces symptômes ne sont pas spécifiques des tumeurs cérébrales. Ils peuvent avoir d'autres causes. C'est leur caractère persistant ou inhabituel qui doit amener à consulter son médecin. [3], [S1]

1.3.10 Diagnostic d'une tumeur du cerveau

Le médecin traitant joue un rôle important dans le diagnostic. En cas de suspicion de tumeur, l'intervention de plusieurs médecins spécialistes est ensuite indispensable : neurologue, neurochirurgien, neuro-oncologue, radiologue, anatomopathologiste (appelé aussi pathologiste), etc. Le diagnostic d'une tumeur du cerveau se fait en plusieurs étapes [3]:

- un examen clinique et neurologique complet ;
- des examens d'imagerie ;
- un examen anatomopathologique, qui consiste à analyser un échantillon de la tumeur.

➤ Examen clinique et neurologique

Il consiste à évaluer l'état de santé général d'une part, et le bon fonctionnement du système nerveux d'autre part. Le médecin impose des questions sur les symptômes ressentis, les antécédents médicaux, personnels, familiaux et chirurgicaux, ainsi que sur l'état de santé général [7]. Il examine l'ensemble du corps (tension artérielle, battements du cœur, etc), puis évalue le fonctionnement du système nerveux grâce à différents tests [3]:

- des exercices musculaires (marcher, serrer la main, sourire pour vérifier le bon fonctionnement des muscles du visage...);
- un test des réflexes ;
- un test de sensibilité (sensation au toucher, réaction au chaud et au froid ou à une légère piqûre...);
- un test d'équilibre et de coordination des mouvements ;
- un examen de la vue, des pupilles, des mouvements des yeux et du fond de l'œil ;
- un test d'audition ;
- un test de langage (capacité à trouver le bon mot par exemple), de lecture, d'écriture ou de dessin ;
- des exercices mentaux (calculs simples), tests de mémoire, de compréhension, etc.

L'examen clinique et neurologique permet de constater d'éventuelles anomalies. Pour déterminer si ces anomalies sont dues à une tumeur ou non, des examens d'imagerie sont indispensables.

➤ L'examen d'imagerie

Les examens d'imagerie consistent à réaliser des images précises du cerveau. Ils permettent de détecter une tumeur, de la localiser de façon précise, de mesurer sa taille et d'évaluer les conséquences qu'elle a, ou peut avoir, sur le cerveau. Pour le diagnostic d'une tumeur du cerveau, une IRM est indispensable. Pour des raisons pratiques, l'IRM est souvent précédée d'un scanner.

- Scanner

L'appareil est constitué d'un lit d'examen et d'un gros anneau (Figure 1.12). Le patient est allongé sur la table d'examen, et la tête est placée à l'intérieur de l'anneau. Un faisceau de rayons X, dirigé sur le crâne, permet d'obtenir plusieurs centaines de radiographies. [S2]

Les radiographies sont transmises à un ordinateur, qui reconstitue des images du cerveau dans les trois dimensions. Généralement, un produit de contraste, à base d'iode, est injecté avant ou pendant l'examen. L'examen dure environ 15 minutes et n'est pas douloureux.



Figure 1.12 : Scanner

- IRM

L'examen d'IRM dure généralement entre 15 et 30 min ; il n'est pas douloureux, mais bruyant. En raison du champ magnétique, tous les objets métalliques doivent être enlevés avant de réaliser une IRM ; certains implants métalliques sont des contre-indications à l'examen : pacemaker, prothèse auditive, valve cardiaque mécanique, pompe à insuline...

Contrairement au scanner, le patient est mis presque en entier à l'intérieur de l'appareil, en position allongé (Figure 1.13). Pour les enfants les plus jeunes, l'IRM est réalisé sous anesthésie générale, pour éviter qu'ils ne bougent pendant l'examen. [S2]



Figure 1.13 : Examen d'IRM

➤ Examen anatomopathologique

Après les examens d'imagerie, l'analyse d'un échantillon de la tumeur est indispensable pour compléter le diagnostic. Cette analyse est appelée examen anatomopathologique, souvent abrégé par les médecins par « anapath ». L'objectif de cet examen est de déterminer toutes les caractéristiques de la tumeur : sa nature exacte, sa composition, son degré d'agressivité. C'est seulement après cet examen que les médecins peuvent affirmer notamment, si la tumeur est cancéreuse ou non, et quel est son grade. L'examen anatomopathologique nécessite de prélever un échantillon de tumeur. Il peut être réalisé [3], [7] :

- Soit avant de commencer les traitements : dans ce cas, les médecins pratiquent une intervention chirurgicale spécifique, appelée biopsie, au cours de laquelle ils prélèvent un échantillon de tumeur, qui est ensuite analysé.
- Soit juste après l'intervention chirurgicale, destinée à retirer la totalité de la tumeur. Dans ce cas, les médecins analysent un ou plusieurs petits morceaux de la tumeur qu'ils viennent de retirer. Cette intervention, appelée intervention à ciel ouvert, a un double objectif : elle permet à la fois de compléter le diagnostic, et de traiter la tumeur.

Dans des cas très rares, notamment chez des personnes âgées, l'examen anatomopathologique ne peut pas être réalisé, car aucun prélèvement n'est possible. Les médecins peuvent alors, exceptionnellement, décider de traiter directement la tumeur par une radiothérapie ou une chimiothérapie.

1.3.11 Traitements envisageables [S2], [7]

Dans la majorité des cas, une équipe multidisciplinaire élabore la meilleure approche à adopter, afin de traiter une tumeur cérébrale spécifique. En effet, hebdomadairement,

neurochirurgiens, radio-oncologues, oncologues et anatomopathologistes se rencontrent afin de partager les données médicales et radiologiques de différents patients, et ainsi d'élaborer un plan de traitement pour chacun, à la lumière de ces informations suivantes :

- Le type de tumeur ;
- La taille et la localisation de la tumeur ;
- L'agressivité de la tumeur ;
- L'évolution de la tumeur primaire, s'il s'agit de traiter des métastases cérébrales ;
- Les états physique, émotif et cognitif du patient.

Le plan de traitement est discuté avec le patient. Certes, son état physique est en cause, mais ses convictions à l'égard de sa maladie, et du traitement, sont également à considérer.

➤ La chirurgie [S2]

La chirurgie peut avoir différents objectifs, elle est utilisée régulièrement dans le traitement des tumeurs primaires, parfois dans celui des métastases. Elle est généralement effectuée sous anesthésie générale, sauf lorsqu'elle est en condition stéréotaxique.

➤ La radio-oncologie ou radiothérapie [S2]

La radiothérapie est utilisée fréquemment dans le traitement des tumeurs cérébrales malignes, parfois bénignes. Elle consiste à diriger des faisceaux de radiation (électrons ou photons) directement sur la tumeur et son pourtour. Ces rayons traversent les tissus et empêchent les cellules de se multiplier. En principe, les rayons agissent de façon similaire sur les cellules saines et sur les cellules cancéreuses. Cependant, les cellules saines ont une meilleure capacité à réparer les effets dus aux rayons que les cellules tumorales.

La radiothérapie peut être soit un complément à la chirurgie, et/ou à l'oncologie (chimiothérapie), soit être utilisée seule.

➤ L'oncologie ou la chimiothérapie [S2]

La chimiothérapie est utilisée fréquemment dans le traitement des tumeurs cérébrales malignes. Elle peut être soit un complément à la chirurgie, et/ou à la radiothérapie. Il s'agit d'administrer de puissants médicaments, les cytotoxiques, selon des modalités très précises. Actuellement, il existe de nombreux médicaments cytotoxiques.

➤ Les traitements médicamenteux

Certains médicaments sont régulièrement associés au traitement chirurgical, de radiothérapie et/ou de chimiothérapie. Les plus communs sont les corticostéroïdes et les anticonvulsivants.

Discussion

Dans ce chapitre, nous avons abordé, en premier lieu l'anatomie cérébrale, et en particulier les structures du système nerveux central, puis nous avons fait un aperçu général sur l'imagerie de la tumeur du cerveau (IRM), et enfin, nous avons présenté les différents types des tumeurs et leurs classifications.

On s'est basé sur l'étude des caractéristiques des tumeurs cérébrales, basées sur leur classification dans le système de l'organisation mondiale de la santé (OMS), pour résumer plusieurs classifications, basées sur la localisation des tumeurs, leur type, leur agressivité, leur apparence radiologique et sur la modification des structures avoisinantes.

Nous avons vu aussi que l'IRM est une technique de visualisation du cerveau par excellence, vu la grande quantité d'information qu'elle fournit, tout en assurant le bien être du patient, mais, la problématique est comment peut-on distinguer les différentes régions du cerveau sur cette image ?

Pour un expert, et vu son expérience et l'importante quantité de connaissances qu'il a acquises, il peut répondre à cette question, mais il peut avoir des difficultés parfois à limiter les différentes régions, présentes dans le cerveau, avec exactitude, surtout lors de la présence d'une pathologie.

Pour éviter d'éventuels effets indésirables, la solution pour les imageurs est l'analyse d'images, dont la segmentation est l'opération clé. Suite à cela, la littérature a connu un nombre énorme de méthodes de segmentation, nous allons donc fournir un état de l'art sur ces méthodes dans le chapitre suivant.

CHAPITRE 2

ETAT DE L'ART

La segmentation est l'une des étapes les plus importantes de l'analyse d'images. Elle vise à décomposer complètement ou partiellement une image en régions qui possèdent une corrélation forte avec les objets d'intérêt (à détecter) dans l'image, ce qui permet par la suite de visualiser et de quantifier ces objets.

Dans le contexte de notre étude, l'objectif visé est de détecter précisément la zone tumorale, c'est-à-dire de l'isoler des principales structures cérébrales. Notre problématique est donc de segmenter les tumeurs cérébrales, à partir des images IRM. Cette segmentation doit naturellement être reproductible, précise et fiable.

Dans ce chapitre, nous allons nous efforcer d'esquisser un état de l'art sur les méthodes de segmentation d'images. Cette revue des différentes techniques et approches n'est exhaustive, mais elle a pour but de montrer la grande diversité de ce vaste domaine.

L'analyse d'une image cherche à passer d'une grande quantité d'informations de bas niveau (i.e. les pixels), à une description symbolique de haut niveau pouvant aider à obtenir une interprétation structurale de cette image. La distinction entre traitement de bas ou de haut niveau est liée au contenu sémantique des entités traitées, et extraites de l'image.

Les traitements de bas niveau opèrent en général, sur les grandeurs calculées, à partir des valeurs attachées à chaque point de l'image, sans faire nécessairement la liaison avec la réalité qu'elles représentent. Par exemple, la détection des contours est un traitement de bas niveau, qui est effectué «sans comprendre» l'image. Le contour détecté peut très bien ne pas correspondre à un bord d'objet dans la réalité, et ne présenter aucun intérêt, Ainsi les traitements de bas niveau opèrent plutôt sur des données de nature numérique. [10]

A l'opposé, **les traitements de haut niveau** s'appliquent à des entités, de nature symbolique, associées à une représentation de la réalité extraite de l'image. Ils sont relatifs à l'interprétation et à la compréhension de l'image, et sont exprimés avec des mots du vocabulaire de l'application. Par exemple, des zones d'une image aérienne peuvent être caractérisées par leur forme (rectangulaire, linéique,..), être étiquetées avec les termes : bâtiment, route, bosquet, ombre,...etc. [10]

Les étapes que comprend le traitement d'image vont être explorées dans la Figure suivante :

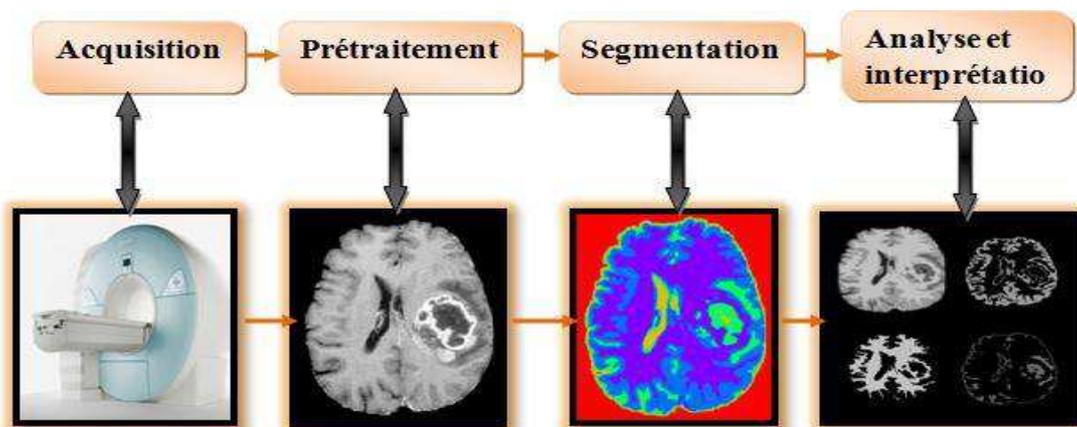


Figure 2.1 : Chaîne d'analyse d'images

La segmentation est sans doute la tâche qui, en traitement d'images, mobilise le plus d'efforts. Certes, cette étape importante n'apparaît pas toujours de façon explicite, mais on peut affirmer qu'elle est toujours présente.

- En imagerie médicale, la segmentation peut aider le médecin dans son diagnostic ;
- En compression vidéo, elle permet de traiter différemment une zone d'intérêt, qui bénéficiera d'une plus grande précision, du reste de l'image qui pourra être plus fortement compressé ;
- En indexation, la segmentation sert à extraire un objet que l'on souhaiterait retrouver dans d'autres images ;

- En postproduction cinématographique, un personnage segmenté peut être remplacé dans un autre décor, ce qui est le cas notamment pour les présentateurs de la météo ;
- En vidéosurveillance, la détection d'objets en mouvement peut révéler la présence d'intrus, ou évaluer la fluidité d'un trafic routier.

Les applications sont nombreuses, et la liste des exemples cités est loin d'être exhaustive. [11]

2.1 Qu'est ce que la segmentation

2.1.1 Définition littéraire de la segmentation

La segmentation est usuellement définie comme l'opération consistant à partitionner une image en régions homogènes. Une région est alors définie comme un ensemble de pixels qui partagent une caractéristique commune comme l'intensité, la couleur, la texture, le mouvement, la distance, ... etc. [12]. Ces régions et contours sont supposés être pertinents, c'est-à-dire que les régions doivent correspondre aux parties significatives des objets du monde réel, et les contours à leurs contours apparents. [13]

La segmentation sera validée si les conditions suivantes sont vérifiées [14] :

- Tous les composants de l'image doivent être classés, autrement dit chaque pixel doit appartenir à une classe ;
- Les régions doivent être homogènes ;
- Les différentes régions doivent être séparées (disjointes).

Le contexte de notre étude repose plus particulièrement sur l'aide au diagnostic des tumeurs cérébrales. L'objectif visé est de détecter précisément la zone tumorale, c'est-à-dire de l'isoler des principales structures cérébrales. **Notre problématique est** donc de segmenter les tumeurs cérébrales à partir des images IRM, et d'extraire les différents tissus existants. Cette segmentation doit naturellement être reproductible, précise et fiable.

2.1.2 Définition formelle

Une définition formelle d'un algorithme de segmentation complète d'une image a été donnée par **Horowitz et Pavlidis en 1975**. [15]

Soit X le domaine de l'image, et f la fonction qui associe à chaque pixel une valeur $f(x, y)$. Si nous définissons un prédicat P sur l'ensemble des parties de X (P : prédicat \Rightarrow homogénéité), la segmentation de X est définie comme une partition de X en n sous-ensembles $\{R_1, \dots, R_n\}$ (Figure 2.2), (En imagerie médicale, les régions R_i correspondent aux structures anatomiques : organes, os, ...etc.), tels que:

- $X = \coprod_{i=1}^n R_i$
- $\forall i \neq j, R_i \cap R_j = \emptyset$

- $\forall i \in \{1, \dots, C\}$ les sous-ensembles R_i sont connexes
- $\forall i \in \{1, \dots, C\}$ $P(R_i) = \text{vrai}$
- $\forall i, j \in \{1, \dots, C\}^2$ R_i est adjacente à R_j et $i \neq j \implies P(R_i, R_j) = \text{faux}$

Où \amalg représente une union d'ensemble disjoints.

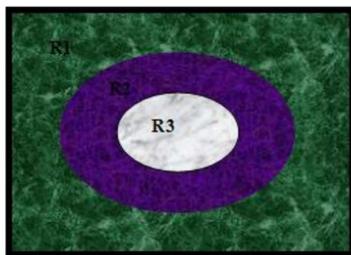


Figure 2.2 : Segmentation d'une image en 5 régions

- La première condition intervient simplement dans le fait que la segmentation est complète, ce qui signifie que chaque pixel de l'image doit appartenir à une région et à une seule : tout algorithme ne doit s'arrêter qu'après avoir traité tous les pixels de l'image ;
- La seconde indique que les régions sont bien séparables ;
- La troisième condition implique que toute région doit être connexe. La connexité des régions est induite par le voisinage défini sur l'image ;
- La quatrième condition implique que tous les pixels d'une même région sont homogènes entre eux ;
- La cinquième condition indique qu'il ne peut y avoir le même prédicat pour deux régions adjacentes, autrement dit les pixels de deux régions adjacentes ne sont pas homogènes entre eux.

2.1.3 Objectifs de la segmentation

L'objectif de la segmentation est de permettre l'exploitation du contenu de l'image pour l'interprétation : aide au diagnostic en imagerie médicale, localisation et reconnaissance en imagerie aérienne et satellitaire, en vidéo surveillance, et en contrôle robotique, ou mesure des évolutions en contrôle de qualité, en suivi thérapeutique, ...etc).

Dans le cas de la segmentation d'images médicales, les objectifs sont [39]:

- D'étudier les structures anatomiques ;
- D'identifier les régions d'intérêts, localisation de la tumeur, lésions et d'autres anomalies ;
- De mesurer le volume des tissus pour quantifier la croissance de la tumeur ;
- D'aider à la planification du traitement préalable à la radiothérapie, dans le calcul de la dose du rayonnement.

La segmentation d'images est au cœur de nombreux problèmes en imagerie médicale, puisque bien souvent elle constitue la première étape d'un véritable flux de traitements que subiront ces images.

Comme précisé précédemment, la segmentation est une étape qui s'avère primordiale ; il est de ce fait très important d'obtenir des résultats satisfaisants au cours de cette étape. La segmentation peut être conduite selon différentes procédures sur les images ; elle peut ainsi être effectuée [17] :

- De manière automatique, par traitement d'images (seuillage, détection de contours). Cette méthodologie est particulièrement adaptée à des structures simples, sur des images bien contrastées et avec un marquage intense ;
- De manière semi-automatique, faisant appel à l'intervention d'un opérateur ;
- De manière manuelle, en délimitant des polygones autour des structures pertinentes.

Il faut noter que les méthodes de segmentation automatique permettent une reconstruction rapide, elles sont néanmoins beaucoup moins précises que les techniques acceptant une correction manuelle.

2.2 Les différentes approches de segmentation

Il existe de nombreuses approches de segmentation, et en cette section, nous allons présenter les diverses techniques connues en les organisant selon l'approche qui les régit. Ainsi, nous avons retenu quatre approches. Cette classification et ses ramifications plus poussées sont représentées dans la Figure ci-dessous. [15]

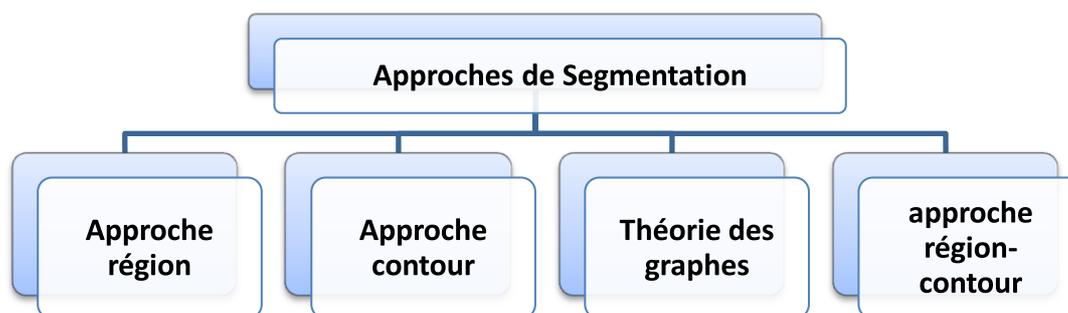


Figure 2.3 : Classification des différentes approches de segmentation

2.2.1 Segmentation par approche région

Les méthodes appartenant à cette famille manipulent directement des régions. Soit elles partent d'une première partition de l'image, qui est ensuite modifiée en divisant ou regroupant des régions, soit elles partent de quelques régions qui sont amenées à croître par incorporation de pixels jusqu'à ce que toute l'image soit couverte. Dans la Figure suivante, nous allons citer les méthodes appartenant à cette approche.

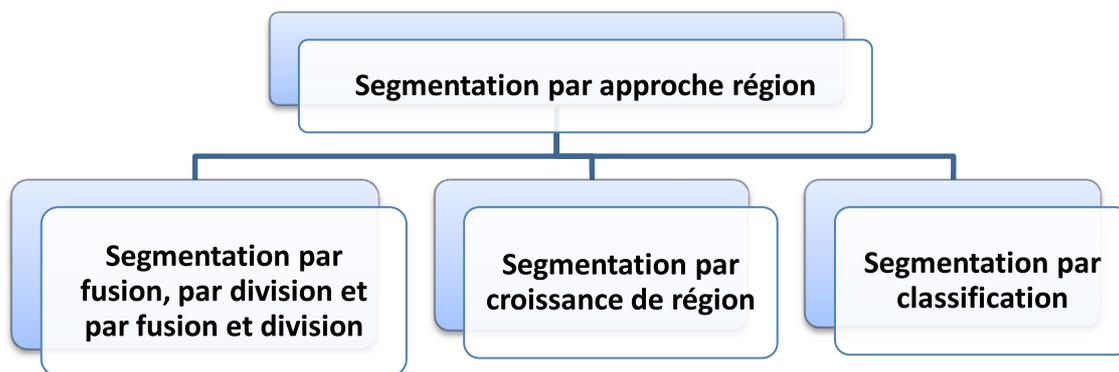


Figure 2.4 : Les différentes méthodes de segmentation par approche région

2.2.1.1 Approche par division, fusion et fusion division (split & merge)

➤ Méthode de segmentation par division de régions

Initialement, l'image est considérée comme une seule région. Par la suite, chaque région R_i est traitée, puis prédicat d'homogénéité est appliquée (niveau de gris, couleur, texture,...). [14]

Si la région R_i ne vérifie pas le prédicat, elle est alors divisée en plusieurs sous régions (généralement 4) (Figure 2.5). L'opération est appliquée sur chaque sous régions, et l'algorithme de reconstruction s'arrête lorsque toutes les régions respectent le prédicat d'homogénéité (division de toutes les régions non homogènes).



Figure 2.5 : Exemple de la division

➤ Méthode de segmentation par fusion

Dans cette étape, le prédicat d'homogénéité est vérifié pour les couples de régions voisines. Si deux régions vérifient ce prédicat, elles seront fusionnées (fusion de toutes les régions adjacentes dont l'union respecte les critères d'homogénéité). [14]

Un point intéressant est que selon, la segmentation par division ne donne pas le même résultat que la segmentation par fusion, bien que l'on considère les mêmes critères d'arrêt. Suite à cette affirmation, il serait judicieux de combiner les deux approches pour obtenir une segmentation plus raffinée, c'est ce que nous allons présenter dans ce qui suit.

➤ Méthode de segmentation par division/fusion

Egalement nommée « Split and Merge », cette technique fonctionne en considérant une représentation pyramidale de l'image analysée. Les régions sont de formes carrées, et correspondent aux différents éléments d'un étage donné de la pyramide, (Figure 2.6)



Figure 2.6 : Illustration du concept pyramidal de l'image pour la segmentation par fusion et division de régions

Ainsi, si une région de l'image considérée ne respecte pas les critères fixés, elle sera divisée en quatre nouvelles régions. Réciproquement, si 4 régions indépendantes, mais voisines, respectent les critères de division, elles seront fusionnées dans l'étage supérieur de la pyramide, (Figure 2.7)

En somme, cette segmentation peut se rapporter à la construction d'un « quadtree » de segmentation, où chaque feuille « node » représente une région dite homogène, c'est-à-dire qu'elle respecte les critères fixés. (Figure 2.8)



Figure 2.7 : Décomposition en 4, faire apparaître des blocs similaires

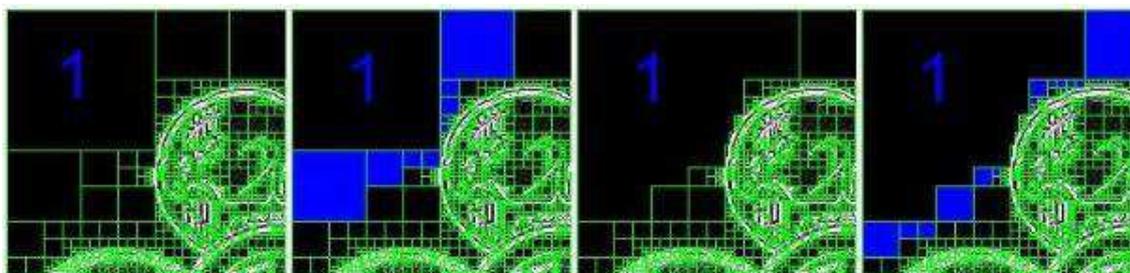


Figure 2.8 : Agrégation itérative des blocs similaires au bloc 1

Berriche et Benyettou [26] ont présenté un outil de segmentation des images scannographiques et IRM cérébrales, basé sur la méthode de division-fusion (split & merge) pour la détection des anomalies présentes dans ces images.

2.2.1.2 Segmentation par croissance de région

C'est une méthode locale et récursive, qui a pour but de faire croître une région, avant de passer à la suivante, sans parcours particulier, déterminé *a priori* (méthode par agrégation libre de pixels). On part d'un germe, il y a croissance suivant un critère de similarité jusqu'à atteindre le critère d'arrêt.

[27] proposent une méthode de croissance de régions pour la segmentation du cerveau sur des images IRM tridimensionnelles.

[28] présentent une méthode d'identification des tumeurs de la matière blanche. Cette méthode suppose la segmentation préalable du cortex, de la matière grise et de la matière blanche. Les lésions sont détectées par un maximum de vraisemblance.

[29] a fait un état de l'art sur les méthodes de croissance de région utilisées pour la segmentation de tumeurs cérébrales ; parmi les travaux cités dans son article, on trouve:

- **Kaus et autres en 2001**, utilisent la croissance de région pour segmenter les tumeurs cérébrales pour les images IRM.
- **Salman et autres en 2005**, et **Salman et Badawi en 2005**, ont prouvé que la croissance de région est une approche efficace, avec moins de calcul intensif que d'autres méthodes (non basé-région), pour la segmentation des tumeurs du cerveau, en particulier pour les tissus et les régions homogènes. Son inconvénient majeur est l'effet de volume partiel qui limite la précision de la segmentation des images cérébrales.
- **S. Lakare et autres en 2000**, ont introduit la croissance de région modifiée (**MRGM**), qui est utilisée pour enlever l'effet de volume partiel, et ils ont incorporé l'information du gradient pour plus de précision en détection de contour, et même pour le remplissage des trous après segmentation.
- **Salman en 2009**, a présenté une analyse comparative de la croissance de région traditionnelle et de la MRGM, dédiée à la segmentation 3D des tumeurs cérébrales, dans des images IRM pondérées en T1. Dans son étude, Salman montre que la MRGM augmente la précision des mesures volumétriques des tumeurs du cerveau, produisant des erreurs relativement inférieures à la croissance de région traditionnelle, par rapport à une segmentation manuelle.

[30] proposent une croissance de région, combinée avec des opérations de morphologies mathématiques, afin de segmenter le ventricule latéral et le troisième ventricule. La croissance de régions est guidée par des connaissances anatomiques a priori sur le système ventriculaire.

[31] combinent la méthode de la croissance de région avec une approche par mixture de gaussiennes pour segmenter les tissus cérébraux.

2.2.1.3 Segmentation par classification

Les méthodes de classification permettent de regrouper des objets en groupes ou classes d'objets plus homogènes. Les objets regroupés ont des caractéristiques communes, ils sont similaires, mais se distinguent clairement des objets des autres classes. Généralement, les résultats des méthodes de classification sont plus ou moins différents. [25]

Dans le domaine de la segmentation d'images, les méthodes de classification sont soit supervisées soit non supervisées. [25]

➤ Classification supervisée

La classification supervisée est une méthode qui nécessite l'intervention d'un expert ; elle est aussi appelée méthode discriminante. Dans ces méthodes, les classes sont connues *a priori*, avant d'effectuer l'opération d'identification des éléments de l'image. Elles demandent une première phase d'apprentissage sur l'échantillon représentatif, dans le but d'apprendre les caractéristiques de chaque classe, et une deuxième phase pour décider l'appartenance d'un individu, à telle ou à telle classe.

Les données segmentées de l'ensemble d'apprentissage proviennent d'un étiquetage manuel, des images ou des régions d'intérêt, en C classes de tissus (C_1, C_2, \dots, C_c), par un ou plusieurs experts. Chaque classe C_i se voit donc affecter un ensemble d'apprentissage E_i , et les données de l'ensemble de test sont segmentées en fonction des E_i .

Nous allons passer en revue les méthodes de segmentation de tumeurs, basées sur des techniques de classification supervisée. On peut distinguer cinq catégories :

- Les k plus proches voisins (KPP)

Le KPP (k-nearest-neighbors (KNN) en anglais) est une méthode simple de classification, qui nécessite une phase d'apprentissage. Il permet de classer chaque pixel de l'image, en fonction de la classe d'appartenance des pixels de son voisinage (des k plus proches voisins en terme de distance entre leurs attributs et/ou leurs localisations spatiales) [19]. Le classificateur KNN est considéré comme un classificateur non paramétrique car il ne fait aucune hypothèse sur la structure statistique des données. [1]

Vinitski et autres en 1997 dans [1] ont développé une méthode qui utilise des patients spécifiques pour classer les images pondérées en T2, T1 et PD en 10 classes de tissus. Le classificateur utilisé est un classificateur KNN, qui attribue des étiquettes aux pixels, sur la base de l'étiquette la plus fréquente, parmi les K points les plus proches, sous une distance métrique.

L'algorithme KNN est une méthode simple et efficace pour la classification multi-classes, qui est capable de modéliser des distributions non-linéaires. Il s'agit du premier

procédé qui segmente tous les composants de la tumeur (partie solide, œdème et nécrose). Cette méthode ne comportait aucune régularisation spatiale, elle est donc très sensible au bruit et à l'hétérogénéité des tumeurs.

Kaus et autres, 1999, 2001 et Warfield et autres, 2000 dans [1] ont proposé une méthode automatique pour la segmentation des tumeurs cérébrales homogènes, appliquée aux images IRM, qui a utilisé un atlas de segmentation manuel comme information spatiale, pour corriger les résultats de la classification KNN. Cette méthode incorpore à la fois la classification supervisée KNN et le recalage. La méthode KNN utilisée classe une image en différentes classes de tissus, sous le critère de l'intensité, en utilisant une base d'apprentissage de données de patients spécifiques (l'initialisation du système de classification est effectuée par une sélection de plusieurs points de chaque tissu par l'utilisateur). Pour résoudre les problèmes de mauvaise classification, du fait du chevauchement de la distribution de l'intensité de différents tissus, un recalage d'atlas non linéaire est utilisé.

- L'approche bayésienne

Dans cette approche supervisée et paramétrique, les données sont supposées suivre une multi-variation de distributions normales (gaussienne), où la moyenne et la covariance sont estimées à partir de l'ensemble de données d'apprentissage. L'objectif est d'estimer les étiquettes de classe, en maximisant la probabilité a posteriori $P(C | X)$, où X représente les données observées et C la classe.

Sur la base de la règle de Bayes, nous avons :

$$P(C | X) = P(X | C) P(C)$$

où $P(X | C)$ est la probabilité conditionnelle se lit « Probabilité de x sachant C »

$P(C)$ est la probabilité a priori de la classe C , qui est calculée, en utilisant la distribution de différents types de tissus, et $P(X)$ est la probabilité de pixel / voxel.

Récemment, [32] ont proposé une nouvelle méthode, basée sur une combinaison de modèle bayésien, et l'affinité à base de graphes, pour la segmentation des tumeurs cérébrales et de l'œdème.

[33] L'algorithme SWA (Sliding Window Algorithm) a été utilisé pour segmenter l'image, où dans le premier niveau, chaque nœud est un voxel. Cette méthode est appliquée pour la segmentation des tumeurs GBM (Glioblastome Multiforme), en utilisant des images pondérées en T1, pondérées en T1 avec rehaussement de contraste, et en Flair.

- Expectation maximisation (EM)

L'algorithme EM a été développé par [35] et [36], et a été réalisé en deux étapes, de manière itérative :

- une étape d'évaluation de l'espérance (E), où l'on calcule l'espérance de la vraisemblance, en tenant compte des dernières variables observées ;
- une étape de maximisation (M), où l'on estime le maximum de vraisemblance des paramètres, en maximisant la vraisemblance trouvée à l'étape E.

E et M étapes sont réitérés jusqu'à ce que les estimations de paramètres deviennent stables.

[34], [62] ont été le premier groupe à adapter l'algorithme EM pour la segmentation de tumeurs cérébrales. Cette méthode a été développée sur la base du travail de **Leemput et autres** [37], pour la segmentation du cerveau sain.

Récemment, ce groupe a présenté une approche plus générale, fondée sur l'algorithme EM qui est utilisé dans la 1^{ère} étape de cette méthode, effectuée en trois phases. L'algorithme EM est utilisé pour la détermination des régions d'anomalies. Cette méthode permet de détecter l'œdème, et n'utilise pas des images contrastées, mais elle ne convient pas dans le cas de grandes déformations.

- Les champs de Markov

Les champs de Markov sont utilisés pour ajouter l'information de la répartition spatiale des pixels, qui modélise les interactions entre un pixel et son voisinage. [15]

Soit S un ensemble de pixels et $X = (X_s)_{s \in S}$ une famille de variables aléatoires définie sur S , où chaque X_s est à valeurs dans un ensemble fini de classes $\Omega = \{\omega_1, \omega_2, \dots, \omega_k\}$.

Une telle famille sera par la suite appelée « champ aléatoire ». D'autre part, soit un système de voisinage V , on notera par la lettre P les diverses lois de probabilité, liées à X .

On dit qu'un champ X est un champ de Markov relativement à V , si et seulement si les deux propriétés suivantes sont vérifiées :

- Positivité : $\forall x \in \Omega^{\text{card}(S)}, P(x) > 0$;
- Markovianité : $P(X_s = x_s \mid X_t = x_t, t \neq s) = P(X_s = x_s \mid X_t = x_t, t \in V_s)$.

La propriété de Markovianité signifie que la probabilité en un site s , conditionnelle à tous les autres sites, n'est fonction que de la configuration du voisinage du site considéré. Autrement dit, la probabilité d'apparition d'une classe donnée en un site s , conditionnellement au reste du champ, est égale à sa probabilité d'apparition connaissant simplement ses voisins.

Zang et autres en 2001 dans [20] ont utilisé les champs de Markov cachés, pour la segmentation des tissus cérébraux.

Gering dans [1] a utilisé les champs de Markov, pour affiner les résultats d'EM, incorporer une structure à la contrainte de frontière utilisant une couche multi MRF et présenter un algorithme de distinction des pixels du volume partiel de la tumeur en créant un espace d'adaptation avant les pixels qui sont aux frontières de structures normales.

Bricq et autres [16] proposent une méthode de segmentation markovienne des IRM 3D pour détecter les lésions de la sclérose en plaques.

Bricq [18] propose une méthode basée sur la modélisation par chaînes de Markov cachée prenant en compte la notion de voisinage 3D et d'inclure l'information à priori apportée par un atlas pour la segmentation d'IRM cérébrales et la détection des lésions de la sclérose en plaques (SEP).

- La machine à vecteurs de support (SVM)

Dans les dernières années, SVM (Support vector machine) a attiré beaucoup d'attention. Il est le classificateur plus récent dans l'apprentissage des machines, il a été proposé par **Vapnik** dans [1] et est basé sur la théorie statistique de l'apprentissage.

Le principe des machines à vecteurs de support consiste à déterminer un classifieur linéaire appelé hyperplan pour séparer deux classes de données. Les points de données les plus proches de celui-ci définissent des points appelés vecteur de support. Pour obtenir une segmentation robuste, il faut maximiser la marge, i.e la distance entre l'hyperplan et les vecteurs de support [20]. Si les données sont non linéairement séparables, ce qui est souvent le cas, celles-ci sont projetées dans un espace de dimension supérieure à celle de l'espace d'entrée, pour les rendre linéairement séparables, par une transformation, puis trouver un séparateur dans cet espace de réinscription [20].

Zhang et autres en 2004 et **Zhou et autres en 2005** dans [1] ont proposé une méthode de segmentation des tumeurs cérébrales par classification SVM, avec l'utilisation de quelques opérations morphologiques, pour éliminer les erreurs de classification.

Lee et autres en 2005 dans [1] ont combiné SVM et l'algorithme MRF, les SVM supposent que les voxels sont indépendants et distribués identiquement, en plus, elles sont très sensibles au bruit, d'où l'importance de la combiner avec les MRF.

Ruan et autres en 2007 dans [1] ont proposé une méthode de classification SVM pour des images IRM multispectrales (T1, T2, ρ et Flair).

Dans [21] la segmentation des tumeurs cérébrales a été faite par la méthode de machine à vecteur support.

Récemment [22] ont employé un nouveau et puissant type de machine d'apprentissage supervisé, avec des caractéristiques de généralisation élevées : les moindres carrées (LSSVM). Donc un processus itératif est utilisé pour la segmentation du cerveau, de sorte que les cartes de probabilités des tissus du cerveau sont mises à jour à n'importe quel itération.

➤ Classification non supervisée

Les méthodes de classification non supervisée n'ont pas besoin d'éléments d'apprentissage, étiquetés par un expert. En contrepartie, les classes n'ont aucune étiquette ou notion sémantique. L'algorithme définit les classes de pixels, en minimisant la différence

intra-classes, et en maximisant la différence interclasses, à partir des données. [64]. Cette méthode, comme de nombreuses autres, repose en grande partie sur les choix de l'expérimentateur : variables prises en compte, métrique, . . . etc.

Le résultat de la classification est soit une partition, soit une hiérarchie, et nous verrons plus en détails la classification non supervisée qui donne des partitions, au paragraphe suivant, car c'est la méthode qui s'adapte le mieux pour nos images IRM. La classification par partitionnement se divise en deux parties :

➤ Partitionnement "dur"

L'idée générale est de découper l'espace des données en un certain nombre de régions disjointes, définies par des frontières, et de décréter que tous les pixels, situés dans une même région de l'espace, appartiennent à une même classe.

Chaque classe est représentée par un "prototype", pixel virtuel, sensé être le plus représentatif des éléments de la classe. Ces prototypes sont positionnés de façon itérative dans les zones à forte densité, et les pixels sont affectés aux classes sur la base d'un critère de proximité, aux différents prototypes.

il existe de nombreuses techniques de classification par partitionnement dur, la plus connue étant k_means (ou "K-moyennes") et ses variantes. Notez qu'un type très particulier de Réseaux de Neurones, les cartes de Kohonen (ou "SOM") peut être perçu comme une technique de partitionnement puisque cherchant à donner, dans la mesure du possible, une représentation plane des classes qui respecte leurs positionnements relatifs dans l'espace des données.

➤ Partitionnement "doux"

L'idée selon laquelle, chacune des classes réelles sous-jacentes, occupe une région limitée de l'espace, peut paraître irréaliste. En particulier, l'Analyse Discriminante nous a habitués à penser en termes de classes, ayant des distributions multi normales, et donc se chevauchant nécessairement. Il est donc naturel de considérer la possibilité, que les classes empiètent les unes sur les autres. Dans cette catégorie, nous pouvons trouver : les Mélanges de modèles et la Classification floue.

Dans les mélanges de modèles, les classes se chevauchent, mais chaque pixel appartient à une classe et une seule (bien que la détermination de cette classe ne puisse être faite que de façon probabiliste). A l'inverse, En classification floue, on reconnaît qu'un pixel peut effectivement appartenir simultanément à plusieurs classes. [65], [S11]

Parmi les travaux réalisés en utilisant la classification non supervisée, on cite :

[23] a utilisé une approche hiérarchique divisée en deux étapes : une étape agglomérative, ou il a utilisé l'approche T-LAMDA, et une étape qui utilise l'approche de bissection ou divisive (dans ce cas la bissection est le k_means) ;

Vemuri et Rahman (1995) dans [20] ont utilisé les k-means pour la segmentation d'IRM cérébrales ;

[24] ont appliqué l'algorithme k-means pour segmenter des tissus du cerveau, puis les champs de Markov pour améliorer le résultat de la segmentation (Figure 2.9) ;

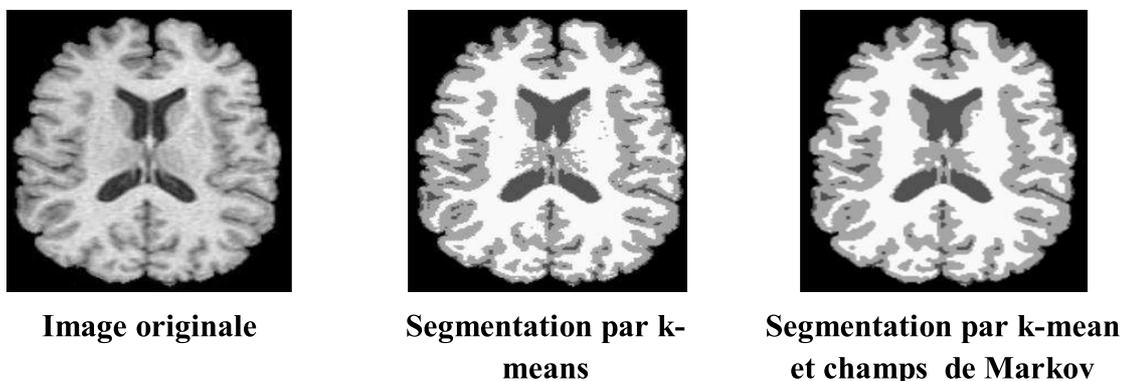


Figure 2.9 : Segmentation de tumeur cérébrale

[42] utilisent les Means Shift (algorithme de classification non paramétrique) de manière adaptative pour segmenter les tissus cérébraux (Figure 2.10).

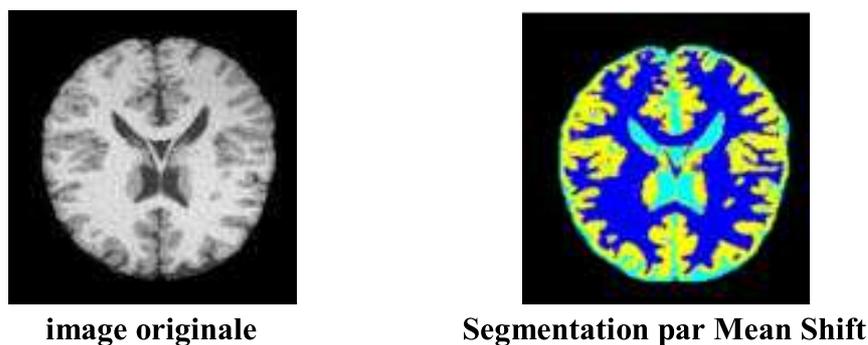


Figure 2.10 : Segmentation par Mean Shift

Garcia et autres (2008) dans [20] ont combiné le Mean Shift avec une méthode de type EM pour la segmentation des lésions de SEP.

Suckling et autres (1999) dans [20] ont utilisé une méthode de classification floue pour la classification des tissus.

Ahmed et autres (2002) dans [20] introduisent dans FCM (fuzzy-c means), un terme de régularisation spatiale, inspiré de la modélisation markovienne. Ils introduisent l'influence du voisinage dans le degré d'appartenance de chaque voxel.

Dans [43], FCM semi supervisé a été utilisé pour segmenter les IRM cérébrales (Figure 2.11).

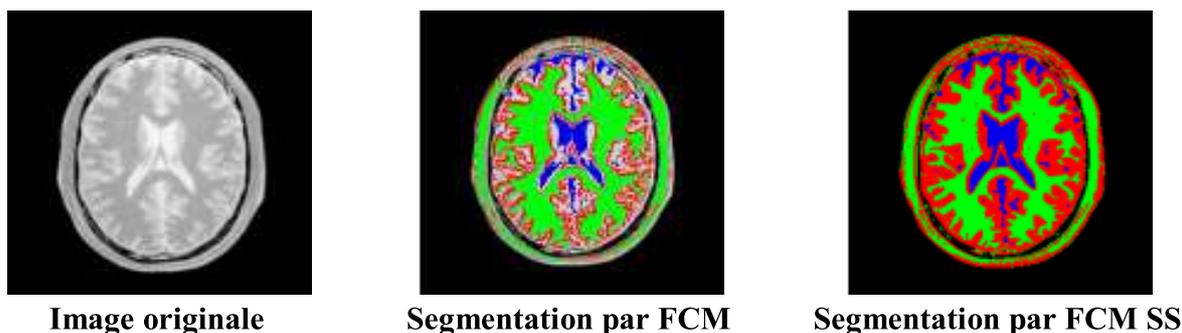


Figure 2.11 : Segmentation de tumeur cérébrale par FCM

[44] ont proposé une classification supervisée, inspirée des méthodes de classification floue et des méthodes reposant sur la méthode EM (est utilisé en classification pour estimer certains paramètres). L'aspect flou et possibiliste sont tous les deux pris en considération, rendant la méthode plus robuste, pour la segmentation des images IRM pathologiques de différentes modalités (Figure 2.12).

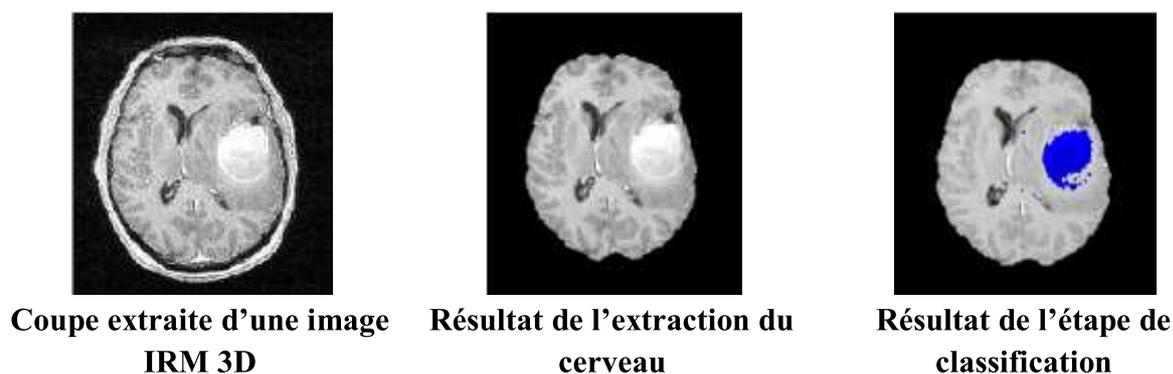


Figure 2.12 : Exemple de segmentation par Classification

En IRM traditionnelle, Clark et autres en 1998 dans [44] ont utilisé les c-moyennes floues comme étape d'initialisation à un système expert, pour segmenter des volumes de tumeur ou d'œdème, sur des images IRM cérébrales.

Xue et coll en 1998 dans [29] utilise les FCM pour combiner le filtre moyen au filtre médian local afin de réaliser la segmentation locale de volumes IRM du cerveau

Dans [45], **Pham et coll** ainsi que **Jiang et coll** utilisent les inhomogénéités d'intensité des volumes IRM, dans la fonction objective, et obtiennent ainsi un FCM adaptatif qui permet une meilleure segmentation. [47]

Dans [45], les techniques mises en revue dans cet article sont des méthodes de segmentation des images médicales bruitées, avec probabilité spatiale, telles que : **NFCM** (Novel Fuzzy C-Means), **FLICM** (Fuzzy Local Information C-Means) et **ISFCM** (Improved Spatial Fuzzy C-Means).

Le problème principal de ces méthodes est la qualité de la segmentation des frontières des tumeurs. Et en raison de l'effet de volume partiel, ces techniques souffrent de la mauvaise classification des voxels, il est donc difficile, d'avoir une région nette de la tumeur.

La plupart du temps, quelques étapes de prétraitement, tels que les opérations morphologiques, l'interaction de l'utilisateur et les connaissances à priori, ont été utilisées pour supprimer des objets non valides, ou pixels/voxels mal classés, à partir des résultats de la segmentation, mais ces opérations ne peuvent pas résoudre complètement le problème. De plus la segmentation des tumeurs hétérogènes reste un problème non résolu dans ces méthodes. Enfin, la plupart de ces méthodes segmentent un type spécifique de tumeurs, et sont non généralisées sur de grands types de tumeur. [1]

2.2.2 Segmentation par approche contour

Pour surmonter certaines limitations des méthodes de segmentation par approches région, des méthodes par approches contour, sont utilisées pour chercher des frontières explicites ou implicites, entre les régions correspondant aux différents types de tissus.

Dans les dernières années, les modèles déformables ; une des méthodes les plus populaires des méthodes de segmentation contour, ont été largement utilisés dans la segmentation d'images. L'idée derrière les modèles déformables est assez simple. L'utilisateur détermine une estimation initiale pour le contour, qui est ensuite déformé par les forces dérivées de l'image, jusqu'à la délimitation des objets désirés.

On peut distinguer deux principaux types de modèles déformables [1] : modèles déformables paramétriques et modèles déformables géométriques.

Les contours actifs paramétriques sont représentés explicitement, comme des courbes paramétrées, dans une structure Lagrangienne, tandis que les contours actifs géométriques, sont représentés implicitement comme les ensembles de niveau, d'une fonction bidimensionnelle, qui se développe dans une structure eulérienne.

2.2.2.1 Modèles déformables paramétriques

Les modèles déformables paramétriques qui ont attiré le plus d'attention à ce jour sont populairement connus comme les « snakes ». [66]. Les snakes ou contours actifs sont un cas particulier de la théorie des modèles déformables, multidimensionnelle, générale présentée par. [66]

Les contours actifs ont été largement utilisés pour leurs sensibilités de détection des contours des tumeurs cérébrales. Selon [29], cette détection donne de meilleurs résultats que les méthodes classiques de détection de bords, telles que le Laplacien et l'opérateur de Sobel.

L'énergie externe de la fonction du snake n'est positive que dans les régions homogènes et nulle sur les bords [48], un certain nombre de méthodes ont été proposées pour améliorer la performance du snake, telles que :

[49] ont mis en œuvre deux de ces méthodes améliorées, pour la segmentation des tumeurs sur les IRMs cérébrales 2D, en modalité T1: le modèle du ballon, et le snake en champs de vecteurs gradient (GVF : gradient vector flow). L'amélioration apportée par ces méthodes est que : le modèle de ballon permet d'élargir la plage de capture du snake, et le GVF utilise une diffusion spatiale des vecteurs gradients d'une carte contour obtenu par le gradient de l'image, au lieu d'utiliser le gradient d'image seul en tant que force externe.

[51] ont présenté un modèle de région déformable modifiée, pour l'extraction de frontières de tumeur cérébrale, d'IRM 2D.

Les méthodes des contours actifs détectent mieux les bords tumoraux, par rapport aux autres méthodes, mais elles ont trois limites principales :

- La première est que, lorsque le contour initial et le contour de l'objet à segmenter, diffèrent largement en forme et en taille ; le contour initial doit être paramétré vers les vrais bords de l'objet, pour bien converger. Mais, vu que les méthodes de re_paramétrage ont besoin d'un temps de calcul immense, quelques méthodes proposées génèrent le contour initial manuellement ce qui nécessite une interaction de l'utilisateur.
- La deuxième limite est que, les snakes ont des difficultés à s'adapter aux changements topologiques, comme la division ou la fusion du contour initial.
- Enfin, les contours actifs classiques qui utilisent le gradient de l'image comme force, ont souvent le problème de divergence, lorsque le contour de l'objet à segmenter est mal défini.

2.2.2.2 Modèles déformables géométriques

Les modèles déformables géométriques, proposées indépendamment par [53] et [54], fournissent une solution pour répondre aux limites des modèles déformables paramétriques (en particulier l'adaptation topologique). Ils sont basés sur la théorie d'évolution des courbes, et sont mises en œuvre à l'aide des ensembles de niveau (Level set) [55] qui correspondent à une méthode numérique. En particulier, les courbes et surfaces évoluent uniquement avec les mesures géométriques, ce qui entraîne une évolution indépendante de la paramétrisation.

Comme dans les modèles déformables paramétriques, l'évolution est couplée avec les données d'image, pour récupérer les contours des objets. Etant donné que l'évolution est indépendante de la paramétrisation, l'évolution des courbes et des surfaces peut être représentée implicitement, comme un ensemble de niveau d'une fonction de dimension supérieure. En conséquence, les changements de topologie peuvent être traités automatiquement. [56]. La forme mathématique des jeux d'ensembles de niveau est défini par :

$$\frac{\partial \Phi}{\partial t} = V(k) |\nabla \Phi|$$

Où $V(k)$ est appelée fonction vitesse, k est la courbure et Φ est la fonction du level set.

L'utilisation du Level set a été largement exposée dans la littérature de l'imagerie médicale, et plusieurs ouvrages ont été publiés sur la segmentation des IRM du cerveau sain et pathologique. [57] ont présenté une méthode semi-automatique basé sur les Level Sets pour la segmentation des gliomes de grade II et I2.

2.2.3 Segmentation par Théorie des graphes

L'histoire de la théorie des graphes débute peut-être avec les travaux d'Euler au XVIIIe siècle et trouve son origine dans l'étude de certains problèmes, tels que celui des ponts de Königsberg [40],[41].

Dans les approches de segmentation, utilisant la théorie des graphes, l'idée directrice est de créer un graphe à partir de l'image, constitué de nœuds et d'arrêtes, selon des procédés assez simples, et de travailler sur ces graphes, pouvant ainsi utiliser toute la panoplie d'outils développés dans le cadre de cette théorie. Un travail relativement important sera de valuer les arêtes puisque ce sont elles qui permettront de donner les caractéristiques de l'image à notre graphe.

Un état de l'art très récent a été fait par [61], où ils ont décrit le concept des théories de graphes, basé sur la segmentation d'images, et ils l'ont classifié en 3 différentes catégories : coupe de graphe accéléré (speed up-based graph cut), coupe de graphe interactif (interactive-based graph cut), et coupe de graphe basée sur la forme a priori (shape prior-based graph cut).

2.2.4 Approches Régions-Contours

La segmentation par coopération régions-contours suscite un grand intérêt ces dernières années. Elle consiste en une coopération entre la segmentation par régions, et la segmentation par contours. Elle exploite les avantages de ces deux types de segmentation pour aboutir à un résultat de segmentation plus précis, et plus fidèle que celui obtenu à l'aide d'une seule technique.

L'intégration des deux types de segmentation peut être réalisée à différents niveaux. Ainsi, nous présentons ici les approches de segmentation coopérative régions-contours en trois classes. [38]

- **Coopération séquentielle** : Le principe général de la coopération séquentielle est que l'une des techniques, par régions ou par contours, est réalisée en premier lieu. Son résultat sera par la suite exploité par l'autre technique (Figure 2.13(a)).

- **Coopération des résultats** : Dans la coopération des résultats, les deux types de segmentations sont réalisés de façon parallèle et indépendante, et la coopération sera faite au niveau de leurs résultats respectifs (Figure 2.13(b)).
- **Coopération mutuelle** : Dans ce cas, les différentes techniques de segmentation sont exécutées en parallèle, tout en échangeant mutuellement des informations. L'information échangée sert à aider la technique de segmentation dans la prise de décision dans le cas de lacunes ou d'informations insuffisantes (Figure 2.13(c)).

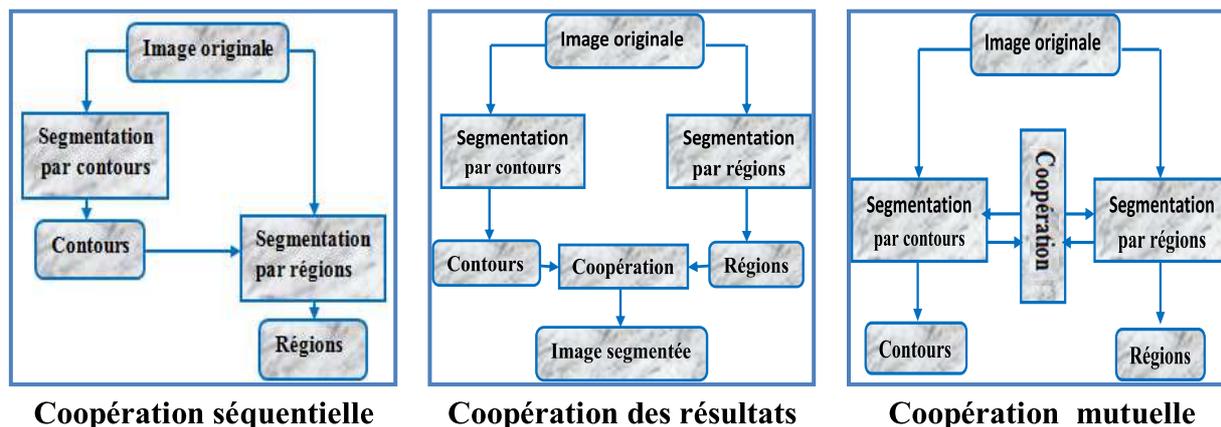


Figure 2.13 : Principe des trois types de coopération

[68] été les premiers à proposer une combinaison entre une méthode de segmentation régions avec les snakes, pour la segmentation 3D de tumeurs cérébrales. Dans l'étape de segmentation initiale, une coupe de bon contraste d'intensité a été choisie, donc, après un seuillage et quelques opérations morphologiques, la tumeur est segmentée dans cette coupe. Le contour de la tumeur extrait est considéré comme contour initial du snake pour cette coupe. Le contour final de chaque coupe est considéré comme contour initial pour la coupe suivante.

[50] ont combiné FCM avec les snakes, tel que FCM, suivie de plusieurs opérations morphologiques, fournit une segmentation initiale de la tumeur, qui sera raffinée par le modèle déformable paramétrique (snake).

[58] ont exploité une méthode de segmentation 3D automatique, en combinant les Level Sets et les FCM.

[59] ont coopéré le Level Set avec une méthode de seuillage comme a proposée [60] mais d'une façon améliorée : Cette méthode est applicable sur l'espace 3D, de plus la méthode de seuillage sert à calculer la fonction de vitesse du Level Set.

[52] ont proposé un modèle déformable paramétrique, contraint par les relations spatiales, comme étape de raffinement, qui fournit une estimation précise des contours de tout type de tumeurs cérébrales sur les IRMs T1.

Discussion

Dans ce chapitre, nous avons proposé une classification des méthodes de segmentation d'IRM cérébrales en explicitant les techniques les plus connues et les plus employées. Cependant chacune d'entre elles a ses qualités et ses défauts, et c'est sur cette base que doit se faire le choix de l'emploi de l'une ou l'autre de ces techniques.... ?

Puisque le but de ce mémoire est de proposer une méthode de segmentation d'IRM cérébrales, pour des structures d'intérêts aussi bien pathologiques que saines, nous avons opté pour une méthode de classification floue et de détection par analyse de symétrie comme socle de la segmentation initiale qui sera détaillée dans le chapitre 3. In vivo, ces techniques de segmentation en région souffrent d'un défaut commun, qui est l'imprécision de la détection des contours. Pour cette raison, nous avons pensé aux approches contour, afin d'assouplir cette anomalie. Ces approches visent à exploiter les discontinuités des images pour déterminer les frontières des différentes régions, et parmi ces méthodes nous allons employer **les modèles déformables**. De même ces méthodes ont un défaut collectif, qui est le fait qu'elles segmentent des fois les faux objets, alors il est préférable d'avoir une intervention des approches région, pour définir les régions dont on désire extraire les frontières.

Pour ces raisons et afin d'avoir une méthode qui sied à nos attentes, nous proposons de **combiner** une méthode de classification floue ou l'analyse de symétrie, avec un modèle déformable (implémenté via snakes), contraint par une relation spatiale de distance, qui prend en considération les zones homogènes, ainsi que les transitions entre elles, simultanément, afin d'aboutir à des résultats beaucoup plus satisfaisants.

CHAPITRE 3

PRETRAITEMENT ET SEGMENTATION INITIALE

Malgré de nombreux efforts, et des résultats prometteurs dans la communauté de l'imagerie médicale, la segmentation précise et reproductible, et la caractérisation des anomalies, sont toujours une tâche ardue et difficile en raison de la variété des formes, des localisations et des intensités de divers types de tumeurs. Certaines d'entre elles peuvent déformer les structures environnantes, ou peuvent être associées à un œdème ou à une nécrose, ce qui modifie l'intensité de l'image autour de la tumeur.

Comme nous l'avons vu dans le chapitre précédent, les méthodes existantes souffrent d'un manque de robustesse, de précision, et nécessitent dans leur majorité une interaction manuelle. La plupart d'entre elles sont généralement dédiées à des tumeurs contrastées, ou des types spécifiques de tumeurs, et ne sont pas facilement extensibles sur d'autres types.

Le but des deux chapitres suivants est de contribuer à ce domaine, en proposant une méthode originale, pour répondre à une large classe de types de tumeurs. Le cadre de cette méthode comporte trois phases principales : un prétraitement, une segmentation initiale et un raffinement de la segmentation.

Dans ce chapitre, nous expliquons la phase de prétraitement et la phase de segmentation initiale. La phase de prétraitement comprend les opérations qui permettent la réduction du bruit, par filtrage anisotrope, de l'hétérogénéité d'intensité et de la variation d'intensité inter-coups des images. L'étape suivante consiste à faire l'isolation du cerveau et sa segmentation, par une méthode robuste, en utilisant des opérations morphologiques, ce qui a pour objectif, d'éliminer les classes radiométriques qui ne nous intéressent pas (le crâne, la graisse, la peau et les muscles). Ensuite, nous calculons le plan de symétrie du cerveau, qui est aussi une bonne approximation du plan inter-hémisphérique. Ce plan permet de définir les relations spatiales directionnelles ; de plus, il va servir à l'analyse de l'histogramme, qui est considérée comme l'étape initiale de notre processus de segmentation. Enfin, nous abordons l'étape de segmentation initiale, où nous proposons deux méthodes : la 1^{ière} repose sur la classification floue, et la 2^{ième} est basée sur l'analyse de symétrie. Les deux méthodes fournissent deux types de données, la détection de la tumeur, et des tissus avoisinants, qui seront exploités dans l'étape de raffinement de la segmentation.

La méthode de segmentation des tumeurs cérébrales automatisée, que nous avons développée, est constituée de trois phases principales: le prétraitement, la segmentation initiale et le raffinement de la segmentation, comme illustré dans la figure 3.1.

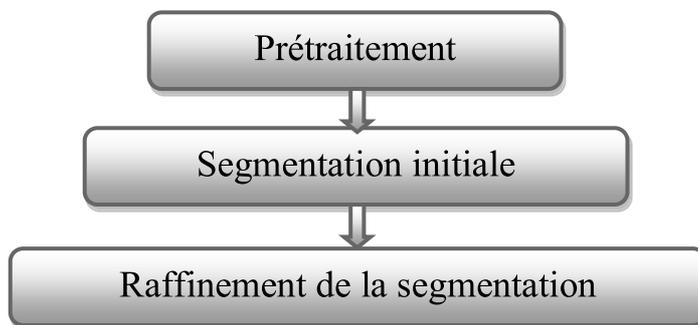


Figure 3.1 : Organigramme global de la méthode proposée

Dans le présent chapitre, nous décrivons les deux premières parties de notre méthode, la troisième partie sera abordée dans le chapitre 4.

3.1 Prétraitement

Ce traitement doit permettre d'obtenir des images de bonne qualité, pour permettre une bonne classification, et pour optimiser le temps de calcul. Il se décompose en trois étapes (Figure 3.2) :

- ❖ L'application d'un filtre anisotrope sur l'image, pour éliminer le bruit, et rendre les contours plus nets ;
- ❖ La détermination du volume d'intérêt (Segmentation du cerveau) : le volume dans lequel se situe le cerveau. Le but de cette opération est de réduire la région à analyser. Cela va impliquer une réduction très importante du temps destiné au traitement des zones inintéressantes ;
- ❖ Enfin, une dernière opération consiste à calculer le plan inter-hémisphérique.

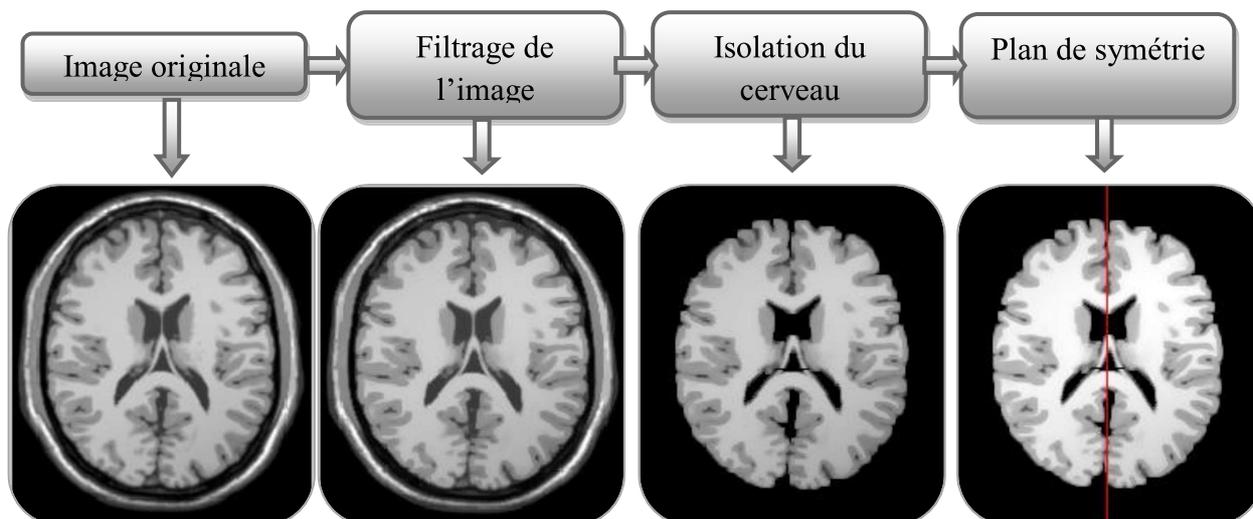


Figure 3.2 : Organigramme du processus de prétraitement

3.1.1 Filtrage du bruit dans les IRM

Malgré des améliorations significatives de la qualité d'image, au cours des dernières années, la pleine exploitation des données d'imagerie par résonance magnétique (IRM) est souvent limitée par le faible rapport signal-bruit (SNR), ou le contraste sur bruit (CNR). [71]. Donc, pour une meilleure distinction entre les différents tissus du cerveau, et pour réduire le bruit, il est nécessaire de filtrer l'image, avant d'estimer les paramètres (Figure 3.3). Plusieurs techniques ont été développées :

- [72] propose de filtrer l'image par le filtre de Wiener, suivi par un filtrage Gaussien ;
- [73] applique un filtrage à base d'ondelettes sur le logarithme de l'image ;
- [74] utilisent le filtrage à base de la diffusion anisotrope, pour réduire le bruit, étant donné que la diffusion fut développée spécialement pour les IRM. [69]

En effet, si le bruit n'est pas assez réduit dans les régions homogènes, il se peut que des pixels, appartenant au cerveau, ne se retrouvent pas dans le masque du cerveau. La seconde raison pour laquelle le filtre doit être appliqué, est le fait que la transition entre les différents tissus et le cerveau ne soit pas franche. Le fait d'appliquer un filtre, de type anisotrope, permet de rendre les transitions entre les tissus plus importantes.

On considère que l'image non dégradée $f(x,y)$ est affectée d'un bruit additif $n(x,y)$:

$$g(x,y) = f(x,y) + n(x,y) \quad (3.1)$$

Pour résumer, à partir de $g(x,y)$, on désire supprimer $n(x,y)$ pour obtenir $f(x,y)$.



Figure 3.3 : Bruit sur la matière blanche
(a) et (b) selon deux modes d'acquisitions différents

3.1.1.1 Filtrage anisotrope

Ce filtrage s'inscrit dans la lignée des filtres EPSF (Edge Preserving Smoothing Filtering), c'est-à-dire qu'il préserve les contours des objets, tout en filtrant les zones homogènes. Il est basé sur l'équation de diffusion de la chaleur. Les principes fondamentaux du filtre vont être expliqués. [75]

- Fondement théorique

En physique, le phénomène de la diffusion équilibre les différences de concentration, sans modification de la masse générale. L'idée consiste à appliquer ce phénomène au traitement d'images, c'est-à-dire que l'on va identifier localement la concentration du niveau de gris d'un pixel \vec{x} pour une image $I(\vec{x})$.

Mathématiquement, on exprime la propriété d'équilibrage des concentrations par la loi de Fick (équation 3.2) :

$$j(x) = -C(\vec{x}) * \bar{\nabla} I(\vec{x}) \quad (3.2)$$

Avec : J : Flux ;
C : Coefficient de diffusion ;
 $\bar{\nabla}$: Opérateur Gradient ;
I : Image.

Par ailleurs, l'équation de la conservation de la quantité de matière est donnée par (équation 3.3) [75] :

$$\frac{\partial I(\vec{x})}{\partial t} = -div[J(\vec{x})] \quad (3.3)$$

div : l'opérateur de divergence.

t : le temps.

I : l'image.

L'équation (équation 3.4), souvent appelée équation de la diffusion de la chaleur, est obtenue en remplaçant $J(\vec{x})$ par son expression (équation 3.2) dans (équation 3.3) :

$$\frac{\partial I(\vec{x})}{\partial t} = -div[C(\vec{x}) * \bar{\nabla} I(\vec{x})] = \frac{\partial}{\partial t} [C(\vec{x}) * \bar{\nabla} I(\vec{x})] \quad (3.4)$$

C : Coefficient de diffusion ;

$\bar{\nabla}$: Opérateur de Gradient.

Le coefficient de diffusion $C(\vec{x})$ permet de contrôler l'intensité du lissage sur l'image $I(\vec{x})$. La solution de l'équation différentielle (équation 3.4), dépend du coefficient de diffusion. Dans le cas où il est constant, la diffusion est de type isotrope, alors que lorsqu'il est variable, la diffusion est de type anisotrope. [75]. En imagerie IRM, on s'intéresse au filtrage par diffusion anisotrope.

➤ Diffusion anisotrope

Le but principal recherché par la diffusion anisotrope, est de filtrer l'image, pour réduire le bruit dans les zones où il est présent, mais en même temps d'éviter le lissage des contours. A cet effet, [69] modifie l'équation de diffusion (équation 3.4), pour faire de la diffusion anisotrope. Cette modification est fondée sur les principes suivants :

- Diffusion et homogénéisation maximale loin des contours ;
- Diffusion minimale au niveau des contours.

Pour ce faire, ils utilisent la norme du gradient comme estimateur de présence des contours, car un gradient élevé représente une forte probabilité de présence d'un contour, et inversement, un gradient faible représente une faible probabilité de présence d'un contour. A partir de là, ils aboutissent à une nouvelle formulation (équation 3.5), où désormais, le coefficient de diffusion dépendra de la force des gradients, qui est exprimée par leurs amplitudes [69] :

$$\frac{\partial I(\vec{x})}{\partial t} = \text{div}[C(\vec{x}) * \bar{\nabla} I(\vec{x})] = \frac{\partial}{\partial t}[C(\vec{x}) * \bar{\nabla} I(\vec{x})] = \frac{\partial}{\partial t}[C(\vec{x})] * \bar{\nabla} I(\vec{x}) + C(\vec{x}) * \frac{\partial}{\partial t}[\bar{\nabla} I(\vec{x})] = \bar{\nabla} C(\vec{x}) * \bar{\nabla} I(\vec{x}) + C(\vec{x}) * \Delta I(\vec{x}) \quad (3.5)$$

Avec :

- div : Opérateur de divergence ;
- $\bar{\nabla}$: Opérateur de Gradient ;
- Δ : Opérateur de Laplacien ;
- I : Signal/Image ;

$C(\vec{x}) = g(\|\bar{\nabla} I(\vec{x})\|)$: Coefficient de diffusion ;

g : Fonction non linéaire.

De nombreuses fonctions non linéaires de « g » ont été proposées, chacune correspondant à un critère de stabilité, de rapidité et de convergence; il convient de citer les plus connues.

- Perona et Malik [69]

Les deux fonctions proposées sont données ci-dessous (équation 3.6) et (équation 3.7):

$$g(\|\bar{\nabla} I(\vec{x}, t)\|) = \frac{(k)^2}{(\|\bar{\nabla} I(\vec{x}, t)\|)^2 + (k)^2} \quad (3.6)$$

$$g(\|\bar{\nabla} I(\vec{x}, t)\|) = \exp\left(\frac{(\|\bar{\nabla} I(\vec{x}, t)\|)^2}{(k)^2}\right) \quad (3.7)$$

Où le coefficient k caractérise l'amplitude des gradients.

- Weickert [69]

Pour une grande rapidité de convergence, Weickert propose la fonction ci-dessous (équation 3.8) :

$$g(\|\bar{\nabla} I(\vec{x}, t)\|) = 1 - \exp\left(-C_m / \left(\frac{\|\bar{\nabla} I(\vec{x}, t)\|}{k}\right)^m\right) \quad (3.8)$$

Avec : m : Paramètre de convergence ; k : Coefficient d'amplitude de gradient.

3.1.1.2 Résultat et comparaison

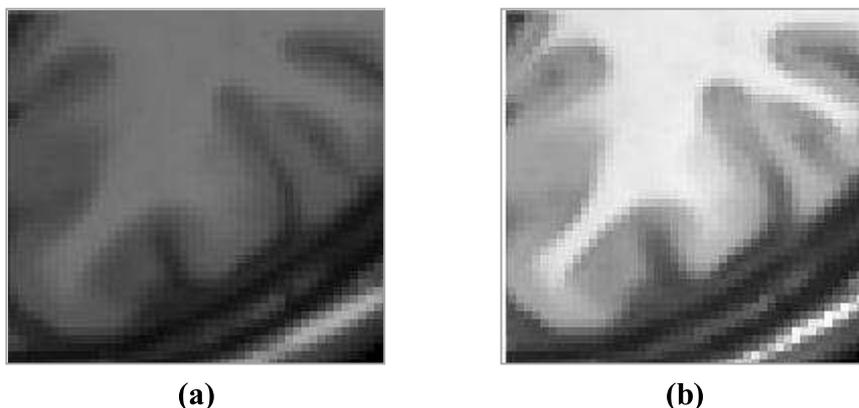


Figure 3.4 : Résultat et comparaison du filtrage d'image
(a) avant filtrage, (b) après filtrage par Perona & Malik

On voit bien que le filtre anisotrope accentue le contraste sur contours, lisse les régions et diminue aussi l'effet de volume partiel, Figure 3.4

Remarques

- Le principal défaut que possède ce filtre est qu'il lisse plus de zones qu'il n'en faut. C'est-à-dire, une région que nous considérons homogène va être décomposée en plusieurs zones lisses de niveaux légèrement différents.
- Lors de la classification, basée sur l'histogramme, il est important de disposer d'un histogramme dont les classes sont bien mises en évidence ; il est donc possible de filtrer l'histogramme, pour fusionner les sous populations, créées lors du filtrage anisotrope.
- Le filtrage par diffusion anisotrope et aussi un rehausseur de contraste, et il est donc inutile d'appliquer d'autres opérateurs.

Avant la segmentation, nous allons voir comment nous pouvons réduire le volume important des IRM, pour garder juste l'information utile et nécessaire. Nous allons faire une opération nommée «**isolation du cerveau**», par une méthode simple et efficace à la fois. Elle utilise un filtrage par diffusion anisotrope, suivi par des opérations morphologiques. [76], [77]

3.1.2 Isolation du cerveau

3.1.2.1 Principe

L'objectif de cette étape est d'isoler le cerveau, composé de matière blanche, de matière grise, du liquide céphalo-rachidien, et d'autres éléments présents sur les coupes (Figure 3.5) tels que : le fond, la peau, la graisse, les os et le sang que ce processus vise à éliminer.

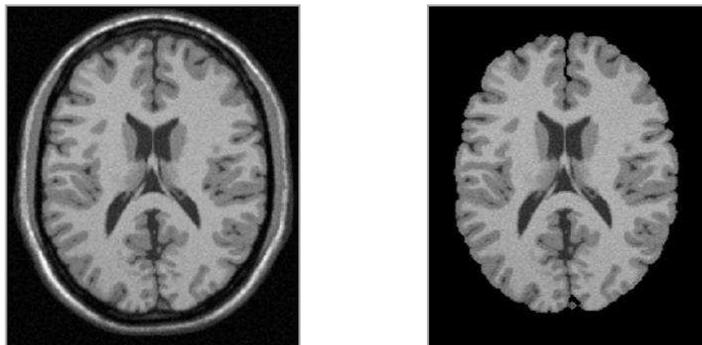


Figure 3.5 : Isolation du cerveau

L'intérêt d'un tel prétraitement est double. D'une part, il permet de réduire considérablement la zone d'intérêt, lors de traitements ultérieurs, et donc de réduire le volume des données à traiter. D'autre part, en travaillant sur une région d'intérêt, ces traitements sont plus performants, car plus ciblés, et moins perturbés par des informations pouvant être considérées comme du bruit.

Dans cette problématique, plusieurs travaux ont été réalisés. A titre d'exemple, nous pouvons citer :

Dans [78], les auteurs proposent une méthode, qui consiste en une pré-segmentation par EM (Estimation Maximisation), et une classification à l'aide d'une approche Bayésienne. Le masque de l'encéphale est déterminé à l'aide d'une méthode, qui combine l'algorithme du Flood Fill [78] (remplissage des trous), et les propriétés géométriques de l'encéphale.

D'autres auteurs [79] utilisent une étape de prétraitement, basée sur la diffusion anisotrope, et intégrant un détecteur de contour, de type contours actifs (Snakes), pour retrouver la forme du cerveau.

Dans [80], Les auteurs commencent par réduire le bruit de fond, en utilisant le filtre de Rayleigh, pour traiter par la suite le bruit de l'image, en utilisant la diffusion anisotrope. Pour obtenir le masque du cerveau, l'image est binarisée, moyennant des seuils, obtenus à partir de l'histogramme de l'image. Une phase d'étiquetage permet de sélectionner le masque du cerveau.

Dans [81], la méthode qui est basée sur le travail de [82], commence par un filtrage anisotrope, suivi par des opérations de morphologie mathématique, comprenant la ligne de partage des eaux, l'ouverture, la fermeture, l'érosion et la dilatation.

3.1.2.2 Etapes de la méthode

La méthode que nous proposons pour la segmentation du cerveau est celle présentée par [83]. elle est illustrée par la Figure 3.6 :

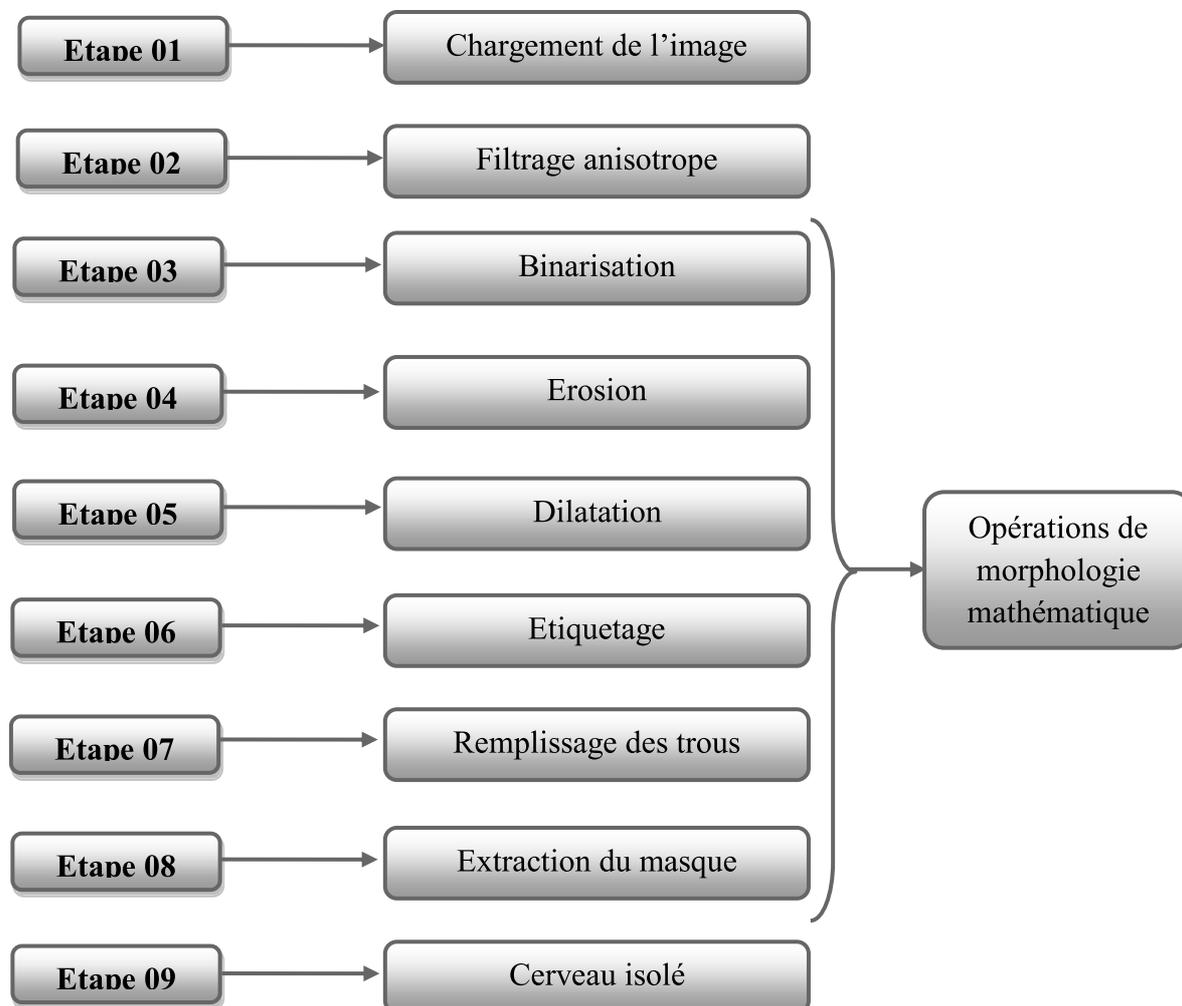


Figure 3.6 : Organigramme d'isolation du cerveau

➤ Image originale

Afin de faciliter la compréhension du passage d'une étape à l'autre, nous allons utiliser pour chaque étape, des images IRM synthétiques du cerveau, l'image test est nommée I_{org} (Figure 3.7(a)).

➤ Filtrage anisotrope

Pour réduire le bruit dans les hautes intensités des images IRM, tout en préservant autant que possible les frontières des régions, il est nécessaire de filtrer l'image, avant d'estimer les paramètres. Pour cela, nous allons utiliser un filtre anisotrope [70]. L'application du filtre anisotrope à l'image I_{org} , donne l'image I_{filt} (Figure 3.7(b)).

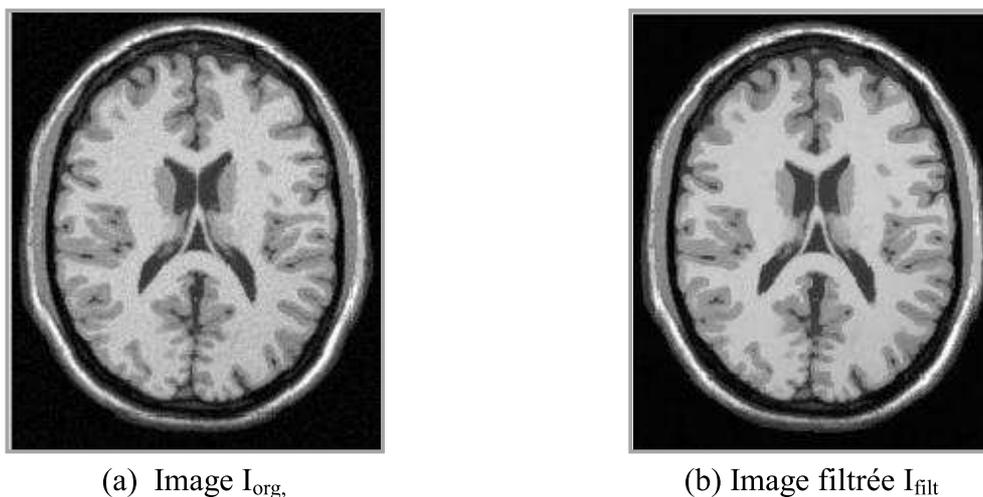


Figure 3.7 : Filtrage par diffusion anisotrope

➤ Binarisation

La binarisation est une opération qui produit deux classes de pixels : l'une est représentée par des pixels noirs, de niveau de gris 0, et l'autre par des pixels blancs, de niveau de gris 255, comme le montre l'équation (équation 3.9). Pour une meilleure valeur de ce seuil, on a préféré utiliser le seuillage par l'algorithme d'Otsu [84], (Figure 3.8) tel que :

$$I_{Bin}(\vec{x}) = \begin{cases} 0 & \text{si } I_{Diff}(\vec{x}) < S \\ 255 & \text{si } I_{Diff}(\vec{x}) > S \end{cases} \quad (3.9)$$

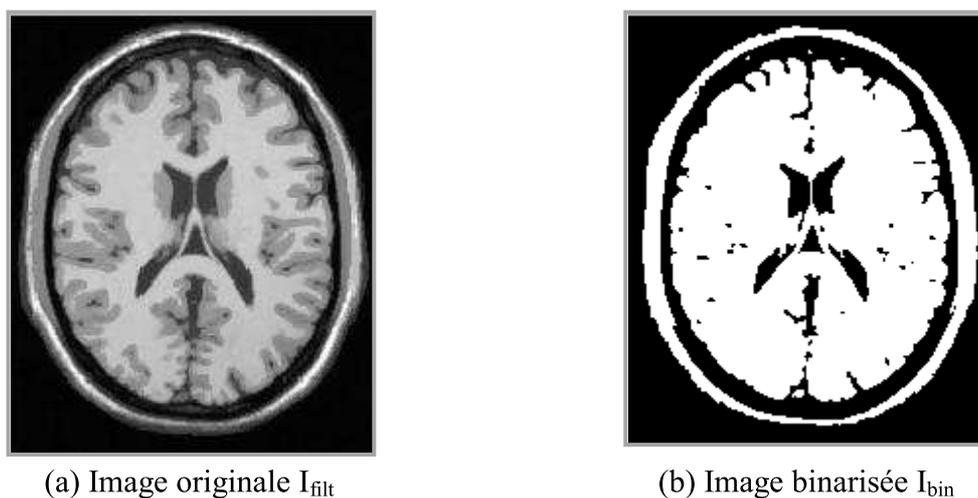


Figure 3.8 : Binarisation

➤ Erosion morphologique [83]

La connexion entre le cerveau et la boîte crânienne est un problème très fréquent en imagerie cérébrale. Pour garantir leur séparation, on applique une érosion sur l'image I_{bin} , où l'élément structurant B représente un disque de $R=2$, définie par l'équation 3.10 (Figure 3.9).

$$I_{Ero}(I_{bin}) = \{x \in I_{bin} | B_x \subseteq I_{bin}\} \quad (3.10)$$

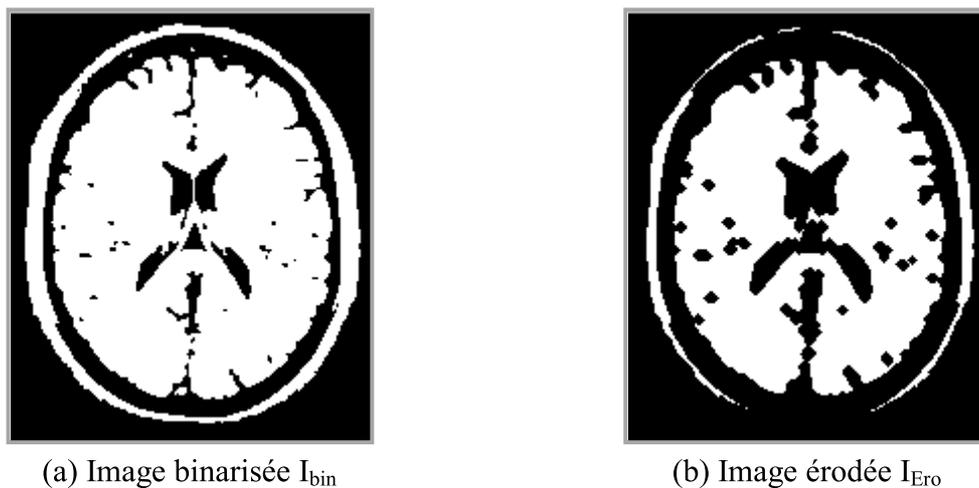


Figure 3.9 : Erosion

➤ Dilatation morphologique

Pour compenser les pertes en surface du cerveau après l'érosion, nous appliquons une dilatation binaire sur l'image érodée. Le résultat de la dilatation de l'image érodée I_{Ero} , par le même élément structurant B est donné par l'équation 3.11 (Figure 3.10). [83]

$$I_{Ero}(I_{bin}) = \{x \in I_{bin} | B_x \subseteq I_{bin}\} \quad (3.11)$$

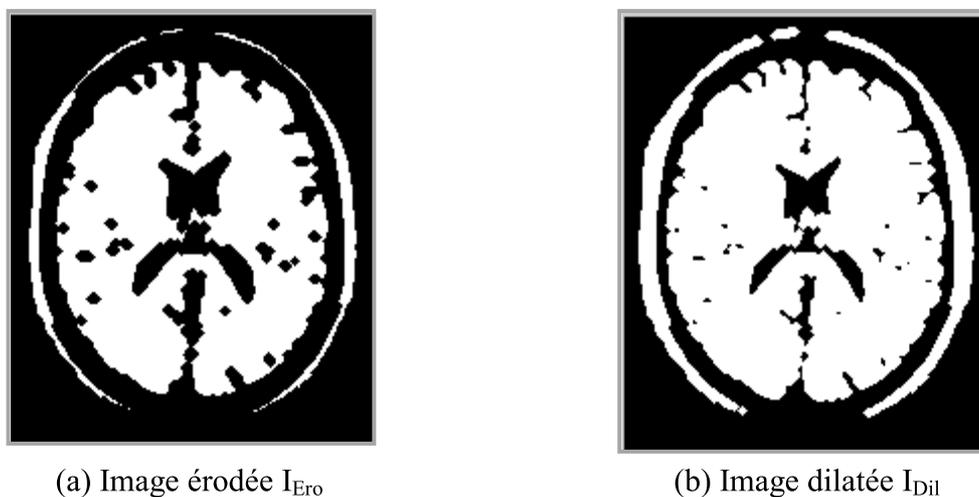


Figure 3.10 : Dilatation

➤ Etiquetage

A l'issue de l'étape précédente, le cerveau se présente comme la partie la plus importante, en nombre de pixels blancs ; pour le conserver, on procède à un étiquetage en composantes connexes (Figure 3.11(a)). Le cerveau représente la composante de plus forte cardinalité. [83]

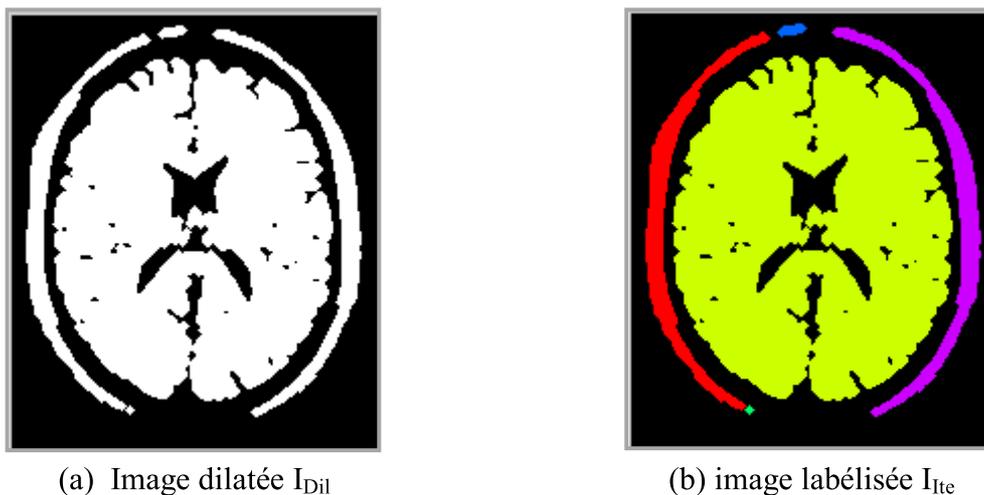


Figure 3.11 : Etiquetage en composantes connexes

➤ Remplissage des trous

Pour fermer les trous noirs, contenus dans le cerveau (Figure 3.12(a)), on utilise une ouverture morphologique.

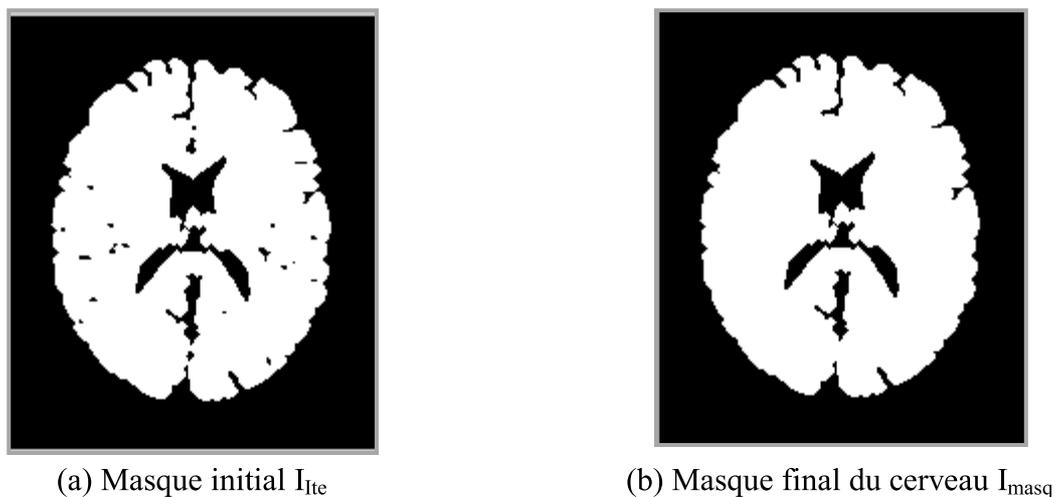
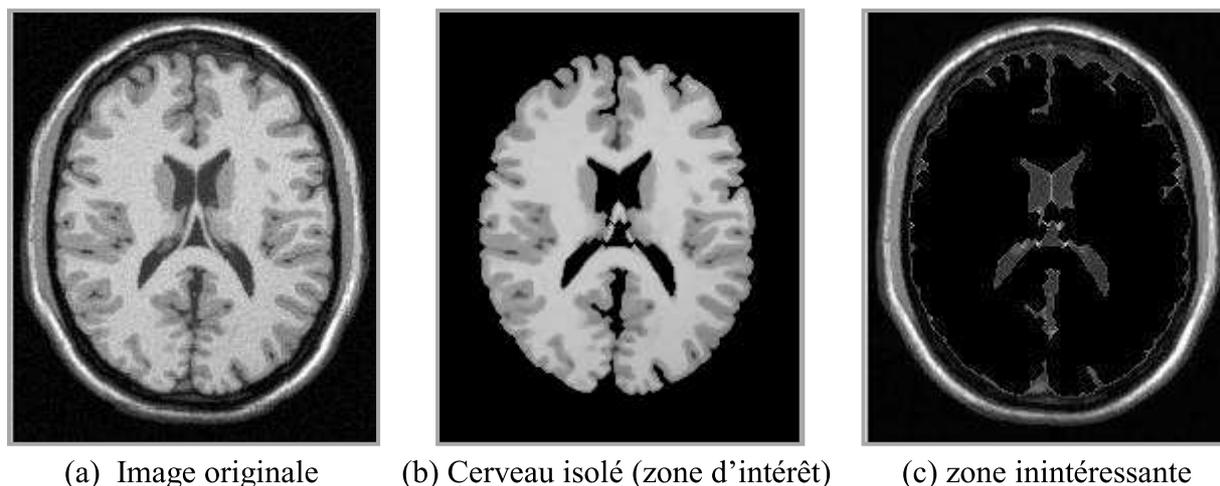


Figure 3.12 : Opération de remplissage des trous

➤ Application du masque pour l'extraction du cerveau

L'opération d'isolation du cerveau est facile à réaliser ; elle consiste à faire une intersection entre le masque obtenu précédemment, et l'image originale (Figure 3.13(b)). [83]



(a) Image originale

(b) Cerveau isolé (zone d'intérêt)

(c) zone inintéressante

Figure 3.13 : Opérations d'isolation du cerveau

Une fois que le cerveau est isolé, nous allons calculer son plan de symétrie. Le plan de symétrie de l'image en niveaux de gris, et celui du masque binaire du cerveau segmenté dans le cas normal, sont approximativement égaux. Pour augmenter l'exactitude, et pour accélérer l'algorithme dans les cas pathologiques, nous calculons le plan de symétrie sur le masque binaire du cerveau segmenté.

3.1.3 Calcul du plan de symétrie

Le plan de symétrie du cerveau est une bonne approximation du plan sagittal, qui est défini comme étant le plan qui sépare le mieux les hémisphères. La détection automatique de ce plan, dans des images du cerveau, est une tâche très utile, et nous allons l'utiliser pour segmenter, et détecter les tumeurs cérébrales.

Dans cette partie, nous présenterons quelques méthodes existantes, appliquées à la détection du plan de symétrie du cerveau dans les IRM, puis nous ferons une description détaillée de la méthode proposée.

Plusieurs méthodes de détection de symétrie ont été proposées. [95] utilisent une différence d'intensité entre les pixels, ce qui revient à une distance normalisée. La corrélation a été largement utilisée, notamment par [96], sur des images en niveaux de gris, et par [97], sur des images de contours. Citons également l'utilisation par [98] du changement de signe stochastique, décrit par [99]. [100] utilisent les moindres carrés tamisés (LTS least trimmed squares). Cette approche est a priori très robuste, lorsqu'elle est appliquée à la recherche du meilleur plan de symétrie, puisqu'elle est fondée sur un tri des erreurs, et sur l'élimination des points aberrants. Cependant, il ne s'agit pas d'une mesure globale de symétrie. L'inconvénient de cette approche est qu'elle est difficile à réaliser. Enfin, [90] propose une mesure de symétrie par la transformée de Hough (TH).

Le but de la détection par Hough est de généraliser l'idée de symétrie, pour les objets simples, en utilisant la TH, pour montrer qu'il est possible d'exposer de manière automatique, les éventuels axes de symétrie dans une image.

3.1.3.1 Calcul du plan de symétrie par la transformée de Hough

Dans la détection d'éléments spécifiques, il existe des algorithmes qui, pour identifier ces formes élémentaires, entreprennent de suivre les contours, pour finalement les lier par des critères, plus ou moins complexes, afin de remonter jusqu'aux formes recherchées. Une autre approche de ce problème, serait de tenter d'accumuler des évidences, sur l'existence d'une forme particulière, telle qu'une droite, un cercle ou une ellipse. C'est cette démarche qui a été adoptée dans la transformée de Hough.

La transformation de Hough a été proposée et brevetée par P.V.C. Hough [101] en 1960, pour détecter des alignements de points, à l'aide d'un oscilloscope et de deux caméras vidéo. Dans les dernières décennies, la transformée de Hough est devenue un outil standard, dans le domaine de la vision artificielle. Elle permet la détection de droites, de cercles ou d'ellipses, de façon traditionnelle. Elle peut aussi être étendue à des cas de description d'objets plus complexes.

Plus généralement, les travaux de Rosenfield [93], au début des années 70, présentent cette transformation comme une méthode, permettant de détecter une forme géométrique paramétrable (citons par exemple les cercles, les ellipses, et plus généralement les coniques). De nombreux travaux ont ensuite été réalisés, aussi bien d'un point de vue théorique, que d'un point de vue pratique, pour ses applications en reconnaissance de formes.

Plusieurs études de synthèses ont été publiées par Maitre dans [93], ainsi que de nombreux travaux concernant la détection de formes paramétriques très diverses, en particulier les cercles Slansky dans [93] et les paraboles.

Dans ce qui suit, nous allons illustrer brièvement le principe de la TH sur l'exemple de la détection des droites, puis nous allons voir son application pour la détection du plan de symétrie.

3.1.3.2 Fondements théoriques de la TH

Nous appellerons "espace des droites", un plan dont les axes représentent respectivement la pente et l'ordonnée à l'origine des droites [S9]. De la même manière qu'un point est parfaitement localisé dans un espace de dimension 2, par ses coordonnées (x,y), une droite est parfaitement localisée dans cet espace des droites, par ses paramètres a et b, a étant son coefficient directeur et b son ordonnée à l'origine. Le couple (a,b) représente les coordonnées de cette droite dans l'espace des droites.

Il vient alors assez vite, l'intuition qu'un point de l'image, devrait être représenté par une droite dans l'espace des droites. En effet, on a dans le cas d'une droite [S9] :

$$y = ax + b \quad (3.12)$$

a et b sont des constantes, et la droite est par définition constituée des points, dont les coordonnées vérifient cette équation.

Dans le cas d'un point, on peut écrire :

$$b = -ax + y \quad (3.13)$$

Autrement dit, toutes les droites passant par le point (x,y) fixé, voient leurs paramètres a et b vérifier cette équation. Or, on reconnaît là, une équation de droite. C'est cette droite (a,b) qui caractérise, dans l'espace des droites, le point (x,y) . [S10]

La figure 3.14 donne un exemple de droite, du point (a,b) , dans l'espace (x,y) , et la droite du point (x,y) dans l'espace (a,b) .

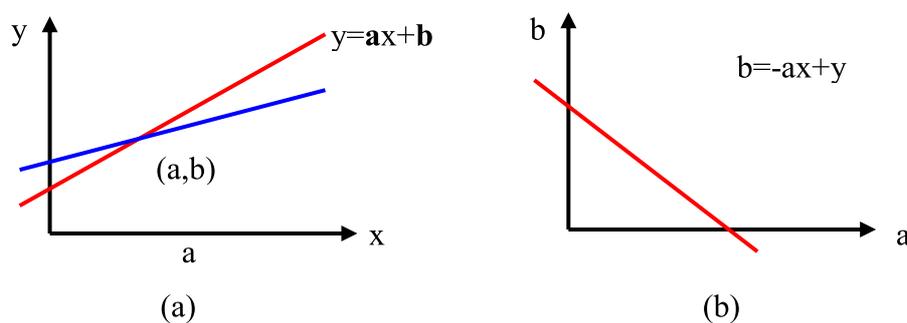


Figure 3.14 : Représentation d'une droite

(a) Espace xy , (b) Espace ab

Pour chaque point p , toutes les droites passant par ce point, correspondent à une seule droite D_p dans l'espace (a, b) . (Figure 3.15)

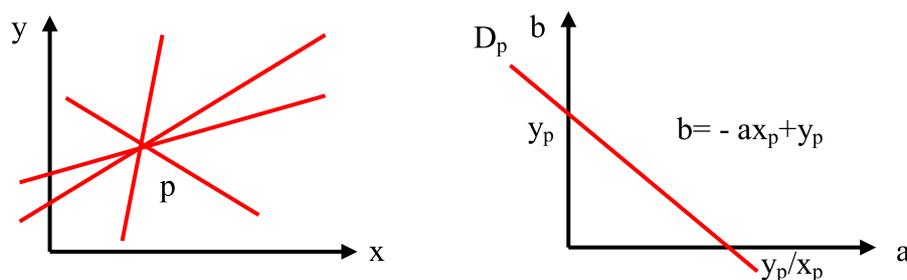


Figure 3.15 : Représentation d'un point dans l'espace ab

Pour deux points p et q , on a deux faisceaux de droites, qui ont en commun la droite qui relie les points p et q , dans l'espace (x, y) . A cette droite (p, q) correspond l'intersection des 2 droites D_p et D_q , représentant p et q dans l'espace (a,b) (Figure 3.16).

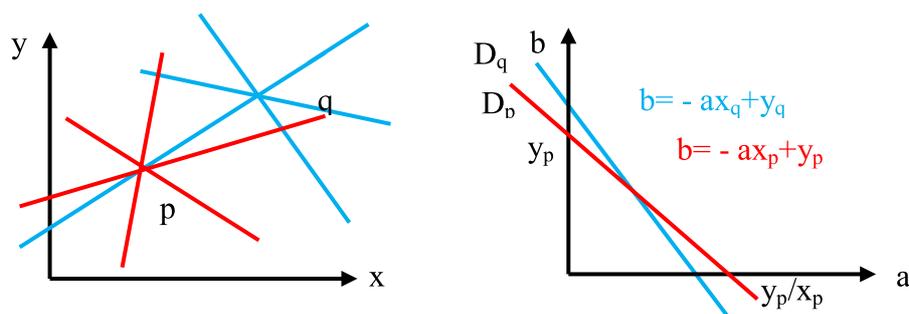


Figure 3.16 : Représentation d'une droite dans l'espace ab

Le problème est que l'espace (a, b) est non borné ($a \rightarrow \infty, b \rightarrow \infty$). La solution est d'utiliser une représentation **polaire** (ρ, θ) , appelée l'Accumulateur (Figure 3.17). [91], [S10]

A un point de contour, on associe la sinusoïde d'équation suivante :

$$\rho = x \cos \theta + y \sin \theta \quad (3.14)$$

ρ et θ sont des paramètres : $0 < \rho < \text{diagonale de l'image}$
 $0 < \theta < 2 \Pi$

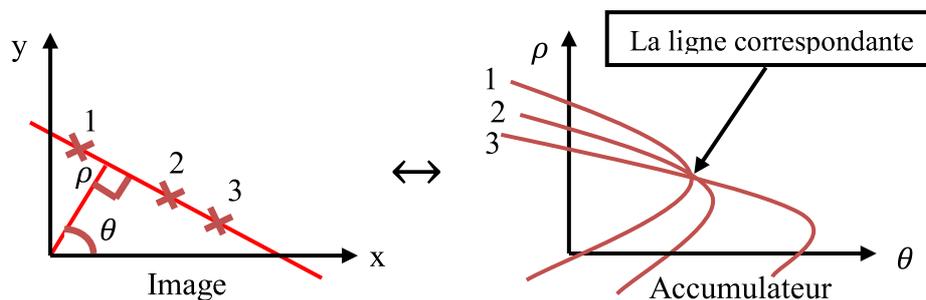


Figure 3.17 : Représentation dans l'espace (ρ, θ)

A chaque point de l'espace (ρ, θ) correspond une droite sur l'image (Figure 3.18).



Figure 3.18 : Accumulation

3.1.3.3 Principe de la méthode par TH [94]

La méthode consiste à restreindre les images à un ensemble de "*points significatifs*" beaucoup moins nombreux mais porteurs de l'information géométrique (les symétries éventuelles). Il s'avère que les contours de l'image répondent très bien à ces contraintes.

Ensuite, on considère tous les couples de points et on calcule leur médiatrice. Mais contrairement au cas des objets simples, on ne vérifie pas une invariance par symétrie, même approchée, mais on se contente d'accumuler les médiatrices dans l'espace de Hough. Dans le cas idéal, c'est-à-dire celui où il y a un vrai axe de symétrie, il sera accumulé $N/2$ fois où N est le nombre de points du contour. En effet $N/2$ points sont les symétriques des $N/2$ autres par une symétrie axiale dont l'axe est leur médiatrice. Les autres médiatrices sont réparties de manière à peu près aléatoires dans l'espace. En pratique, si des axes de symétrie existent, ils correspondront donc à des maxima locaux dans l'espace de Hough.

La dernière étape consiste donc à détecter ces zones d'accumulation par des méthodes inspirées des algorithmes de classification et, plus précisément, à donner les droites correspondant à des maxima locaux et donc à des axes de symétrie.

➤ Organigramme de la méthode [92]

Nous donnons l'organigramme qui représente les différentes étapes de la détection de l'axe de symétrie, en utilisant la transformée de Hough (Figure 3.19).

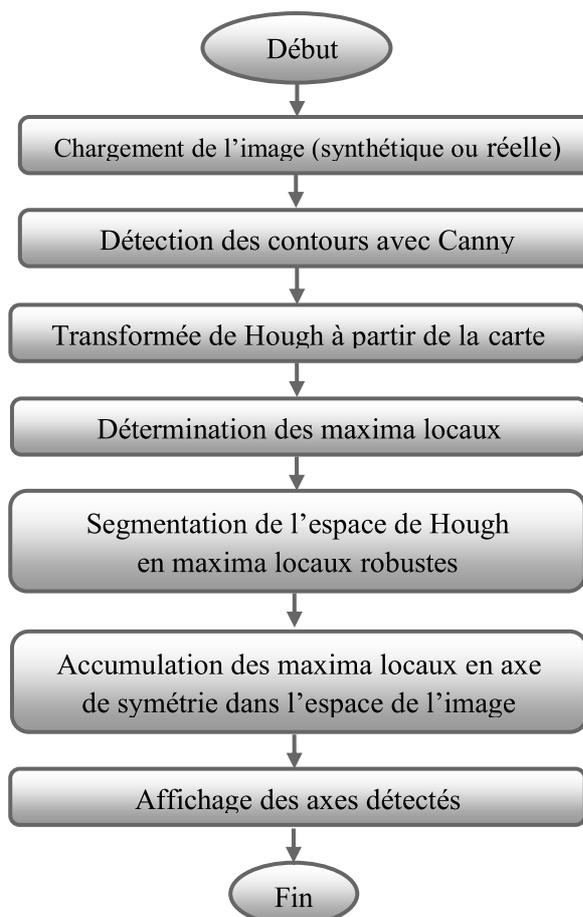


Figure 3.19 : Organigramme de la détection du plan de symétrie par la TH

➤ Détection de contours

Comme nous l'avons dit plus haut, nous avons besoin d'un petit nombre de points, pour réduire de manière importante le temps de calcul (ce nombre devant rester significatif pour trouver des axes pertinents). En outre, nous avons besoin de contours fiables, non bruités. Il existe plusieurs méthodes pour le faire, on peut citer : la méthode de Prewitt, Roberts, Sobel ou Canny ... etc.

Les méthodes de Prewitt et Roberts donnent des contours discontinus, peu exploitables, car perdant partiellement la symétrie de l'image. Au premier abord, Sobel semble être le plus intéressant. On constate que si on augmente la valeur du seuil des différentes méthodes, on trouve que seul Canny fournit des contours stables avec peu de points (Figure 3.22) alors qu'avec Sobel, les contours finissent par se déconnecter [94].

Finalement, et selon la synthèse de [94], nous avons retenu la méthode de Canny avec des seuils typiques de l'ordre de 0,5 à 0.7. Les contours obtenus sont à la fois fidèle à la géométrie originale de l'image, et relativement "pauvres" en points, permettant ainsi des calculs rapides (Figure 3.20).

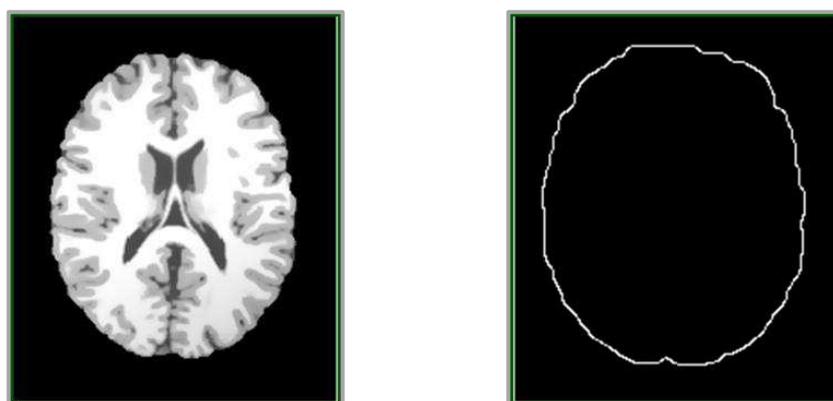


Figure 3.20 : Carte contour obtenue avec le détecteur de Canny, $S=0.7$

➤ Application de la transformée de Hough

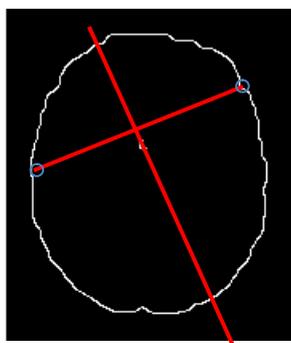


Figure 3.21 : Calcul de médiatrices

A ce stade, nous prenons tous les couples de points du contour calculé, et nous déterminons leur médiatrice, comme le montre la figure 3.21.

Chaque médiatrice calculée, correspond à une case de l'espace de Hough (discrétisée à un degré et à un pixel près). [90]. Une fois l'accumulation terminée, on obtient le type de représentation de la figure 3.22.

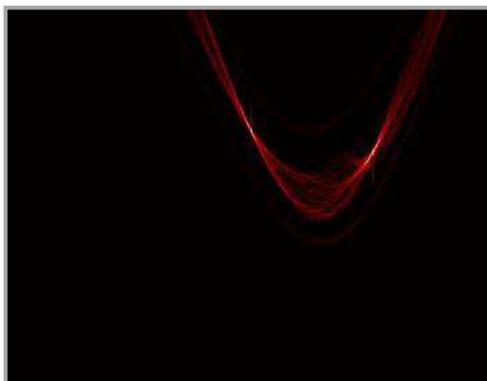


Figure 3.22 : Accumulation

A l'œil, il est facile de repérer deux maxima locaux importants, dont on peut vérifier qu'ils correspondent à deux axes de symétrie de l'image. En revanche, les trouver de manière automatique est moins évident (la forme en arche de la sinusoïde correspond à l'existence d'un point commun à de nombreuses médiatrices, c'est-à-dire un centre de symétrie) [94]

➤ Détermination des maxima locaux

En pratique, l'accumulateur obtenu (comme celui de la **Figure 3.24**) présente un grand nombre de maximums locaux. Nous voulons ne garder que ceux qui sont statistiquement significatifs, et qui appartiennent donc à des régions plus denses en droites. Il faut donc délimiter ces régions, ce qui revient à faire une classification de la transformée de Hough, et à en extraire le point le plus "significatif". A ce stade, la reconnaissance des formes nous fournit de nombreux outils. [94]. Le plus général est l'algorithme isodata. Il permet d'ajuster, de manière dynamique et automatique, le nombre de classes (de régions) pertinentes, dont le centre est le point moyen. Cet algorithme, même si en pratique 2 ou 3 itérations suffisent, est gourmand en temps de calcul, difficile à mettre en œuvre, et requière un grand nombre de paramètres de contrôle. Pour réduire le temps de calcul, nous n'autorisons plus le regroupement de classes, et nous n'utilisons qu'un seul paramètre de contrôle : DistMax. [93]

A la fin, nous trions les maxima trouvés, et retenons ceux dont la valeur est la plus élevée. De plus, nous réduisons éventuellement le nombre de points dans l'espace de Hough, en effectuant un seuillage, éliminant une certaine proportion de ces points.

➤ Résultats de la méthode

Le résultat de l'application de cet algorithme, à une image du cerveau, est présenté dans la figure 3.23.

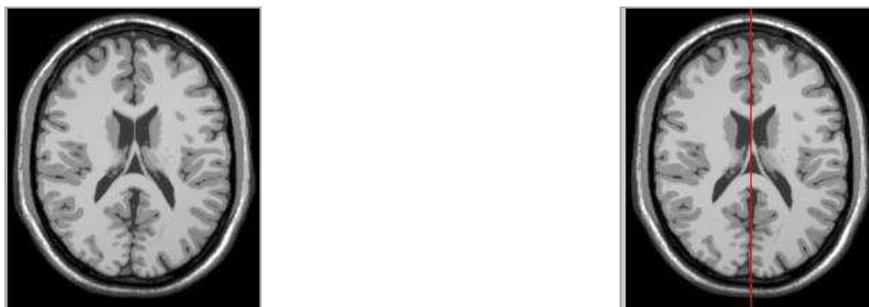


Figure 3.23 : Détermination de l'axe de symétrie

Nous avons retenu la méthode de la transformation de Hough, méthode paramétrique de recherche de formes, appartenant à la famille des approches contour. Cette méthode est adaptée à notre problème, son implantation informatique ne nécessite pas des temps de calcul importants. Dans le chapitre cinq, nous présenterons les résultats de détection du plan de symétrie par la transformée de Hough, sur différentes images, afin de montrer et d'explorer la fiabilité de cet algorithme.

3.2 Segmentation initiale

La segmentation initiale consiste à segmenter, et à détecter initialement la tumeur ou l'œdème. Cette opération est effectuée, en utilisant deux méthodes : une méthode de classification floue, et une méthode, fondée sur l'analyse de symétrie, et quelques opérations morphologiques.

La première méthode s'appuie sur l'hypothèse que la tumeur ou l'œdème apparaît dans l'image avec des niveaux de gris spécifiques, correspondants à une classe supplémentaire.

La deuxième méthode est fondée sur l'hypothèse que la forme du cerveau est approximativement symétrique, et que la tumeur peut changer la symétrie.

Cette détection fournit l'initialisation pour une segmentation plus précise, en utilisant un modèle déformable paramétrique, contraint par des relations spatiales, utilisant le flux du vecteur gradient (GVF). La section de raffinement de la segmentation sera détaillée au chapitre suivant.

3.2.1 Segmentation par classification

La classification fait partie des outils les plus fréquemment utilisés, dans bon nombre de disciplines. Ils ont pour but de déterminer des procédures, permettant d'associer une classe à un objet ; ces objets regroupés ont des caractéristiques communes, sont similaires, mais se distinguent clairement des objets des autres classes.

Les méthodes de classification se divisent généralement en 2 familles : mode supervisé et mode non supervisé. La méthode que nous allons étudier par la suite, est la classification floue non supervisée, vu que nous connaissons a priori, le nombre de classe à segmenter dans

une image IRM cérébrales, qui est de 4 classes pour une image saine (MG, MB, LCR et le fond), et de 5 à 6 classes, pour des images pathologiques (MG, MG, LCR, fond et lésions).

3.2.1.1 La famille des c-moyennes

La famille des C-moyennes est une classe de méthodes floues, très utilisées en classification. On distingue trois types d'algorithmes, suivant les contraintes imposées sur les degrés d'appartenance :

- Les C-moyennes ("Hard C-Means" ou HCM) :

$$\forall k : U_{ik} = 0 \mid 1 ; \sum_{k=1}^c U_{ik} = 1 \quad (3.15)$$

- les C-moyennes floues ("Fuzzy C-Means" ou FCM) :

$$\forall k : U_{ik} \in [0, 1] \text{ et } \sum_{k=1}^c U_{ik} = 1 \quad (3.16)$$

- les C-moyennes possibilistes ("Possibilistic C-means" ou PCM) :

$$\forall k : U_{ik} \in [0,1] \quad (3.17)$$

On remarquera ainsi que :

(HCM) \square (FCM)

Ces méthodes sont fondées sur la minimisation d'une fonctionnelle commune [86]:

$$J(U,V,\omega) = \sum_{i=1}^c \sum_{k=1}^n U_{ik}^m \cdot d_{ik}^2 + \sum_{i=1}^c \omega_k \sum_{k=1}^n (1 - U_{ik})^m \quad (3.18)$$

U est la matrice de partition floue d'éléments U_{ik} , respectant les contraintes relatives à l'algorithme utilisé.

$V = \{V_1, V_2, \dots, V_c\}$ est l'ensemble des prototypes des classes C_i , dont la distance aux x_k est noté d_{ik} .

$w = \{w_1, w_2, \dots, w_c\}$ est l'ensemble des termes de pénalité de PCM des données atypiques, associés à chacune des classes (équivalents à zéro dans le cas de HCM et de FCM).

m appelé coefficient de flou, est un paramètre de l'algorithme, contrôlant la quantité de flou dans la partition ($m > 1$).

3.2.1.2 Classification c-moyenne floue (FCM)

- Présentation de FCM

L'algorithme des C-Moyennes Floues (Fuzzy C-Means : FCM) est une extension directe de l'algorithme classique des c-moyennes (C-Means), où l'on a introduit la notion d'ensemble flou dans la définition des classes, afin de prendre en compte des données imprécises et incertaines.

La modélisation de l'imprécision s'effectue, en considérant des frontières graduelles, au lieu de frontières nettes entre les classes. L'incertitude s'exprime par le fait qu'un pixel possède aussi bien des attributs qui l'assignent à une classe, qu'à une autre. [65]

Le principe de base du FCM est de former, à partir des individus non étiquetés, c groupes, qui soient les plus homogènes et naturels possibles. "Homogène" et "naturel" signifient, que les groupes obtenus doivent contenir les individus les plus semblables possible, tandis que des individus de groupes différents doivent être les plus dissemblables possibles (selon la relation (3.19) [87]), et les classes obtenues ne sont pas forcément disjointes. Dans ce cas, les données x_k ne sont plus assignées à une classe unique, mais à plusieurs, par l'intermédiaire des degrés d'appartenance U_{ik} du vecteur x_k à la classe i .

Si U_{ik} est le degré d'appartenance de x_k à la classe i , la matrice $U_{c \times n}$ est appelée matrice de C -partitions floues, si et seulement si, elle satisfait aux conditions [65]:

$$\forall i \in \{1, \dots, c\}, \forall k \in \{1, \dots, N\} \quad \begin{cases} U_{ik} \in [0, 1] \\ 0 < \sum_{k=1}^N U_{ik} < 1 \end{cases} \quad (3.19)$$

$$\forall k \in \{1, \dots, N\} \quad \sum_{i=1}^c U_{ik}^m = 1 \quad (3.20)$$

La fonctionnelle à minimiser (3.21), et les solutions (3.22), (3.23) au problème du FCM, sont décrites par les formules suivantes :

$$J(U, V, X) = \sum_{i=1}^c \sum_{k=1}^n U_{ik}^m d_{ik}^2 \quad (3.21)$$

$$V_i = \frac{\sum_{k=1}^n U_{ik}^m X_k}{\sum_{k=1}^n U_{ik}^m} \quad (3.22)$$

$$U_{ik} = \sum_{i=1}^c \frac{(d_{ik}^2)^{\frac{2}{1-m}}}{d_{ik}^2} \quad (3.23)$$

- V_i désigne le centroïde du cluster, et X_k l'échantillon numéro k ;
- d_{ik} est la distance entre l'échantillon X_k et le centroïde du cluster i , définie par :
 $d_{ik} = \|X_k - V_i\|$;
- U_{ik} est le degré d'appartenance de l'échantillon k à la classe i . Les U_{ik} forment une matrice $c \times n$, dite matrice d'appartenance M .

$m > 1$ est un indice ou degré de flou (index of fuzziness), qui règle le degré de flou des clusters. Si m tend vers 1, on tend vers des clusters "nets", c'est-à-dire que la matrice comportera uniquement des 0 et des 1 (HCM). Par contre, plus m est grand, plus les clusters

sont “mous”, c’est-à-dire que leur fonction d’appartenance est très étendue. Généralement, les valeurs de m sont prises dans l’intervalle $[1.5, 2]$, permettant d’obtenir des résultats intéressants et d’interprétation aisée.

➤ Algorithme FCM

L’algorithme FCM est se déroule en 5 étapes essentielles qui sont :

Etape (1) :

- choisir le nombre de classes c ;
- fixer le degré de flou m , tel que $1 < m < \infty$, mais généralement il est compris entre $[1.5, 3]$;
- fixer ε (seuil représentant l’erreur de convergence, par exemple $\varepsilon = 0.001$).

Etape(2) :

- initialiser la matrice des degrés d’appartenance par des valeurs aléatoires dans l’intervalle $[0, 1]$, ou bien en leur affectant comme valeur $1/c$;
- choisir la mesure d_{ik} , en prenant par exemple $d_{ik} = \|X_k - V_i\|$.

Etape (3) :

- mettre à jour le vecteur V_i des centres, en utilisant l’équation (équation 3.21) ;
- calculer J par l’équation (équation 3.22) ;

Etape (4) :

- Mettre à jour la matrice de degrés d’appartenance par l’équation (équation 3.23) ;

Etape (5) :

- Répéter les étapes 3 à 4, jusqu’à la satisfaction du critère d’arrêt
- $$|J(U, V, X)_n - J(U, V, X)_{n-1}| < \varepsilon$$

➤ Quelques avantages et inconvénients de FCM [88], [85], [89] :

FCM comme toutes autres méthodes bénéficie aussi bien d’avantages que d’inconvénients, on cite ici les points importants :

- ✓ Un Bon taux de reconnaissance des tissus cérébraux, quelle que soit la modalité et le type d’acquisition (mono ou multi-spectrale).
- ✓ L’avantage des algorithmes automatiques FCM, est que les centres de classes sont calculés de manière automatique.
- ✗ L’algorithme est limité par le choix a priori des paramètres : le nombre de classes, l’initialisation aléatoire des paramètres, le choix du prototype, le paramètre de contrôle du flou. De plus, la fonction d’appartenance est sensible aux bruits.
- ✗ le choix du nombre de prototypes est un problème certes, mais il est possible de fixer un nombre de prototypes plus important à l’initialisation, puis de faire un regroupement des classes, si nécessaire.

- ✘ Concernant la forme des fonctions d'appartenance, on remarque que celles obtenues par le FCM n'ont pas la forme de prémisses floues. On peut constater que des points très éloignés des centres de classe, n'ont pas des degrés d'appartenance nuls, ils tendent au contraire vers 0.5 ; cela est dû à la contrainte probabiliste (équation 3.18), indiquée ci-avant.
- ✘ On peut avoir des points équidistants au centre de la classe, mais qui n'ont pas le même degré d'appartenance. Cela est dû à l'équation (équation 3.21), qui est fonction de la distance du point à la classe, et du point à toutes les autres classes. De ce fait, des singularités se produisent, car deux points bien qu'équidistants à une classe, ne le sont pas par rapport aux autres classes.

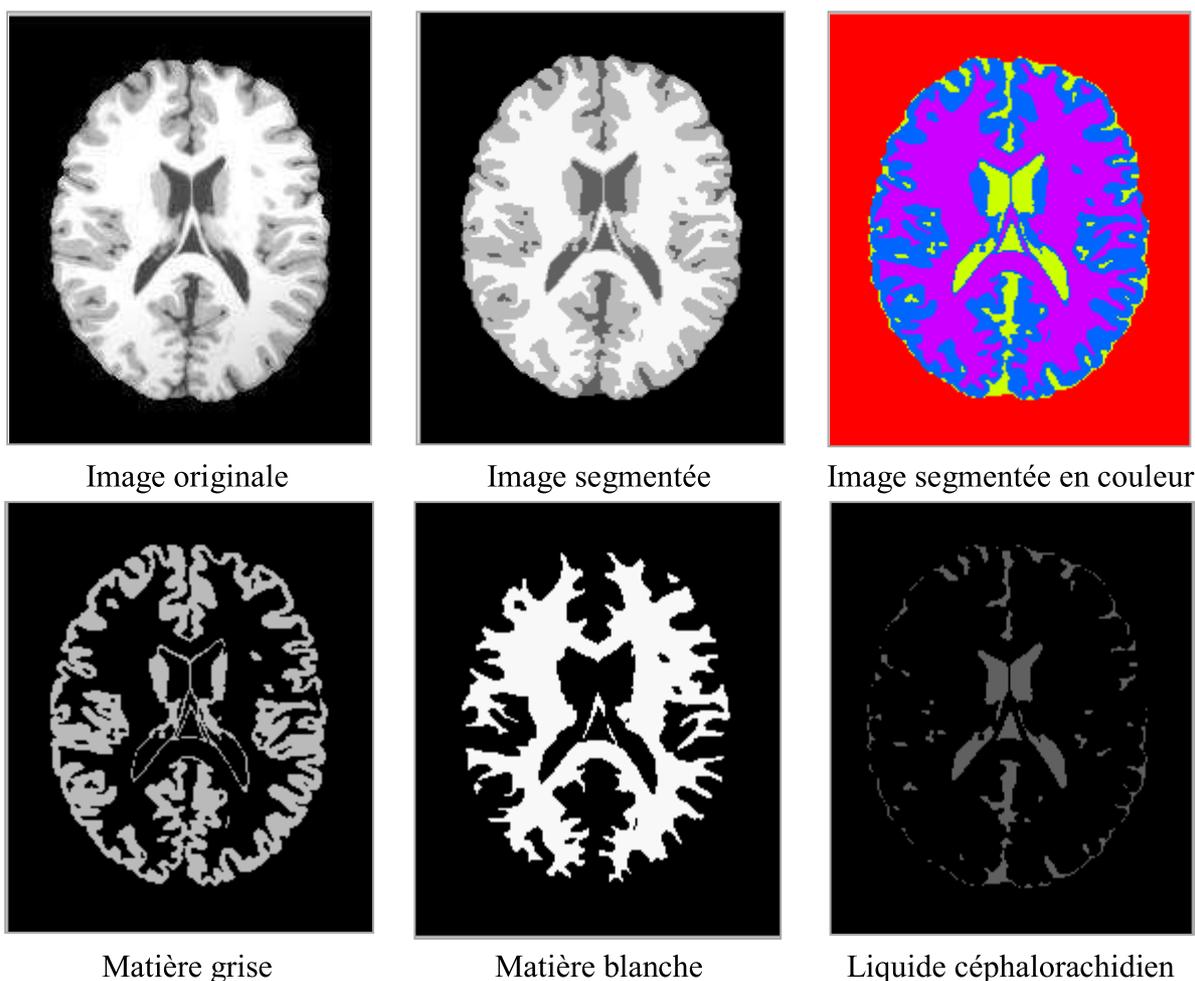


Figure 3.24 : Exemple de segmentation d'une image synthétique du cerveau par FCM

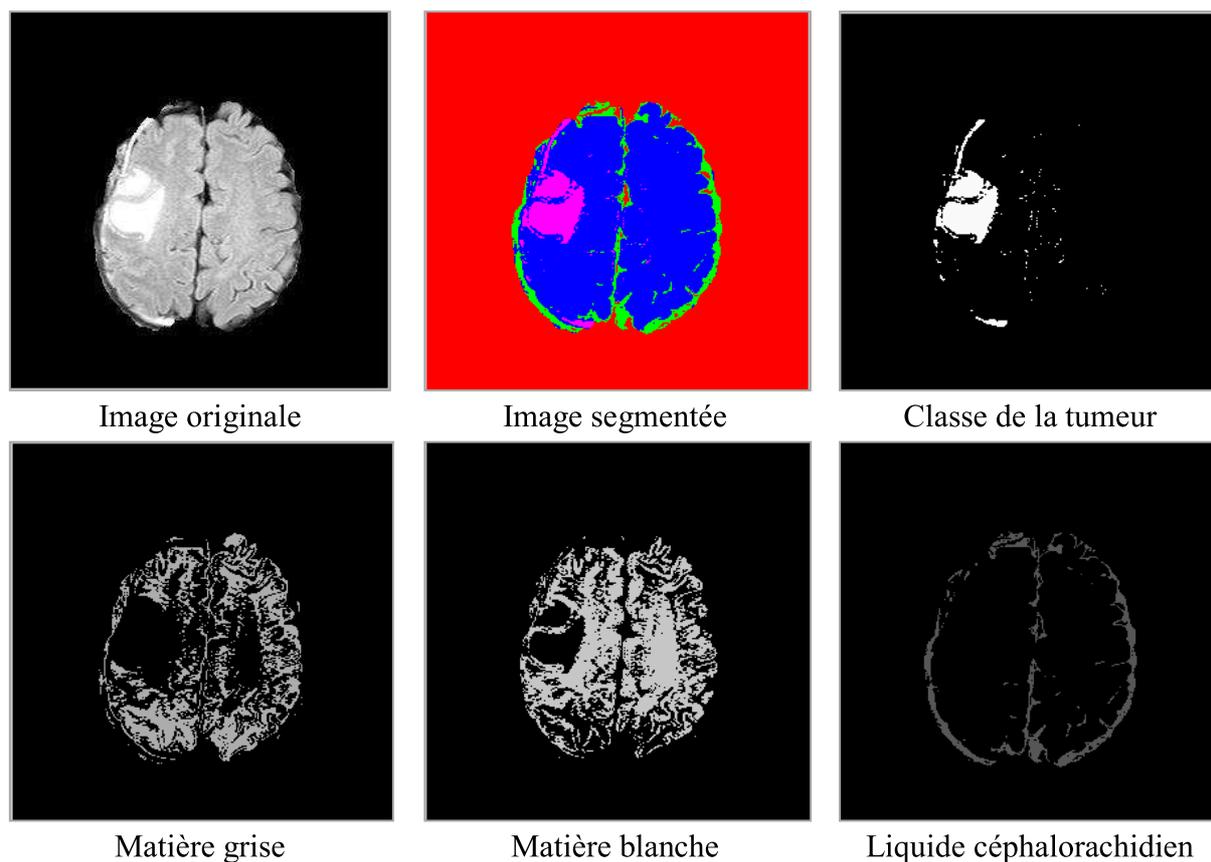


Figure 3.25 : Exemple de segmentation d'une image réelle pathologique du cerveau par FCM

Nous constatons que FCM donne une bonne segmentation pour l'image IRM cérébrale synthétique (Figure 3.24). On peut voir qu'il y a une très bonne discrimination entre les trois tissus, ce qui reflète l'efficacité de cet algorithme.

Cependant, lorsqu'on l'a appliqué sur une image réelle (Figure 3.25), nous avons vu qu'il y a plusieurs pixels mal segmentés, ce qui induit à un petit chevauchement dans les classes de chaque tissu cérébral. Cela peut s'expliquer par les problèmes, liés à l'acquisition, ou aux artefacts, car l'IRM, comme toute autre technique d'acquisition, n'échappe pas à la constitution de fausses images. Les artefacts sont des images observables, qui n'ont pas, à proprement parler, de réalité anatomique. Ils peuvent être évités, ou minimisés, en modifiant certains paramètres d'acquisitions ou de reconstructions.

Pour notre étude, nous nous intéressons à la classe de la tumeur, qui, comme on peut le voir, présente un contour délimité ; donc, une étape de raffinement de la segmentation est indispensable pour palier à ce problème, et pour arriver à une méthode de segmentation rigoureuse et robuste. Cette étape est présentée en détail au chapitre 4.

3.2.2 Segmentation par analyse de symétrie

Pour résoudre le manque de généralité de la méthode précédente, nous suggérons une autre approche, à l'aide du plan de symétrie approximatif. [52]

Le calcul du plan de symétrie du cerveau est exécuté, selon la méthode proposée par [90], fondée sur la transformée de Hough.

Nous supposons que les tumeurs sont localisées dans seulement un hémisphère, ou ne sont pas symétriques.

Notons $H_n(x)$: l'histogramme de l'hémisphère normal (sain) ;
 et $H_p(x)$: l'histogramme de l'hémisphère pathologique ;
 et $H_s(x)$: l'histogramme de l'hémisphère de différence ; tel que $H_s(x)=H_p(x)-H_n(x)$.

$H_s(x)$ fournit des informations sur de nouvelles classes d'intensités, induites par la tumeur, comme le montrent les figures 3.26, 3.29 et 3.30.

Nous classifions ici les tumeurs à partir de leur apparence radiologique en 4 classes comme nous l'avons présenté dans la section 7 du chapitre I : tumeurs non contrastées, tumeurs contrastées et sans œdème, tumeurs contrastées et avec œdème, tumeurs contrastées partiellement.

On regroupe les deux derniers types de tumeurs pour l'analyse d'histogramme, vu qu'ils ont les mêmes caractéristiques.

3.2.2.1 Tumeurs non contrastées (NCON)

Dans le cas d'une tumeur non contrastée, un pic peut être observé, entre LCR et MG, en $H_s(x)$, qui indique la gamme d'intensité de la tumeur. Le pic est positif, si la tumeur se situe dans l'hémisphère droit, sinon, le pic est négatif. Dans ce cas, la tumeur diminue naturellement le volume de la MG et de la MB, d'où un pic négatif peut être vu entre ces deux structures. Lorsque la tumeur fait bouger les ventricules vers l'hémisphère normal, ou si elle est située à la frontière du cerveau, un pic négatif sera observé, avant le pic de la tumeur (dans l'intervalle du LCR) (Figure 3.26).

Pour extraire la tumeur du cerveau, nous utilisons un simple seuillage, et nous définissons :

- la valeur faible du seuil par : $T_b = S_{pt}$;
- la valeur élevée par $T_h = E_{pt}$, où **Pt** représente le pic de la tumeur.

Quand un chevauchement existe entre le pic de la tumeur et l'intervalle de MG ou l'intervalle LCR, i.e :

$$E_{pt} > M_g - \frac{1}{2}\sigma_g \quad \text{ou} \quad S_{pt} < M_l + \frac{1}{2}\sigma_l$$

Avec : M_g : la moyenne de MG, σ_g : La variance de MG

M_l : La moyenne du LCR, σ_l : La variance du LCR

L'extraction sera difficile. Pour remédier à ce problème, nous limitons les valeurs du seuil en fonction de:

- Si $E_{pt} > M_g$ alors $T_h = M_g - \frac{1}{2}\sigma_g$
- Si $S_{pt} < M_l$ alors $T_l = M_c + \frac{1}{2}\sigma_l$

Ces limitations peuvent enlever des pixels de la zone tumorale, mais dans l'étape de raffinement, ils seront ajoutés à nouveau.

Pour illustrer l'influence d'une tumeur non contrastée sur l'histogramme de l'hémisphère normale, nous avons ajouté une tumeur simulée dans l'hémisphère droit d'une image du cerveau sain. La Figure 2.26 montre le résultat de cette simulation. Le pic négatif peut également fournir des informations sur la tumeur, qui peut être utilisé dans le processus de segmentation.

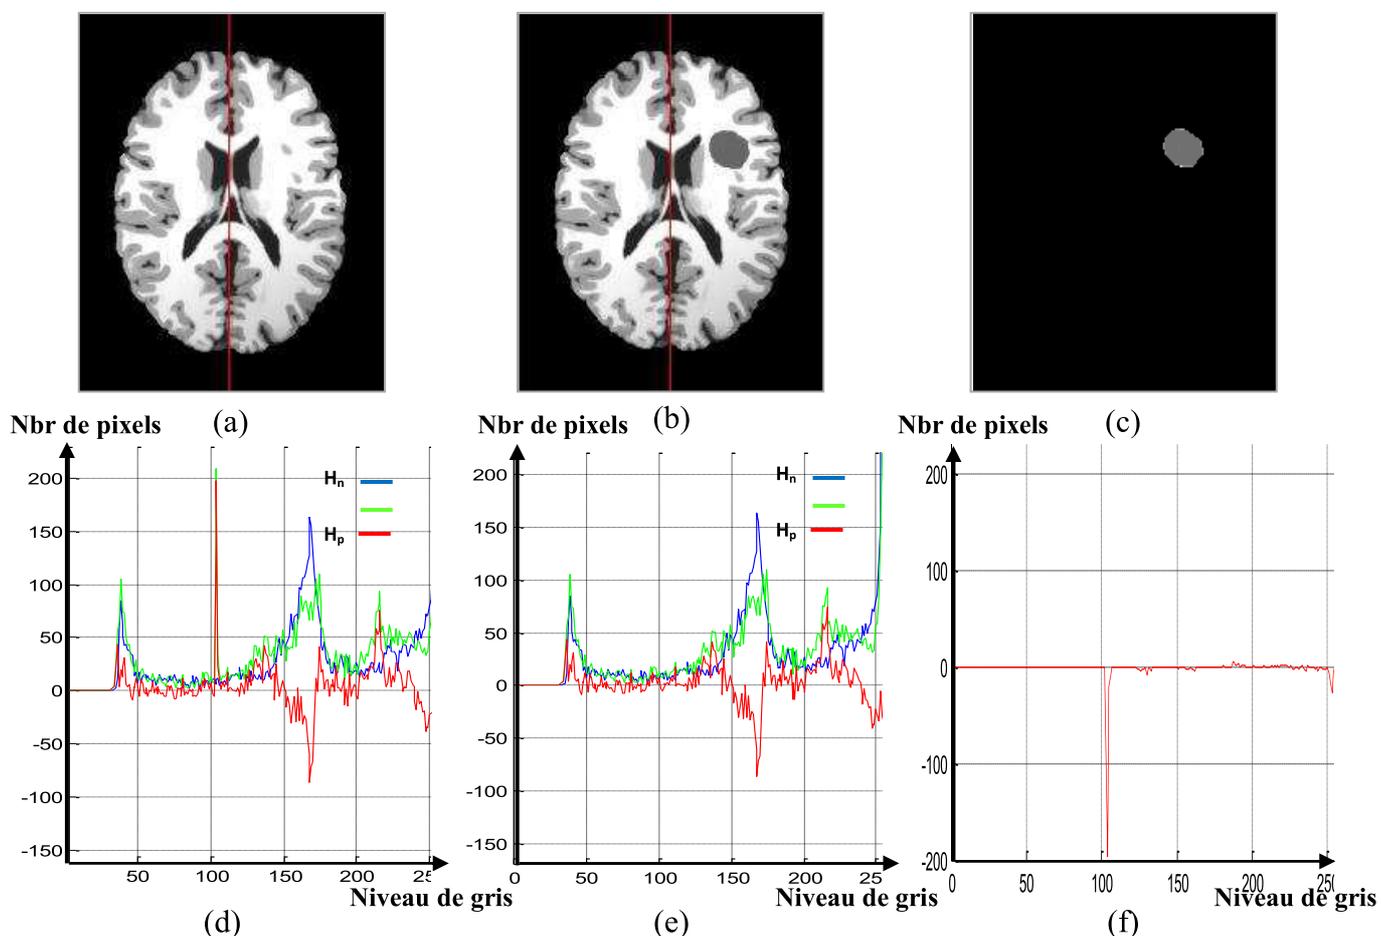


Figure 3.26 : Analyse de symétrie pour une tumeur non contrastée

- (a),(d) : image de cerveau sain et l'histogramme de H_n (Bleu), H_p (Vert) et H_s (Rouge) ;
 (b),(e) : image pathologique et l'histogramme de H_n , H_p et H_s ;
 (c),(f) : la classe de la tumeur et le graphe de différence entre H_s de la figure (d) et H_s de la figure (e)
 $T_b = 98$ et $T_h = 118$; Nbr = Nombre

Etant donné que la présence d'une tumeur diminue le volume des tissus, dans lequel la tumeur est située, le pic négatif illustre donc les tissus qui entourent la tumeur (Figure 3.27). Ainsi, avec un seuillage approprié, nous pouvons obtenir les tissus autour de la tumeur, comme le montre les figures 3.26(c) et figure 3.27.

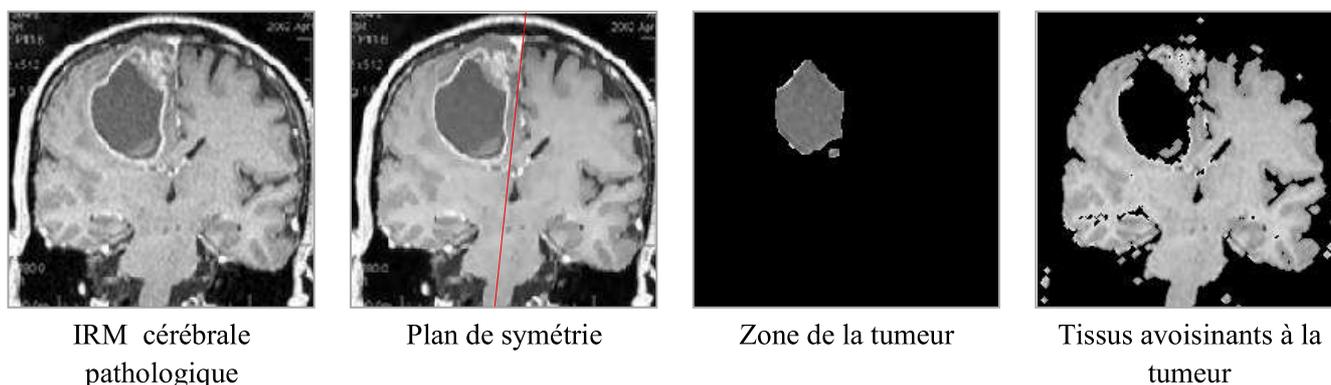


Figure 3.27 : Détection initiale de la tumeur et des tissus environnants par analyse de symétrie

Tumeur : $S_b=92$ et $S_h=120$; Tissus avoisinants : $S_b=140$ et $S_h=210$

3.2.2.2 Tumeur contrastée et sans œdème (CONSA)

Pour cette catégorie, un pic négatif apparaît après la MB, ce qui représente la l'intervalle d'intensité de la tumeur. La tumeur ici diminue également le volume de la MB et de la MG, par conséquent un pic positif apparaît dans la MG et la MB, Figure 3.28

Pour extraire la tumeur du cerveau, un seuillage, avec $T_b = S_{pt}=240$ et $T_h = E_{pt}=255$, est utilisé.

Un chevauchement entre le pic tumeur et la MB peuvent être observé. Bien que, cela se produit rarement, nous appliquons la limitation suivante pour surmonter ce problème:

$$\text{Si } S_{pt} < M_b \text{ alors } T_l = M_b + 2\sigma_b$$

Pour extraire les tissus autour de la tumeur, nous faisons le seuillage du pic positif, avec les valeurs $S_b=180$ et $S_h=240$ (Figure 3.28(d)).

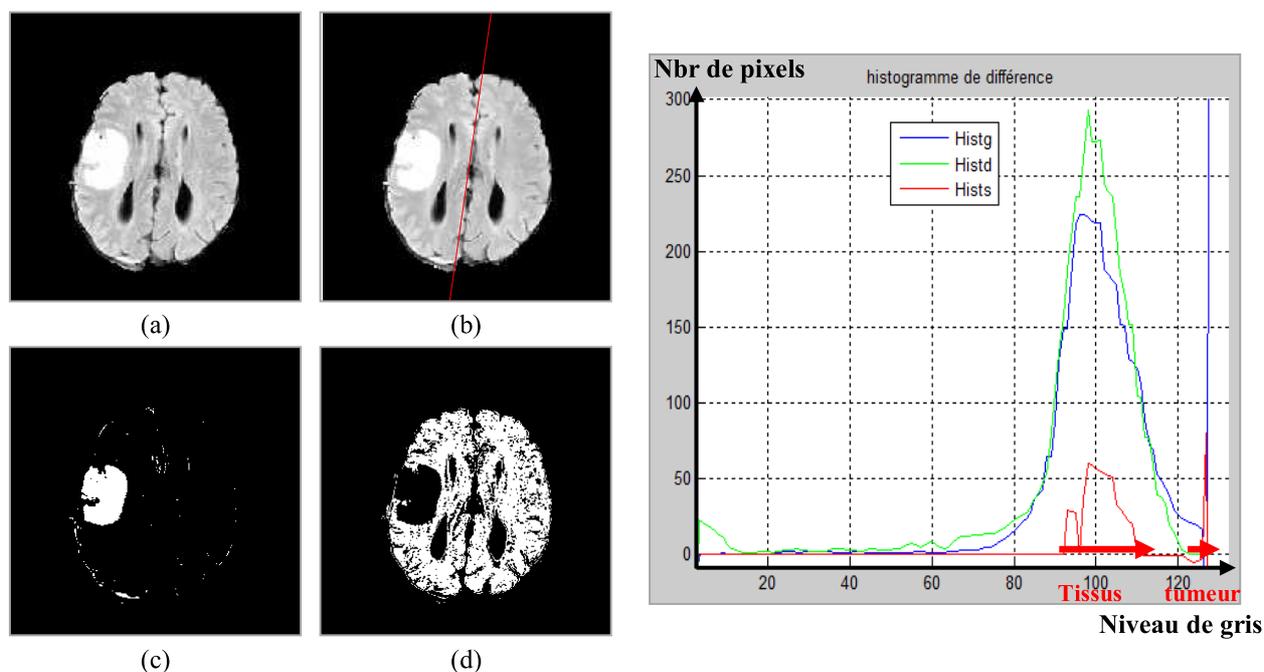


Figure 3.28 : Segmentation d'une tumeur par analyse de symétrie, Tumeur contrastée
 (a) : Image réelle d'une tumeur contrastée, (b) : plan de symétrie, (c) : détection initiale de la tumeur, (d) : tissus avoisinants à la tumeur

3.2.2.3 Tumeur partiellement contrastée (CONP) et contrastée avec œdème (CONAO)

Dans le cas d'une tumeur contrastée avec œdème ou d'une tumeur contrastée partiellement (Figure 3.29), nous avons deux pics positifs en $H_s(x)$, dont le premier indique la plage de l'intensité de l'œdème, et le second (dernier) la plage d'intensité de la tumeur, puisque l'intensité de l'œdème est toujours comprise entre LCR et MG.

Étant donné que ces types de tumeurs déforment souvent les structures cérébrales, ce qui fait déplacer les ventricules vers l'hémisphère normal, alors un pic négatif peut être observé dans la gamme du LCR. La procédure d'extraction de la tumeur est la même que pour les tumeurs contrastées sans œdème. Etant donné que dans ces cas, l'œdème entoure la tumeur, alors, nous appliquons un seuillage, en utilisant la gamme du pic de l'œdème, pour obtenir les tissus environnants.

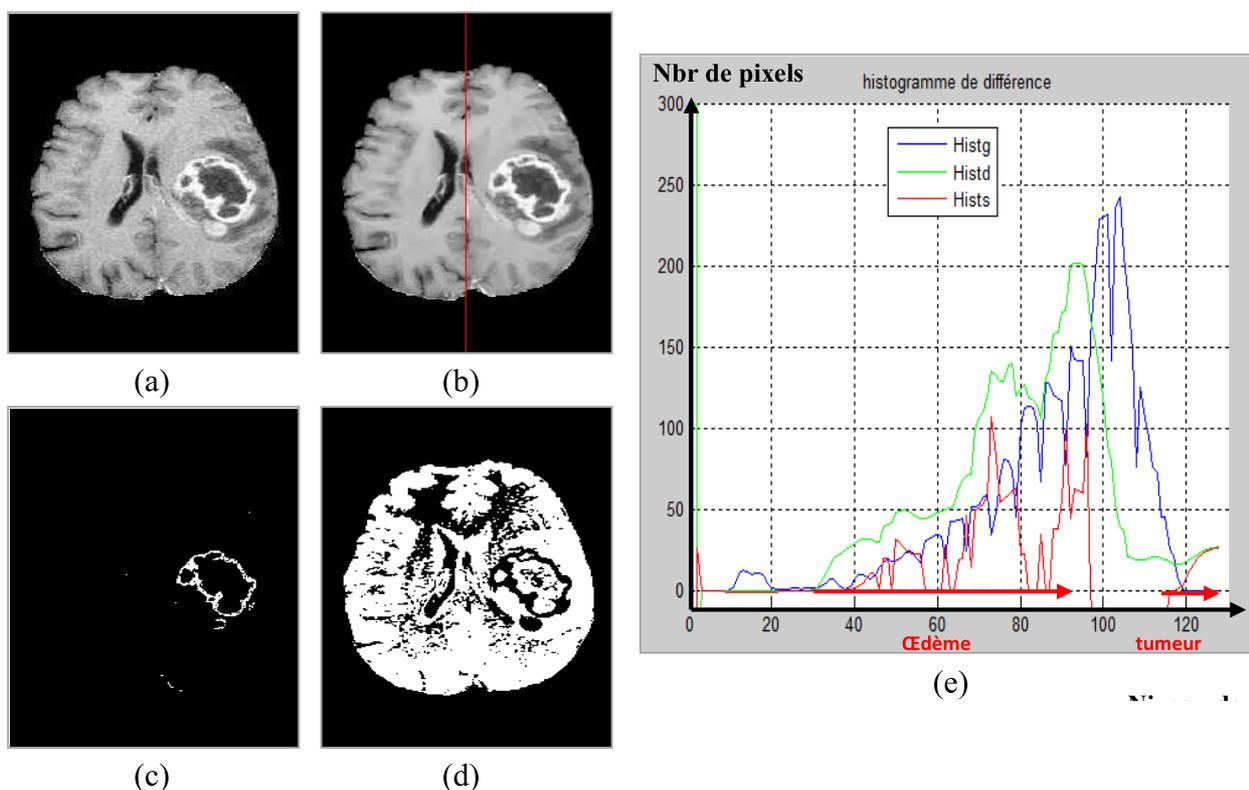


Figure 3.29 : Segmentation d'une tumeur par analyse de symétrie, Tumeur contrastée avec œdème et partiellement contrastée avec œdème

(a) Image réelle d'une tumeur PCON, (b) plan de symétrie, (c) détection initiale de la tumeur, (d) tissus avoisinants à la tumeur

Discussion

A travers cette section, nous avons présenté la diffusion anisotrope, qui se présente comme un outil de filtrage et de réduction du bruit très performant, et assez simple, que ce soit au niveau de son utilisation, ou de son implémentation. Sa supériorité sur les filtrages classiques est incontestable, dans la mesure où il réussit à conserver des contours nets. A partir des travaux de Perona et Malik, d'autres recherches ont été effectuées, pour optimiser les résultats de la diffusion anisotrope, en optimisant le coefficient de diffusion, notamment une extension en 3D. Les résultats intéressants, obtenus par la diffusion anisotrope, nous ont permis de rendre possible son intégration, dans la méthode proposée pour la segmentation des IRM cérébrales.

Nous avons développé aussi une méthode de prétraitement, nommée « Isolation du cerveau », qui permet de réduire le volume important des IRM, en ne gardant que l'information utile.

D'autre part, nous avons implémenté une méthode générale pour la détection et la segmentation initiale des tumeurs cérébrales, qui peut être utilisée dans n'importe quel type d'images du cerveau (avec différentes modalités). La méthode d'analyse de symétrie a été suggérée pour résoudre le manque de généralités des méthodes de classification floue. Or, cette méthode a besoin d'une intervention manuelle, lors de l'insertion des seuils d'intensité de la classe de la tumeur ou des tissus environnants.

Afin d'améliorer les frontières des objets segmentés, nous présentons dans le chapitre suivant une étape de raffinement, consistant en l'amélioration des résultats de la segmentation initiale.

CHAPITRE 4

RAFFINEMENT DE LA SEGMENTATION INITIALE

La deuxième partie de notre cadre de travail est le raffinement de la segmentation. L'entrée se compose des informations, issues de la segmentation initiale, faite au chapitre 3, après quelques prétraitements avec des opérations morphologiques. Ces informations se décomposent en deux parties : une détection initiale de la tumeur et une détection des tissus avoisinants.

Comme nous l'avons expliqué au chapitre 2, les méthodes basées région exploitent la seule information locale pour chaque pixel, sans prendre en compte l'information contour. Elles ont un haut niveau d'automatisation.

D'autre part, les modèles basés contours souffrent de la difficulté de détermination du contour initial, mais ils réalisent une bonne segmentation des frontières des objets.

Pour cela, nous avons opté pour une méthode de segmentation contour, qui a pour but de raffiner la segmentation initiale. Les modèles déformables paramétriques ont été largement utilisés pour la segmentation des tumeurs alors nous allons utiliser les contours actifs guidés par GVF avec des contraintes issues des relations spatiales.

La méthode globale est donc une combinaison des paradigmes basés région et basés contours. Elle fonctionne en 2D, et est généralement suffisante pour segmenter un grand nombre de tumeurs, pour n'importe quelle modalité d'images IRM et avec n'importe quelle forme.

Ce chapitre est organisé comme suit : dans la section 4.1, nous faisons un aperçu général de la méthode, ensuite dans la section 4.2, nous présentons quelques généralités sur les relations spatiales. La section 4.3 décrit la méthode de raffinement de la segmentation, en utilisant les modèles déformables, guidés par les GVF. Ensuite, une démonstration de la méthode d'initialisation automatique du Snake est proposée, de même que les différentes forces externes existantes. Dans la section 4.4, nous exposons la méthode proposée, en intégrant les relations spatiales au modèle déformable, et enfin, nous terminons par une discussion.

4.1 Aperçu de la méthode générale

La méthode de segmentation automatique que nous avons développée est composée de deux phases : l'initialisation et le raffinement, comme le montre la figure 4.1. La première phase a été présentée au chapitre précédent, dans laquelle, on détecte et on segmente initialement la tumeur ou l'œdème. Pour effectuer cette opération, une méthode de classification floue, et une analyse de la symétrie par des opérations morphologiques ont été utilisées. Cette première étape a permis d'effectuer une segmentation initiale, qui va être raffinée, dans cette deuxième étape par une segmentation plus précise, en utilisant un modèle déformable paramétrique, contraint par des relations spatiales floues. Ceci permet une représentation explicite des relations entre la tumeur ou l'œdème, et les tissus environnants, ce qui renforce la robustesse de la méthode.

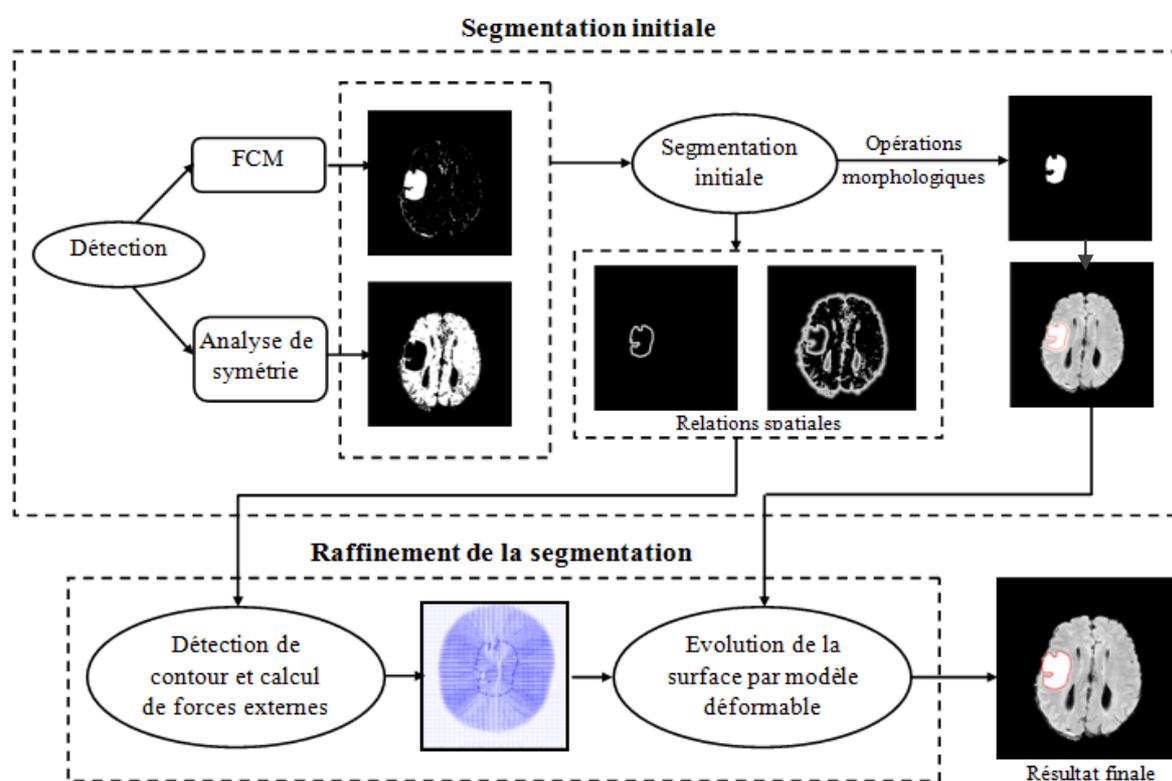


Figure 4.1 : Aperçu général de la méthode proposée

Plusieurs sources d'imprécision sont prises en compte dans la méthode proposée. L'imprécision est intrinsèquement présente dans les images, en raison du phénomène observé lui-même (limites imprécises de zones pathologiques, par exemple), du système d'acquisition, du processus de reconstruction numérique (conduisant à des imprécisions spatiales et d'intensité). En outre, les connaissances disponibles sont également sujettes à l'imprécision. Par exemple, on exploite l'ordre constant des niveaux de gris des principaux tissus du cerveau, mais la plage exacte des valeurs de chaque tissu est imprécise. Nous allons également faire usage de relations spatiales, exprimées sous forme linguistique, telles que « près de la tumeur », qui ne peuvent être modélisées de façon précise. Toutes ces raisons justifient l'utilisation de modèles flous, en plusieurs étapes de l'approche proposée (classification floue basée sur les niveaux de gris, modèles de relations spatiales).

4.2 Relations spatiales

4.2.1 Introduction

Les relations spatiales (RS), constituent les éléments de base, contenus dans la description linguistique de configurations spatiales, et décrivent l'organisation et la description des différents objets dans une image. Elles sont très utilisées pour décrire, détecter et reconnaître les objets : elles permettent de lever l'ambiguïté entre des objets d'apparences similaires, et sont souvent plus stables que les caractéristiques des objets eux-mêmes (c'est le cas des structures anatomiques). Ces relations sont classées généralement en différentes catégories : relations de distance, relations topologiques, relations de direction ... etc.

Leur importance a été soulignée dans de nombreux domaines liés à l'informatique et à l'ingénierie, comme l'intelligence artificielle, le traitement automatique de la langue naturelle (TALN), les systèmes d'informations géographiques (SIG), la robotique autonome, la vision par ordinateur ou la reconnaissance des formes.

Pour la segmentation et la reconnaissance d'objets, ces relations constituent des connaissances structurelles, par opposition à l'information numérique, telle que le niveau de gris ou la texture, qui est extraite des images. Elles sont un moyen efficace pour décrire des scènes structurées [103] [102], et sont potentiellement utiles dans de nombreux domaines d'application : imagerie aérienne [103], reconnaissance de visages [104], imagerie médicale.

Les relations spatiales ont été relativement peu utilisées en traitement d'images, on trouve les travaux de :

- La reconnaissance de structures cérébrales [105], [106], avec la relation « **between** » [108] et [109] ;
- L'interprétation d'images et la reconnaissance anatomique [110],[107] , [109] ;
- La segmentation des structures internes cérébrales [112], [109] ;
- La segmentation des tumeurs cérébrales [111], [1] ;
- L'interprétation et l'adaptation ontologiques (relations spatiales floues ontologies). [113], [114], [107]

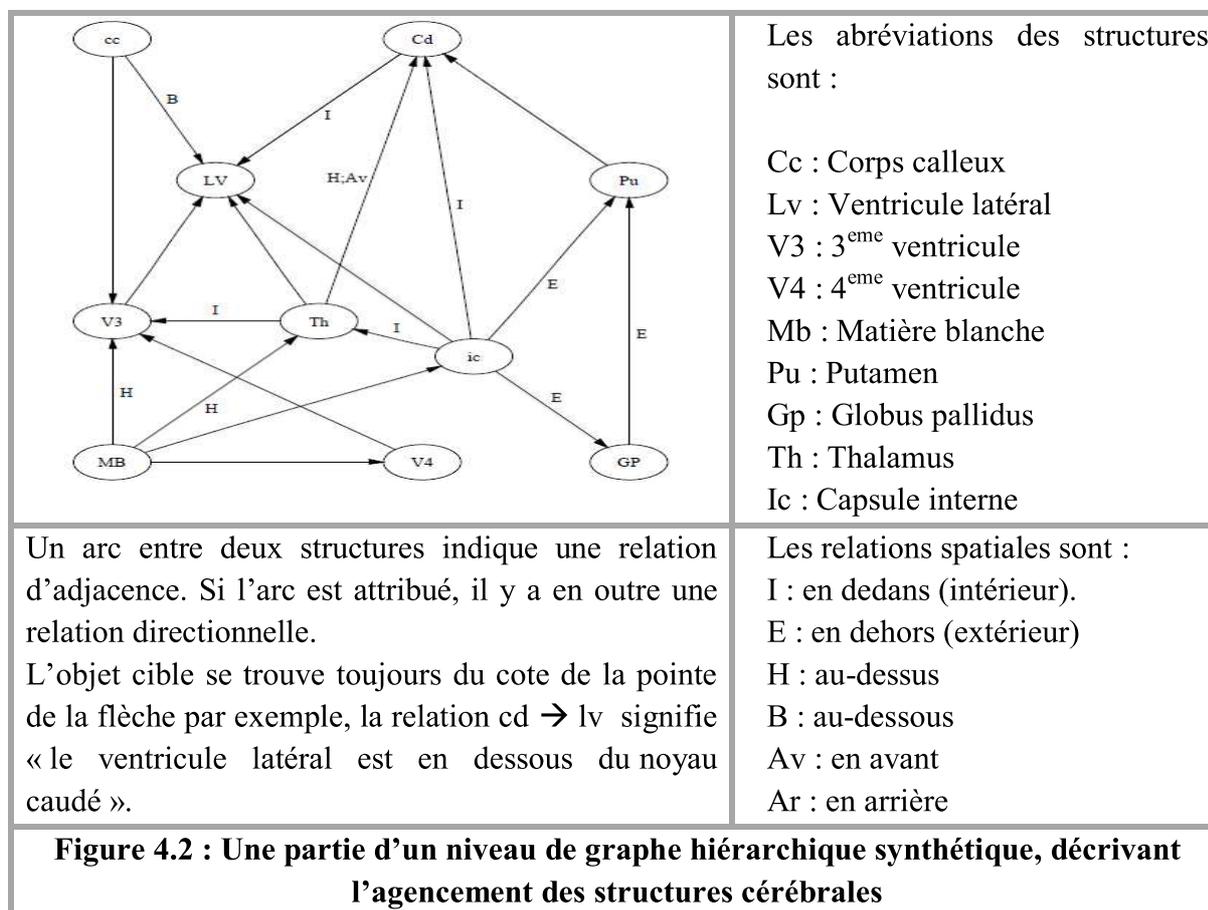
Cependant, elles n'ont été que rarement utilisées en imagerie cérébrale. Dans [105] et dans [106], elles n'ont servi qu'à la reconnaissance des structures, la segmentation proprement dite utilisant respectivement une classification d'intensités et une ligne de partage des eaux.

[115] ont introduit des relations de distances pour la segmentation, mais ne considèrent pas d'autres types de relations.

Il n'existe donc pas de méthodologie générale, permettant d'utiliser différents types de relations spatiales pour la segmentation d'images.

4.2.2 Description de l'anatomie cérébrale par des relations spatiales

La description des relations spatiales présente les structures de façon hiérarchique, les structures d'un même niveau étant liées par des relations. Il existe une bonne hiérarchie proposée par Neuronames¹. Cette étude a été faite au laboratoire de l'école nationale supérieure des télécommunications, au département TSI à Paris, en collaboration avec un neuroanatomiste (D. Hasboun, CHU La Pitié-Salpêtrière, Paris). Ils ont élaboré une description des structures cérébrales à partir des relations spatiales.



Voici quelques exemples de descriptions utilisant les relations spatiales :

- direction : le thalamus est en dehors du troisième ventricule, et en dessous du ventricule latéral;
- distance : le noyau caudé est proche du ventricule latéral ;

¹ <http://rprcsgi.rprc.washington.edu/neuronames/>

- adjacence : le thalamus est adjacent au troisième ventricule ;
- symétrie : les structures homologues des deux hémisphères (par exemple les deux thalamus) sont approximativement symétriques, par rapport au plan inter-hémisphérique.

Cette description est formalisée par un graphe hiérarchique synthétique (exemple sur la figure 4.2). Il s'agit d'un graphe hiérarchique attribué, c'est-à-dire qu'un ensemble de graphes, appelés niveaux, tels que les nœuds de deux niveaux successifs, sont liés par des relations d'inclusion. Chaque niveau est un graphe attribué, les nœuds représentant les structures, et les attributs d'arc, les relations les liant.

4.2.3 Représentation des relations spatiales

On peut distinguer deux types d'approches pour la représentation de relations spatiales : les méthodes qualitatives et les méthodes quantitatives.

- Les méthodes qualitatives : reposent souvent sur la logique formelle, ou sur des extensions du calcul des intervalles, et ne peuvent pas être intégrées dans un cadre numérique, comme celui des modèles déformables. [111], [105]
- Les méthodes quantitatives : fournissent une évaluation numérique des relations ; celles reposant sur les ensembles flous sont particulièrement intéressantes, car elles permettent de modéliser l'imprécision, qui peut être issue des traitements effectués sur l'image, mais aussi être intrinsèque aux relations (les directions sont par exemple intrinsèquement imprécises). Plutôt que de définir une relation en « tout-ou-rien », nous en définissons un degré de satisfaction.

On peut distinguer deux types d'approches floues pour la représentation de relations spatiales. On définit:

- Soit une valeur représentant le degré de satisfaction entre deux objets donnés ;
- soit un ensemble flou, représentant en tout point de l'espace, le degré de satisfaction de la relation, par rapport à un objet de référence.

La première approche a été appliquée à de nombreuses relations : adjacences floues [128], distances [116], symétries entre objets flous [117] et représentation des directions par les histogrammes d'angles et de forces [118]. Cependant, ce type de représentation est mal adapté à l'intégration dans un modèle déformable. En effet, notre objectif est de diriger le modèle vers les points de l'espace, pour lesquels la relation est satisfaite. Nous devons donc connaître le degré de satisfaction en chaque point.

Les relations de direction et de distance ont été représentées par la seconde approche comme dans [128]. Les directions sont représentées en calculant un paysage flou, qui

correspond à une dilatation floue de l'objet de référence, par un élément structurant représentant la direction considérée.

Pour les distances, on définit des ensembles flous sur l'espace des distances R^+ , correspondant à différentes relations, telles que : « près de », « loin de », « à une distance approximativement égale à ». Il suffit alors de combiner ces ensembles flous avec une carte de distance, pour obtenir un ensemble flou dans l'espace de l'image. Des exemples de tels ensembles flous sont présentés en figure 4.3.

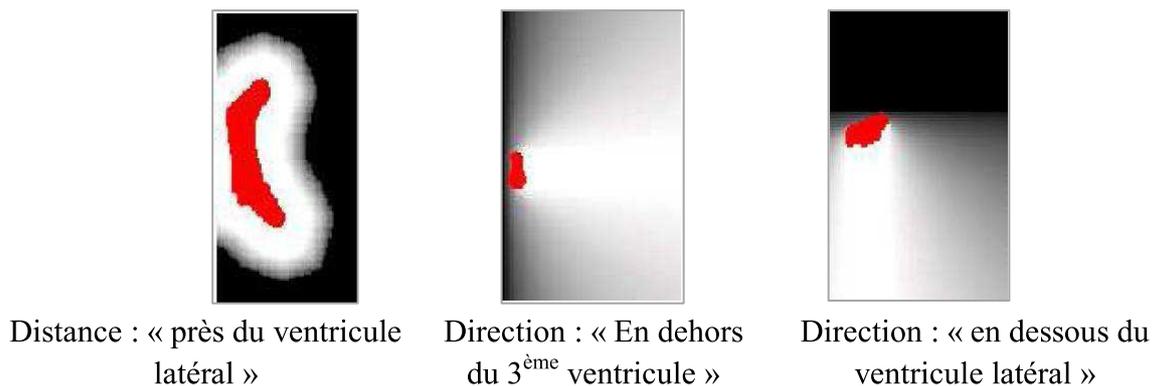


Figure 4.3 : Exemples de coupes d'ensembles flous représentant les relations de distance et de direction

Enfin, un autre avantage de ces représentations est que, différentes relations peuvent être combinées à l'aide d'opérateurs de fusion entre ensembles flous [119]. On peut choisir des t-normes (norme triangulaire) pour les fusions conjonctives et des t-conormes (Co_norme triangulaire) pour les fusions disjonctives [120]. Les différentes t-normes et t-conormes correspondent à différents degrés de sévérité ou d'indulgence dans la combinaison.

4.2.4 Types de relations spatiales

Il existe trois familles de relations : topologiques, de distance et de direction (Figure 4.4). Bien que se recoupant, elles portent des informations de natures différentes, et sont souvent définies dans des espaces différents (nécessité d'une métrique et d'un référentiel pour définir l'orientation). La plupart d'entre elles sont binaires, mais il existe des relations ternaires, telles que « entre ».

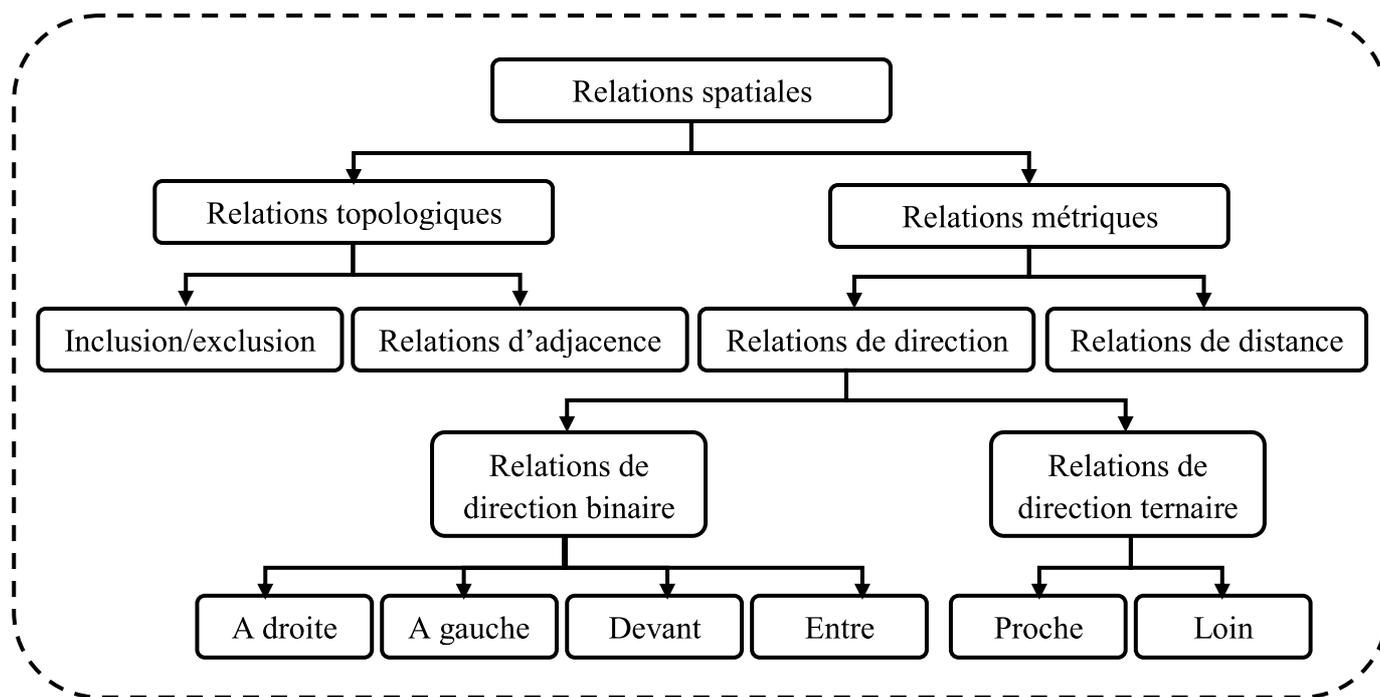


Figure 4.4 : Types de relations spatiales sens des flèches

4.2.4.1 Relations topologiques : intérieur, extérieur et frontières

La topologie est un aspect fondamental de l'espace. La littérature est très abondante sur la formalisation des relations topologiques [114]. L'une des principales approches est la RCC « Region Connection Calculus », dans laquelle les relations entre les entités spatiales, fermées et connectées, sont issues d'un prédicat de connexion.

Dans cette théorie, huit principales relations exclusives sont définies. Il a été étendu à des objets imprécis, via l'approche de « jaune d'œuf » [121]. Une autre approche, connue sous le nom des neuf intersections [122], utilise une partition de l'espace en trois régions, pour chaque objet (sa limite, son intérieur et son complément), qui constituent la base de calcul des relations. Un des avantages de ces approches est qu'elles construisent un ensemble exhaustif de relations topologiques. Elles sont organisées en un réseau, et sont impliquées dans des outils de raisonnement logique.

En plus de ces formalismes qualitatifs, les approches quantitatives permettent d'exprimer toutes ces relations pour les objets numériques, en utilisant des valeurs 0 ou 1, pour les relations exprimées en « tout ou rien », et des nombres flous, pour exprimer les degrés qui détiennent les relations (degré de contiguïté, degré de chevauchement, ... etc.).

4.2.4.2 Relations de direction

Les relations directionnelles sont utiles pour décrire la position relative d'un objet par rapport aux autres, et nécessitent de l'espace pour être orientées, c'est à dire un système de référence, comme décrit ci-dessous. Les relations les plus utilisées sont liées par trois axes de

références : « à droite », « à gauche », « au-dessus », « au-dessous », « devant », « derrière ». Des relations plus spécifiques peuvent être obtenues en combinant certaines de celles de base, tels que « Pour l'avant » et « de gauche ».

Les relations plus complexes de cette catégorie comprennent par exemple la relation ternaire «Entre » ou la relation binaire « Le long de ». Le langage naturel a beaucoup de termes pour parler de ces relations, qui sont parfois très difficiles à modéliser mathématiquement [123] [127]. La représentation floue de ces relations a été proposée, en tenant compte de quelques situations typiques [108]. Par opposition aux relations topologiques, il serait très difficile de définir de manière exhaustive un ensemble de relations avec un grand degré de généralité suffisant.

4.2.4.3 Relations de distance

Les distances sont également très couramment utilisées pour décrire l'agencement spatial des objets. Il existe deux types de distance [110], celles qui se basent seulement sur la comparaison des degrés d'appartenance, et celles qui tiennent compte en plus, de la distance spatiale ; cette dernière est la mieux adaptée au raisonnement spatial.

[124] représentent les relations de distance par des degrés, calculés à partir de la distance moyenne entre les points des deux régions. Ils introduisent une normalisation par le diamètre de l'une des régions.

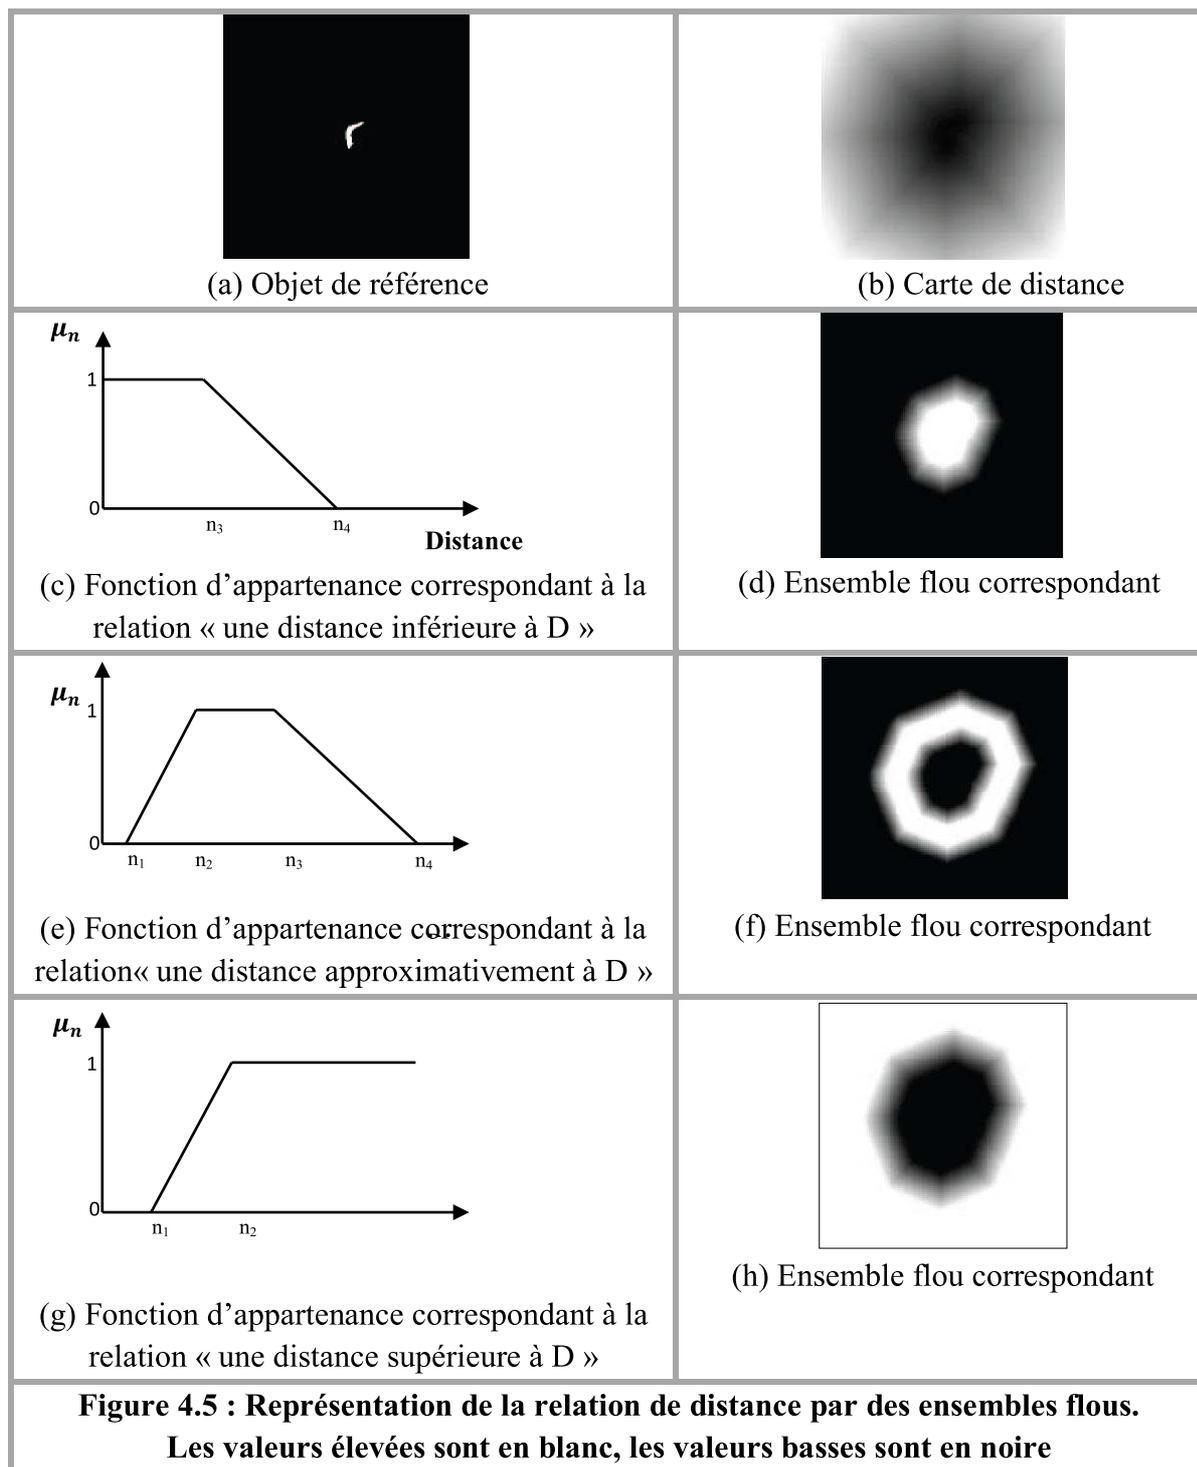
[128] a proposé de représenter les relations de distance par rapport à un objet de référence A, qui est un objet flou.

L'intérêt de la deuxième méthode, par rapport à celles qui comparent directement deux objets, est qu'on peut mesurer, n'importe quel point de l'objet cible à un point de l'objet de référence ; de même, on a la possibilité de fusionner cet ensemble flou de distance avec d'autres ensembles d'une autre relation. Une telle méthode est mieux présentée dans [116].

Parmi les distances spatiales, on trouve celles reposant sur les dilatations floues. Par exemple, pour une telle expression « à une distance inférieure à », « à une distance supérieure à », « à une distance approximativement égale à », on construit un objet flou dans l'espace d'image S montrant la relation considérée (Figure 4.5).

La relation de distance considérée est calculée sous la forme d'une fonction d'appartenance sur \mathbb{R}^+ , que nous appelons μ_n . On prend souvent un trapèze à titre d'exemple. Selon la figure 4.5(e), $[n_2 \ n_3]$ est le noyau de \mathbb{R}^+ , et $[n_1 \ n_4]$ est le support de \mathbb{R}^+ , avec $n_1 < n_2 < n_3 < n_4$. On fixe différemment n_1, n_2, n_3, n_4 , selon la relation voulue.

Pour la relation « proche de », $n_1 = n_2 = 0$, et n_3 et n_4 sont choisis, selon les connaissances a priori de la plus grande distance entre un point de l'objet cible et un point de l'objet de référence. Pour la relation « loin de », n_1 et n_2 sont définis selon la plus petite distance.



Pour cela, on représente les éléments structurants suivants :

$$v_1(v) = \begin{cases} 1 - \mu_n(d_E(v, 0)) & \text{si } d_E(v, 0) \leq n_2. \\ 0 & \text{si } d_E(v, 0) \leq n_3. \end{cases} \quad (4.1)$$

$$v_2(v) = \begin{cases} 1 & \text{si } d_E(v, 0) \leq n_2. \\ \mu_n(d_E(v, 0)) & \text{si } d_E(v, 0) \leq n_3. \end{cases} \quad (4.2)$$

Où d_E est la distance euclidienne dans S , $v \in S$ et $d_E(v, 0)$ est la distance euclidienne entre v et le centre de l'élément structurant.

L'ensemble flou représentant la relation de distance à l'objet A est alors :

$$\mu_d = t[D_{v2}(\mu_A), 1 - D_{v1}(\mu_A)] \quad (4.3)$$

Où $D_{vi}(\mu_A)$, $i \in \{1,2\}$ est la dilatation floue de μ_A par l'élément structurant vi .

Cependant, les dilatations floues prennent beaucoup de temps en calcul. Dans le cas de référence binaire, [116], on peut réduire considérablement le temps de calcul, en calculant une carte de distance de Chanfrein à l'objet A , et en la combinant avec μ_n , pour avoir l'ensemble flou correspondant à la relation spatiale.

Dans l'approche proposée, nous allons employer la relation de distance, car c'est la seule relation utilisée pour la segmentation des images cérébrales.

4.3 Modèles déformables

Un modèle déformable est un objet hybride, réunissant un modèle géométrique et une fonction d'énergie potentielle (et c'est la fonctionnelle à minimiser pendant l'évolution). La fonction d'énergie potentielle engendre des forces qui régularisent la surface, et la rapprochent des données, en minimisant une énergie E , telle que : $E = E_{\text{ext}} + E_{\text{int}}$

L'idée repose sur l'utilisation d'une forme (courbe, surface ou volume), que l'on initialise proche de la forme désirée, puis que l'on fait évoluer itérativement, pour atteindre les frontières de l'objet à segmenter. Cette évolution se fait, en général, grâce à des contraintes a priori (sur la forme), combinées à des contraintes, basées sur le contenu de l'image (Figure 4.6).

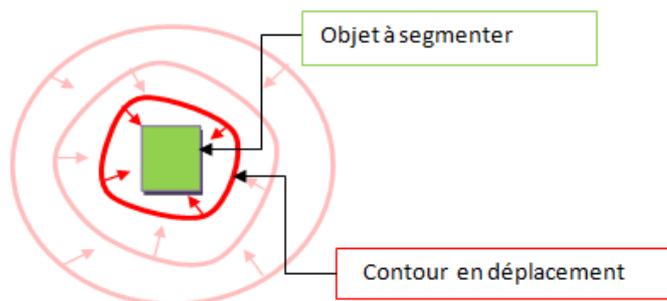


Figure 4.6 : Principe du modèle déformable

4.3.1 Types de modèles déformables

On peut distinguer trois principaux types de modèles déformables [11] :

- Modèles déformables paramétriques (type qui nous intéresse dans notre étude) ;
- Modèles déformables géométriques ;
- Modèles déformables géodésiques.

Les contours actifs paramétriques sont représentés, explicitement, comme des courbes paramétrées dans une structure Lagrangienne, tandis que les contours actifs géométriques sont représentés, implicitement, comme les ensembles de niveau d'une fonction bidimensionnelle, qui se développe dans une structure Eulérienne [11]. Le troisième s'inspire des deux premiers modèles.

Nous avons fait le choix du premier type de modèles. Tout d'abord, les objets auxquels nous nous intéressons ont une topologie bien définie, presque toujours sphérique, et la possibilité de changer de topologie n'est donc ni nécessaire ni souhaitable. Par ailleurs, lorsque de tels modèles sont implémentés avec une représentation discrète, leur convergence peut être obtenue rapidement.

4.3.2 Modèles déformables paramétriques

4.3.2.1 Définition

Les contours actifs paramétriques, ou "Snakes", représentent le premier exemple dans cette catégorie. Ils ont été introduits pour la première fois par Kass, Terzopoulos et Witkin en 1987 [66], chez Schlumberger à Palo Alto (Californie).

On peut définir un contour actif, ou « Snake », comme une courbe fermée C , qui minimise son énergie, influencée par une contrainte interne, et guidée par une force d'image, qui pousse la courbe vers les contours présents dans l'image.

En notant le contour déformable paramétré $X(s) = (x(s), y(s))$, $s \in [0,1]$, on peut écrire la fonctionnelle d'énergie, associée au Snake2D comme suit :

$$E(X) = E_{int}(X) + E_{ext}(X) \quad (4.4)$$

E_{int} : est une contrainte de régularisation, pour obtenir un contour lisse ;

E_{ext} : est le terme d'attache aux données, qui dépend du gradient de l'image.

- Energie interne (E_{int})

L'énergie interne ne dépend pas de l'image, ni de la forme à « contourer »; elle ne dépend que des points du contour. Elle regroupe des notions, comme la courbure du contour, ou la régularité d'espacement des points. En effet, le contour doit conserver une forme

arrondie, en minimisant les dérivées d'ordre 1 et 2 (Equation (4.5)), et doit empêcher un point de se détacher trop loin du reste du contour. Idéalement, l'énergie interne est minimale pour un cercle, où tous les points sont régulièrement espacés.

L'énergie interne modélise, entre autres, la tension. Elle a été définie par [66], par l'équation (4.5):

$$E_{int}(X) = \frac{1}{2} \int_0^1 \left(\alpha(s) \left| \frac{\partial X}{\partial s} \right|^2 + \beta(s) \left| \frac{\partial^2 X}{\partial s^2} \right|^2 \right) ds \quad (4.5)$$

α , β : sont des constantes positives, et représentent le coefficient d'élasticité et de rigidité respectivement.

On peut voir que cette énergie se compose de deux termes : un terme du premier ordre $\left(\frac{\partial X}{\partial s} \right)^2$, contrôlé par $\alpha(s)$, qui représente l'élasticité du contour, et un terme du second ordre $\left(\left(\frac{\partial X}{\partial s} \right)^2 \right)^2$, contrôlé par $\beta(s)$, qui représente la rigidité du contour.

Le choix des fonctions $\alpha(s)$ et $\beta(s)$ impose les caractéristiques du contour durant sa déformation.

La propriété d'élasticité peut être illustrée, en examinant le terme de la dérivée première, qui n'est autre que le module au carré du vecteur tangent à la courbe donnée par l'équation 4.6.

$$\left(\frac{dX(s)}{ds} \right)^2 = \left(\frac{dx(s)}{ds} \right)^2 + \left(\frac{dy(s)}{ds} \right)^2 \quad (4.6)$$

La longueur \mathbb{L} d'une courbe paramétrique peut être exprimée par l'équation 4.7.

$$\mathbb{L} = \int_0^1 \left(\sqrt{\left(\frac{dx(s)}{ds} \right)^2 + \left(\frac{dy(s)}{ds} \right)^2} \right) ds \quad (4.7)$$

Les deux équations (4.6) et (4.7) montrent que la longueur du contour n'est qu'une simple intégration du module de la dérivée première du long de la courbe. La minimisation de la dérivée première consiste en une minimisation de la longueur globale du contour, ce qui reflète une certaine élasticité entre les différents nœuds du contour, c'est-à-dire que les nœuds sont attirés par eux-mêmes, puisque le poids relatif de ce terme est contrôlé par $\alpha(s)$. Plus ce paramètre est grand, plus l'élasticité est grande, et plus la tendance du contour à se contracter est grande.

De même, la rigidité peut être illustrée par la dérivée seconde, qui n'est autre que le taux de changement de la valeur de la tangente à la courbe. Minimiser ce module revient à réduire la possibilité d'un changement brusque, en n'importe quel nœud.

➤ Energie externe (E_{ext})

L'énergie externe dépend des caractéristiques de l'image, et du bon fonctionnement de l'algorithme de segmentation. C'est la force qui dirige le contour vers la position désirée dans l'image. On peut regrouper à l'intérieur de cette énergie plusieurs termes, que l'on juge nécessaire pour une bonne segmentation. Elle contient essentiellement, un terme associé aux changements abrupts de l'image, les arrêtes, et d'autres termes optionnels relatifs à chaque cas. L'une des forces les plus utilisées est celle relative au gradient de l'image, défini par l'équation 4.8:

$$E_{ext} = \int_0^1 P(X) ds \quad (4.8)$$

Le potentiel P est souvent issu du gradient de l'image.

On montre qu'un contour qui minimise l'énergie précédente est une solution de :

$$F_{int}(x) + F_{ext}(x) = 0 \quad (4.9)$$

Avec

$$F_{int}(X) = \frac{\partial}{\partial s} \left(\alpha(s) \frac{\partial X}{\partial s} \right) - \frac{\partial^2}{\partial s^2} \left(\beta(s) \frac{\partial^2 X}{\partial s^2} \right) \quad (4.10)$$

$$F_{ext} = -\nabla P(X) \quad (4.11)$$

Pour résoudre ce problème d'optimisation, on rend l'équation dynamique, et la solution est l'état d'équilibre de :

$$\gamma \frac{\partial x}{\partial t} = F_{int}(x) + F_{ext}(x) \quad (4.12)$$

On peut choisir de modéliser directement le problème par une équation de forces dynamiques (équation 4.12), plutôt que d'utiliser l'énergie. Les forces internes sont en revanche les mêmes, et on peut utiliser des forces externes qui ne dérivent pas nécessairement d'un potentiel, ce qui rend la formulation plus générale.

4.3.2.2 Inconvénients des Snakes

Selon plusieurs auteurs, cette approche est toutefois limitée par plusieurs inconvénients :

- Le contour initial doit être proche de l'objet à segmenter, pour que l'algorithme converge ;
- La contrainte de régularité est forte, et ne permet pas de détecter les zones concaves du contour ;
- Le Snake ne permet pas le changement de topologie, et donc pas de détection simultanée de plusieurs objets ;
- Une telle régularité pousse le contour à rétrécir, voire à disparaître, s'il ne rencontre pas des zones de gradient suffisamment fort.

Face à ces inconvénients, de nombreux travaux ont porté sur la recherche de forces externes, plus sophistiquées, afin d'améliorer le Snake traditionnel. Ils seront présentés dans les paragraphes suivants. De même, pour assurer la convergence du modèle, nous proposons une initialisation automatique du Snake, en utilisant les informations, issues de la segmentation initiale et du flux de vecteur gradient.

4.3.3 Forces externes

L'évolution du modèle déformable vers les contours de l'objet à segmenter, dépend directement du choix de la force externe. On peut s'inspirer des principaux types de forces externes, des thèses de [65], [126] et [110]. Mais dans cette section, on ne considère que celles qui interviennent dans notre travail.

4.3.3.1 Force du gradient

A l'origine, [66] ont proposé de faire évoluer le Snake, suivant une force, calculée à partir du gradient de l'image ; ce type de force possède cependant une région d'attraction réduite, comme le montre la figure 4.7. Le modèle doit alors être très près du contour recherché.

[67] utilisent une force potentielle, c-à-d dérivée d'une énergie externe, comme le montre l'équation 4.11. Le potentiel, quant à lui, est défini à partir du module du gradient de l'image.

$$P_1(x, y) = - \|\nabla f(x, y)\|^2 \quad (4.13)$$

La force dérivée d'un tel potentiel a un domaine d'attraction réduit. Les auteurs proposent de l'agrandir, en convoluant l'image par une gaussienne, d'écart type σ .

$$P_2(x, y) = - \|\nabla[G_\sigma(x, y) * f(x, y)]\|^2 \quad (4.14)$$

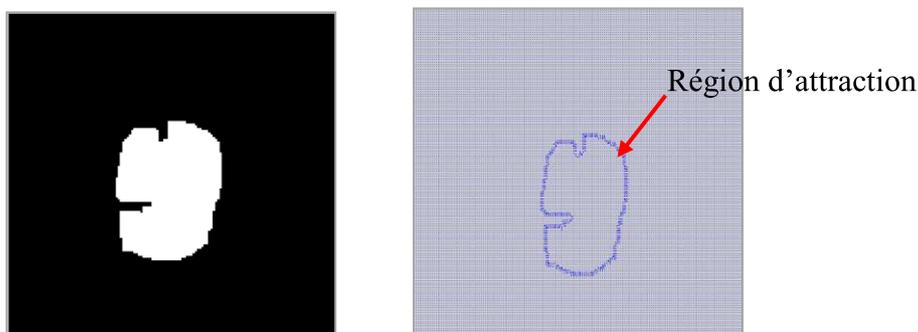


Figure 4.7 : Force externe calculée par le gradient de l'image

Plus σ est grand, plus l'attraction est suffisante. Or, si tel est le cas, le contour ne sera pas repéré précisément, car on introduit du flou au contour. Pour résoudre ce problème, ils ont

proposé d'utiliser une **force gaussienne multi-échelles**, avec des valeurs de σ de plus en plus petites.

Pour cela, au début, il faut évoluer le modèle avec une grande valeur de σ . Puis, lorsque l'équilibre est atteint, et que le modèle s'est donc rapproché du contour recherché, on procède à une nouvelle évolution, avec une valeur plus petite. La principale difficulté réside toutefois dans le choix des valeurs successives de σ .

4.3.3.2 Le flux du vecteur gradient (GVF)

Pour résoudre les problèmes du Snake traditionnel, associés au domaine d'attraction (l'initialisation) et à la convergence vers les concavités éventuelles des contours, [125] ont introduit une force, fondée sur la diffusion du vecteur gradient, appelée « Gradient Vector Flow » (GVF).

La définition par diffusion permet aux forces du GVF de s'étendre loin de l'objet, ce qui permet ensuite au contour actif de retrouver le contour réel, tout en étant placé plus loin qu'un contour actif traditionnel (Figure 4.8).

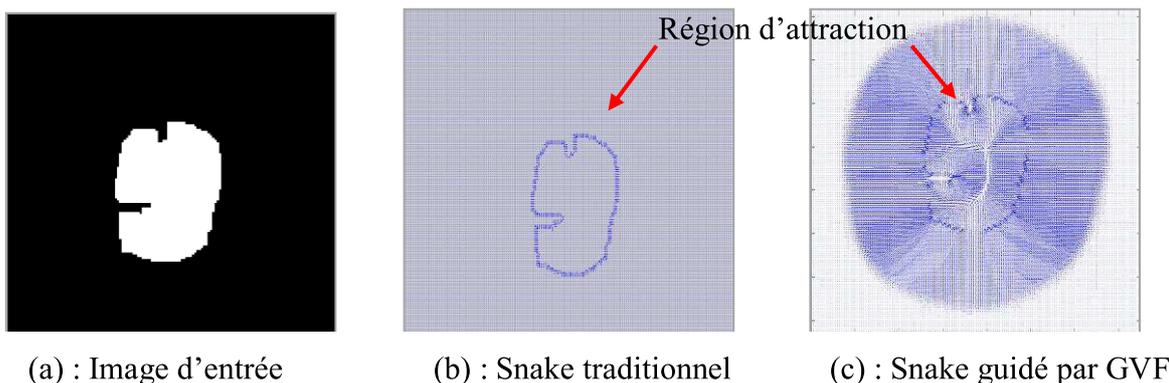


Figure 4.8 : Zone d'attraction

De plus, ce principe de diffusion permet également au contour actif de type GVF d'accéder dans les fines concavités (Figure 4.9), ce qui est un problème pour les contours actifs traditionnels.

Un des avantages des Snakes, guidés par GVF, est que le contour initial peut traverser les bords de l'objet à détecter, tout en assurant une bonne convergence.

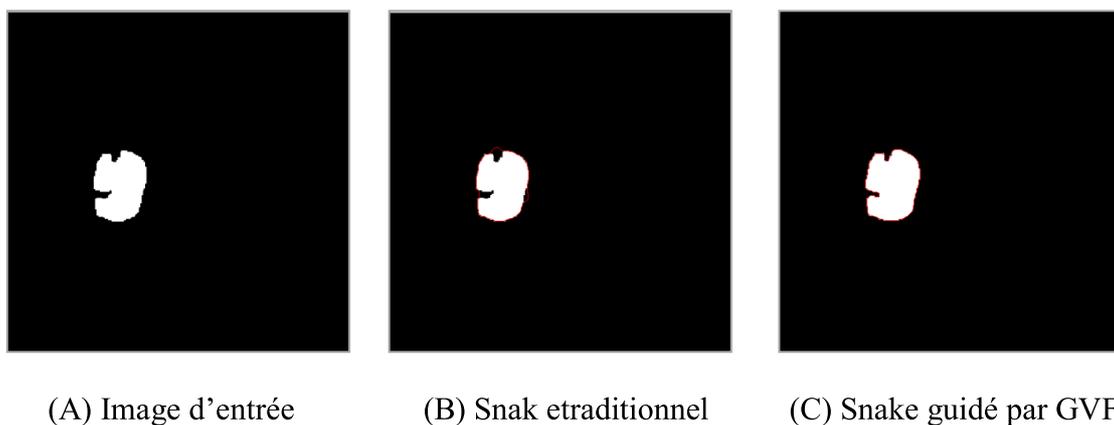


Figure 4.9 : Convergence aux concavités

Calcul des champs GVF

On définit ici un nouveau champ de forces externes statiques $F_{ext} = V(x, y)$, qu'on appelle le flux du vecteur gradient. Pour obtenir l'équation dynamique du Snake correspondant, nous remplaçons la force potentielle F_{ext} dans l'équation (4.11), ce qui donne :

$$X_t(s, t) = \alpha X^{(2)}(s, t) - \beta X^{(4)}(s, t) + v \quad (4.15)$$

On suppose qu'un détecteur de contours a été utilisé pour produire un ensemble de contours $f(x, y)$, dérivé d'une image $I(x, y)$. Le GVF est alors défini comme la solution d'équilibre de l'équation de diffusion suivante :

$$\begin{cases} \frac{\partial v}{\partial t} = g(\|\nabla f\|)\nabla^2 v - h(\|\nabla f\|)(v - \nabla v) \\ v(x, y) = \nabla f(x, y) \end{cases} \quad (4.16)$$

Dans la première équation, le 1^{ier} terme est le terme de lissage, puisque ce terme seul va produire un champ de vecteurs à variation lente. Le 2^{ième} terme est attaché aux données, car il force le champ de vecteurs à rester proche du gradient de f .

Les deux fonctions g et h sont des fonctions de pondération, qui dépendent du gradient du contour ; g doit être décroissante et h croissante pour que le champ de vecteur u varie lentement, loin des contours (là où le gradient est faible), mais se comporte comme ∇f , à proximité des contours. En plus, h doit dominer au niveau des contours, autrement dit, la fidélité aux données doit dominer par rapport à l'effet de lissage. On peut choisir :

$$\begin{cases} g(r) = e^{-\frac{r^2}{k}} \\ h(r) = 1 - g(r) \end{cases} \quad ou \quad \begin{cases} g(r) = \mu \\ h(r) = r^2 \end{cases} \quad (4.17)$$

4.3.3.3 Contraintes issues des relations spatiales

Peu de travaux ont porté sur l'introduction d'informations, issues des relations spatiales dans les modèles déformables, citons par exemple [1], [110] ... etc.

Pour cela, il faut les intégrer dans le schéma d'évolution du Snake, via une force externe. Cette force devrait être combinée à une force issue des données :

$$F_{ext} = \lambda F_C + \nu F_R \quad (4.18)$$

Où λ et ν sont des coefficients de pondération, F_C est un terme classique d'attache aux données, et F_R est une force associée aux relations spatiales.

Soit R un ensemble flou, représentant une relation spatiale, et μ_R sa fonction d'appartenance. Le rôle de la force F_R est de contraindre le modèle déformable à évoluer vers les régions où la relation est satisfaite. Elle devra donc être dirigée vers les valeurs élevées de μ_R . Lorsque la relation est complètement satisfaite, le modèle ne doit être dirigé que par

l'attache aux données ; F_R doit donc être nulle dans le noyau de R . Enfin, moins la relation est satisfaite, plus la norme de la force doit être grande. Nous imposerons donc que cette norme soit proportionnelle à $(1-\mu_R)$.

4.3.4 Initialisation automatique du Snake

Le Snake traditionnel nécessite une intervention manuelle pour l'initialisation du contour. Or, nous proposons dans cette partie d'automatiser cette tâche en s'inspirant du travail fait par [129]. Alors nous débutons par une petite description de la méthode de Clovis et autres, ensuite, nous présentons notre méthode proposée.

4.3.4.1 Initialisation du Snake en utilisant le GVF

Le positionnement du contour initial est une étape cruciale pour la segmentation par contours actifs. Bien que certaines techniques, comme le GVF, rendent l'initialisation moins contraignante, ils ne l'automatisent pas entièrement. De plus, un mauvais positionnement de la courbe initiale, peut aboutir à des résultats aberrants. [129]. Cette limitation est illustrée par un exemple dans la figure ci-dessous (Figure 4.10).

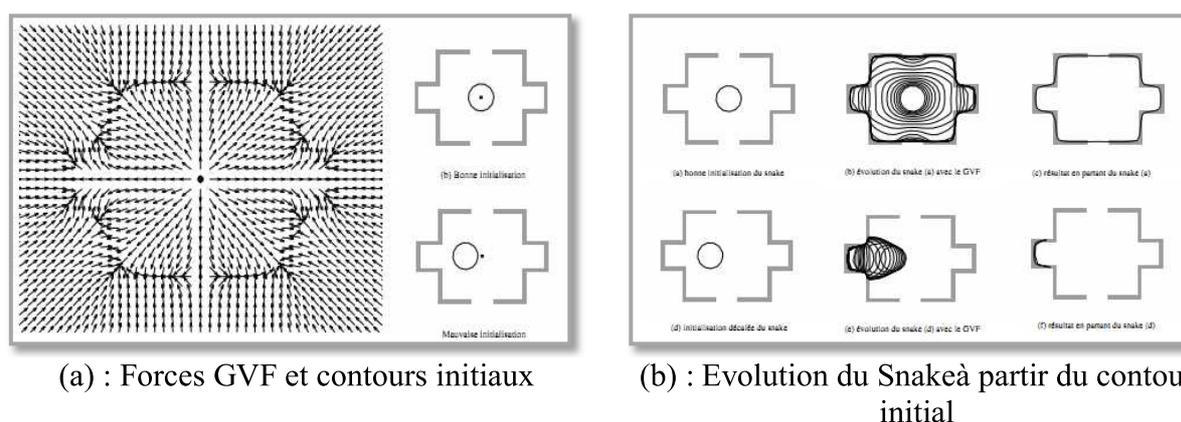


Figure 4.10 : Importance de l'initialisation, pour l'utilisation du Snake, guidé par GVF

Sur la première rangée de la figure (Figure 4.10(a)), nous initialisons le contour actif au centre de la forme géométrique. Nous remarquons que la courbe converge vers le contour. Sur la deuxième rangée, le contour initial est légèrement excentré sur la gauche. Le Snake se plaque complètement sur un des bords de l'objet. Pour cette problématique, nous construisons une méthode générale d'initialisation automatique du Snake, fondée sur le FCM ou sur l'analyse de symétrie, et sur la technique du GVF.

4.3.4.2 Méthode proposée d'initialisation automatique du Snake

Les étapes de la méthode d'initialisation automatique proposée sont les suivantes :

- Faire une segmentation initiale par FCM ou par analyse de symétrie;

- Faire une détection initiale de la tumeur avec sélection de sa classe;
- Appliquer des opérations morphologiques pour éliminer les petits objets, et fermer tous les trous, afin d'obtenir un masque optimal de la tumeur;
- Tracer le contour du masque obtenu;
- Vérifier que le contour contient tous les centres de divergence (ces centres sont les points sur lesquels les vecteurs du GVF changent de plusieurs directions). Un exemple d'un centre de divergence est illustré sur la figure (Figure 4.11).
- Appliquer ce masque comme contour initial du Snake.

Ces étapes sont illustrées dans la figure (Figure 4.12)

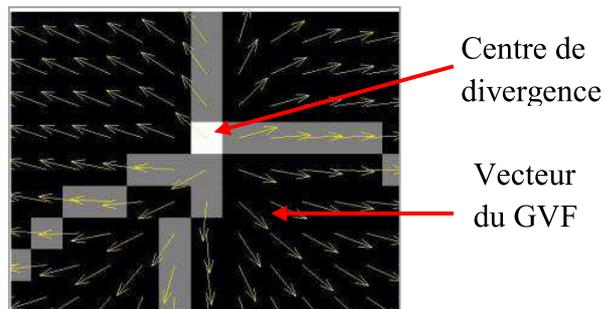


Figure 4.11 : Centre de forte divergence des vecteurs GVF

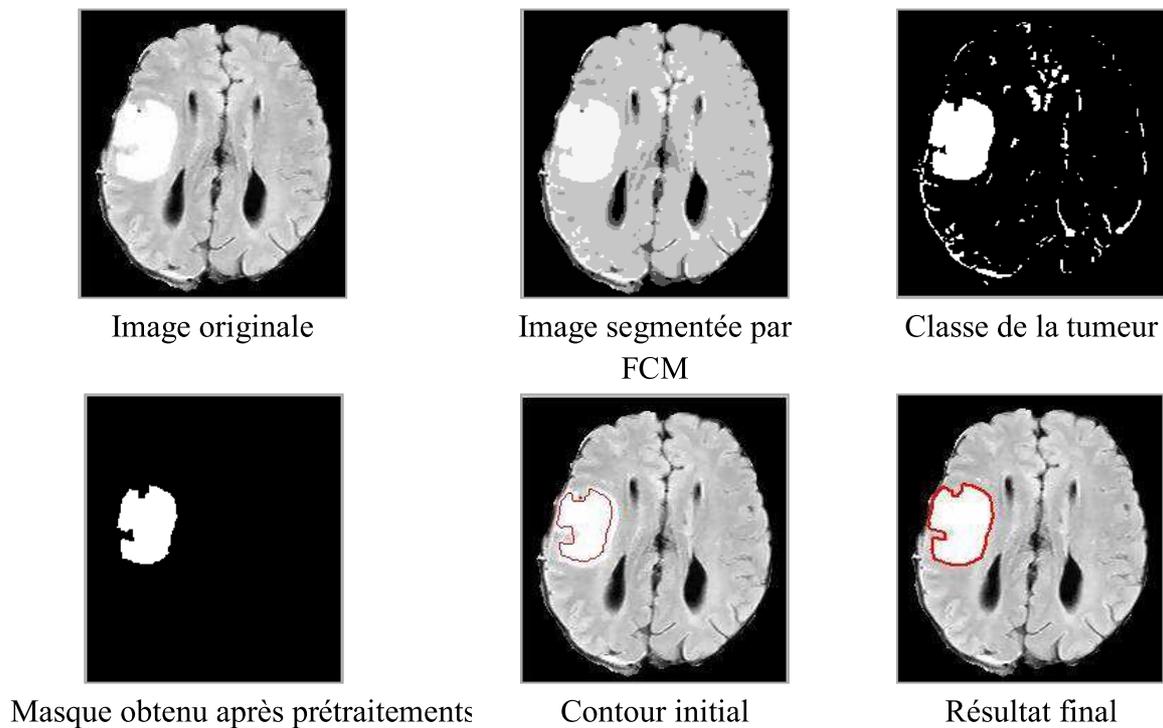


Figure : 4.12 Etapes d'initialisation automatique du Snake



Figure 4.13 : Initialisation manuelle du Snake

Selon les résultats présentés, on trouve que l'initialisation automatique du contour permet de segmenter les cavités tumorales correspondantes, avec une courbe finale, se répartissant sur la globalité des parois. Contrairement au cas de l'initialisation manuelle (Figure 4.13), pour laquelle, quelques points du contour final convergent vers de faux contours, ce qui donne une fausse segmentation en contour.

4.4 Méthode proposée : Modèle déformable, contraint par des relations spatiales

Les relations spatiales sont utilisées pour guider la reconnaissance des objets dans une image, lorsqu'elles fournissent des informations importantes sur l'organisation spatiales de ces objets. [52]

Dans notre approche, le modèle déformable est guidé par la relation de distance « proche de ». Dans le cas de la détection de tumeur par analyse de symétrie, deux informations sont disponibles :

- La détection initiale de la tumeur ;
- tissus environnants à la tumeur.

Alors, l'utilisation de la distance entre la segmentation initiale de la tumeur et les tissus environnants à la tumeur (ce qui permet au modèle déformable de ne pas converger vers les (faibles) faux contours).

Pour les relations de distances, on utilise un intervalle flou, de forme trapézoïde, dans l'espace \mathbb{R}^+ , de noyau $[0 \ n_1]$ et de support $[0 \ n_2]$ (Figure 4.14). Ici, n_1 et n_2 sont définies selon la grande distance entre la segmentation initiale de la tumeur et les tissus environnants.

Pour obtenir l'ensemble flou de l'espace d'image, f est combinée avec la carte distance de l'objet de référence A : $d(P) = f(d_A(p))$ où P est un point de l'espace.

Les deux relations « proche de la segmentation initiale de la tumeur » ; « proche de la segmentation initiale des tissus environnants à la tumeur » sont combinées, en utilisant l'opérateur de fusion conjonctive (Figure 4.15). L'ensemble flou résultant donne de fortes valeurs dans les régions où les deux relations sont satisfaites, et de faibles valeurs ailleurs.

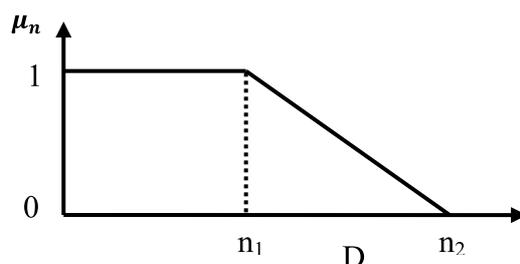
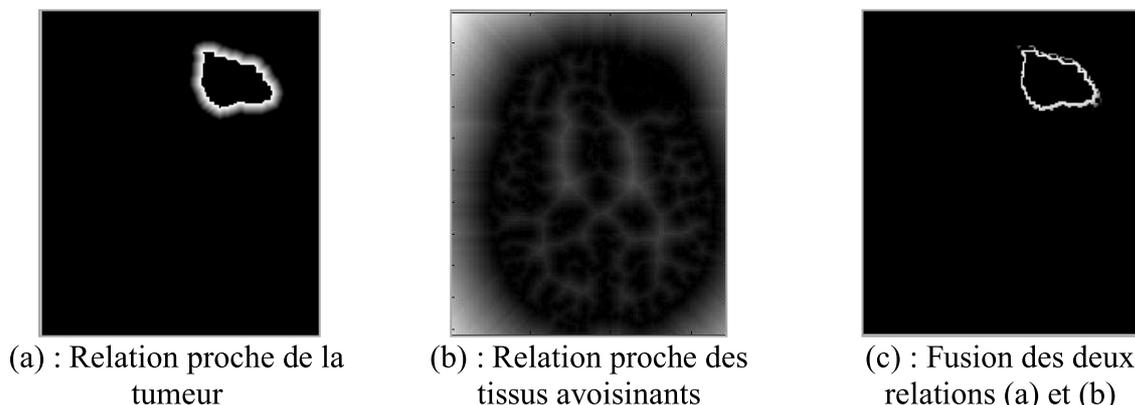


Figure 4.14 : Intervalle flou dans l'espace de distances correspondant à la relation « proche de »



(a) : Relation proche de la tumeur

(b) : Relation proche des tissus avoisinants

(c) : Fusion des deux relations (a) et (b)

Figure 4.15 : Relations spatiales utilisées pour la segmentation de la tumeur détectée (les grandes valeurs du niveau de gris correspondent aux régions où la relation est satisfaite)

Plusieurs méthodes ont été proposées, pour calculer la force, à partir de l'ensemble flou μ_R (le degré de satisfaction de la relation flou au point p) ; on peut citer les méthodes proposées dans [111] :

- En utilisant l'ensemble flou comme un potentiel d'énergie ;
- En utilisant une force potentielle de distance ;
- En utilisant une diffusion du vecteur gradient.

Les trois forces proposées vérifient les propriétés requises, et ne sont pas strictement équivalentes ; mais, elles ont souvent des comportements semblables, de plus le 3^{ème} type de force introduit une régularisation, qui semble a priori intéressante. [111]

Dans notre méthode, nous allons utiliser la diffusion du vecteur gradient, ce qui permet également d'obtenir une grande zone d'attraction. Le GVF permet d'obtenir un champ de vecteurs régulier, tout en restant proche du gradient original, aux points pour lesquels sa norme est élevée. Dans notre cas, nous remplaçons la carte de contours par notre ensemble flou μ_R , dans la formule du GVF :

$$\begin{cases} \frac{\partial v}{\partial t} = c \nabla^2 v - \|\nabla \mu_R\|^2 (v - \nabla \mu_R) \\ v(P, 0) = \nabla \mu_R(P) \end{cases} \quad (4.19)$$

En particulier, dans le noyau, et en dehors du support, seul le terme de diffusion agit, ce qui donne une force non nulle (Figure 4.16). Cependant, comme nous voulons que la force soit nulle dans le noyau, nous utiliserons la normalisation suivante :

$$F_R = (1 - \mu_R) \frac{u}{\|u\|} \quad (4.20)$$

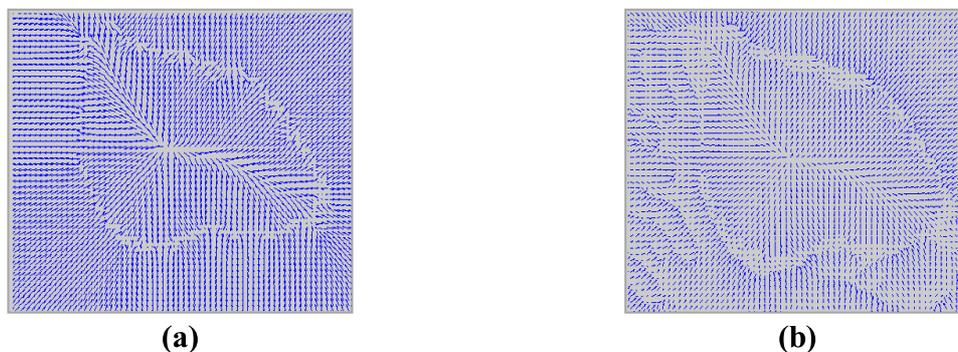


Figure 4.16 : Force externe F_R à partir de μ_R , correspond à une relation R .
 (a) : F_R de la relation « proche de la tumeur » dans la figure 4.15(a), (b) : F_R de la fusion des deux relations dans la figure 4.15(c), par l'équation 4.18 (un zoom en 2 est appliqué pour l'affichage)

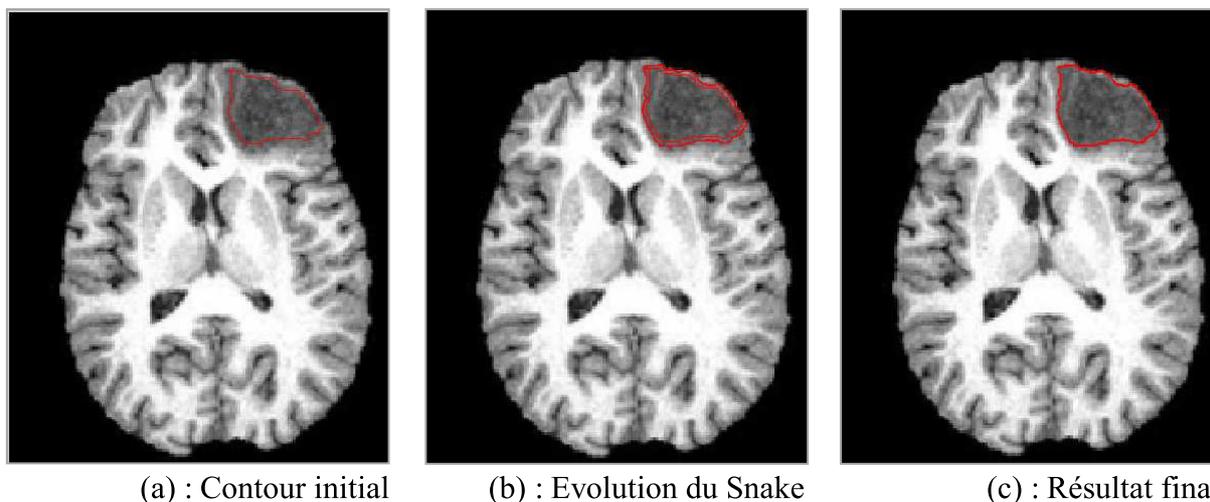


Figure 4.17 : Résultat de la segmentation par modèle déformable, intégrant des relations spatiales

La Figure 4.17 présente un exemple de contour déformable, contraint par des relations spatiales. L'objectif est de segmenter la tumeur, et l'évolution sera contrôlée par un terme de régularisation (celui proposé par [66]), un terme d'attache aux données, et une force correspondant aux relations spatiales. L'attache aux données est un GVF, calculé à partir d'un détecteur de contours. La force de relation spatiale, contraint le résultat à être « près de la tumeur » (Figure 4.15(a)) et « près des tissus avoisinants » (Figure 4.15(b)). Ces deux forces sont combinées (Figure 4.15(c)). Quand le modèle n'est soumis qu'aux termes de régularisation et d'attache aux données, il converge vers les contours des premiers objets

rencontrés. À l'inverse, quand la force de relation spatiale est ajoutée (Figure 4.17), le contour n'est pas arrêté par les objets ne satisfaisant pas la relation, et converge vers celui recherché. Cet exemple illustre que les relations spatiales évitent aux modèles déformables d'être attirés par les contours d'objets non désirés, et permettent donc de les initialiser, loin des objets à segmenter.

Discussion

Dans ce chapitre, nous avons présenté un petit panorama des méthodes de représentation de relations spatiales, en particulier des relations topologiques, métriques et directionnelles. Les relations de distance ont été utilisées tout au long de notre travail.

Ensuite, après avoir rappelé les principes qui régissent l'évolution des modèles déformables, nous avons présenté :

- D'une part, comment intégrer des connaissances a priori, issues de relations spatiales (obtenues à partir de la segmentation initiale). Ceci se fait par l'intermédiaire d'une nouvelle force externe, qui contraint le modèle à satisfaire à une relation donnée ;
- D'autre part, nous avons constaté le grand intérêt de l'initialisation automatique, qui assure la bonne convergence du Snake, vu que le contour initial est très proche du contour de l'objet recherché. Ce qui donne à la fin une méthode robuste et automatique.

Après avoir présenté les notions de base, qui sont utilisées dans notre méthode, nous allons exposer leurs implémentations, et les résultats obtenus.

CHAPITRE 5

RESULTATS ET DISCUSSIONS

Dans ce chapitre, nous allons faire la présentation des résultats détaillés de la segmentation, appliquée sur différentes images (synthétiques, images IRM de cerveaux, sains ou pathologiques, pondérées en T1, T2, et en Flair). Une interprétation et une discussion des différents résultats suivront.

Pour pouvoir faire une évaluation quantitative de la méthode, il est nécessaire de disposer d'images segmentées manuellement par un expert. De nombreux auteurs utilisent une comparaison avec des segmentations manuelles, pour calculer des valeurs indiquant la performance de la méthode. Dans le cas où nous ne disposons pas de segmentation manuelle, nous ne pouvons pas calculer de telles mesures, et nous devons nous contenter, soit d'une inspection visuelle, soit d'une expertise faite par un médecin spécialiste, afin de juger et d'estimer la fiabilité et l'efficacité de notre méthode.

5.1 Présentation de l'interface et Implémentation

Il est nécessaire de fournir à l'utilisateur un outil, permettant de visualiser les images obtenues par les segmentations décrites aux chapitres précédents. Pour cela, une interface utilisateur a été développée, et intitulée « Segmentation des tumeurs cérébrales par modèle déformable contraint par des relations spatiales ». Nous allons, tout d'abord, présenter brièvement l'environnement de ce logiciel, puis détailler les étapes de sa réalisation, et les différentes structures qui le constituent, ainsi que les résultats obtenus par les différents algorithmes utilisés.

5.1.1 Environnement logiciel

Ce travail a été réalisé au sein du laboratoire LARIM (laboratoire de Recherche en Imagerie Médicale), avec un ordinateur doté, du processeur pentium R Dual-Core CPU T4200 @ 2.00 GHz, de mémoire vive RAM de 2 GB, et d'un autre processeur Intel Pentium 4 CPU 2.66 GHz, avec 512 GB de RAM.

5.1.2 Langage adopté pour la programmation

Pour la programmation, notre application a été implémentée avec le langage de programmation Matlab, version 7.13.0.564(R2011). Notre choix est justifié par la souplesse et par la facilité de travail avec cet outil. Matlab (matrix laboratory) est une bibliothèque très riche et simple à utiliser, elle nous a permis d'utiliser ses propres fonctions, comme par exemple : `distfcm`, `stepfcm`, `initfcm`, `gradient` ... etc.

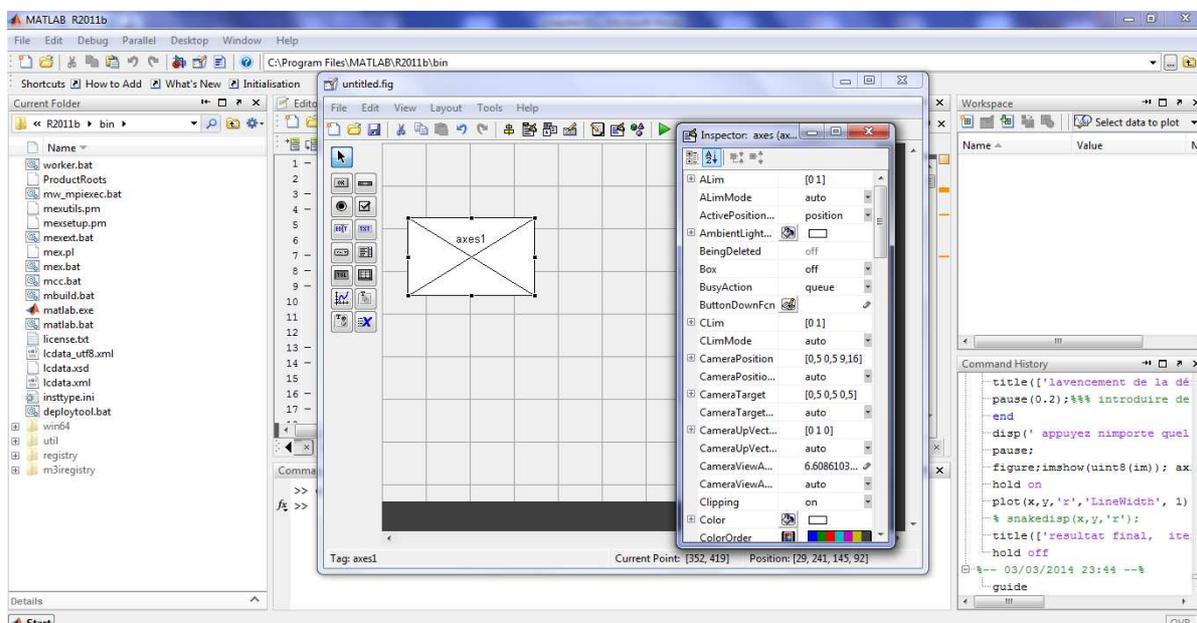


Figure 5.1 : Présentation de l'interface de développement graphique

Matlab est un langage très performant utilisé pour :

- Le calcul scientifique ;
- L'acquisition des données ;

- Le développement des algorithmes ;
- La modélisation et la simulation ;
- L'analyse, l'exploration et la visualisation des données et des résultats.

L'outil Guide (GUI) nous a bien facilité la réalisation de l'interface graphique (Figure 5.1). Elle est assurée en général par:

- La création de fenêtres qui permettent l'affichage des images ;
- L'utilisation d'un menu principal, avec des sous menus qui renferment toutes les fonctionnalités de ce logiciel ;
- La création d'une barre d'outils, qui facilite l'accès direct aux fonctionnalités d'application.

5.1.3 Structure du logiciel

Notre logiciel est développé en deux interfaces principales, la première nommée «Prétraitements », et la seconde nommée «Segmentation ». Dans l'interface «Prétraitements», nous avons implémenté les étapes du prétraitement, vu au chapitre 3 (Figure 5.2), et dans l'interface «Segmentation», nous avons réalisé toutes les méthodes de segmentation: celles utilisées en segmentation initiale, et celles utilisées en raffinement de la segmentation (Figure 5.3).

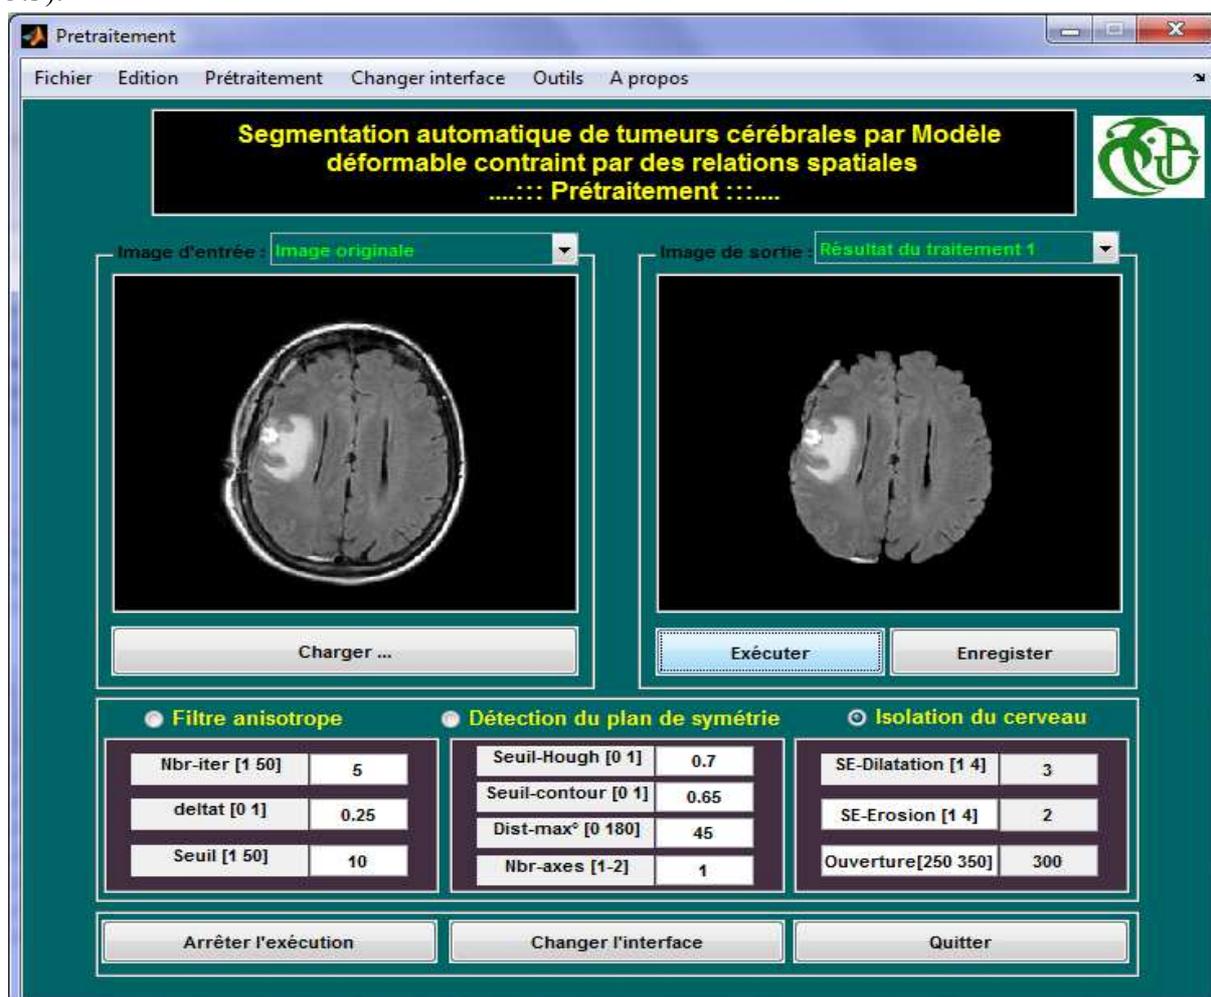


Figure 5.2 : Interface de prétraitement

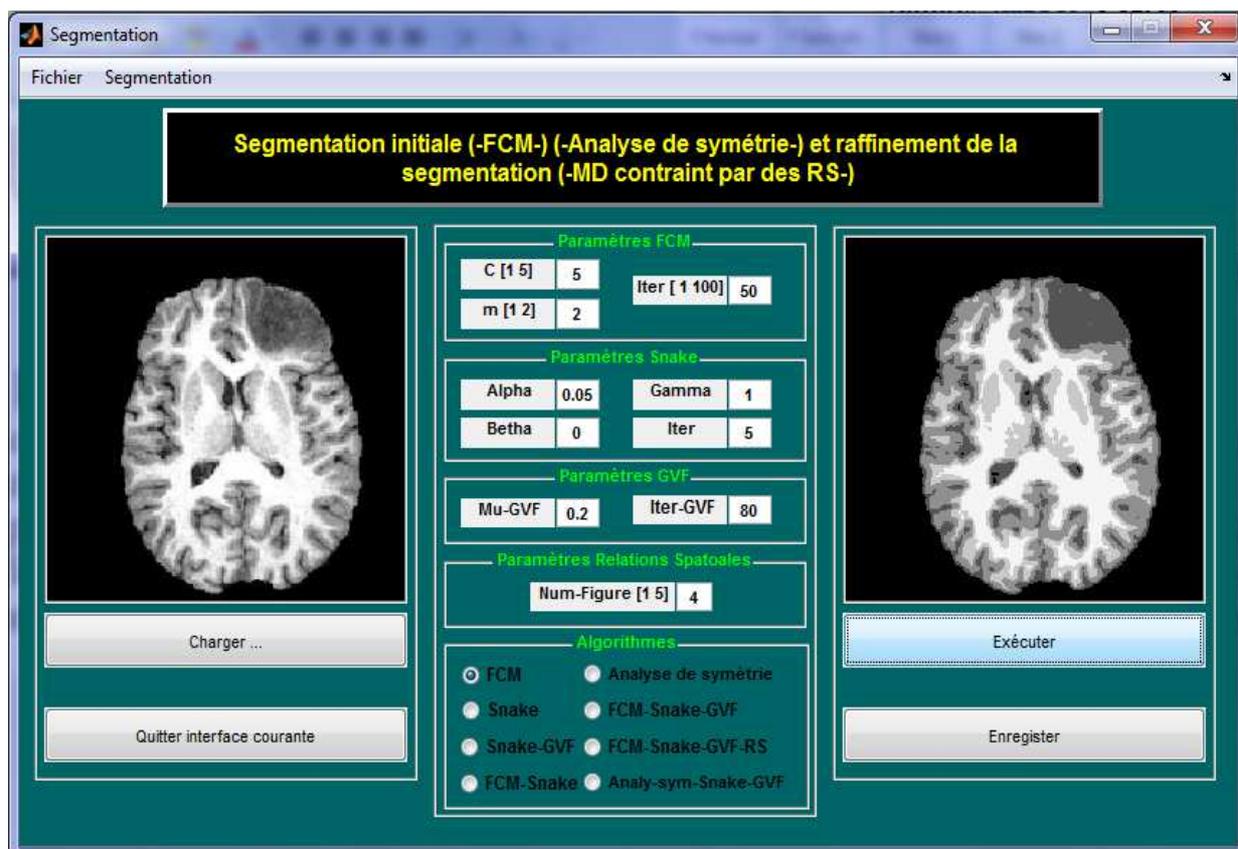


Figure 5.3 : Interface de la segmentation

Pour la description du logiciel et de toutes ses structures, on s'est servi d'un manuel utilisateur qu'on a développé, afin de présenter la fonction de chaque structure, et le fonctionnement général du logiciel réalisé. Il sera présenté à la fin du mémoire, comme annexe.

5.2 Images utilisées

Dans la suite de ce mémoire, nous allons utiliser des IRM cérébrales pondérées en T1, en T2 et en Flair, nous présentons ci-dessous ces images avec les propriétés de chacune.

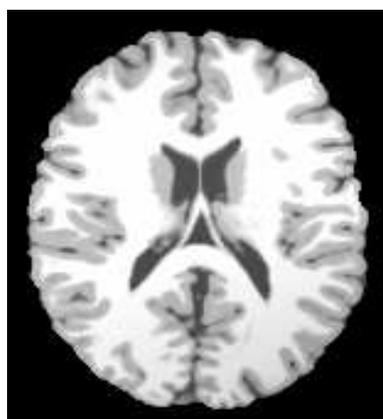


Image 1



Image 2



Image 3

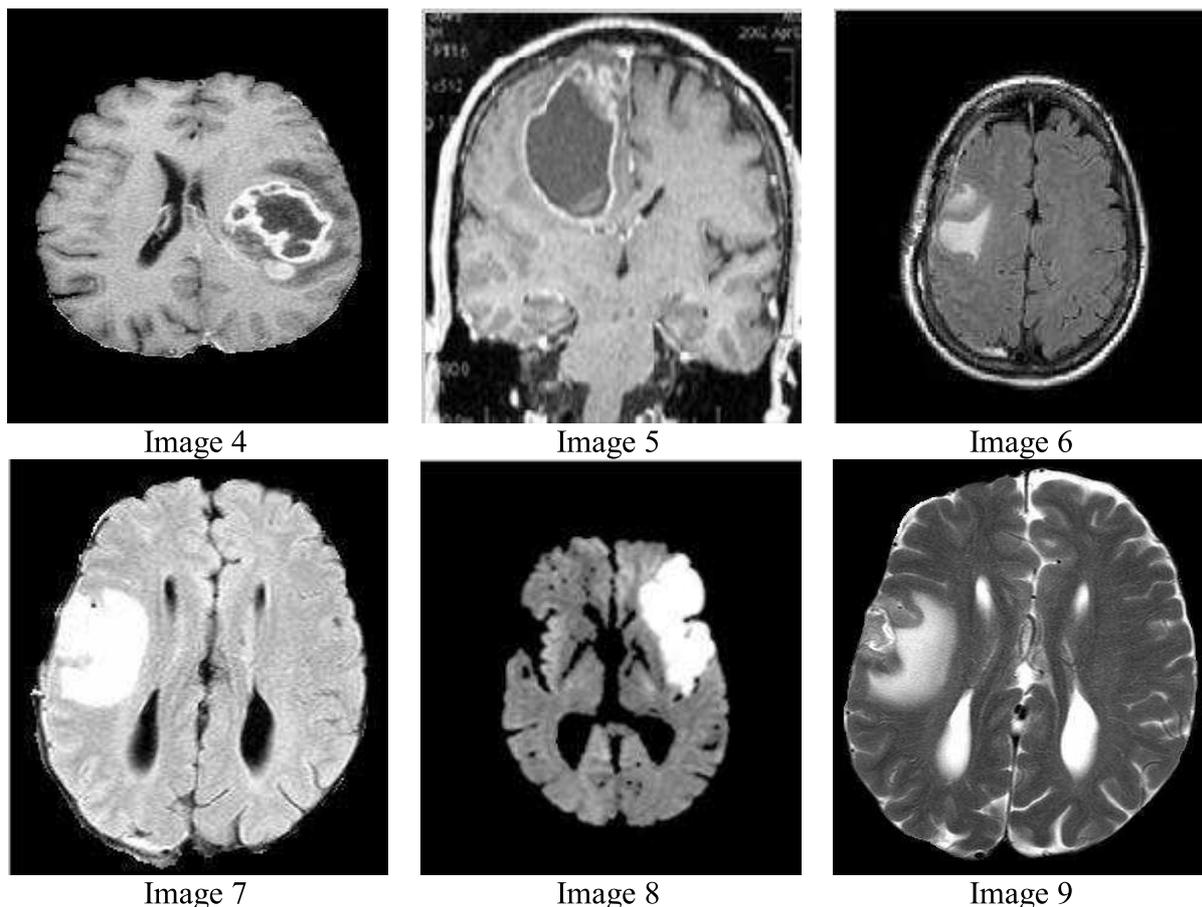


Figure 5.4 : Images utilisées

Description

Chaque image présentée dans la Figure 5.4, prendra le même nom dans tout le reste de ce document. Nous avons utilisé Matlab pour extraire les propriétés des images, et pour les pathologies, un médecin spécialiste a fait l'expertise, pour extraire les informations nécessaires sur la pathologie.

- **Image 1** : Image synthétique du cerveau isolé, pondérée en T1, coupe axiale, taille 217*543 ;
- **Image 2** : IRM cérébrale Flair, coupe axiale, de taille 147*360, Image avec injection du produit de contraste, sa tumeur est bénigne ;
- **Image 3** : IRM cérébrale pondérée en T1, coupe axiale, de taille 203*519, La tumeur est bénigne ;
- **Image 4** : IRM cérébrale pondéré en T1, coupe axiale, de taille 219*558, la tumeur est maligne avec œdème et capsule ;
- **Image 5** : IRM cérébrale pondérée en T1 avec scalpe, coupe coronale, de taille 200*600, Tumeur maligne avec nécrose et une portion charnue ;
- **Image 6** : IRM Flair T2 avec scalpe, coupe axiale, taille 288*288 ;
- **Image 7** : IRM cérébrale Flair T2, coupe axiale, taille 288*288 ;
- **Image 8** : IRM cérébrale Flair T2, coupe axiale, taille 288*288 ;

- **Image 9** : IRM cérébrale pondérée en T2, de taille 373*939, Tumeur maligne avec œdème et capsule.

5.3 Résultats, interprétations et discussions

Dans cette partie, les méthodes de segmentation proposées ont été mise en œuvre, dans le contexte de l'identification des principaux tissus cérébraux, et de l'extraction de la zone tumorale.

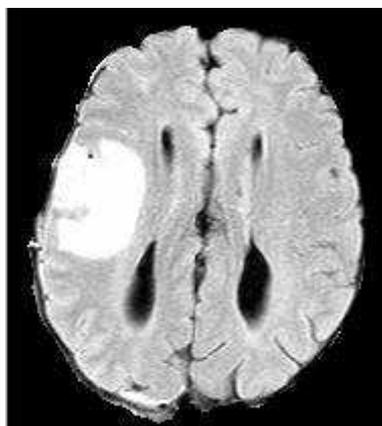
Nous présentons dans un premier temps les résultats obtenus après prétraitement, à savoir le filtrage anisotrope, l'extraction du cerveau et la détection de la symétrie. Nous exposerons par la suite les résultats obtenus après l'étape de segmentation initiale, en utilisant l'algorithme de classification floue et l'analyse de symétrie, puis les résultats obtenus dans la seconde étape, qui comprend l'approche contour (le modèle déformable paramétrique, guidé par GVF), et enfin les résultats de notre approche coopérative, qui constitue la troisième étape.

Au cours de cette étude, nous allons faire varier les différents paramètres, et analyser le comportement du système de segmentation, vis-à-vis de ces variations, afin de comparer la robustesse et l'efficacité de chaque méthode.

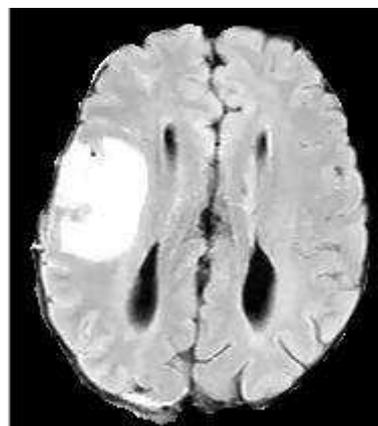
5.3.1 Résultats du prétraitement

5.3.1.1 Résultats du filtrage anisotrope

Pour une meilleure distinction entre les différents tissus du cerveau des images IRM, et pour réduire le bruit, il est nécessaire de filtrer ces images avant de les utiliser dans d'autres traitements tels que la segmentation, pour cela, nous présentons ci-dessous, L'effet du filtre Anisotrope sur des images IRM de différentes modalités.



« Image 7 »



« Image7 » filtrée

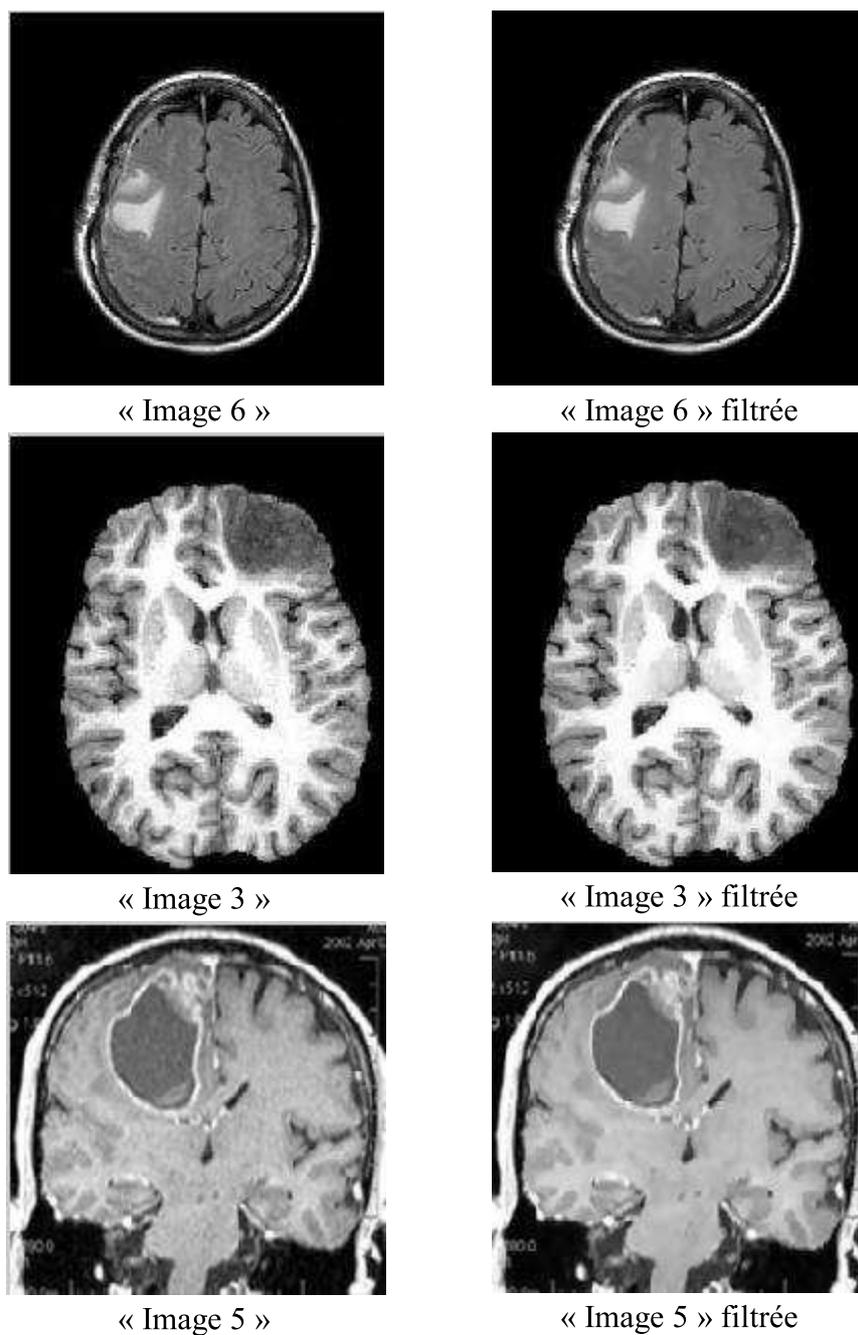


Figure 5.5 : Résultats du filtrage anisotrope sur des images IRM, avec différentes modalités

Interprétation

La Figure 5.5 donne une illustration sur l'influence du filtrage, sur différentes modalités d'images IRM (Images pondérées en T1, T2 et en Flair). Toutes les images filtrées montrent une différence des régions lisses et homogènes, par rapport aux images originales. Nous avons fait varier les paramètres de l'algorithme. Les meilleurs résultats ont été obtenus pour les valeurs suivantes : **Nbr d'itérations = 3; $\nabla t = 0.25$; valeur de seuil = 5.**

5.3.1.2 Résultats de l'isolation du cerveau

La segmentation du cerveau consiste à isoler l'encéphale et à éliminer l'os, la peau et les méninges. Pour ce faire, nous avons employé des opérations morphologiques, telles que : l'érosion, la dilatation, l'ouverture et la fermeture, en utilisant le disque comme élément structurant, de taille 2 ou 4, selon l'image à traiter. Nous avons appliqué cette opération sur une séquence de 16 images, et nous présentons les résultats obtenus (Figure 5.6).

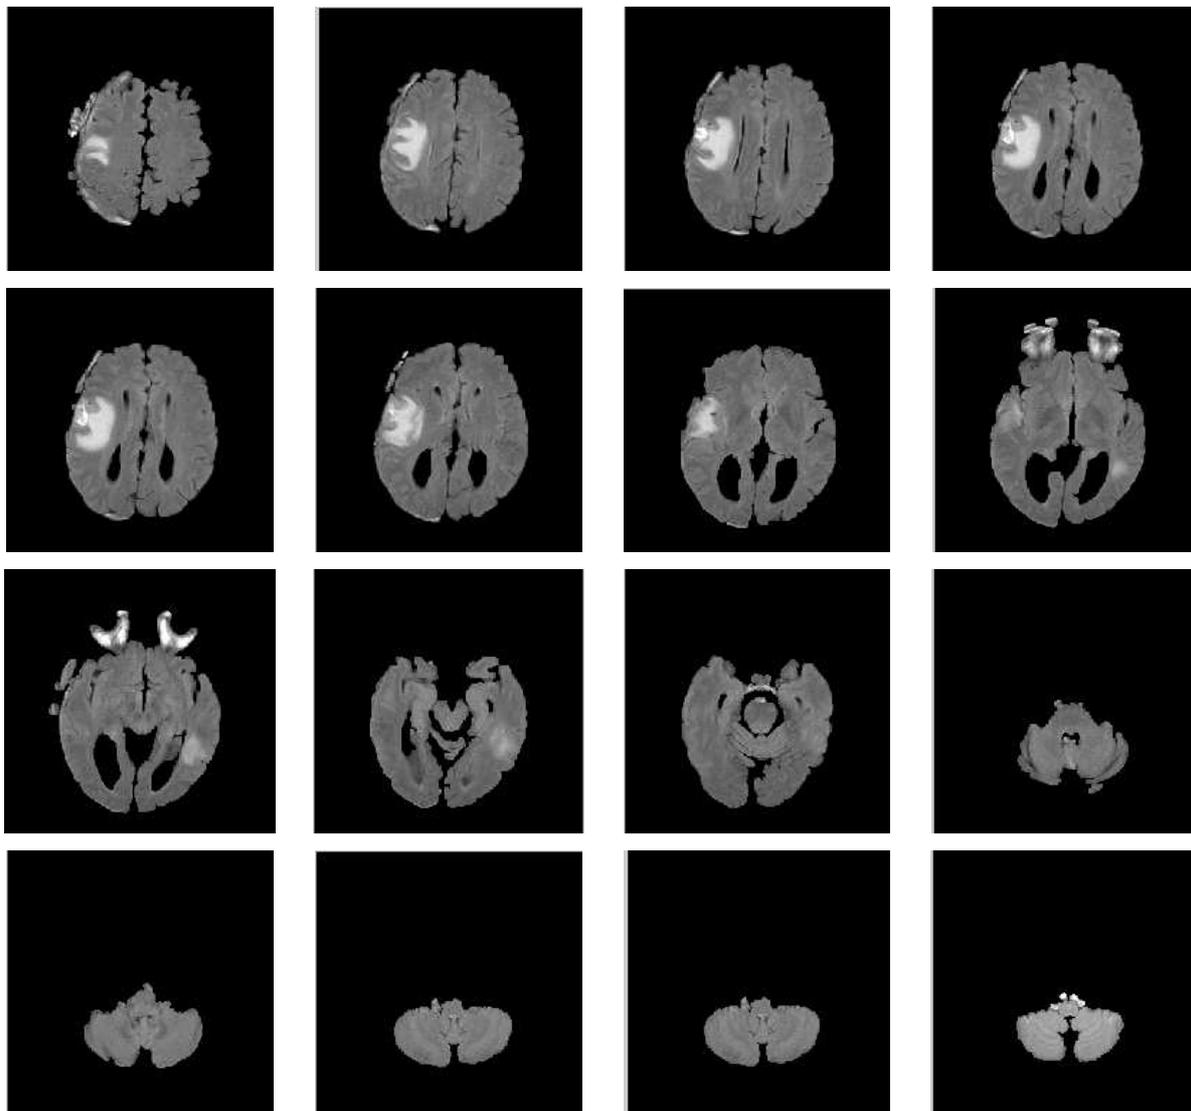


Figure 5.6 : Isolation du cerveau sur une séquence de 16 images

Interprétation

Afin de montrer la généricité et l'efficacité de la méthode adoptée, nous l'avons appliquée sur une séquence de 16 images IRM pathologiques pondérées en Flair T2 (**Figure 5.6**), ces images ont une taille de 288*288. Les résultats obtenus sont semblables à ceux donnés par le logiciel commercial BET de MRICro. Cependant, la méthode n'est pas exempte de tous défauts, puisque cette opération ne conserve pas uniquement le cerveau, mais on retrouve aussi les méninges, les os du cou et les yeux, pour quelques images, et à certains endroits.

5.3.1.3 Résultats de la détection du plan de symétrie

Nous avons calculé le plan de symétrie qui détecte le plan inter-hémisphérique, qui sépare les deux hémisphères, pour avoir des informations a priori. Ces dernières seront ajoutées à notre modèle comme relations spatiales

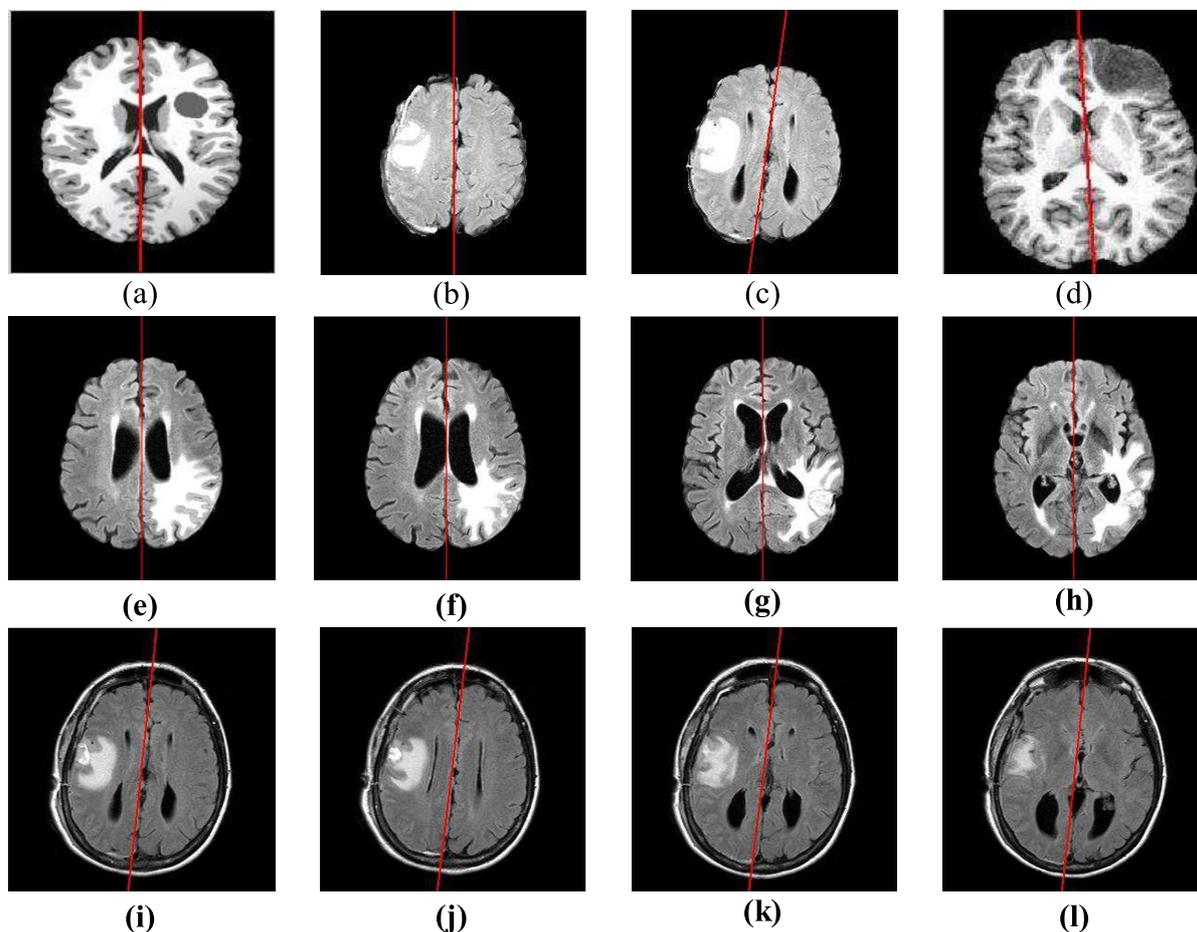


Figure 5.7 : Résultats de la détection du plan de symétrie

Interprétation

Nous avons appliqué notre méthode de détection de symétrie sur toutes les modalités d'IRM cérébrales, présentant une pathologie, et visuellement, on voit une détection correcte du plan de symétrie du cerveau, pour chaque image, même de celles avec scalpe (Figure 5.7 (i), (j), (k), (l)).

Le bon choix des paramètres assure la convergence de l'algorithme, et dans notre cas, on a pris les valeurs suivantes: **Seuil hough=0.7**, **Distance maximale = 45**, **nombre d'axes=1** et **le seuil de contour=0.55** sauf pour : l'image (a) le seuil est de 0.65, (b) il est de 0.35, et pour (c) il est de 0.7.

Après l'étape de prétraitement, on obtient des images qui ne contiennent que les trois substances, avec ou sans pathologie, avec des régions lisses et moins bruitées. Elles sont

mieux adaptées à être utilisées dans la phase de segmentation, dont les résultats seront exposés dans la section suivante.

5.3.2 Résultats de Segmentation initiale (FCM et Analyse de Symétrie)

5.3.2.1 Segmentation par C-moyennes flous

Pour vérifier le bon fonctionnement de l'algorithme FCM, nous l'avons appliqué sur une image IRM synthétique du cerveau « **Image 1** », contenant quatre classes (MB, MG, LCR et le fond). Les résultats ont été présentés au chapitre 03 (page 74). Dans cette partie, nous allons voir son apport sur des images IRM réelles, présentant une pathologie, ce qui implique d'augmenter le nombre de classes, selon la pathologie et son environnement (la tumeur, l'œdème, la nécrose...etc.) (Figure5.8).

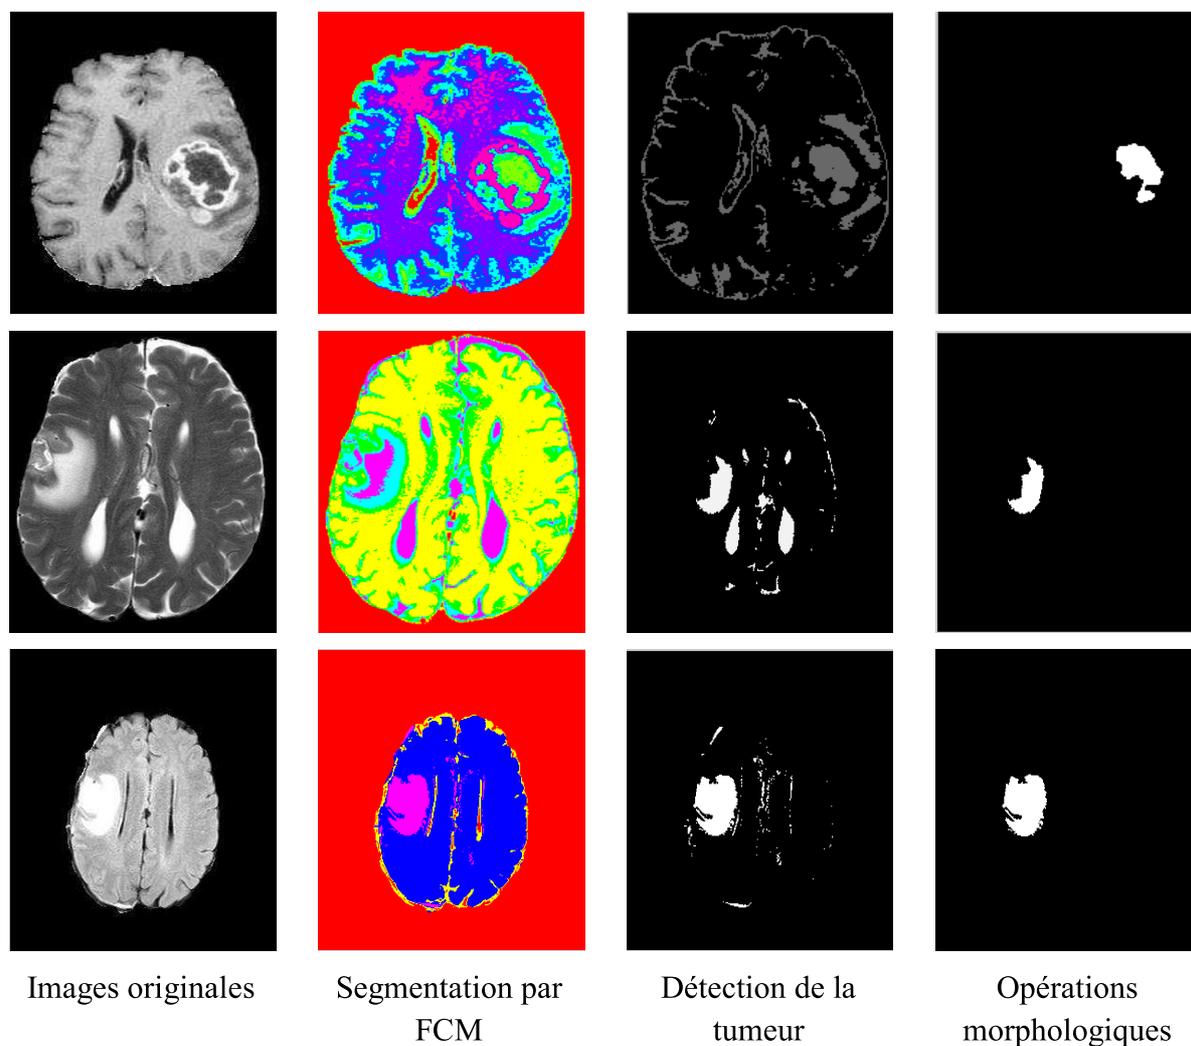


Figure 5.8 : Segmentation par FCM et détection de la tumeur

Interprétation

Sur la 1^{ère} ligne, on utilise une IRM « **image4** » (Les caractéristiques de cette image sont indiquées précédemment). La tumeur sur cette image est maligne. Les cellules tumorales malignes s'infiltrent dans le parenchyme sain, ce qui explique les contours flous observés. Dans le résultat de la segmentation par FCM, la capsule (en **rose**), l'œdème (en **vert** à l'extérieur), ainsi que la nécrose (le **vert** qui se situe à l'intérieur) peuvent être facilement distingués.

Sur la 2^{ème} ligne, on utilise l'image IRM « **Image 9** », présentant une tumeur maligne. La grande masse à gauche, sur l'image originale représente l'œdème, à sa gauche se trouve la tumeur avec sa capsule.

Sur la 3^{ème} ligne, on utilise une image IRM « **Image 7** », le manque de contraste dans ce type d'image est très remarquable, à tel point que l'on ne peut pas distinguer la MB de la MG. Mais, le résultat de la segmentation de la tumeur a été très optimal.

Pour toutes les modalités d'images IRM, on remarque qu'on a obtenu une bonne détection de la tumeur par FCM, sauf que l'on observe quelques pixels mal segmentés, qui sont assignés à la classe de la tumeur. Pour cela, on fait appel à quelques opérations morphologiques, afin de remédier à ce problème. La Figure 5.7, colonne 4, montre le résultat final. Ces opérations consistent en : une sélection de l'objet d'intérêt, une érosion pour séparer la masse de la tumeur, une ouverture pour éliminer les petits objets, puis une dilatation pour revenir à la taille originale de l'objet, et en dernier, en un remplissage des trous s'il en reste.

On a fixé les paramètres comme suit : **c (nombre de classes) =5 ; Nbr-itr = 50 ; m (degrés de flou)=2, SE (élément structurant) : disque de taille 2, Nbr de pixels pour l'ouverture = 50.**

5.3.2.2 Segmentation par analyse de symétrie

A partir de la détection initiale du plan de symétrie, on sépare les deux hémisphères, et on trace l'histogramme de chacun, puis on trace l'histogramme de différence (H_s), entre l'hémisphère droit (H_d) et l'hémisphère gauche (H_g), et d'après la lecture de H_s , on tire la classe de la tumeur et des tissus avoisinants. On présente ci-dessous les résultats obtenus pour différentes images.

Comme on le voit dans la Figure 5.9(a), les histogrammes sont corrompus par différents types de bruit. Nous avons donc besoin de réaliser une étape de prétraitement, pour lisser le bruit, tout en conservant les structures significatives (Figure 5.9 (b)). On passera ensuite à l'étape de détection de la tumeur, à partir de H_s .

Filtrage de l'histogramme

L'un des meilleurs candidats pour les filtres de lissage d'histogramme est le filtre à diffusion anisotrope. Nous avons tracé les histogrammes de l'image avant et après filtrage anisotrope, puis nous avons comparé les résultats (Figure 5.9).

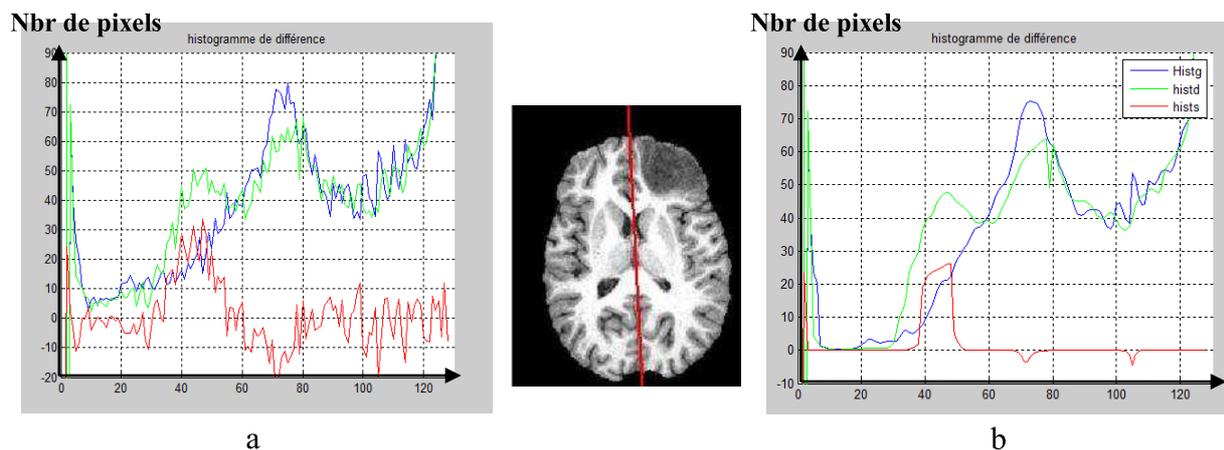


Figure 5.9 : L'histogramme avant et après filtrage anisotrope

Afin de bien estimer l'amélioration qu'apporte le Filtre anisotrope sur l'histogramme, nous allons tracer superposer l'histogramme de H_g , H_d , et H_s avant filtrage sur les histogrammes H_g , H_d , et H_s après filtrage, respectivement.

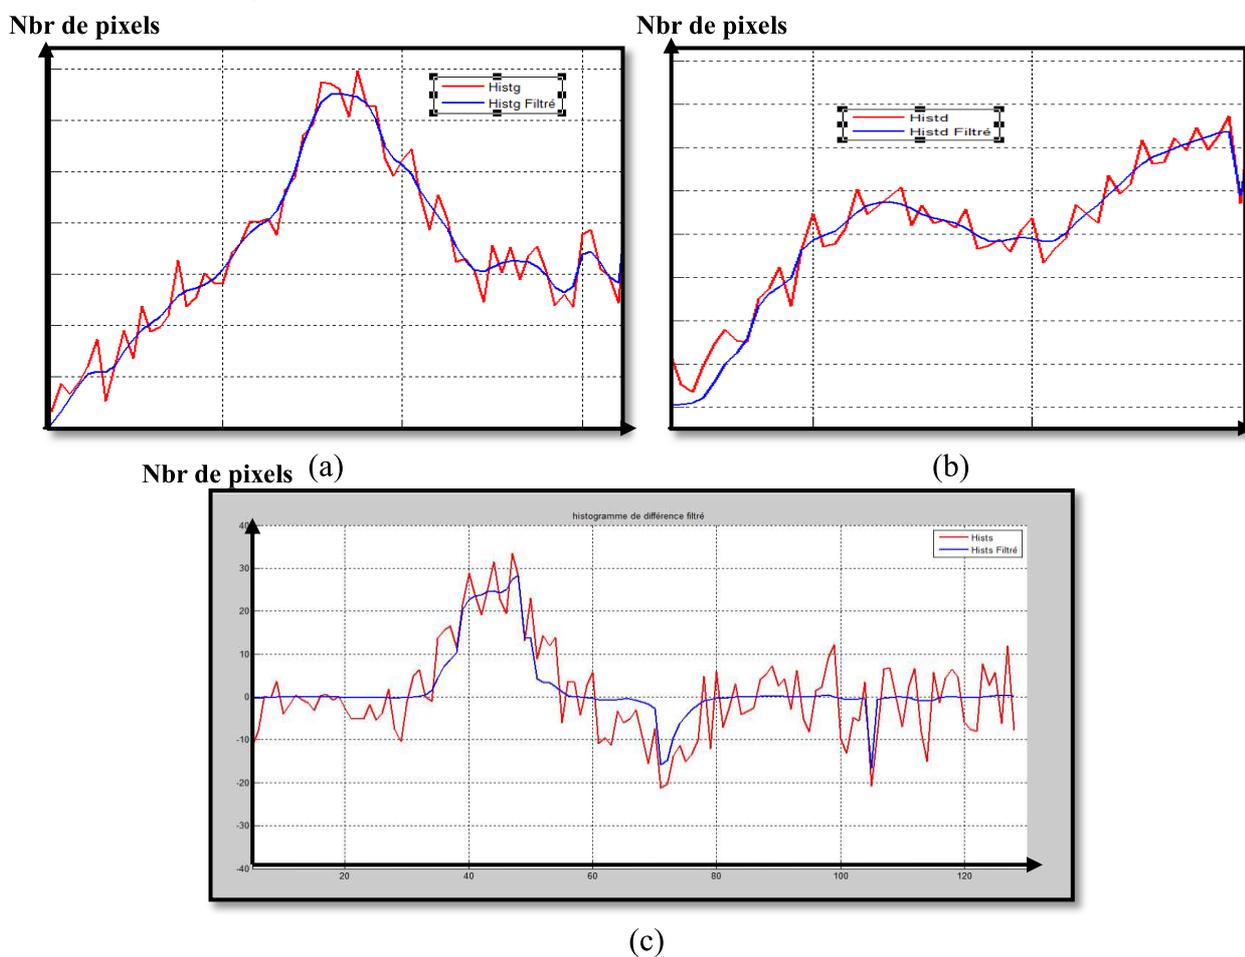


Figure 5.10 : Comparaison d'histogrammes avant et après filtrage

Courbe en rouge : l'histogramme avant filtrage. Courbe en bleu : l'histogramme après filtrage.
(a) : L'histogramme H_g , (b) : L'histogramme H_d , (c) : L'histogramme H_s .

La Figure 5.10(a) représente une portion de l'histogramme de l'hémisphère gauche, la Figure 5.10(b) représente une partie de l'histogramme de l'hémisphère droit, et la Figure 5.10(c) représente le tracé complet de l'histogramme de différence. Le tracé en rouge indique l'histogramme original, et le tracé en bleu l'histogramme après filtrage.

La figure 5.10 montre l'effet du filtre anisotrope sur les histogrammes H_g , H_d et H_s , tels que, leurs tracés sont devenu très lisses, ce qui permet une bonne distinction des intervalles des pics créés.

Détection par analyse de symétrie

H_s calculé précédemment, fournit des informations utiles, sur les nouvelles classes d'intensité, induites par la tumeur. Pour extraire et analyser cette information, nous devons d'abord détecter les pics (changements) dans H_s . Trois types de tumeurs sont segmentés par l'analyse de symétrie, leurs résultats est données par les figures 5.11, 5.12 et 5.13

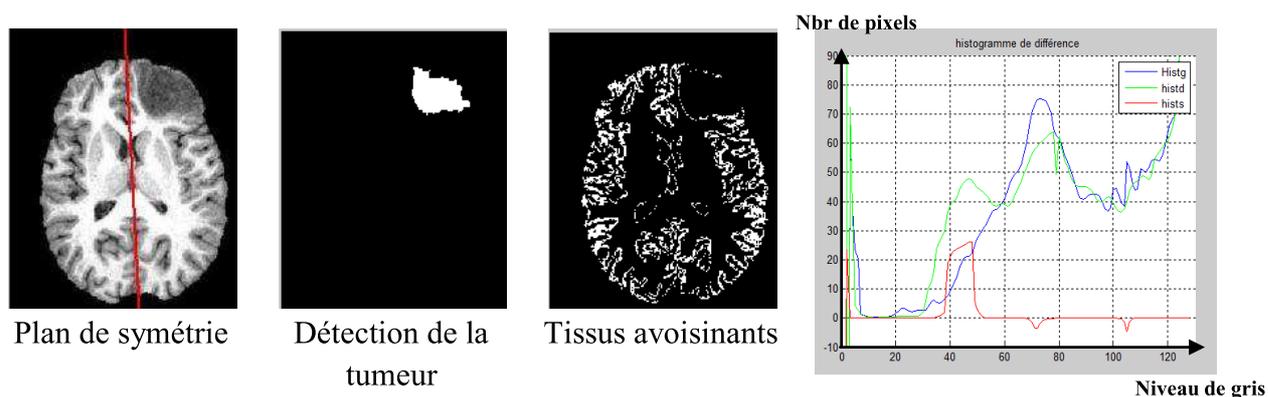


Figure 5.11 : Détection de la tumeur par analyse de symétrie de l'image « Image 3 »

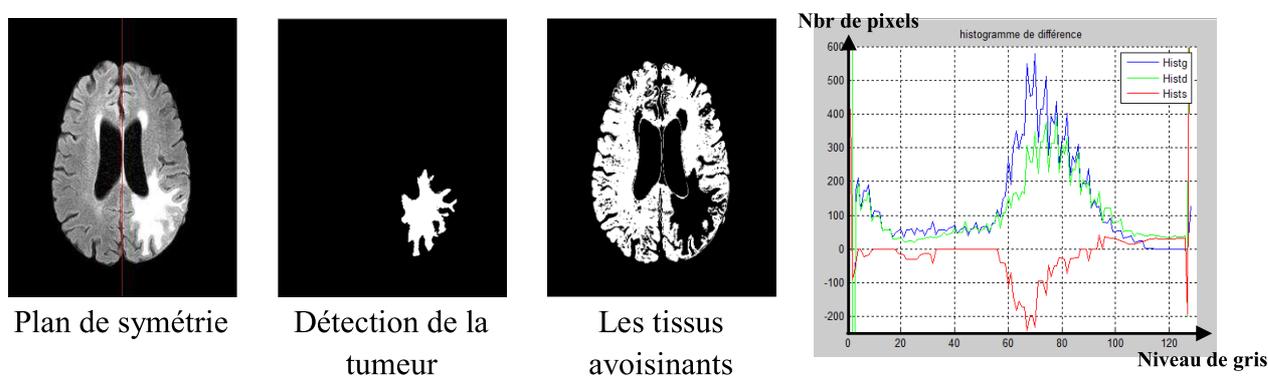


Figure 5.12 : Détection de la tumeur par analyse de symétrie d'une image IRM Flair

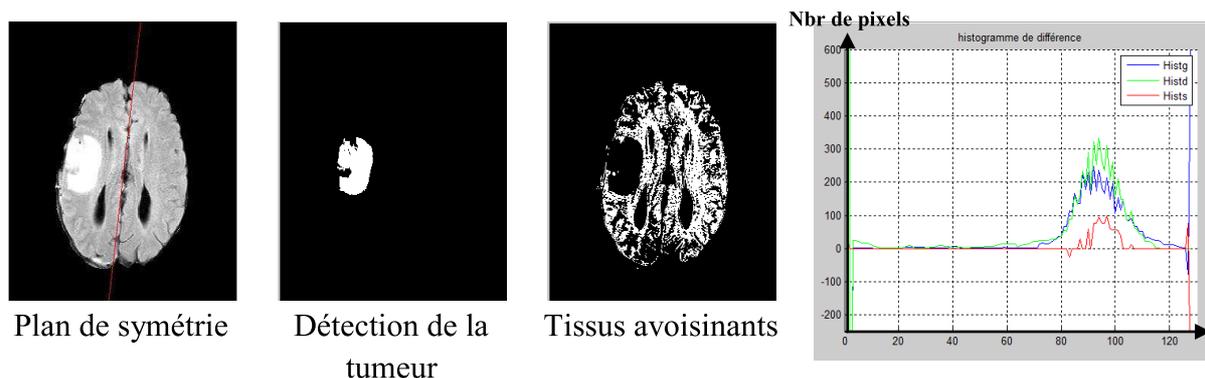


Figure 5.13 Détection de la tumeur par analyse de symétrie de l'image « Image7 »

Interprétation

L'extraction de l'intervalle de la tumeur ou des tissus avoisinants, se fait par intervention manuelle, c'est l'inconvénient majeur de cette méthode ; mais par contre, elle donne des résultats très intéressants, et on obtient des régions homogènes, de même niveau de gris.

5.3.3 Résultats du raffinement de la Segmentation

Dans cette section nous présentons les résultats de segmentation de chaque algorithme seul, puis au fur à mesure en rajoute et on combine entre ces méthodes afin d'éliminer leurs inconvénients et de tirer profit des avantages de la coopération, et à la fin on présente la coopération finale de la méthode proposée.

Les méthodes et les coopérations faites seront présentées par l'ordre suivant :

- Les Snakes traditionnels
- Les Snakes guidés par GVF
- Les Snakes combinés avec FCM
- Les Snakes guidés par GVF combinés avec FCM
- Les Snakes guidés par GVF combinés avec l'analyse de symétrie
- Les Snakes guidés par GVF combinés avec FCM et Relations spatiales
- Les Snakes guidés par GVF combinés avec l'analyse de symétrie et Relations spatiales

5.3.3.1 Contours actifs paramétriques (Snake) et Snake guidé par GVF

Nous présentons dans les figures ci-dessous une petite comparaison des résultats, et des étapes entre les Snakes, et les Snakes guidés par GVF.

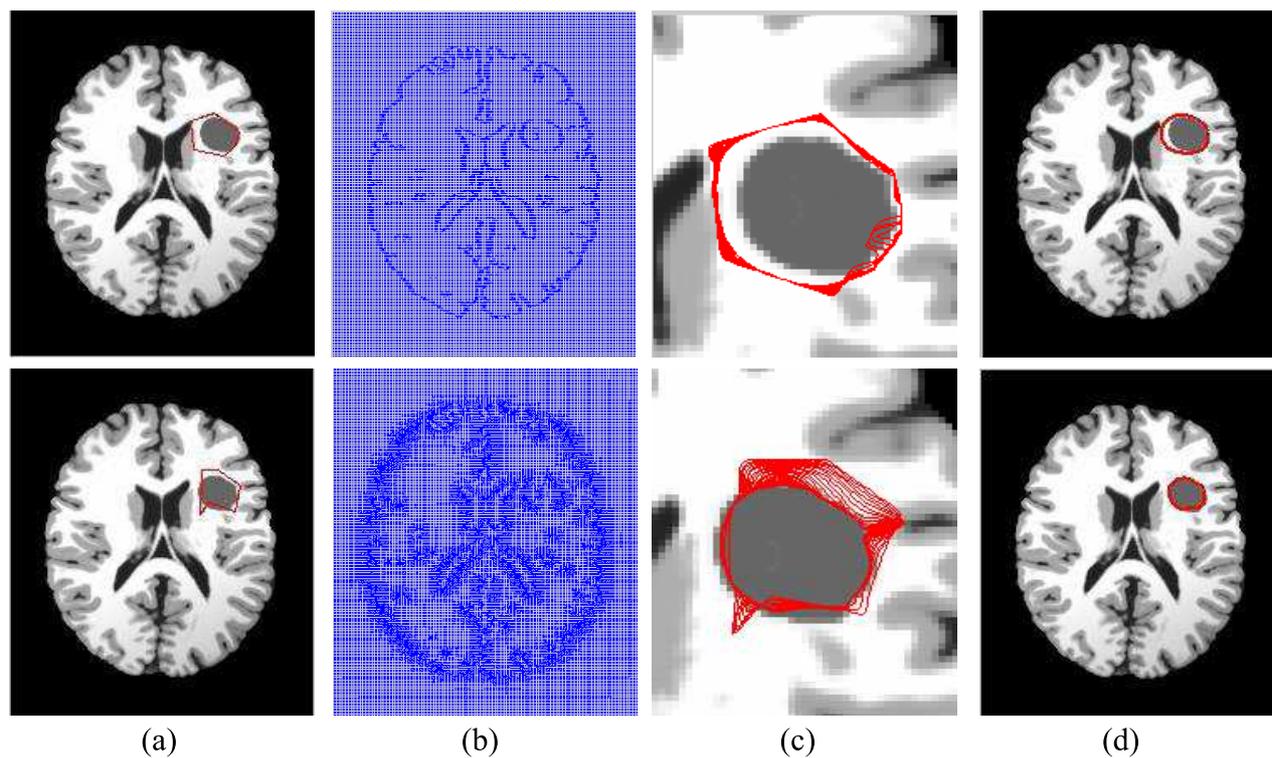


Figure 5.14 : Comparaison de la segmentation d'une image synthétique, par Snake et par Snake guidé par GVF

1^{ère} ligne : Méthode du Snake, 2^{ème} ligne : Méthode du Snake guidé par GVF

(a) : Initialisation manuelle, (b) : Gradient de l'image, (c) : Déformation du modèle, (d) : Résultat final

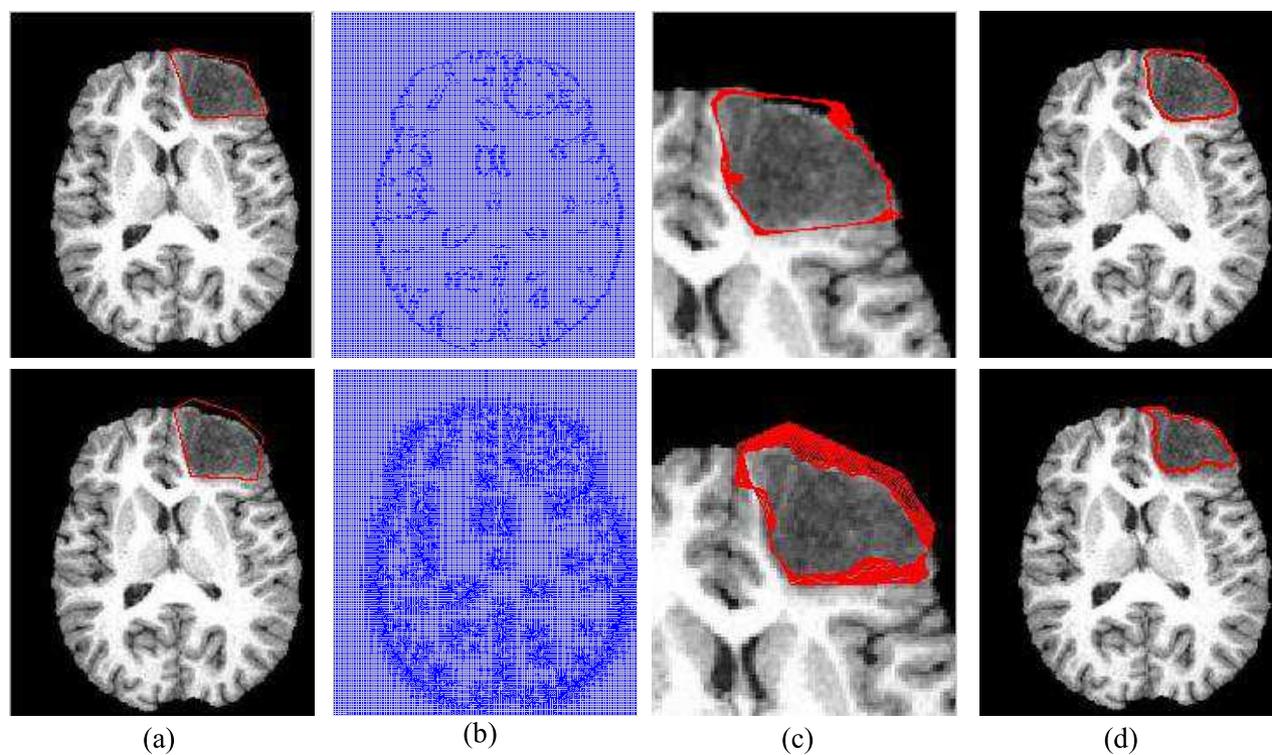


Figure 5.15 : Comparaison de la segmentation d'une IRM réelle par Snake et par Snake guidé par GVF

Interprétation

La segmentation a donné de meilleurs résultats, en utilisant le Snake guidé par GVF. Cela est dû à la grande zone d'attraction (Figure 5.14(b) et 5.15 (b)), qui a donné une plage supérieure à celle obtenue par le Snake, où se fait l'initialisation manuelle du contour initial.

Pour l'image « **Image 1** » (Figure 5.14), le Snake converge partiellement, et grâce à l'intégration des forces du GVF au Snake, le modèle a convergé correctement vers les frontières de l'objet d'intérêt.

Pour l'image « **Image 3** », le deuxième modèle s'est déformé plus qu'il n'en faut, tout en suivant la carte contour, fournie par les forces du flux de vecteurs gradient de l'image originale (Figure 5.15 (b,c)) ce qui a faussé le résultat de la segmentation; d'où la nécessité d'une étape, qui précède le Snake, pour préparer une bonne carte contour, pour orienter le modèle vers les vrais bords, et pour éliminer aussi l'initialisation manuelle.

Les paramètres utilisés: {**Binary = 0.5 ; GVF (mu = 0, 2, Iter = 80) ; Snake (alpha=0.05, beta= 0, gamma = 1, kappa = 0.5, Iter = 20)**}.

On présentera dans la section suivante la coopération entre le Snake guidé par GVF et FCM/Analyse de symétrie.

5.3.3.2 Coopération entre FCM/Analyse de symétrie et Snake guidé par GVF

Le synoptique de la coopération FCM et Snake/GVF est par la figure 5.15:

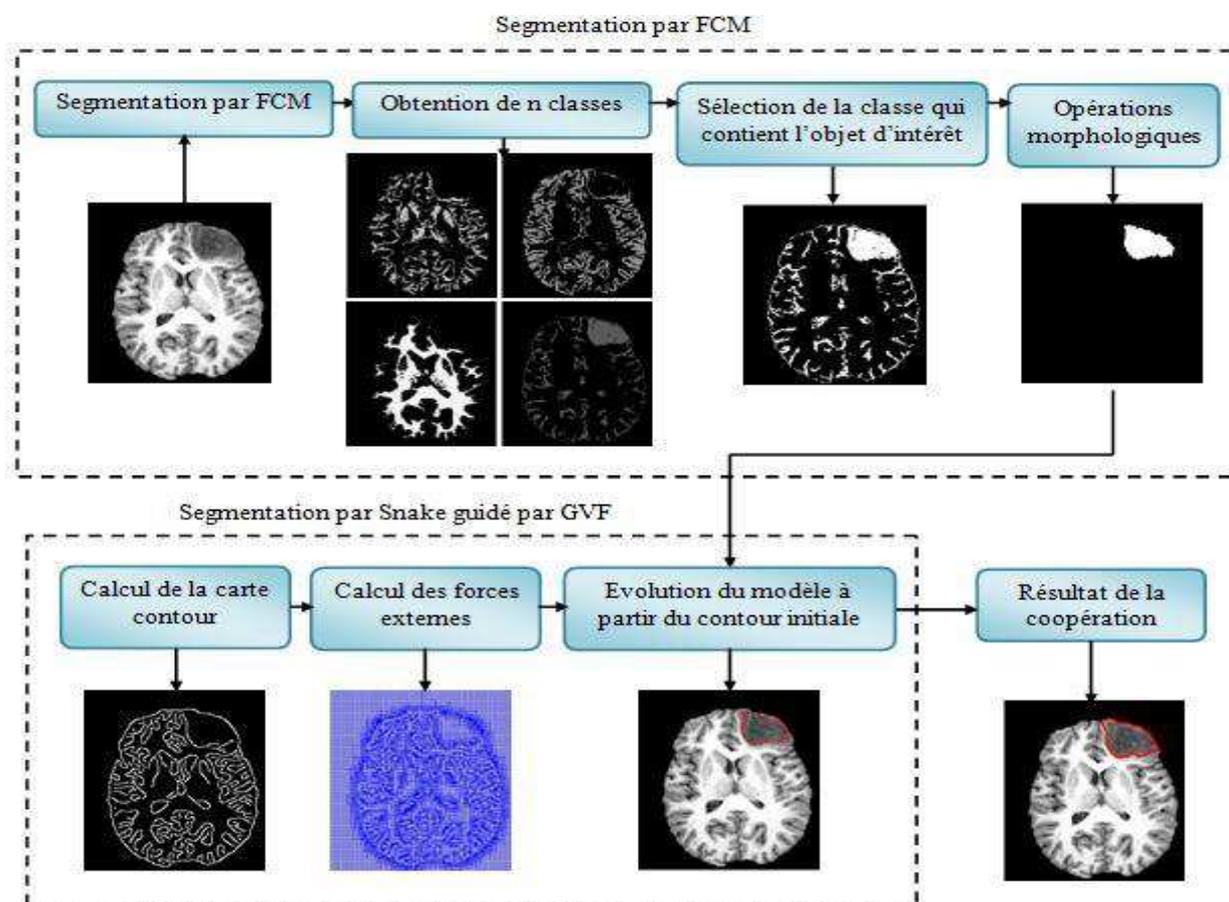


Figure 5.16 : Etapes de la coopération FCM et Snake guidé par GVF

Les opérations morphologiques indiquées dans la Figure 5.17 sont résumées dans la figure ci-dessous :

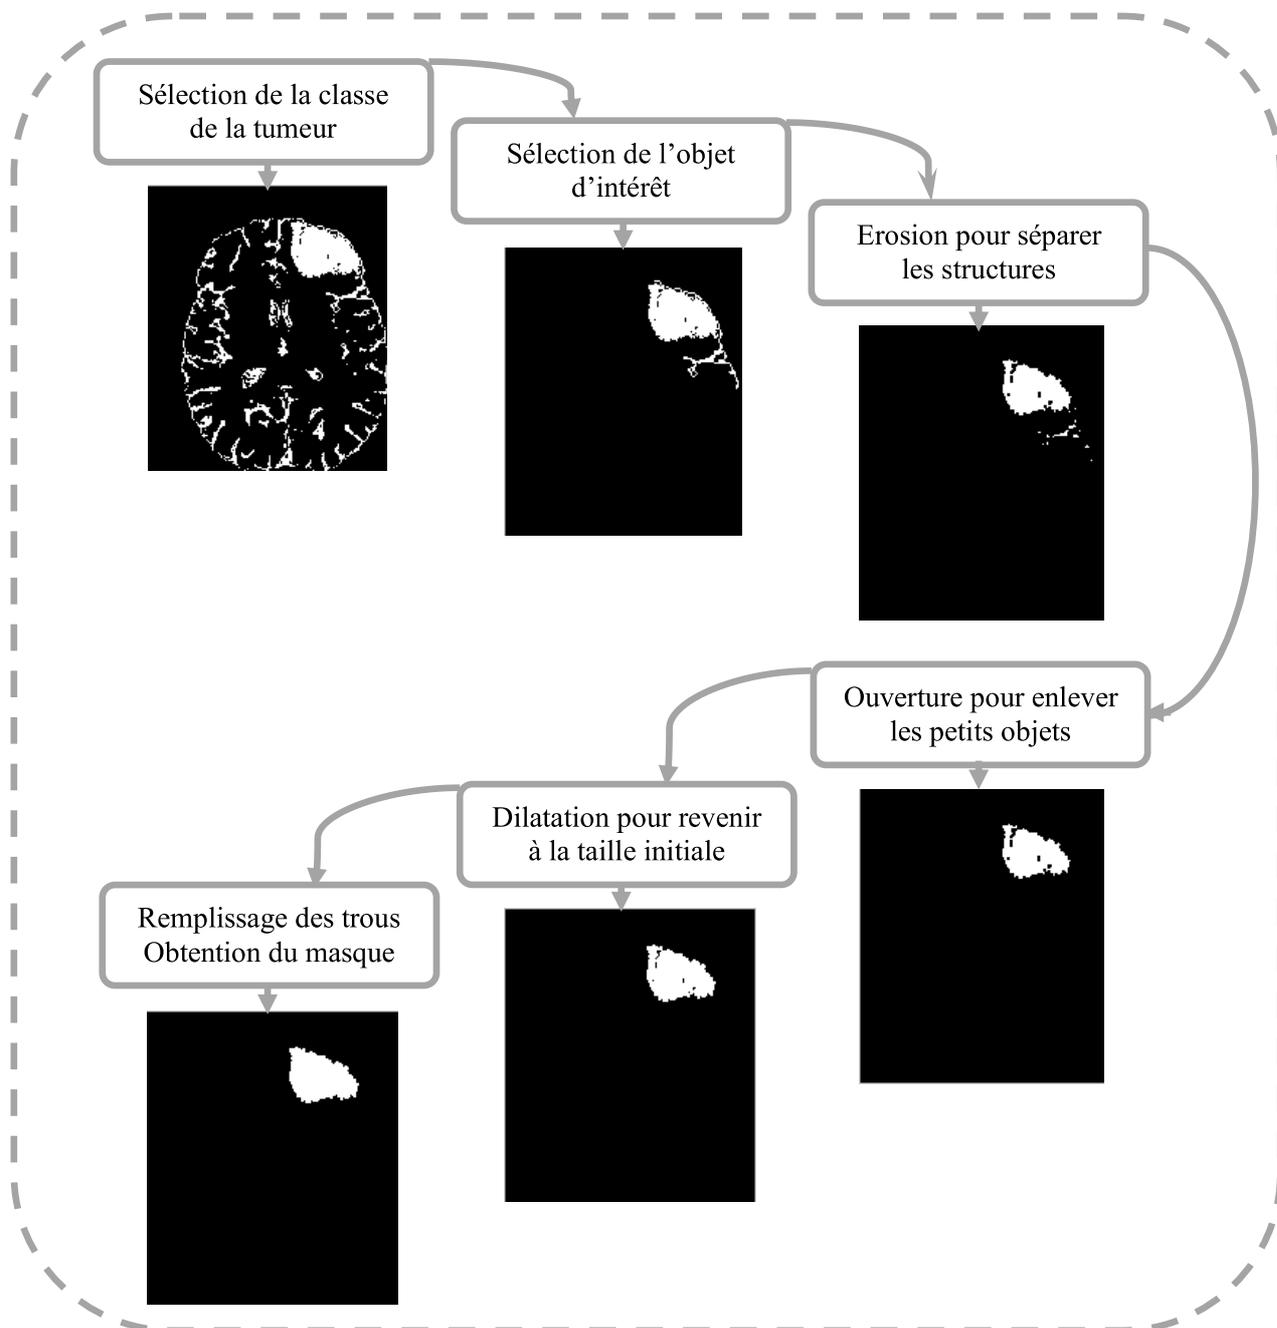


Figure 5.17 : Opérations morphologiques et obtention du masque de la tumeur

Les deux dernières figures montrent toutes les étapes employées pour la coopération automatique du Snake guidée par GVF et de la classification floue, tout en illustrant chaque étape par les résultats obtenus. Dans ce qui suit, nous présentons les résultats de cette coopération.

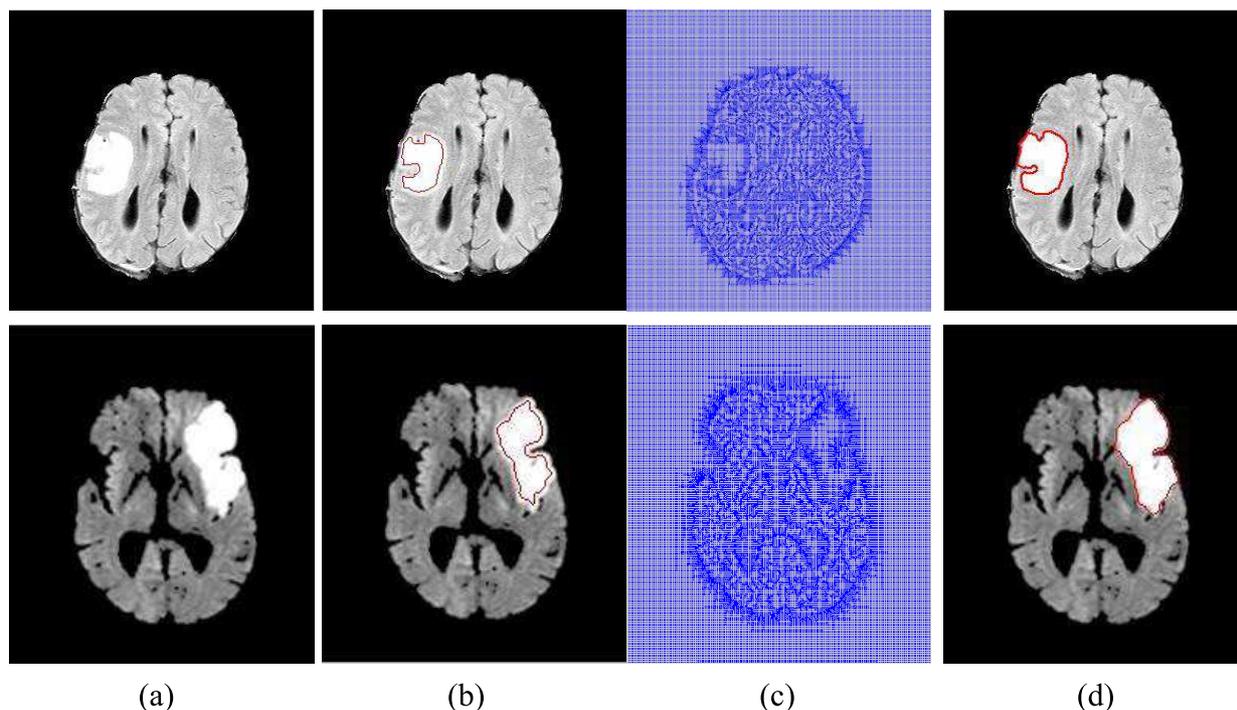


Figure 5.18 : Segmentation par Coopération entre FCM et Snake guidé par GVF
 (a) : Image originale, (b) : Contour initial, (c) : Forces externes, (d) : Résultat final.

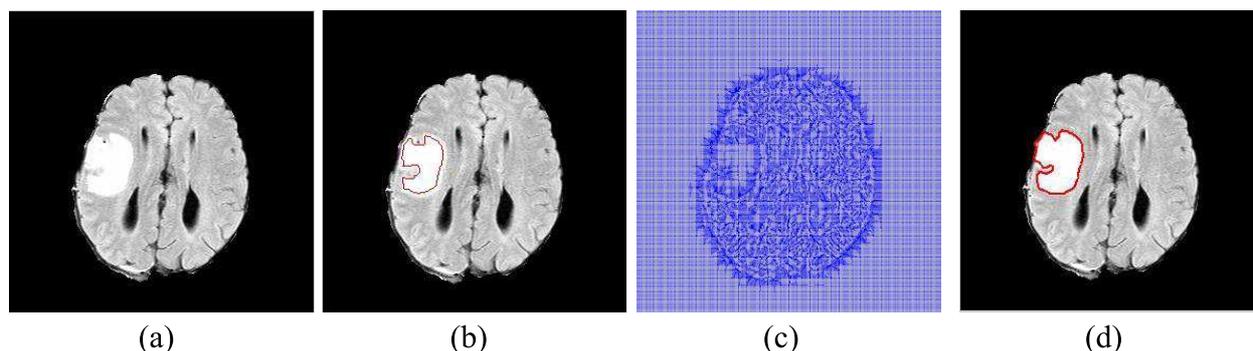


Figure 5.19 : Segmentation par Coopération entre Analyse de symétrie et Snake guidé par GVF

(a) : Image originale, (b) : Contour initial, (c) : Forces externes, (d) : Résultat final.

Interprétation

Le résultat de la coopération s'avère très bon dans la Figure 5.18, «Image 8», et Figure 5.19; de plus, aucune intervention manuelle n'a été effectuée (Figure 5.15(b) : initialisation automatique du contour initial). On en conclut alors que la coopération a abouti à de meilleurs résultats dans l'évolution du Snake, ainsi que dans sa convergence vers les zones concaves.

La segmentation qui utilise l'analyse de symétrie comme segmentation initiale, a donné presque les mêmes résultats que celle par FCM (Figure 5.18 et Figure 5.19).

Pour la 2^{ème} image « **Image 7** » de la Figure 5.18, on remarque que le modèle s'est bien déformé, mais il s'est arrêté un peu plus loin que l'emplacement désiré, à cause des forces non précises du gradient, calculées à partir de l'image totale (Figure 5.18(c)). Dans notre méthode,

ce problème a été résolu, en ajoutant une force externe, issue des relations spatiales, afin de bien guider le modèle vers les bords optimums.

5.3.3.3 Méthode proposée : Coopération entre FCM et Snake guidée par GVF contraint par les relations spatiales

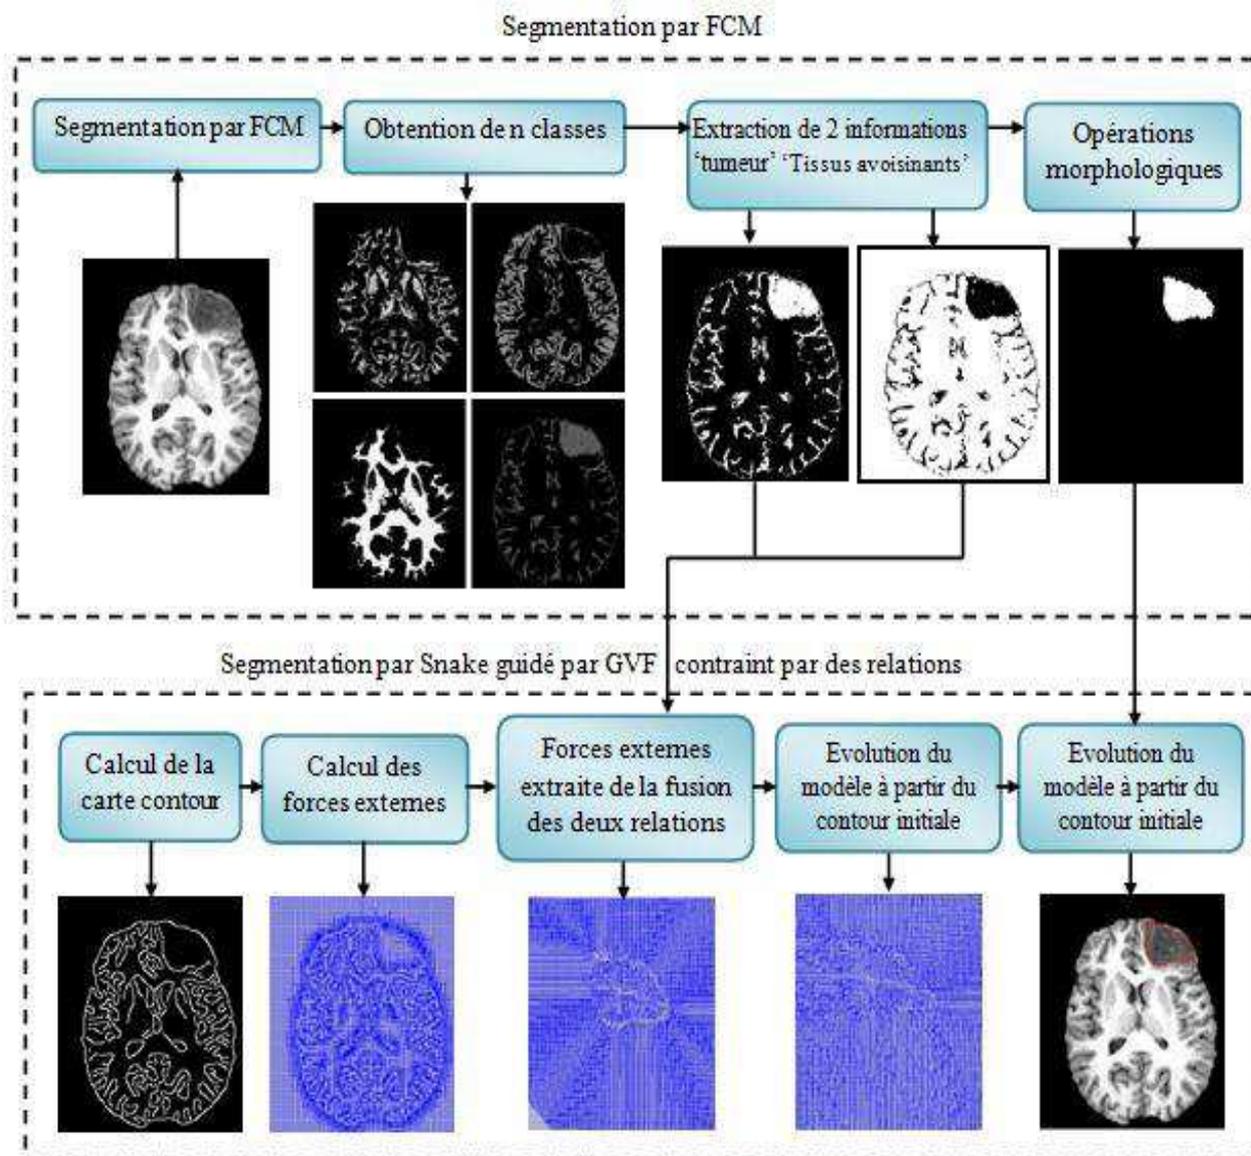
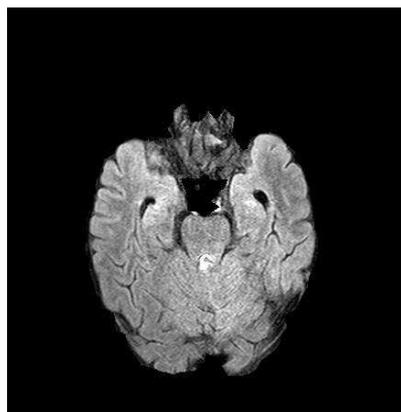
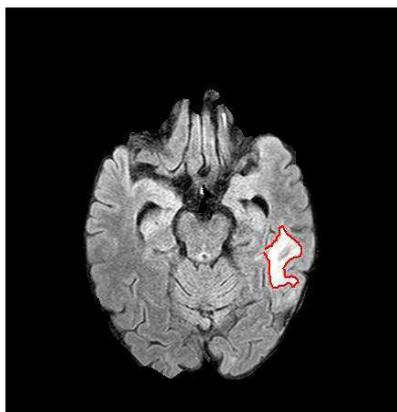


Figure 5.20 : Etapes de la coopération entre FCM et Snake guidé par GVF contraint par des RS

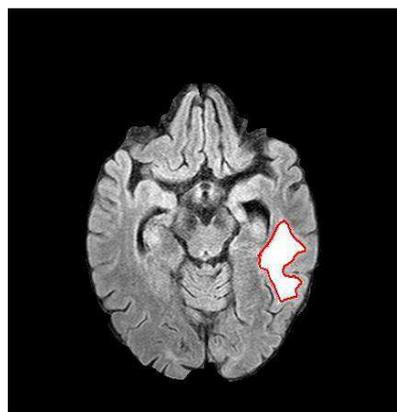
Par rapport à la 1^{ère} coopération de la Figure 5.16, on a ajouté une information a priori, concernant les tissus avoisinants. En fusionnant cette information avec la détection initiale de la tumeur, on se rapproche exactement des vrais bords de l'image (car on suppose que les contours de la tumeur se situent entre la tumeur détectée et les tissus avoisinants). On calcule ensuite une force externe, à partir de ces informations, et on l'ajoute à la force externe totale (selon l'équation 4.14). Les étapes de cette segmentation sont données dans la Figure 5.21, et nous présentons ci-dessous, les résultats de notre méthode appliquée sur une séquence de 20 images IRM Flair de taille 432*432, coupe axiale.



(a1)



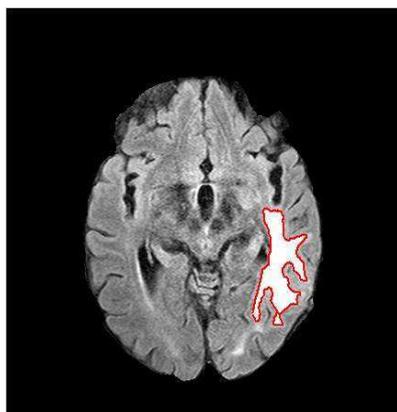
(b1)



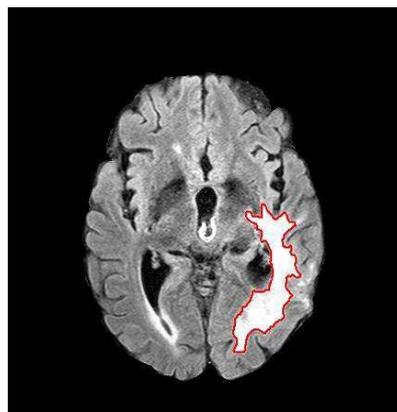
(c1)



(a2)



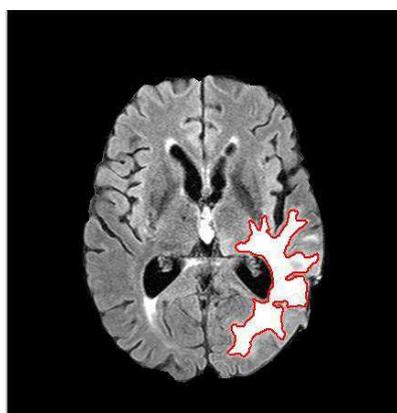
(b2)



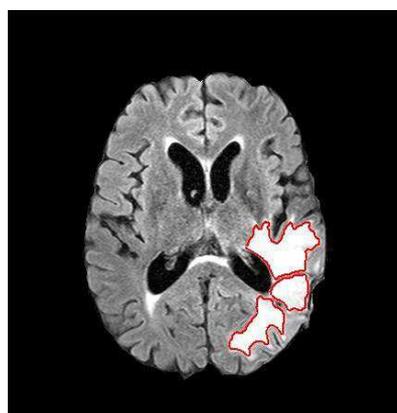
(c2)



(a3)



(b3)



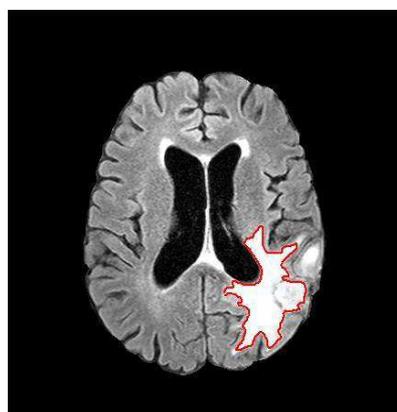
(c3)



(a4)



(b4)



(c4)

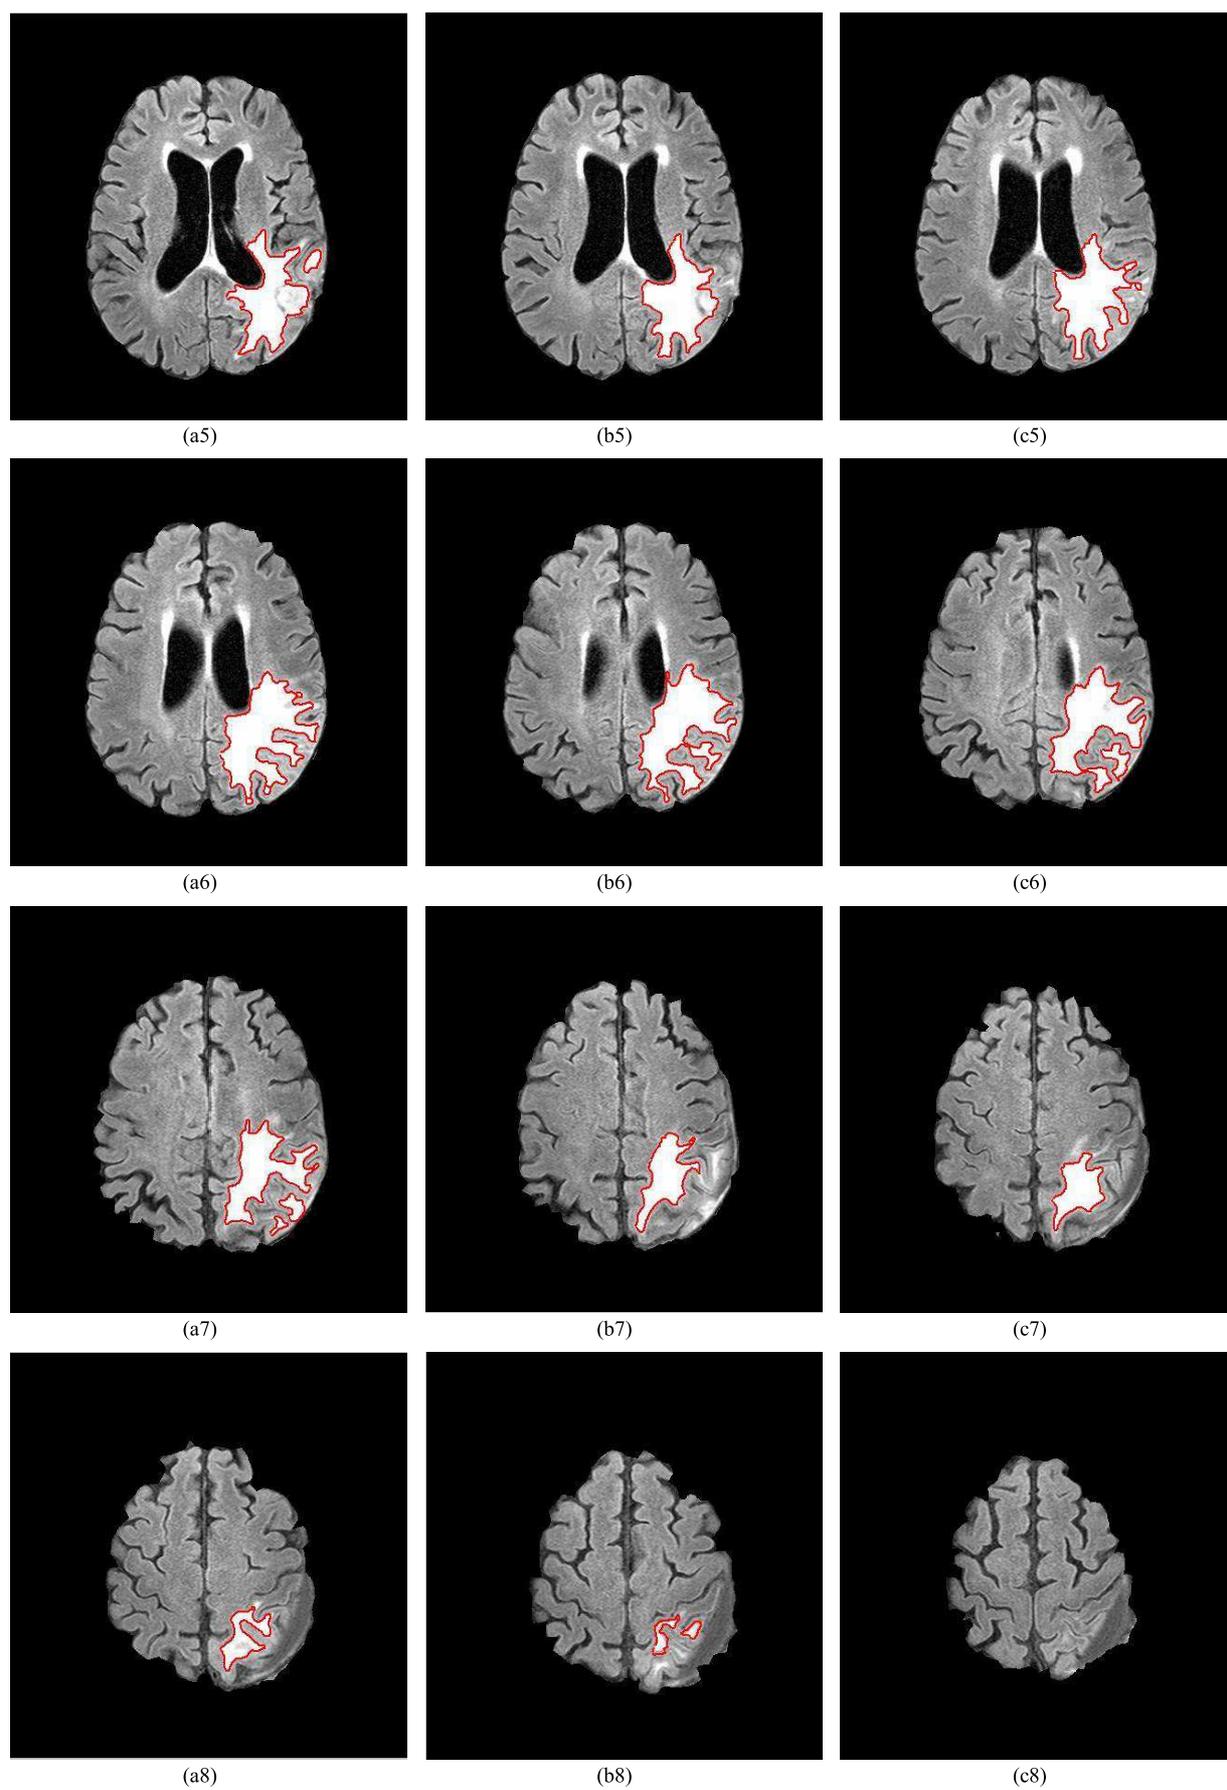


Figure 5.21 : Résultats de la segmentation de la méthode proposée sur une séquence de 24 IRM

Interprétation

Comme le montre la figure 5.21, notre méthode a pu palier les inconvénients rencontrés dans les méthodes précédentes. C'est une méthode automatique, qui ne nécessite aucune intervention manuelle pour l'initialisation ; elle converge correctement vers les vrais contours de la tumeur, même dans les zones de fortes concavités. De plus, elle est généralisable et applicable sur n'importe quelle forme ou type de tumeur (comme l'illustre la Figure 5.21).

Le problème de changement de topologie, rencontré dans la méthode des Snakes, a été surmonté, en faisant segmenter chaque petit objet seul, avec 2 segmentations, puis en combinant les contours résultants, afin de contourner toutes les frontières de la tumeur, même si elle est divisée en sous structures (images (c3), (a4), (a5), (c6), (a7) et (b8) de la Figure 5.21).

Comparaison

Nous faisons ici une comparaison entre le résultat de segmentation par modèle déformable sans et avec intégrations des relations spatiales.

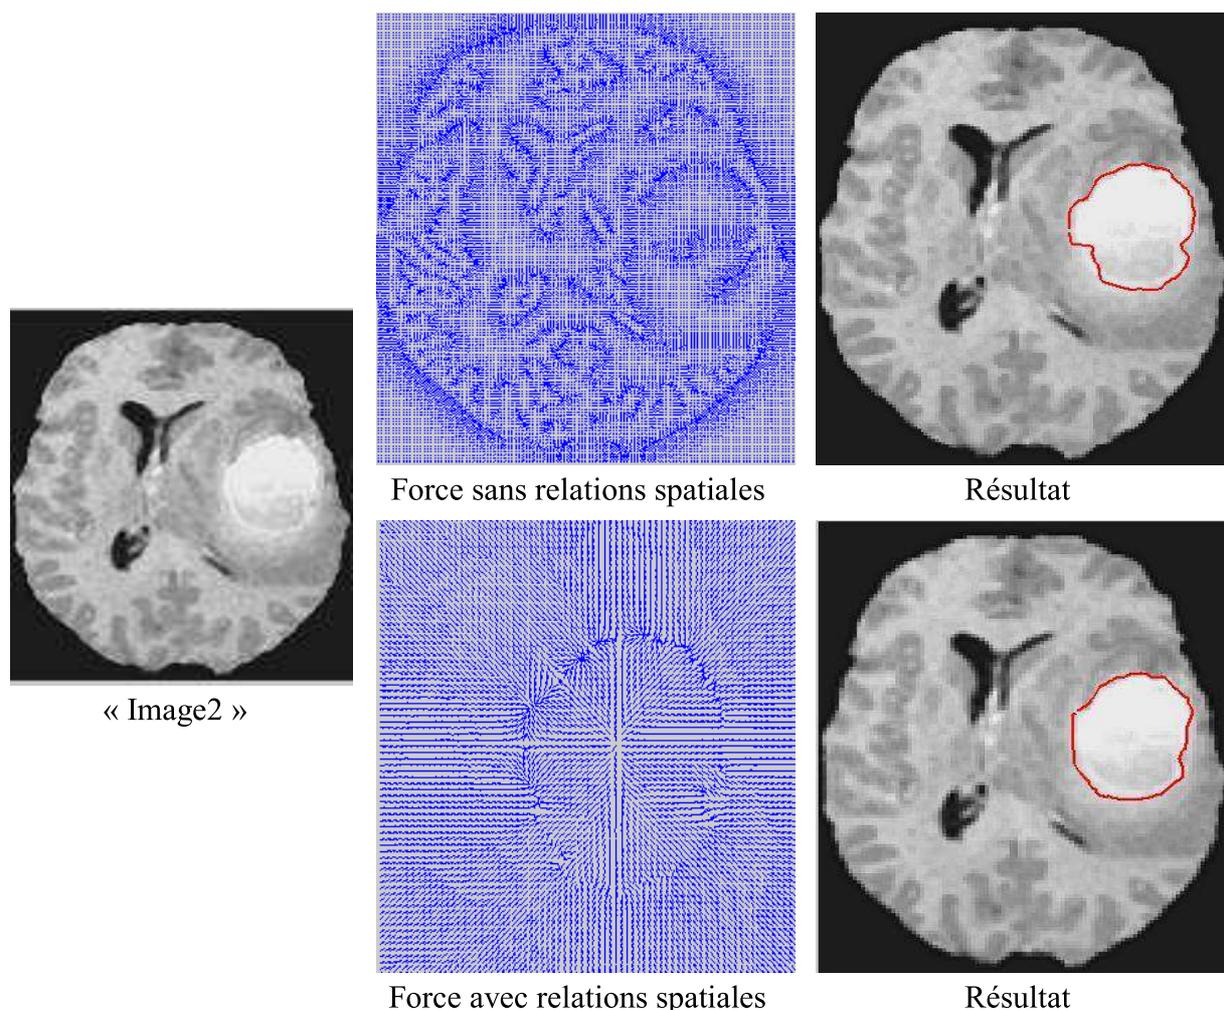


Figure 5.22 : Comparaison de la segmentation entre un modèle intégrant des relations spatiales et un modèle sans relations spatiales (« image2 »)

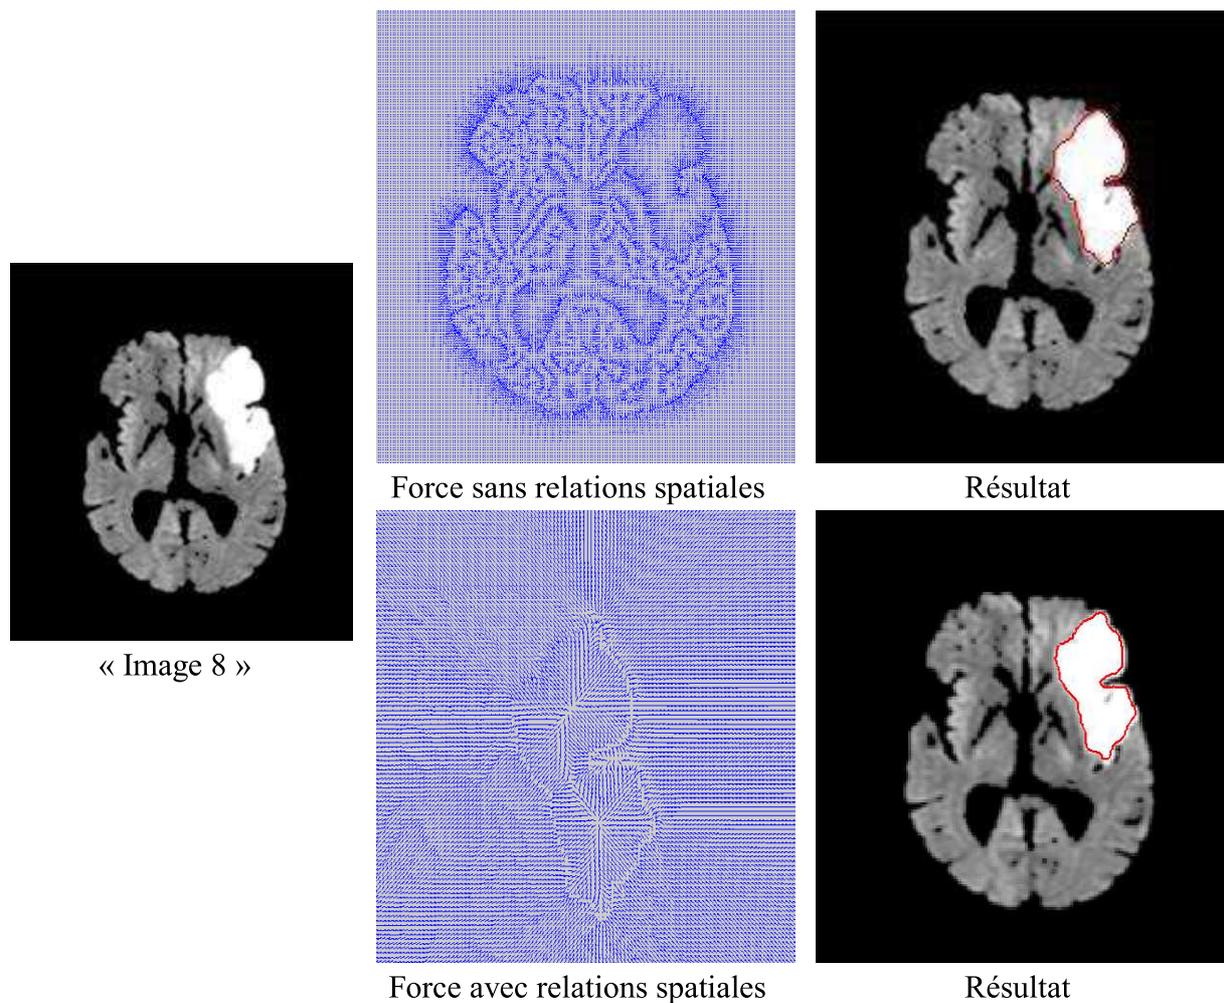


Figure 5.23 : Comparaison de la segmentation entre un modèle intégrant des relations spatiales et un modèle sans relations spatiales (« image 8 »)

Interprétation

On peut observer que le modèle déformable, avec et sans relations spatiales, peut améliorer les résultats de la segmentation initiale. Bien qu'il améliore les paramètres de volume et de surface, il converge quelques fois vers de faux contours, à cause de la mauvaise définition des frontières. Cependant, l'utilisation des relations spatiales permet de réduire le taux de fausse détection, car elle empêche la fuite du contour vers les frontières mal définies. Les figures 5.22 et 5.23 montrent l'amélioration de la qualité de la segmentation des tumeurs, avec notre méthode, comparativement aux autres méthodes, en raison des contours bien définis.

5.3.4 Evaluation des résultats de la méthode

Nous comparons dans la Figure 5.24, le résultat du contour de la tumeur, obtenu par notre méthode, avec celui obtenu par une segmentation manuelle, faite par un expert.

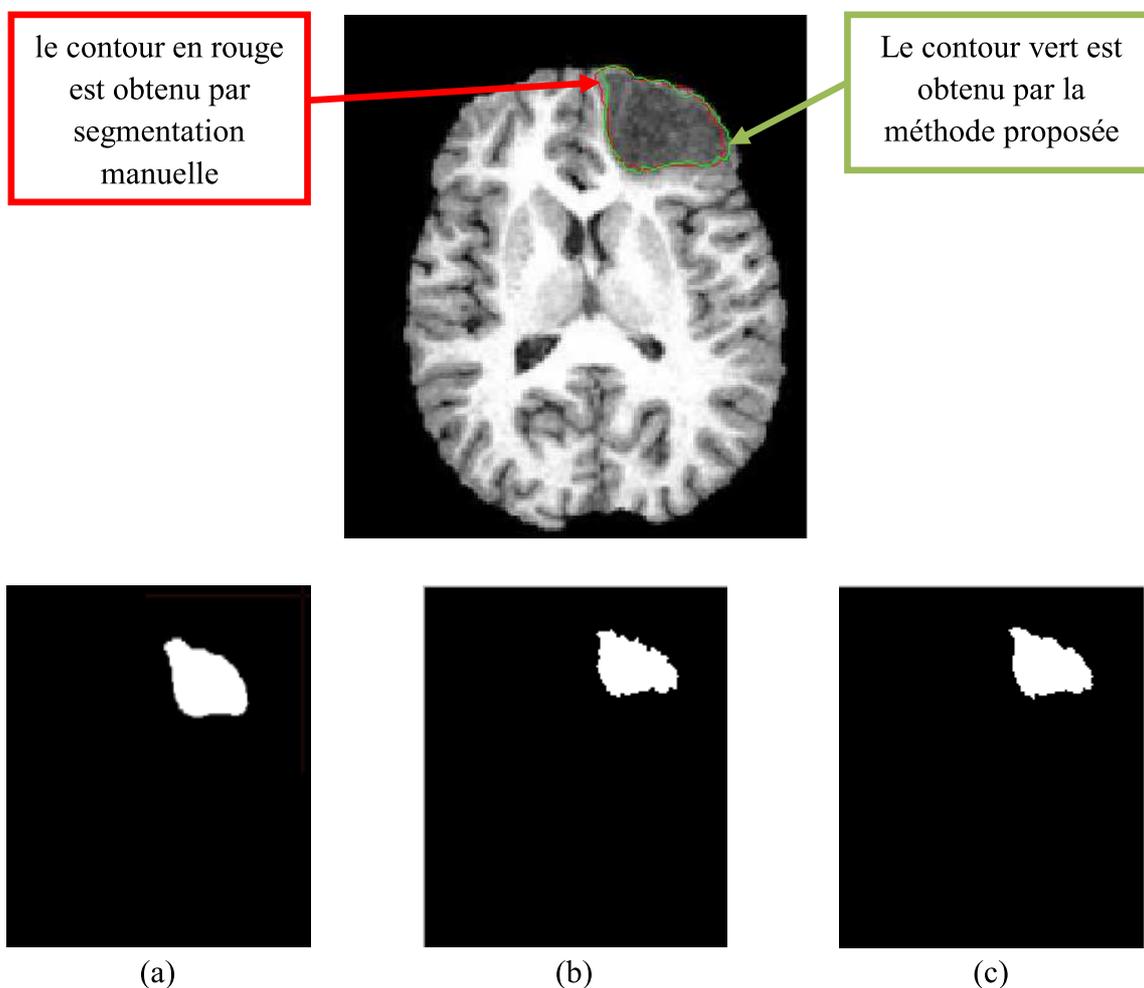


Figure 5.24 Comparaison avec une segmentation manuelle

(a) : Segmentation manuelle, (b) : segmentation avec modèle déformable sans relations spatiales, (c) : Segmentation par modèle déformable contraint par des relations spatiales

Interprétation

Nous remarquons que le contour obtenu avec notre méthode et celui donné par l'expert sont très proches. Cela confirme que notre méthode est fiable et peut être appliquée correctement pour la segmentation de tumeurs cérébrales. La segmentation par les méthodes présentées aux chapitres 3 et 4 (prétraitement, segmentation) se fait presque en temps réel, à part la méthode de détection du plan de symétrie par transformée de Hough, qui dure maximum 40s.

Discussion

L'application des méthodes de segmentation d'images médicales présentant des pathologies demeure encore un domaine de recherche très vaste. Nous avons présenté dans ce mémoire, des méthodes basées sur la coopération de plusieurs méthodes de différentes approches.

Nous avons mis en œuvre une méthode de segmentation hybride qui utilise les informations région et contour à la fois. Nous avons comparé une méthode de classification floue et une méthode d'analyse de symétrie pour la détection des tumeurs ensuite, nous avons utilisé un modèle déformable contraint par des relations spatiales pour raffiner la segmentation.

En comparaison avec d'autres méthodes, notre approche a quelques avantages tels que l'automatisation et la généralité sur plusieurs types de tumeurs. Elle peut aussi segmenter les composantes de la tumeur telles que l'œdème et la nécrose.

Une limite de l'approche peut être observé est que l'analyse de symétrie peut échouer dans le cas d'une tumeur symétrique, toutefois, ce cas est très rare.

Les travaux futurs visent à segmenter les structures internes du cerveau en présence de pathologie, tout en utilisant des relations spatiales floues.

CONCLUSION ET PERSPECTIVES

Le travail de recherche proposé dans ce mémoire rentre dans le cadre de l'analyse d'images, en particulier dans l'étude d'une méthode de segmentation optimisée, appliquée sur des images médicales IRM, dans lesquelles la discrimination entre les tissus cérébraux (matière grise, matière blanche, liquide céphalorachidien), et la tumeur, n'est pas toujours évidente.

Au cours de ce travail, nous avons présenté, et mis en œuvre une technique de segmentation automatique, pour la discrimination entre les tissus cérébraux : matière grise, matière blanche, liquide céphalorachidien, et la tumeur étudiée. Nous nous sommes basés pour cela, sur des images cérébrales, acquises par un appareil d'acquisition très évolué, qui est l'IRM.

En premier lieu, nous avons présenté les principales difficultés rencontrées, lors de la segmentation d'images cérébrales. Nous avons décrit, d'une part, les problèmes liés à l'anatomie relativement la complexité de l'encéphale, puis ceux, liés à l'acquisition du signal RMN. Et d'autre part, nous avons effectué une étude bibliographique de méthodologies existantes, pour résoudre notre problème.

Nous avons présenté ensuite en détail, quelques techniques de traitement d'images, avant de les mettre en œuvre. La dernière partie est le cœur de notre travail ; dans cette partie, on a décrit toutes les étapes de la mise en œuvre de notre approche, ainsi que les résultats obtenus.

Il est apparu très clairement que le prétraitement, tel que le filtrage du bruit et l'isolation du cerveau est un préalable incontournable. Les objectifs de ce mémoire ont donc été formulés comme suit : concevoir en premier lieu une méthode robuste de prétraitement puis, introduire les résultats obtenus dans la phase de segmentation.

La phase de prétraitement est débutée par un filtrage anisotrope du bruit, qu'utilisent beaucoup d'auteurs dans ce genre d'images médicales, pour atténuer le bruit, issu de l'acquisition. Nous avons délimité par la suite la zone d'intérêt du cerveau, en procédant à son isolation de sa boîte crânienne, et d'autres structures inutiles. Puis, nous avons effectué une détection du plan inter-hémisphérique, qui servira d'indicateur de l'hémisphère pathologique, et qui va permettre la détection automatique du type de la tumeur, selon l'apparence radiologique. Ces opérations de prétraitement ont pour but d'améliorer la qualité d'image et de restreindre la zone de travail avant la segmentation.

La méthode de segmentation proposée utilise des approches contours et des approches régions. Les méthodes basées région segmentent des cas difficiles de tumeur, avec un haut niveau d'automatisation, mais elles présentent un inconvénient majeur, qui est l'imprécision des frontières de la tumeur. En outre, nous obtenons souvent des régions non homogènes et

incomplètes, à cause du phénomène de mauvaise classification, du à l'effet de volume partiel. Pour remédier à ces problèmes, des méthodes basées contour ont été proposées, mais celles-ci souffrent aussi du problème d'initialisation, qui doit être bien effectué, pour avoir de bons résultats.

La méthode proposée combine ces deux approches, en utilisant les avantages de l'une pour résoudre les défauts de l'autre. Les méthodes de segmentation région vont résoudre le problème d'initialisation des méthodes contours, et les méthodes contours vont améliorer significativement la qualité de la segmentation régions dans les frontières de l'objet.

Cette coopération séquentielle a deux phases principales : initialisation par une méthode région, et raffinement par une méthode contour.

Pour l'initialisation, on peut utiliser n'importe quelle méthode automatique. Pour notre cas, on a proposé deux méthodes : la première classique, est une classification floue non supervisée, la seconde originale, est basée sur la détection de l'asymétrie dans l'histogramme des hémisphères du cerveau. Elles sont généralisables sur n'importe quelle modalité d'image IRM, et sur une grande classe de tumeurs.

Dans la seconde phase de segmentation, l'application des modèles déformables nous a paru convenable pour compenser les anomalies de la première phase. Pour cela, nous avons utilisé un contour actif, guidé par GVF, initialisé à partir de la surface de détection initiale. L'intégration de relations spatiales entre la tumeur détectée et les tissus environnants nous a permis de guider l'évolution du modèle, et de faire face à certains problèmes du snake-GVF, tels que la fuite dans les contours mal définis. Les résultats de la segmentation coopérative ont montré que l'intégration de relations spatiales présente une bonne efficacité, et qu'elle est applicable sur plusieurs types et formes de tumeurs.

La première partie de notre travail, présenté dans ce document, a fait l'objet d'une présentation dans la troisième école du projet Neuromed, à l'université de Tétouan, Maroc, sous le titre de « Segmentation of brain tumor by cooperation fuzzy possibilistic / deformable model ».

Après la réalisation de notre travail, quelques perspectives peuvent être envisagées :

- ❖ La généralisation de cette méthode sur l'espace 3D, afin d'avoir l'information globale de la pathologie, pour mieux guider le praticien au diagnostic.
- ❖ Les différents types de relations spatiales ont été rarement utilisés pour la segmentation de tumeur ; alors, pour mieux contraindre le modèle, nous proposons d'utiliser d'autres types de relations, telles que les relations de direction.
- ❖ Notre expérience a montré qu'il y a une relation entre les paramètres du snake et la détection initiale de la tumeur ; trouver cette relation pour calculer ces paramètres sera très utile.
- ❖ Pour segmenter deux tumeurs ou plus, il est approprié d'employer un modèle déformable, prenant en compte le changement de topologie, tels que les modèles déformables géométriques.
- ❖ En procédant à la segmentation par Analyse de symétrie, la lecture visuelle de l'histogramme ne donne pas toujours de limites précises des intervalles des classes, pour cela, nous proposons d'automatiser cette tâche, en calculant tous les points significatifs (l'intersection de la courbe de l'histogramme avec l'abscisse des x) qui représentent les intervalles exacte de chaque région dans l'image, inclus les régions pathologiques.
- ❖ Pour comparer les différentes méthodes, une évaluation quantitative ou qualitative est conseillée. Ça permet par exemple de cibler une modalité d'images, qui donne des résultats intéressants.

ANNEXE A : TYPE DE TUMEURS CEREBRALES

A.1 Les types de tumeurs fréquentes chez l'adulte [S1], [S2], [S3]

Les types de tumeurs cérébrales fréquentes chez l'adulte sont résumés dans le tableau (Tableau A.1) ci-dessous :

Tumeurs neuroépithéliales	Tumeurs astrocytaires	
	Tumeurs oligodendrogiales	Oligodendrogliome Oligodendrogliome anaplasique
	Tumeurs mixtes oligoastrocytaires	Oligoastrocytome Oligoastrocytome anaplasique
	Tumeurs ependymaires	Ependymome Ependymome anaplasique
	Tumeurs de plexus choroïde	Papillome du plexus choroïde Carcinome du plexus choroïde
	Tumeurs gliales d'origine incertaine	Gliomatose cérébrale
	Tumeurs neuronales et mixtes (neuro-gliales) (rares, retrouvés plus fréquemment chez le jeune adulte)	Gangliocytome Gangliogliome Neurocytome Gangliogliomes anaplasiques Tumeurs neuroépithéliales dysembryoplastiques (DNET)
	Tumeurs neuroblastiques (rares)	Esthésioneuroblastome Neuroépithéliome Olfactif
	Tumeurs pinéales (petite région cérébrale qui est composée de cellules spécifiques)	Pinéalocytome Pinéaloblastome
	Tumeurs embryonnaires	Médulloépithélome Ependymoblastome Médulloblastome Tumeur supratentorielle neuroectodemale primitive (PNET) Tumeur atypique térato-rhabdoïde

Les tumeurs des nerfs périphériques	Schwanome ou neurinome	
	Neurofibrome	
	Perineurinome	
	Tumeurs malignes des nerfs périphériques	
Les tumeurs des méninges	Tumeurs méningothéliales	Méningiome bénin (plusieurs types histologiques) Méningiomes malins (plusieurs types histologiques et degrés de malignité)
	Tumeurs mésenchymateuses non méningothéliales (rares)	Lipome Liposarcome Angiolipome Fibrome Fibrosarcome Chondrome Histiocytome fibreux malin Leiomyome Leiomyosarcome Rhabdomyosarcome Chondrosarcome Hémangiome Ostéome Ostéosarcome
	Tumeurs primaires mélanocytiques	Mélanocytose diffuse Mélanocytome Mélanome malin
	Tumeurs d'origine incertaine	Hémangioblastome
Les tumeurs germinales		Germinome Carcinome embryonnaire Tumeur du sac vitellin Choriocarcinome Tératome mature et immature Tumeurs germinales mixtes
Les tumeurs de la région sellaire	Adénome hypophysaire	Bénin Carcinome
	Craniopharyngiome	

Les tumeurs d'origine hématoïétique		Lymphome Plasmocytome
Les métastases		

Tableau A.1 : Différents types de tumeurs du cerveau.

A.1.1 Les tumeurs neuroépithéliales

Elles représentent les tumeurs cérébrales primaires les plus fréquentes et elles prennent pour origine, soit les neurones, soit les cellules entourant les neurones (les cellules gliales). Dans ce cas, elles font parties de la famille des gliomes. Certaines tumeurs sont aussi mixtes, c'est-à-dire qu'elles sont composées d'un mélange de neurones et de cellules gliales. Dans cette catégorie, on trouve des tumeurs plus rares, qui proviennent d'autres types cellulaires, précisés plus bas. [S1], [S2], [S3]

➤ Tumeurs astrocytaires (un autre type de cellules gliales)

Elles se développent à partir de cellules gliales, de forme étoilée (astrocytes). Ces tumeurs pouvant dégénérer (transformation bénigne à maligne), un suivi régulier est indispensable. Elles peuvent se développer dans toutes les régions du cerveau ou de la moelle épinière. (Figure A.1)

- Chez les adultes, on les rencontre le plus souvent dans les lobes cérébraux;
- Chez les enfants, elles se développent dans le tronc cérébral, les lobes cérébraux et le cervelet.

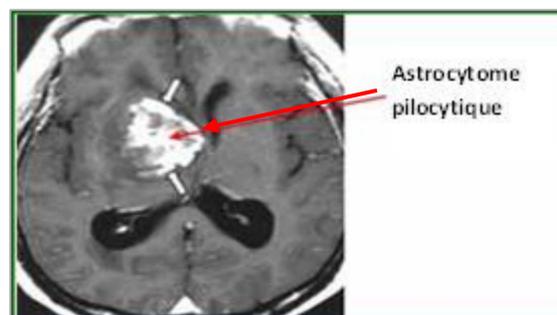


Figure A.1 : Tumeur astrocytaire

On distingue principalement les tumeurs astrocytaires suivantes:

Astrocytomes diffus	Elles touchent surtout les jeunes adultes et ont une forte propension à la transformation maligne. On trouve parmi les tumeurs d'astrocytome diffus les : * Astrocytomes fibrillaires * Astrocytomes protoplasmiques * Astrocytomes gemistocytiques
Astrocytomes anaplasiques	Elles touchent surtout les personnes à partir de 50 ans, et ont une forte propension à la transformation maligne en glioblastomes.
Glioblastomes	Ces tumeurs malignes sont les plus fréquentes chez l'adulte, principalement entre 45 et 70 ans.
Astrocytomes pilocytiques	Elles touchent surtout les enfants et les adolescents. Une transformation maligne est extrêmement rare
Xanthoastrocytomes pléomorphe	

Tableau A.2 : Types de tumeurs astrocytaires

➤ Tumeurs oligodendrogiales

Il existe deux types de tumeurs oligodendrogiales : oligodendrogiales anaplasiques et oligodendrogliomes. Ces derniers sont de grade II et III, elles sont ainsi nommées car elles se développent à partir des oligodendrocytes (Figure A.2), les cellules gliales à l'origine de la formation de la myéline qui isole les fibres des nerfs.

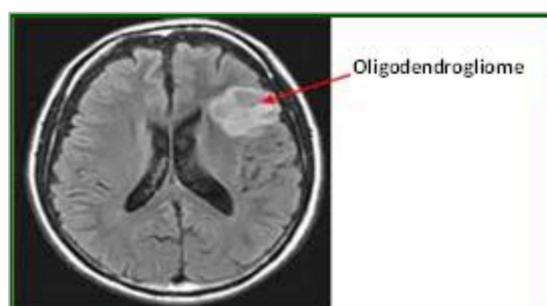


Figure A.2 : Oligodendrogliomes

➤ Tumeurs mixtes oligo-astrocytaires

Dans cette catégorie il existe deux types : les oligoastrocytome, et les oligoastrocytome anaplasique.

➤ Tumeurs épendymaires

Pour cette catégorie aussi il existe deux types, les épendymome anaplasique et les épendymomes. Les épendymomes se développent dans les cavités cervicales, à partir des

cellules gliales qui tapissent les ventricules cérébraux (Figure A.3). Leur malignité est variable. La croissance de la tumeur peut provoquer une obstruction de la circulation du LCR, génératrice d'hydrocéphalie, et peut nécessiter une dérivation. Ces tumeurs touchent surtout les enfants et les adolescents. [S1], [S2], [S3]

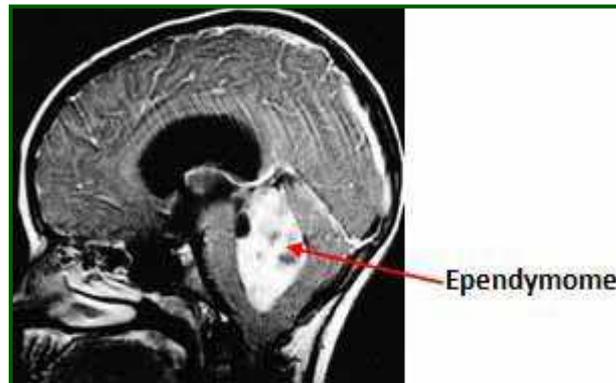


Figure A.3 : Ependymome

➤ Tumeurs de plexus choroïde

Il s'agit d'une tumeur bénigne, pouvant cependant présenter une forme maligne : le carcinome des plexus choroïdes (exceptionnelle). Elle représente 0,6 % des tumeurs cérébrales et 4 % chez l'enfant. On trouve deux types de ce type de tumeur les papillomes de plexus choroïde et les carcinomes du plexus choroïde.

➤ Tumeurs gliales d'origine incertaine : Gliomatose cérébrale.

➤ Tumeurs neuronales et mixtes (neuro-gliales)

Les tumeurs neuronales et mixtes sont rares, et retrouvées plus fréquemment chez le jeune adulte, parmi les types de cette tumeur on cite :

- Gangliocytome ;
- Gangliogliome ;
- Neurocytome ;
- Gangliogliomes anaplasiques ;
- Tumeurs neuroépithéliales dysembryoplastiques (DNET).

➤ Tumeurs neuroblastiques (rares)

C'est des tumeurs rares, elles sont divisées en deux types : les esthésioneuroblastome et les neuropithéliome.

➤ Tumeurs pinéales

C'est des petites régions cérébrales qui sont composées de cellules spécifiques, on trouve deux types dans cette catégorie : les pinéaloctome et les pinéaloblastome.

➤ Tumeurs embryonnaires

Les tumeurs embryonnaires sont plus fréquentes chez les enfants et jeunes adultes, et qui prennent pour origine des cellules peu différenciées, que l'on retrouve au stade embryonnaire, les différents types de cette tumeur sont :

- Médulloépithélome ;
- Ependymoblastome ;
- Tumeur supratentorielle neuroectodermale primitive (PNET) ;
- Tumeur atypique térato-rhabdoïde ;
- Médulloblastome. (Figure A.4)

Les ependymoblastome sont des tumeurs malignes (de grade IV), localisées au niveau du cervelet, touchent surtout les enfants (80% des personnes touchées ont moins de 15 ans).

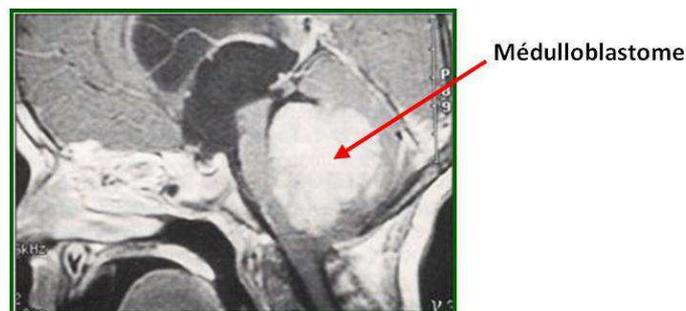


Figure A.4 : IRM T2+gado : médulloblastome

A.1.2 Les tumeurs des nerfs périphériques

Elles proviennent des gaines des nerfs périphériques, qui sont composées de cellules différentes que celles que l'on trouve dans le cerveau. On ne trouve pas donc ces tumeurs dans le cerveau mais au niveau des nerfs crâniens et des nerfs périphériques de tout le corps. Les différents types de tumeurs des nerfs périphériques sont :

- Schwanomes ou neurinomes
- Neurofibromes ;
- Perineurinomes ;
- Tumeurs malignes des nerfs périphériques.

Les tumeurs neurofibromes sont des tumeurs que l'on peut retrouver dans le cadre d'une maladie génétique appelée la neurofibromatose.

Les tumeurs schwanome ou neurinome sont des tumeurs que l'on peut retrouver dans le cadre d'une maladie génétique appelée la neurofibromatose (Figure A.5). Ces tumeurs bénignes,

de grade I dans la plupart des cas, se développent aux dépens des gaines des nerfs périphériques, qui sont composées de cellules différentes de celles du cerveau (cellules de Schwann). On ne trouve donc pas ces tumeurs dans le cerveau, mais au niveau des nerfs crâniens et des nerfs périphériques de tout le corps. Le nerf le plus fréquemment touché est le nerf auditif (neurinome de l'acoustique); sa compression peut engendrer des problèmes d'audition et d'équilibre. [S1], [S2], [S3]

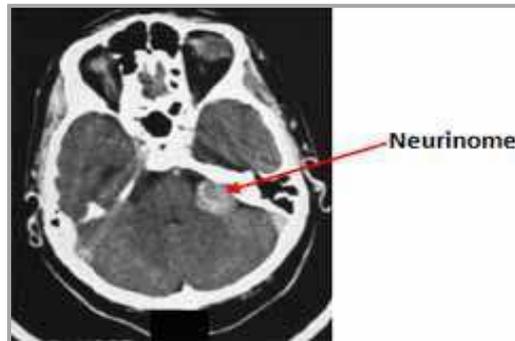


Figure A.5 : Neurinome

A.1.3 Les tumeurs des méninges

Le cerveau est recouvert d'une fine toile protectrice qui se nomme méninge et à partir de laquelle peuvent se former des tumeurs. Il existe quatre types de tumeur

➤ Tumeurs méningothéliales

Les méningiomes se développent aux dépens des méninges, dans la boîte crânienne ou le long de la colonne vertébrale. La plupart des méningiomes sont bénins, mais, dans certains cas isolés, on peut observer une évolution défavorable (bénin à malin).

- Méningiomes malins (plusieurs types histologiques et degrés de malignité) ;
- Méningiomes bénins (plusieurs types histologiques), Figure A.6



Figure A.6: Méningiome

- Tumeurs mésenchymateuses non méningothéliales(rares)
 - Lipome
 - Liposarcome
 - Angiolipome
 - Fibrome
 - Fibrosarcome
 - Chondrome
 - Histiocytome fibreux malin
 - Leiomyome
 - Leiomyosarcome
 - Rhabdomyosarcome
 - Chondrosarcome
 - Hémangiome
 - Ostéome
 - Ostéosarcome

- Tumeurs primaires mélanocytiques
 - Mélanocytose diffuse
 - Mélanocytome
 - Mélanome malin

- Tumeurs d'origine incertaines : Hémangioblastome

A.1.4 Les tumeurs germinales

Il s'agit de tumeurs rares survenant plutôt chez les enfants et les jeunes adultes, dont l'origine cellulaire est germinale, c'est à dire que ce sont les mêmes cellules que l'on retrouve dans les gonades (organes sexuels).

- Germinome
- Carcinome embryonnaire
- Tumeur du sac vitellin
- Choriocarcinome
- Tératome mature et immature
- Tumeurs germinales mixtes

A.1.5 Les tumeurs de la région sellaire

Il s'agit d'une petite région cérébrale bien spécifique, puisqu'elle se situe à la base du crâne et y loge un important centre hormonal, appelé l'hypophyse. Cette région peut être à l'origine de tumeurs spécifiques. Il existe deux types de tumeurs de la région sellaire :

- Adénome hypophysaire (Figure A.7)
- Craniopharyngiome

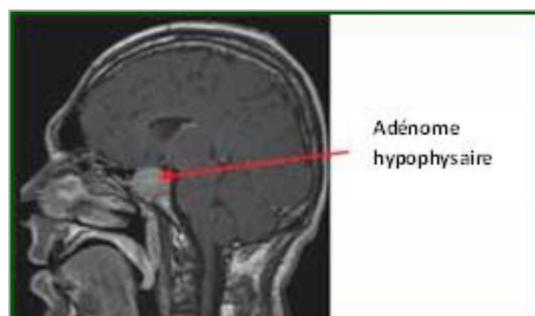


Figure A.7 : Adénome hypophysaire

A.1.6 Les tumeurs d'origine hématopoïétique

Ces tumeurs proviennent des cellules sanguines. Elles surviennent soit isolément dans le cerveau, soit dans un contexte de maladie du sang plus généralisée. Parmi les tumeurs d'origine hématopoïétique on trouve les plasmocytome et les lymphomes.

Un lymphome est une tumeur affectant le système lymphatique. Les lymphomes primitifs du SNC sont des tumeurs malignes relativement rares. L'affaiblissement du système immunitaire (par ex: prise de médicament après une greffe d'organe, SIDA) semble favoriser leur développement. Les lymphomes secondaires du SNC se manifestent généralement sous la forme d'un envahissement des enveloppes du cerveau chez des patients préalablement atteints d'un lymphome, ailleurs dans l'organisme. [S1], [S2], [S3]

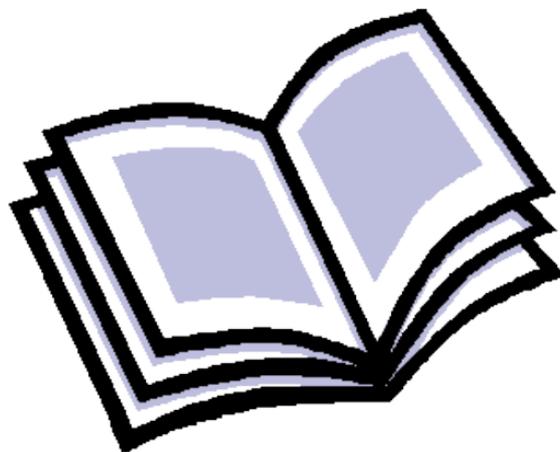
A.1.7 Les métastase

Ce sont les tumeurs cérébrales les plus fréquentes. Elles sont malignes, et secondaires à une tumeur d'une autre région du corps (poumon, sein, rein, peau). Des cellules tumorales migrent vers le cerveau, empruntant la voie sanguine, le plus souvent. Les métastases les plus fréquentes sont celles du cancer du poumon et du sein. [S1], [S2], [S3]



Figure A.8 : IRM T1 + gado : métastases cérébrales d'origine pulmonaire

Manuel Utilisateur Logiciel



15/06/2014

Segmentation de Tumeurs cérébrales

Ce logiciel permet de lire des images IRM cérébrales afin de les analyser. Il permet de prétraiter ces images en trois méthodes : Filtrage avec la diffusion anisotrope, isolation du cerveau et détection du plan de symétrie du cerveau segmenté. Puis, il fait appelle à une autre interface qui s'occupera de la segmentation des ces images, les méthodes utilisées pour ce but sont une variété entre segmentation par approche région, segmentation par approche contour et coopération entre ces deux approches.

Manuel utilisateur logiciel

SEGMENTATION DE TUMEURS CÉRÉBRALES

Ce logiciel permet de lire une image issue de l'IRM, de prétraiter l'image et de faire la segmentation des tumeurs cérébrales. Il a été conçu pour finaliser le travail de magister proposée en 2011 au laboratoire de recherche en imagerie médicale (LARIM) département d'Electronique, Université Saad Dahlab de Blida. Sous la supervision de **M^r et M^{me} cherfa**, et la réalisation par **M^{elle} Bensalem samia**.

B.1 Présentation du Logiciel

B.1.1 Présentation globale du logiciel

Notre logiciel est développé en deux interfaces principales, la première nommée «Prétraitements» figure B.1, et la seconde nommée «Segmentation» figure B.2.

Dans l'interface «Prétraitements», nous avons implémenté les méthodes de prétraitement suivantes :

- Filtrage Anisotrope
- Isolation du cerveau
- Détection du plan de symétrie

Dans l'interface «Segmentation», nous avons réalisé toutes les méthodes de segmentation: celles utilisées en segmentation initiale, et celles utilisées en raffinement de la segmentation

- Pour la segmentation Initiale on cite :
 - ✓ FCM
 - ✓ Analyse de symétrie
- Pour le raffinement de la segmentation on trouve :
 - ✓ Snake
 - ✓ Snake guidé par GVF
 - ✓ FCM/Analyse de symétrie avec Snake
 - ✓ FCM/Analyse de symétrie avec Snake guidé par GVF
 - ✓ FCM avec Snake guidé par GVF contraint par des relations spatiales
 - ✓ Analyse de symétrie avec Snake guidé par GVF contraint par des relations spatiales

L'interface principale «Prétraitement» et l'interface secondaire «Segmentation» sont présentées ci-dessous :

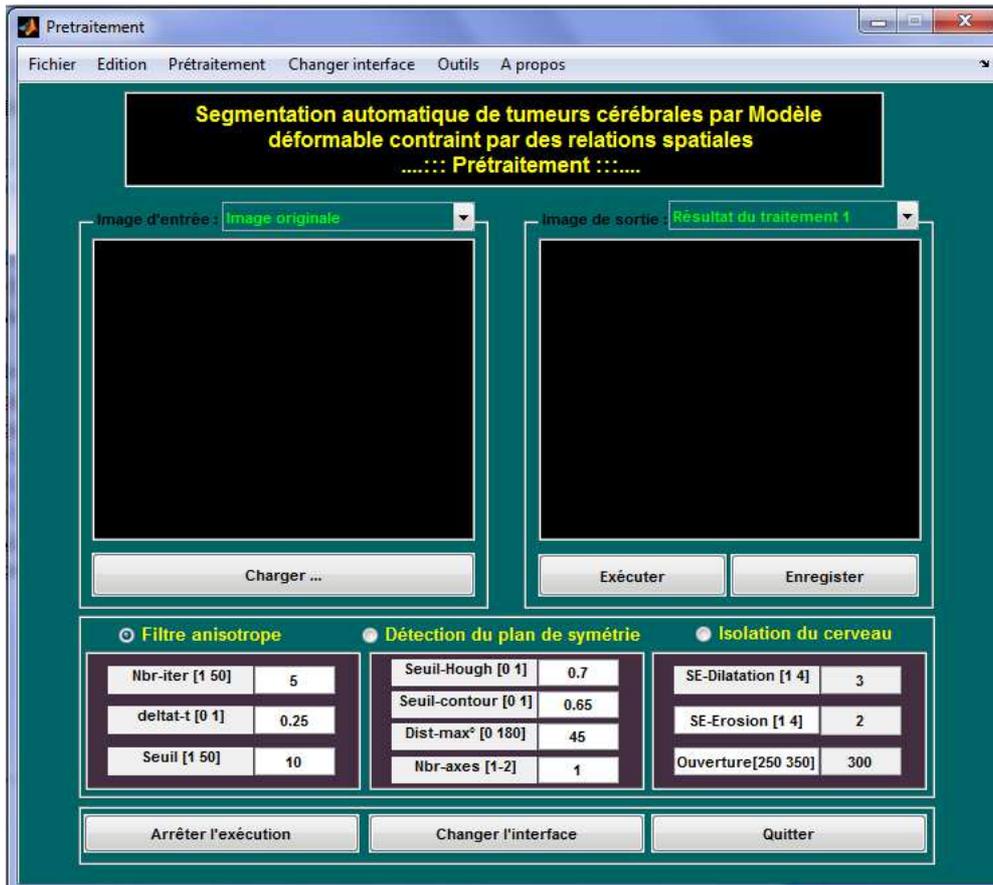


Figure B.1 : Interface Principale



Figure B.2 : Interface secondaire

Notre interface utilisateur s'adapte à tous les systèmes d'exploitation les plus courants, elle permet aussi de respecter les envies de l'utilisateur lorsqu'elle dispose de Boutons qui permettent l'exécution directe des programmes, des raccourcis et d'un menu principal avec des sous menus qui renferment toutes les fonctionnalités d'application. Nous présentons chaque structure en détail par la suite.

B.1.2 Structures du logiciel

Notre interface contient essentiellement des boutons qui servent à effectuer des fonctions prédéfinies, une barre de menu, des raccourcis et une palette de paramètres d'entrée. Une description générale des différents boutons, paramètres et fonctions implémentées sera présentée. (Voir Figure B.3 et B.4)



Figure B.3 : Description globale des modules de l'interface « Prétraitement »

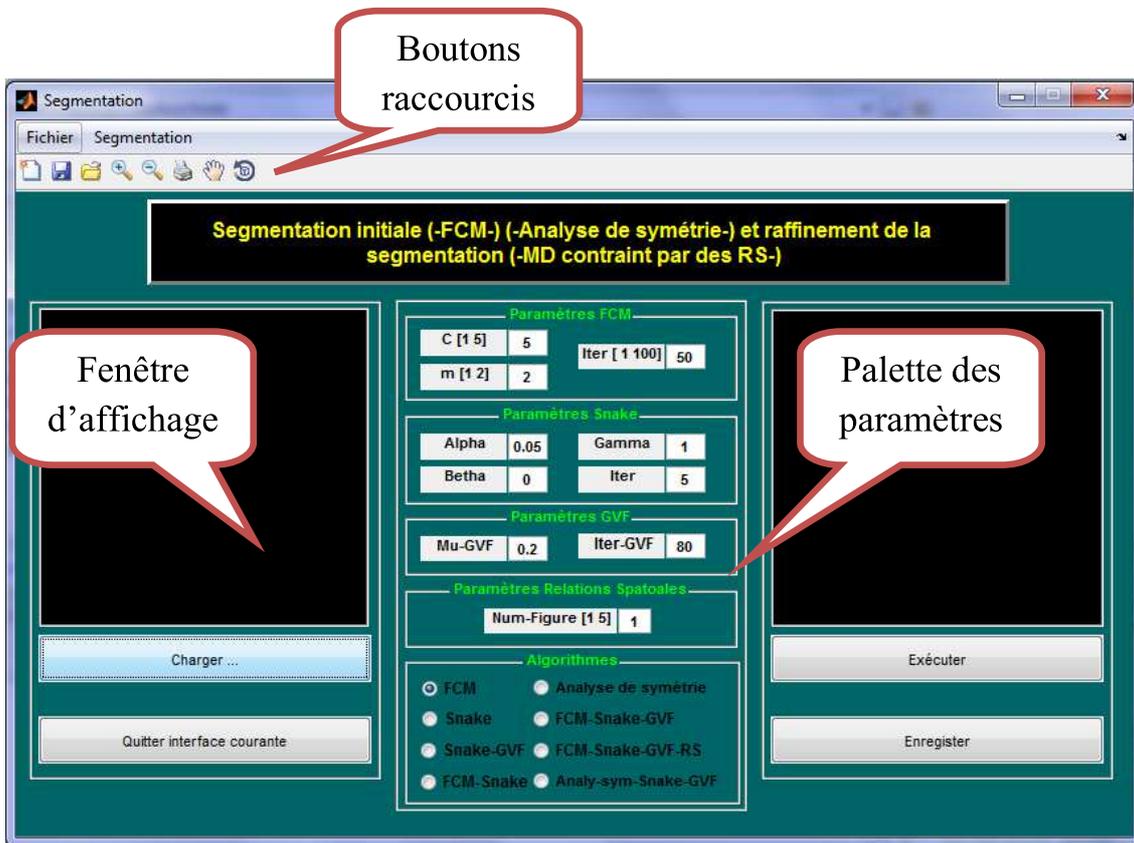
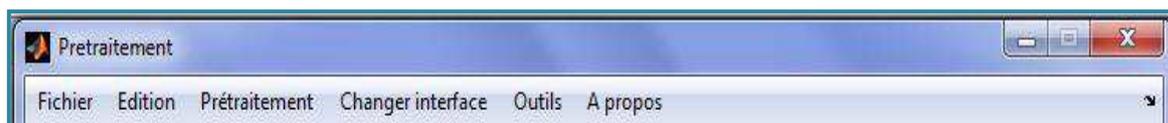


Figure B.4 : Description globale des modules de l'interface « Segmentation »

B.1.2 La barre menu

C'est une barre contenant des articles que l'on peut sélectionner à partir de la souris. L'activation d'un article fait appel, soit à une fonction, soit à une boîte de dialogue.

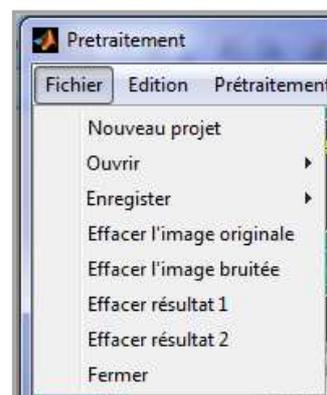
- a) Dans la barre Menu de l'interface principale, on trouve six sous menu : Fichier, Edition, Prétraitement, Changer interface, outils et A propos ;



➤ Fichier

Le sous menu Fichier de l'interface principale contient les commandes suivantes :

1. Nouveau projet
2. Ouvrir
3. Enregistrer
4. Effacer l'image originale
5. Effacer l'image bruitée
6. Effacer résultat 1
7. Effacer résultat 2
8. Fermer



Le rôle principal est d'ouvrir un nouveau projet, et de charger l'image sur laquelle on applique nos traitements, comme le montre la figure suivante :

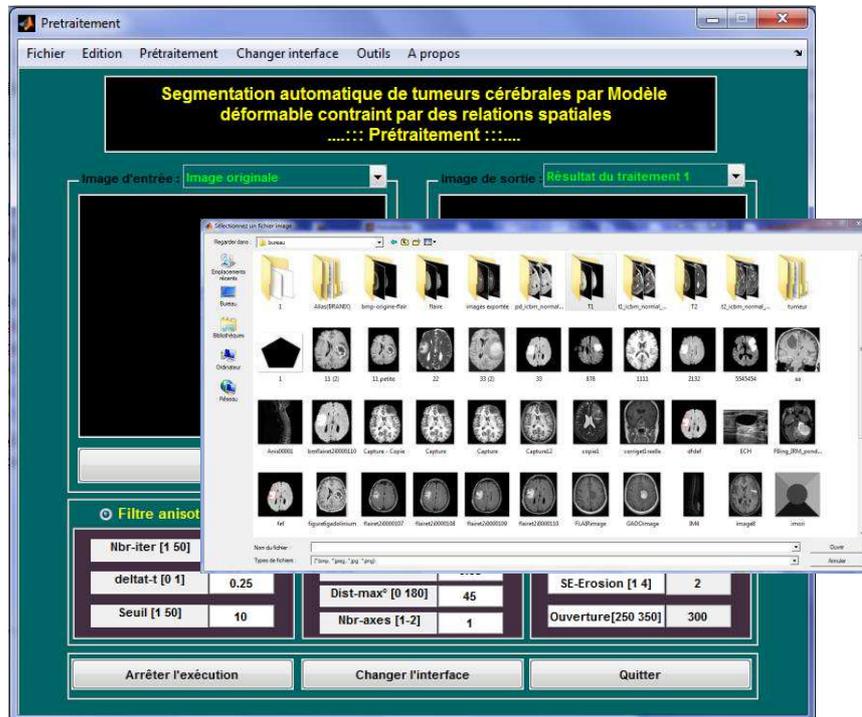


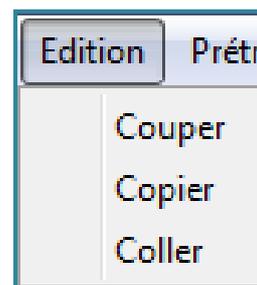
Figure B.5 : Choix de différents types d'image

Ça permet aussi d'enregistrer les résultats obtenus, d'effacer l'image d'entrée ou l'image de résultat, et enfin de quitter l'interface courante.

➤ Edition

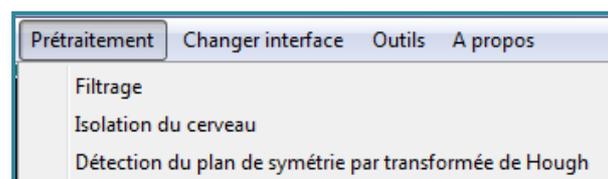
Ça contient les fonctionnalités suivantes :

1. Couper
2. Copier
3. Coller



➤ Prétraitement

Cette commande représente les méthodes de base du prétraitement qui est fait en trois phases :



Un des programmes trouvé dans la barre ci-dessous, doit être choisi, pour fixer le Prétraitement choisi

1. Filtrage Anisotrope

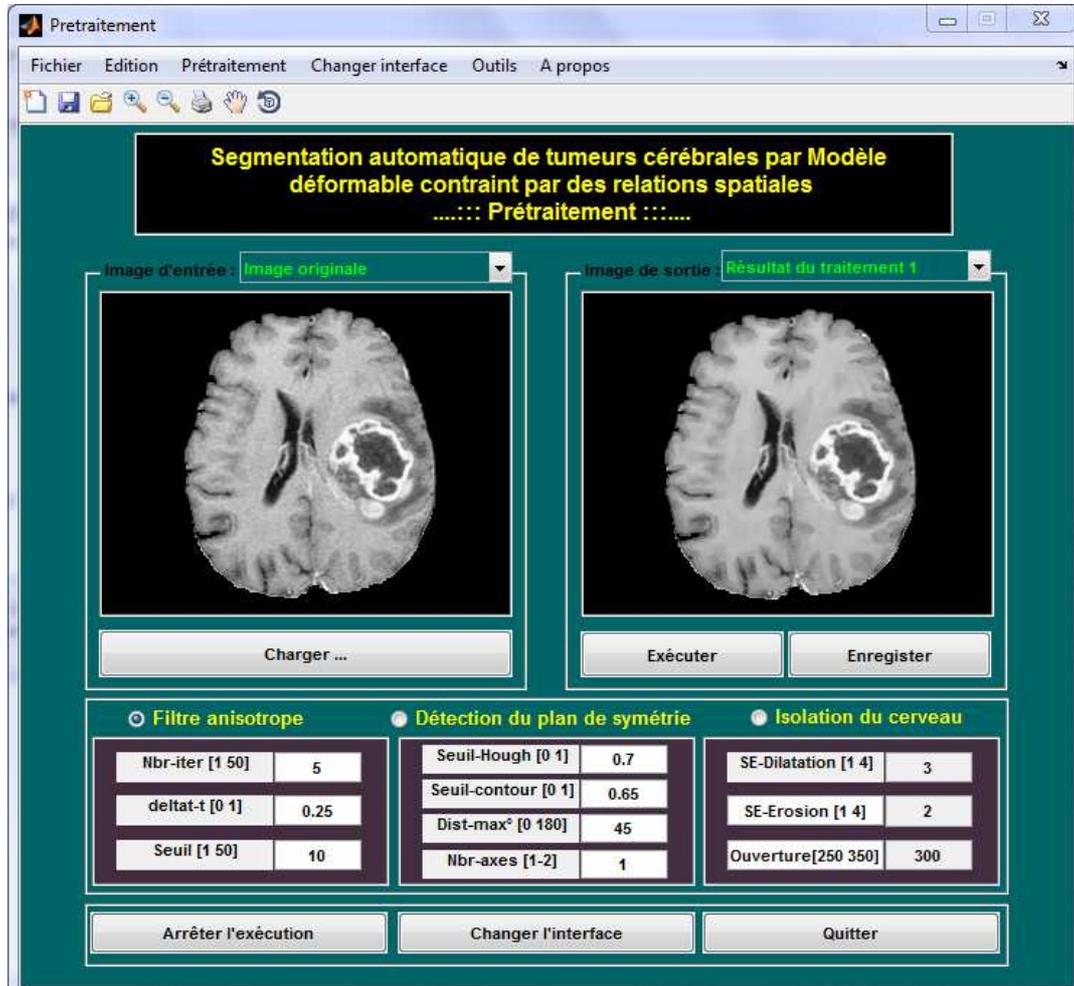


Figure B.6 : Utilisation du Filtrage par l'interface « Prétraitement »

La figure précédente donne le filtrage de l'image affiché sur l'axe 1 et affiche le résultat sur l'axes2.

Pour effectuer cette étape, on sélectionne d'abord le traitement « Filtre anisotrope » puis on clique sur le bouton « Exécuter ».

Dans ce traitement on peut changer de paramètres pour avoir les meilleurs résultats, ces paramètres seront décrits par la suite.

2. Isolation du cerveau

Pour pouvoir effectuer cette étape, on sélectionne le radio-bouton « Isolation du cerveau », et on clique sur le bouton « Exécuter »

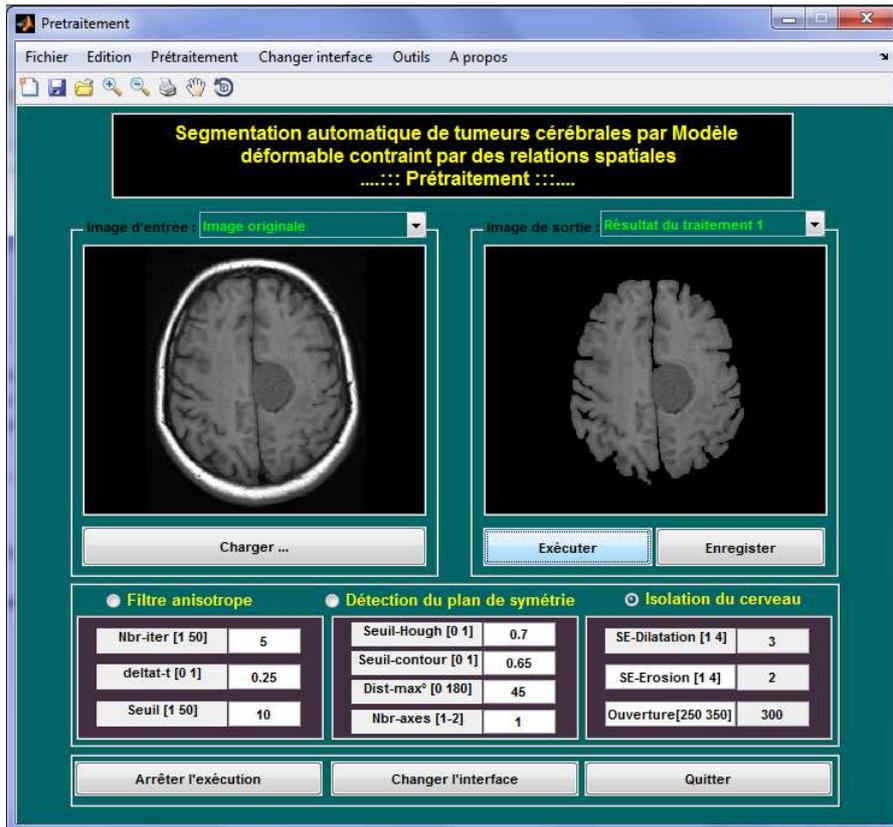


Figure B.7 : Utilisation du programme d'isolation du cerveau

3. Détection du plan de symétrie

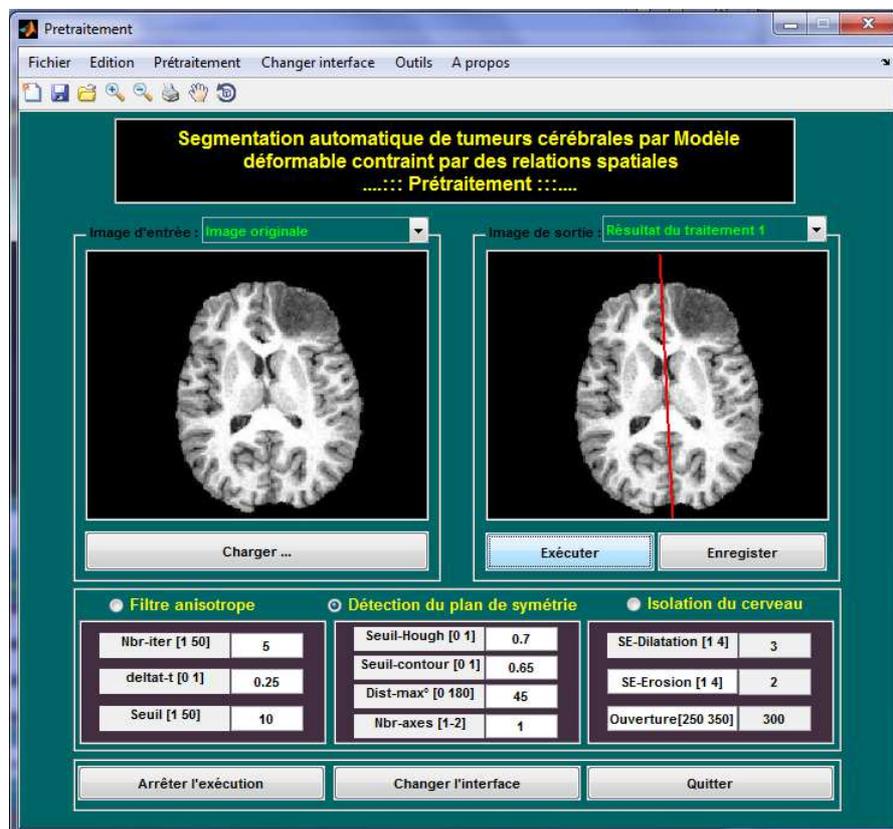


Figure B.8 : Utilisation du programme de détection de l'axe de symétrie

Le même cas pour cette étape, on sélectionne d'abord le traitement « Détection du plan de symétrie » puis n exécute. Le résultat est donné ci-dessus

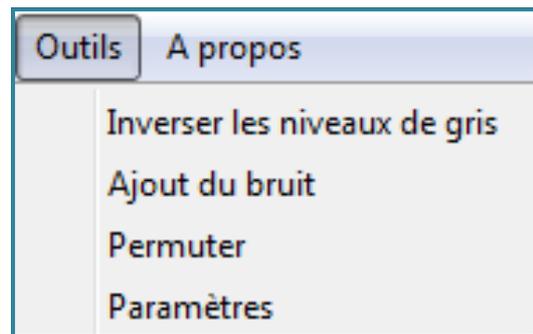
➤ Changer interface

Cette fonctionnalité permet de basculer de cette interface principale, nommé « Prétraitement » vers l'interface secondaire « segmentation »

➤ Outils

Cette commande permet d'effectuer quelques opérations de traitement d'image pour tester nos méthodes, elle nous aide à

1. Inverser les niveaux de gris de l'image chargée ;
2. D'ajouter du bruit pour tester nos algorithmes ;
3. Permuter entre l'image résultat et l'image d'entrée ;
4. Changer de paramètres de chaque méthode.



➤ A propos

En sélectionnant cette commande, il va être affiché l'interface « A propos » qui est présenté dans la page A4 de ce manuel

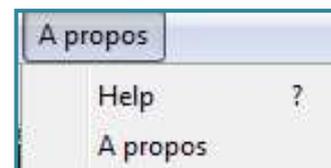
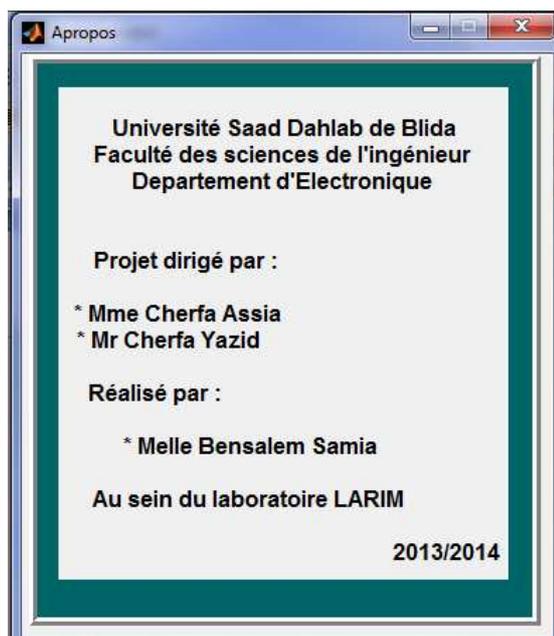
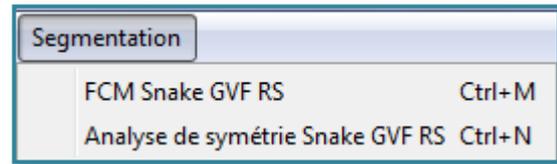
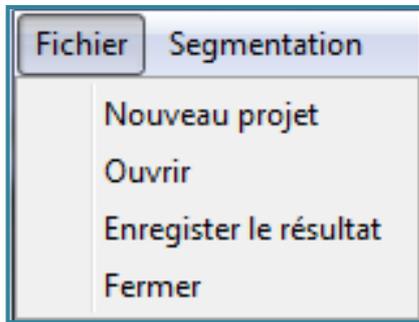


Figure B.9 : Interface secondaire « A propos »

- b) Dans la barre menu de l'interface de segmentation, il existe deux principales fonctionnalités :

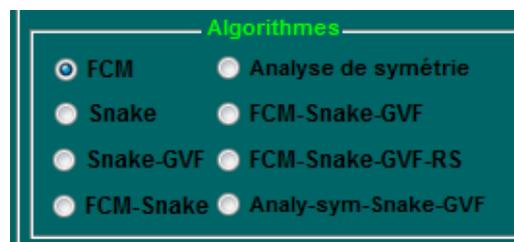


➤ Fichier

Le sous menu Fichier, de cette interface contient les mêmes commandes que contient le sous menu Fichier de l'interface principale.

➤ Segmentation

Le sous menu Segmentation sert à exécuter un programme, ce programme doit être sélectionné parmi les programmes cités dans l'image suivante :



Plusieurs méthodes ont été implémentées dans cette partie, ces méthodes sont divisées en trois approches :

- ✓ **Approche région:** elle comprend la méthode FCM et l'analyse de symétrie, cette approche nous donne une segmentation région de la tumeur, cependant, la définition de son contour est imprécise, pour cela, nous avons opté pour utiliser une méthode d'approche contour ;
- ✓ **Approche contour:** dans notre étude, on employé les contours actifs guidés par GVF comme socle de ce type d'approche, néanmoins, cette méthode nécessite des interventions manuelle de l'utilisateur, spécialement lors de la sélection du contour initiale. Pour ces raisons, nous avons coopéré entre les approches région et les approches contour afin d'en tirer profit des avantages de chacune et de palier à leurs défauts ;
- **Approche coopérative :** Nous avons coopéré entre le FCM (ou Analyse de symétrie) et le Snake guidé par GVF, et afin de mieux orienter l'évolution de ce modèle, nous avons

intégré des relations spatiales comme force externe, issue de la segmentation région, cette méthode coopérative a pu segmenter différents types de tumeurs de différents tailles et formes sur plusieurs images IRM.

Nous présentons ci-dessous un exemple de la segmentation coopérative :

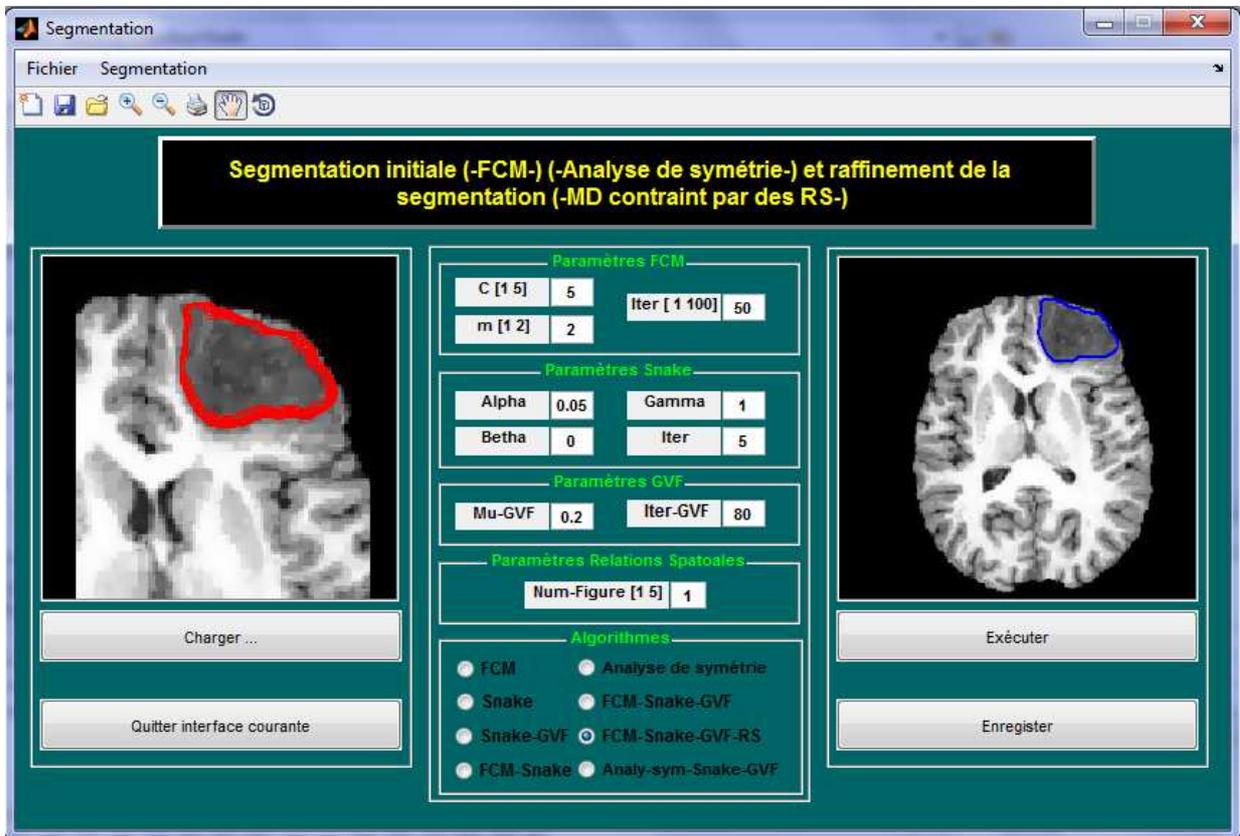


Figure B.10 : Utilisation du programme de segmentation coopérative

B.1.2.2 Les raccourcis

Toutes les commandes et actions utilisateur principales sont disponibles sous forme de raccourcis pour permettre à un utilisateur avancé d'aller plus vite lors de l'utilisation.

Enumération des raccourcis

CTRL + N	Ouvrir un nouveau projet
CTRL + O	Ouvrir une image
CTRL + S	Enregistrer
CTRL + E	Effacer
CTRL + F	Fermer
CTRL + Z	Filtrage Anisotrope

CTRL + Y	Isolation du cerveau
CTRL + X	Détection du plan de symétrie
CTRL + R	Paramètres
CTRL + T	Permuter
CTRL + U	Ajout du bruit
CTRL + V	Inverser les niveaux de gris de l'image d'entrée
CTRL + M	FCM avec Snake guidé par GVF contraint par des relations spatiales
CTRL + N	Analyse de symétrie avec Snake guidé par GVF contraint par des RS

Tableau B.1 : Liste des raccourcis de l'interface

Boutons liés aux raccourcis

Toute commande importante qui se trouve dans les menus déroulants ou sous forme de raccourcis est aussi sous forme de boutons représentatifs situés au dessous de la barre de menu.



Comme le montre l'image ci-dessus, les boutons liés aux raccourcis sont : Nouveau projet, Enregistrer, Ouvrir, Zoom+, Zoom-, Impression, Glissement et rotation. (ces fonction sont données aux boutons par ordre).

B.1.2.3 Palette des paramètres

Pour les deux interfaces, la palette de paramètres permet de varier les valeurs de variables utilisées dans chaque méthode, et pour une bonne orientation de l'utilisateur, on a donné pour chaque paramètres ses seuils, c-à-d sa valeur minimale et sa valeur maximal qui peut prendre

- Paramètres de l'interface principale

<input type="radio"/> Filtre anisotrope	<input checked="" type="radio"/> Détection du plan de symétrie	<input type="radio"/> Isolation du cerveau
Nbr-iter [1 50] 5	Seuil-Hough [0 1] 0.7	SE-Dilatation [1 4] 3
deltat [0 1] 0.4	Seuil-contour [0 1] 0.55	SE-Erosion [1 4] 2
Seuil [1 50] 50	Dist-max° [0 180] 45	Ouverture[250 350] 300
	Nbr-axes [1-2] 1	

Figure B.11 : Palette de paramètres de l'interface principale

- Paramètres de l'interface secondaire

Paramètres FCM			
C [1 5]	5	Iter [1 100]	50
m [1 2]	2		

Paramètres Snake			
Alpha	0.05	Gamma	1
Betha	0	Iter	5

Paramètres GVF			
Mu-GVF	0.2	Iter-GVF	80

Paramètres Relations Spatiales			
Num-Figure [1 5]	1		

Figure B.12 : palette de paramètres de l'interface secondaire

B.1.2.4 Boutons

Nous possédant ici les différents boutons principaux qui permettent l'accès directe et rapide des fonctionnalités désirées, pour chaque interface

➤ Boutons Interface principale

- ✓ Arrêter l'exécution : sert à stopper l'exécution du programme en cours à tout moment ;
- ✓ Changer interface : Sert à basculer entre l'interface « Prétraitement » à l'interface « Segmentation » ;
- ✓ Quitter : Sert à quitter l'interface courante ;
- ✓ Charger : Charger une image à partir d'un répertoire spécifié ;
- ✓ Exécuter : Ce bouton exécute directement le programme sélectionné
- ✓ Enregistrer : Enregistrer le résultat final

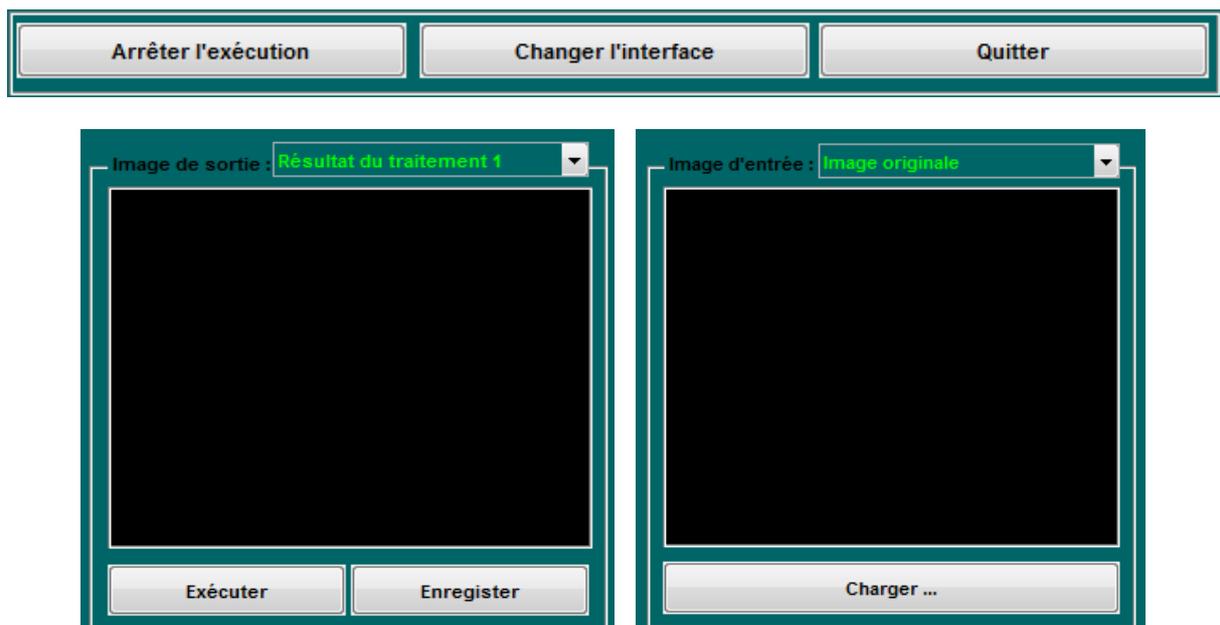


Figure B.13 : Les boutons de l'interface principale

➤ Boutons Interface secondaire

Les boutons, Charger, Exécuter et Enregistrer ont les mêmes fonctions que celles indiquées dans l'interface principale, et pour le bouton « Quitter interface courante », il permet de permuter entre l'interface « Segmentation » avec l'interface « Prétraitement »

La figure ci-dessous montre l'exécution de quelques boutons de cette interface.

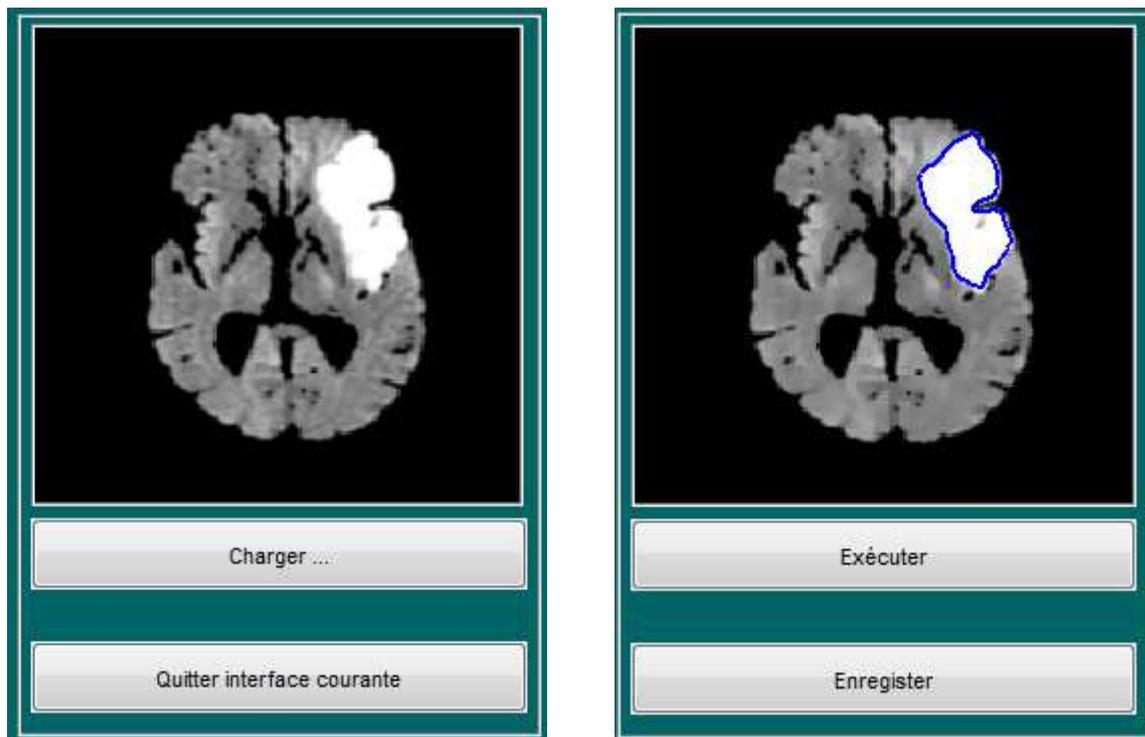


Figure B.14 : Les boutons de l'interface secondaire

Conclusion

Dans ce manuel, nous avons présenté les différentes méthodes utilisées pour le prétraitement et la segmentation de tumeurs cérébrales, ainsi que les différentes structures et fonctions de chaque interface.

Cette interface facilite la tâche à l'utilisateur, elle permet de faire différents traitement d'images, essentiellement, le prétraitement et la segmentation, nous avons vu que sa manipulation est très facile, elle assure un bon résultat, et enfin elle donne aces à l'utilisateur pour varier les différents paramètres afin d'avoir des résultats spécifiques

BIBLIOGRAPHIE

- [1] khotanlou.H « Segmentation 3D de tumeurs et de structures internes du cerveau en IRM » Thèse de doctorat, l'école nationale supérieure des télécommunications, Paris Tech, (2008)
- [2] Hablützel, J « Les tumeurs cérébrales et du système nerveux central » Ligue suisse contre le cancer Effingerstrasse 40, case postale 8219, 3001 Berne. (2009)
- [3] « Les tumeurs du cerveau » Collection Guides de référence Cancer info, INCa, (juin 2010)
- [4] Miri, S « Segmentation des structures cérébrales en IRM : intégration de contraintes topologiques » Rapport de stage, spécialité PARI, option IRMC, université Louis Pasteur Strasbourg. (2007)
- [5] Georges, S « Segmentation des structures sous corticales par fusion floue d'informations sur des images RMN » Mémoire de Fin d'étude Polythèque, Grenoble. (2003)
- [6] Bosc, M « Contribution à la détection de changements dans des séquences IRM 3D Multimodales » Thèse de doctorat. L'université Louis Pasteur-Strasbourg I. (2003)
- [7] Dob, I et Bensalem, S « Segmentation de tumeurs cérébrales par coopération flou/possibiliste-Modèle déformable » Mémoire de fin d'étude, université Saad Dahlab de Blida. (2010)
- [8] Géraud, T « Segmentation des structures internes du cerveau en imagerie par résonance magnétique » Thèse de doctorat. Ecole nationale supérieure des télécommunications – Paris. (1998)
- [9] Calmels, L « Imagerie fonctionnelle et microscopique du petit animal orientée vers la cancérologie » Thèse de doctorat. Ecole doctorale STI TS. Université de Paris. (2010)
- [10] Ammadi, A « Détection automatique de phénomènes présents dans une image satellitaire en composition colorée » Mémoire de master. L'université mohammed5. (2008)
- [11] Gastaud, M « Modèles de contours actifs pour la segmentation d'images et de vidéos » Thèse de doctorat. L'université de Nice - Sophia Antipolis. (2005)
- [12] Hatt, M « Détermination automatique des volumes fonctionnels en imagerie d'émission pour les applications en oncologie » Thèse de doctorat. L'Université Occidentale et de Telecom Bretagne. (2008)
- [13] Lecoeur, J « Segmentation d'IRM cérébrales Multidimensionnelles par coupe de graphe » Thèse de doctorat. L'université de Rennes I. (2010)
- [14] Aliouche, W et Djadi, N.A « Reconstruction tridimensionnelle à partir de coupes

- séries : Application aux images médicales » Institut I.N.I Oued-Smar, Alger. (2008)
- [15] Lecoeur, J et Barillot, C « Segmentation d'images cérébrales : Etat del'art » Rapport de recherche, Institut INI, version révisée en (2008)
- [16] Bricq, S ; Collet, Ch et armspach, J.P « Unifying framework for multimodal brain MRI segmentation based on hidden markov chains » Medical image analysis, vol. 12, No 6, pp. 639-652. (2008)
- [17] Banrezes, B « La modélisation 3D : contribution et nouvelles perspectives en neuroanatomie fonctionnelle » Thèse de doctorat. L'université de Paris 6, (2002)
- [18] Bricq, S « Segmentation d'images IRM anatomiques par inférence bayésienne multimodale et détection de lésions » Thèse de doctorat, Université Louis Pasteur-StrasbourgI. (2008)
- [19] Jain, A et Dubes, R « Algorithms for clustering data » Computer science, Mcconnell interworking computer systems : Interconnectiong networks and systems. (1988)
- [20] Hadjadj, Z « Segmentation de pathologies cérébrales par coopération de méthodes » Mémoire de magister, Université Saad Dahlab de Blida. (2011)
- [21] Ayachi, R et Ben amor, N « Brain tumor segmentation using support vector machine » Ed, Springer-Verlag, Berlin Heidelberg, pp. 736-747. (2009)
- [22] Kathane, M.S et Thakare, V « Brain Segmentation using Support Vector Machine: Diagnostic Intelligence Approach » IJCA, ICBEST, pp.12-14. (2012)
- [23] Steinbach, M ; Karypis, G et Kumar, V « A comparison of document clustering techniques » Workshop en 'text mining', Université de Minnesota, (2000)
- [24] Pham, D.L, Xu, C et Prince, J.L « A survey of current methods in medical image segmentation » Annual Review of Biomedical Engineering, (1998)
- [25] Atine, J.A « Méthodes d'apprentissage floue application a la segmentation d'images biologiques » Thèse de doctorat. Laboratoire d'analyse et d'architecture des systèmes du CNRS (Toulouse). (2005)
- [26] Berriche et Benyettou, M « L'interprétation des images médicales cérébrales : Segmentation par l'approche Split and Merge » Laboratoire de modélisation et optimisation des systèmes industriels : LAMOSI, USTO, Algérie. (2009)
- [27] Thiran, J.P; Warscott, B et Macq « A queue based region growing algorithm for accurate segmentation of multi dimensional digital images » Signal processing, Vol. 60, pp. 1-10. (1997)
- [28] Warfield, S; Dengler, J; Zaers, J; Guttman, C; wells, W; Ettinger, G.J; Hiller, J et Kilinis, R « Automatic identification of grey matter structures from MRI to improve the segmentation of white matter lesions» Journal of image Guided survey, pp. 326-338. (1995)

- [29] Gordillo, N; Montseny, E et Sobrevilla, P « State of art survey on MRI brain tumor segmentation » *Magnetic Resonance Imaging*. pp.1426-1438, Elsevier. (2013)
- [30] Schnack, H.G ; Hulshoff Pol, H.E ; Baaré, W.F.C ; Viergever, M.A et Kahn, S. « Automatic segmentation of the ventricular system from MR images of the human brain » *Neuroimage*, vol.14, No 1, pp. 95-104. (2001)
- [31] Richard, N ; Dojat, M et Garbay, C « Automated segmentation of human brain MR images using multi-agent approach » *Artificial intelligence in medicine*, vol. 30, pp. 153-175. (2004)
- [32] Corso, J.J ; Sharon, E et Yuille, A « Multilevel segmentation and integrated Bayesian model classification with an application to brain tumor segmentation » *MICCAI2006*, volume LNCS 4191, pp 790–798, Copenhagen, Denmark. (2006)
- [33] Sharon, E; Brandt, A, et Basri, R « Segmentation and boundary detection using multiscale intensity measurements » *IEEE Conference en vision par ordinateur et reconnaissance de formes*, volume 1, pp 469-476. (2001)
- [34] Moon, N, Bullitt, E, Leemput, K. V, et Gerig, G « Model based brain and tumor segmentation » *ICPR*, pages 528–531, Quebec. (2002)
- [35] Moon, T.K « The expectation maximization algorithm » *IEEE, Signal Processing Magazine*, 13(6):47 – 60. (1996)
- [36] Ambroise, C, Dang, M., et Govaert, G « Clustering of spatial data by the EM algorithm » *Chapitre GEOENV I*, pp 493–504. Kluwer Academic Publishers. (1995)
- [37] Leemput, K. V, Maes, F, Vandermeulen, D, Colchester, A, et Suetens, P « Automated segmentation of multiple sclerosis lesions by model outlier detection » *IEEE Transactions on Medical Imaging*, 20:677–688. (2001)
- [38] Sebari, I et Dong Chen, HE « Les approches de segmentation d'image par coopération région-contour » *Université de Sherbrooke. Centre d'applications et de recherches en télédétection (CARTEL)*. Vol. 7, n° 1-2-3-4, p. 499-506. (2007)
- [39] Balwinder Singh, P « A review on brain tumor detection using segmentation » *IJCSMC*, Vol. 2, Issue. pg.48–54. (2013)
- [40] Sigward, E « Introduction à la théorie des graphes » (2002). Cour sur <http://www.ac-nancy-metz.fr/enseign/maths/m2002/institut/ipr/graphes/Graphes.pdf>
- [41] Pelle, S « Géométrie : la théorie des graphes. Cours Ingénieur 1ère année » *École nationale des sciences géographiques*. (2005)
- [42] Mayer, A et Greenspan, H « Segmentation of brain MRI by adaptive mean shift » *International symposium on biomedical imaging: Macro to Nano*, pp. 319-322. (2006)
- [43] Zitouni, R et Belhadj, I « Segmentation contextuelle des images IRM cérébrales par le FCM semi supervisé. Première étape à l'aide au diagnostic » *Journée francophone d'informatique médicale, Lille*. (2005)

- [44] Toumi, L, Semchedine, M et Moussaoui, A « une approche robuste semi-supervisé pour la détection des tumeurs cérébrales » JIG'2007- 3^{ème} journée internationale sur l'informatique graphique, Algerie. (2007)
- [45] Li, Y et Zhijun, G « A Review of Segmentation Method for MR Image » IEEE. College of Computer and Information Engineering, Harbin, China. Vol. 978, N. 1, pp.4244-5555. (2010)
- [46] Maz, S, Madjeed, H et Irshad, H « Image segmentation using fuzzy clustering : a survey » 6th International Conference on Emerging Technologies (ICET). 978. pp. 181-186IEEE. (2010)
- [47] Pham, D.L et Prince, J.L « Adaptive fuzzy segmentation of magnetic resonance images » IEEE Trans. Med. Imag., vol. 18, no. 9, pp. 737–752, (1999)
- [48] Chan, T et Vese, L « Active contours without edges » IEEE Trans Image Process; Vol. 10, no. 2, pp. 266 – 77. (2001)
- [49] Luo, S, Li, R et Ourselin, S « A new deformable model using dynamic gradient vector flow and adaptive balloon forces » APRS Workshop on Dig Image Comp; p. 9–14. (2003)
- [50] Law, A.K.W, Zhu, H, Chan, B.C.B, Iu, P.P, Lam, F,K et Chan, F.H.Y « Semi automatic tumor boundary detection in MR image sequences » International symposium on intelligent Multimedia, traitement de video et parole. pp. 28-31, Hong kong. (2001)
- [51] Law, A, Lam, F et Chan, F « A fast deformable region model for brain tumor boundary extraction » Int Conf EMBS, 2:1055 – 6. (2001)
- [52] Khotanlou, H, Colliot, O, Atif, J et Bloch, I. « 3D brain tumor segmentation in MRI using fuzzy classification, symmetry analysis and spatially constrained deformable models » Fuzzy Set Syst, 1, 60(10):1457 –73. (2009)
- [53] Caselles, V, Sethian, F, Coll, T et Dibos, F « A geometric model for active contours » Numerische mathematik, 66 :1-31. (1993)
- [54] Malladi, R, Sethian, J et Vemuri, B.C « Shape modeling with front propagation : A level set approach » IEEE transactions on pattern analysis and machine intelligence, Vol. 17, no. 2, pp. 158-175. (1995)
- [55] Osher, S et Sethian, J « Fronts propagation with curvature dependent speed : Algorithms based on Hamilton-jacobi formulations » Journal of computational physics. 79 :12-49. (1988)
- [56] Xu, C, Pham, D.L et Prince, J.L « Handbook of medical imaging » Vol 2, chapter medical image segmentation using deformables models : medical image processing and analysis, pp. 129-175. SPIE press. (2000)

- [57] Droske, M, Mayer, B, Rumpf, M et Schaller, C « An adaptive level set method for medical image segmentation » Proceedings of the 17th international conference on information processing in medical imaging, Vol 2082 of LNCS, pp 416-422. Springer-Verlag. (2001)
- [58] Ho, S, Bullitt, E et Gerig, G « Level set evolution with region competition : Automatic 3D segmentation of brain tumors » Dans ICPR, pp. 532-535, Quebec. (2002)
- [59] Taheri, S, Ong, S.H et Chong, V « Threshold-based 3D tumor segmentation using level set (TSL) » IEEE workshop on applications of computer vision (WACV 07), pp 45-51, Texas, USA. (2007)
- [60] Chen, T et Metaxas, D.N « Gibbs prior models, marching cubes and deformable models : a hybrid framework for 3D medical image segmentation » Medical image computing et computer-assisted intervention (MIICCAI), Vol. 2879 de LNCS, pp. 703-710, Montreal, Canada. (2003)
- [61] Faliu, Y et Inkyu, M « Image Segmentation: A Survey of Graph-cut Methods » IEEE, International Conference on Systems and Informatics (ICSAI), Vol. 978, no. 1, pp. 1963-1941. (2012)
- [62] Prastawa, M, Bullitt, E, et Gerig, G « Synthetic ground truth for validation of brain tumor MRI segmentation » Conference international en Medical Image Computing and Computer Assisted Intervention (MICCAI), volume 3749, Computer Science, pages 26–33. Springer. (2005)
- [63] Derivaux, S, Lefèvre, S, Wemmert, C et Korczak, J.J « Apport d'une classification non supervisée floue à la segmentation par ligne de partage des eaux » LSIIT - CNRS - Université Louis Pasteur – UMR. (2005)
- [64] Vandewalle, V « Estimation et sélection en classification semi-supervisée » Thèse de doctorat. L'université Lille 1. (2009)
- [65] Semchedine.M., Toumi, L et Moussaoui, A « Système coopératif de classification floue possibiliste avec rejet d'ambiguïté. Application à la segmentation d'image IRM » 4^{ème} Conférence International en "Computer Integrated Manufacturing". (2007)
- [66] Kass, M, Witkin, A et Terzopoulos, D « Snakes : Active contour models » Le journal international de la vision artificielle, vol. 1, pp. 321-331. Schlumberger à Palo Alto (Californie). (1988)
- [67] Terzopoulos, D « On matching deformable models to images » Topical Meeting on Machine Vision, Vol, 12, pp. 160-0167. (1987)
- [68] Zhu, Y et Yang, H « Computed tumor boundary detection using a Hopfield neural network. IEEE transactions on Medical Imaging, Vol, 16, N, 1, pp. 55-67. (1997)
- [69] Perona, P et Malik, J « Scale-Space and Edge Detection Using Anisotropic Diffusion » IEEE transactions on pattern analysis and machine intelligence, Vol. 12 No. 7. (1990)

- [70] Sellami, M et Fethi, C « Analyse d'image IRM 3D » Mémoire d'ingénieur, département d'Electronique, université Saad Dahleb de Blida. (2007)
- [71] Gerig, G, Kubler, O, Kikinis, R et Jolesz, F.A « Nonlinear Anisotropic Filtering of MRI Data » IEEE transactions on medical imaging. Vol. 11. No. 2. (1992)
- [72] Somkait,U et Pichet, W « Feature extraction in medical MRI images » Proceedings of the 2004 IEEE.Conference on cybernetics and intelligent systems, pp 340-344. (2004)
- [73] Somkait, U «Edge detection in ultrasonic images using GABOR filter » IEEE transactions on pattern analysis and machine intelligence, pp. 175-178. (2004)
- [74] Gallo, G, Zingale, A, et Zingle, R « Detection of MRI brain contour using nonlinear anisotropic diffusion » 18th annual international conference of IEEE engineering in medicine and biology society, pp 1062-1064. (1996)
- [75] Germond,L, Dojat, M, Taylor,C et Garbay, C « A cooperative framework for segmentation of MRI brain scans » Artificial Intellegence in Medicine. (2000)
- [76] Serra, J « morphologie mathématique » Cours <http://cmm.ensmp.fr/~serra/cours/>. (2000)
- [77] Serafini, N « Implantation d'une librairie de morphologie mathématique sur un processeur DSP » Thèse de doctorat, Ecole d'ingénieurs de Genève. HSE :110 (2001)
- [78] Atkins, M.S et Mackiewich, B.T « Fully Automatic Segmentation of the Brain in MRI » IEEE transactions on medical imaging, vol. 17, no. 1, pp 98-107. (1998)
- [79] Le Thuc,V, Taleb-Ahmed,A, Saint Michel, T, Ayachi, M et Pruvo, J.P « Contribution à la segmentation automatique de l'encéphale à partir de coupes IRM » Vision Interface '99, Trois-Rivières, Canada. (1999)
- [80] Capelle, A.S, Alata, O, Fernandez, C, Lefevre, S et Ferrie, J.C « Unsupervised segmentation for automatic detection of brain tumors in MRI » Image Processing 2000, Proceedings. 2000 International Conference. Vol 1, pp. 613-616. (2000)
- [81] Schiess, M « Segmentation d'image anatomique du cerveau chez l'adulte » Ecole d'ingénieurs de Genève HES Section informatique. (2003)
- [82] Pasini, S « Traitement d'images cérébrales pour la détection et le suivi des processus tumoraux » Mémoire d'ingénieur, Ecole d'ingénieurs de Genève HES, (2001)
- [83] Cherfa, Y Cherfa, A, Kabir, Y, Kassous, S, Juillard, A, Dojat, M et Garbay, C « Segmentation of magnetic resonance brain images using edge and region cooperation characterization of stroke lesions » The International Arab Journal of Information Technology IAJIT Vol.04, Nbr 3. (2008)
- [84] Otsu, N « A threshold selection method from grey scale histogram » IEEE Trans. on Syst. Man and Cyber., vol 1, pp 62-66. (1979)

- [85] Barra, V « Fusion d'Images 3D du Cerveau : Etude de Modèles et Applications » Thèse de doctorat. L'Université d'Auvergne. (2000)
- [86] Saint-jean, C « classification paramétrique robuste partiellement robuste en reconnaissance des formes » Thèse de doctorat. L'université de La Rochelle. (2001)
- [87] Lankton, S, et Tannenbaum, A « localising Region-Based contours » IEEE Transactions on image processing, vol. 17, NO. 11. (2008)
- [88] Lecellier, F « Les contours actifs basés région pour la segmentation d'images: Application à la segmentation du contour de l'endocarde sur des images d'échographie cardiaque » GREYC UMR CNRS 6072 - Equipe Image. (2005)
- [89] Zitouni, R « Segmentation contextuelle des images irm du cerveau humain : application à la classification semi supervisée » Thèse d'ingénieur, Université Rerhat abbas. (2004)
- [90] Brava, M « Utilisation de la transformée de Radon pour la localisation de micro-outils chirurgicaux dans une image échographique » Mémoire, université de Lyon, Institut National des sciences appliquées-INSA, centre de recherche et d'applications en traitement de l'image et du signal-EREATIS. (2003)
- [91] Letouzey, L et Chabrier, T « Transformée de Hough » cours dans Laboratoire GePaSUD. Université de Bordeaux, (2008)
- [92] Bergounioux, M « quelques méthodes mathématiques pour le traitement d'image » Cours. (2008)
- [93] Patrice, B « traitement d'image ultrasonores: etude et application de la transformation de hough aux echos de diffraction » Thèse de doctorat, université de Bourgogne, UFR sciences et techniques. (1999)
- [94] Bouatou, V et Soulier, L « Détection d'axes de symétrie dans une image par transformation de hough. Sujet proposé par le professeur Henri Maître, Université Paris tech, Option Traitement des Images, 3ème année E.N.S.T. (2001)
- [95] O'Mara, D et Owens, R « Measuring bilateral symmetry in digital images » In proceedings of tencon'96 IEEE conference : Digital Signal Processing Applications, vol 1, pp. 151-156. (1996)
- [96] Ardekani, B, Kershaw, J, Braun, M, et Kanno, I « Automatic detection of the mid-sagittal plane in 3D brain images » IEEE transactions on medical imaging, Vol, 16, N 6, pp. 947-952. (1997)
- [97] Liu, Y, Colins, R, et Rothus, W « Robust midsagittal plane extraction from normal and pathological 3D neuroradiology images » IEEE transactions on medical imaging, Vol, 20, N 3, pp. 175-192. (2001)
- [98] Minoshima, S, Berger, K, Lee, K, et Mintum, M. « An automated method for rotational correction and centering of three-dimensional functional brain images.

Journal of nuclear medicine, Vol, 33, N, 8, pp. 1579-1585. (1992)

- [99] Venot, A, Lebruchec, J, et Roucayrol, J, « A new class of similarity measures for robust image registration. Computer Vision, Graphic and image processing, 28, pp. 176-184. (1984)
- [100] Prima, S, Ourselin, S, et Ayache, N « Computation of the mid-sagittal plane in 3D brain image » IEEE transactions on medical imaging, Vol, 21, N, 2, pp.122-138. (2002)
- [101] Hough, P.V.C. « Method and Means for Recognizing Complex Pattern » U.S. Patent, N, 3069654. (1962)
- [102] Skubic, M ; Blisard, S ; Adams, J et Matsakis, P « Qualitative analysis of sketched route maps : translating a sketch into linguistic descriptions » IEEE transactions on systems, Man and cybernetics-part B:cybernetics, Vol, 34, N, 2, pp. 1275-1282. (2004)
- [103] Cesar, R.M; Bengoetxea, E; et Bloch, I « Inexact graph matching using stochastic optimization techniques for facial features recognition » In proc. International conference on pattern recognition ICPR Vol, 2, pp. 465-468, Québec, Canad. (2002)
- [104] Keller, J.M et Wang, X « A fuzzy rule based approach to scene description involving spatial relationships » Computer vision and image understanding, Vol, 80, pp. 21-24. (2000)
- [105] Bloch, I; Geraud, T et Maitre, H « Representation and fusion of heterogeneous fuzzy information in the 3D space for model-based structural recognition-Application to 3D brain imaging. Artificial intelligence, Vol, 148, pp .141-175 ENST département TSI France. (2003)
- [106] Perchant, A et Bloch, I « A new definition of fuzzy attributed graph homomorphism with application to structural shape recognition in brain imaging. In porc » IEEE instrumentation and measurement technology conference IMTC, Vol, 3, pp. 1801-1806. (1999)
- [107] Bloch, I « Fuzzy spatial relationships for image processing and interpretation: a review » Image and vision computing Vol, 32, N, 2, pp. 89-110. (2005)
- [108] Bloch, I; Colliot, O et Cesar, R,M « On the ternary spatial relation “between” » IEEE transactions on systems, man, and cybernetics-part B: cybernetics, Vol 6, N, 2, pp. 312-327. (2006)
- [109] Nempont, O; Atif, J; Angelini, E,D; Bloch, I « Propagation de contraintes pour la segmentation et la reconnaissance de structures anatomiques à partir d’un model structurel » Information-interaction-intelligence (I3). 10(1). (2012)
- [110] Colliot, O « Représentation, évaluation et utilisation de relations spatiales pour l’interprétation d’image application la reconnaissance de structures anatomiques en imagerie médicale » Thèse de doctorat, ENST département TSI, Télécom Paris Tech.

(2003)

- [111] Colliot, O; Camara, O et Bloch, I « Integration of fuzzy spatial relations in deformable models-Application to brain MRI segmentation » Elsevier, Pattern recognition, Vol, 39, pp. 1401-1414, ENST département TSI France. (2006)
- [112] Geoffroy, F; Atif, J et Bloch, I « Sequential model-based segmentation and recognition of image structures driven by visual features and spatial relations » Computer vision and image understanding 116: 146-165. (2012)
- [113] Atif, J; Hudelot, C et Bloch, I « Adaptation de connaissances génériques pour l'interprétation d'images médicales : représentation par ontologies et par graphes et modélisation floue » Ontologies, graphes et modélisation floue pour l'interprétation d'images, ENST (GET-Telecom Paris). (2008)
- [114] Hudelot, C ; atif, J et Bloch, I « Fuzzy spatial relation ontology for image interpretation » Fuzzy sets and systems , Vol, 159, pp. 1929-1951, ENST department TSI (Telecom Paris Tech). (2008)
- [115] Pitiot, A; Delingette, H; Ayache, N et Thompson, P.M « Expert knowledge guided segmentation system for brain MRI » In Proc. Medical image computing and computer-assisted intervention MICCAI. 566-652.Mentreal Canada. (2003)
- [116] Bloch, I « On fuzzy distances and their use in image processing under imprecision. Pattern recognition » Vol, 32, N, 11, pp. 1873-1895. (1999)
- [117] Colliot, O; Tuzikov, A.V; Cesar, R.M et Bloch, I « Approximate reflectional symmetries of fuzzy objects with an application in model-based object recognition » Fuzzy sets and systems, 147(1):141-163. (2004)
- [118] Matsakis, P et wendling, L « A new way to represent the relative position between areal objects » IEEE transactions on pattern analysis and machine intelligence, Vol, 21, N, 7, pp. 634-643. (1999)
- [119] Bloch, I « Information combination operators for data fusion: a comparative review with classification » IEEE transactions on systems,man,and cybernetics-PartA, Vol, 26, N, 1, pp. 52-67. (1996)
- [120] Dudois, D et Prade, H « fuzzy sets and systems, they and applications » Academic press, new York. (1980)
- [121] Hazarika, S et Cohn, A.G « A taxonomy for spatial vagueness: an alternative egg-yolk interpretation » imprécision spatiale, incertitude et granularité Symposium, Ogunquit, Maine, États-Unis. (2001)
- [122] Freksa, C ; Knauff, M ; Krieg-Bruckner, B ; Nebel, B et Barkowsky, T « Spatial Cognition IV-Reasoning, Action, Interaction » Series Springer, en genie de perception, Springer, Berlin. (2004)
- [123] Herskovits, A « Language and Spatial Cognition.Une étude interdisciplinaire des

prépositions en anglais » Cambridge University Press, Cambridge, MA. (1986)

- [124] Krishnapuram, R; Keller, J et Ma, Y « Quantitative analysis of properties and spatial relations of fuzzy image region » IEEE transactions on fuzzy systems, Vol, 1, N, 3, pp. 222-223. (1993)
- [125] Xu, C et Prince, J.L « Gradient Vector Flow : A new external force for snakes » IEEE, Conférence en vision par ordinateur, reconnaissance des formes (CVPR), pp. 66-71. (1997)
- [126] Montagnat, J, Delingette, H, et Ayache, N « A review of deformable surfaces : topology geometry and deformation » Image and Vision computing, Vol, 19, pp. 1023-1040. (2001)
- [127] Talmy, L « How language structures space. dans: HL Pick, LP Acredolo (Eds.), l'orientation spatiale: théorie, recherche et application » Plenum Press, New York. (1983)
- [128] Bloch, I « Mathematical morphology and spatial relationships : Quantitative, semi-quantitative and symbolic settings » Dans L. et P. Sztandera Matsakis, Editeurs, Application calcul Soft dans la définition de relations spatiales, pp: 63-98. Springer. (2002)
- [129] Tauber, C, Batatia, H, Ayache, A « A general quasi-automatic initialization for snakes : application to ultrasound images » IEEE, International conference on Image Processing (ICIP2), Genova, pp. 806-809, (2005)

WEBOGRAPHIE

- [S1] <http://www.wikipedia.org/>
- [S3] http://www.chuv.ch/neurochir/nch_home/nch_activites_cliniques/nch_interventions_adultes/nch_tumeurs_adultes.htm
- [S4] <http://www.fmp-usmba.ac.ma/umvf/UMVFmiroir/campus-numeriques/campus-neurochirurgie/spip3a0d.html?article191>
- [S5] <http://www.psychoweb.fr/articles/neuropsychologie/98-tumeurs-cerebrales-types-de-tumeurs.html>
- [S6] <http://www.aboutkidshealth.ca/Fr/ResourceCentres/BrainTumours/BrainTumoursAnOverview/TypesofBrainTumours/Pages/default.aspx>
- [S7] <http://www.who.int/fr/>
- [S8] <http://www.imaios.com/fr/e-Cours/e-MRI>
- [S9] <file:///D:/r%C3%A9daction%202013/3%20-%20%20etat%20de%20l%27art%20de%20la%20segmentation/documentations/Tutoriel%20sur%20la%20segmentation%20d%27images%20m%C3%A9dicales.htm>
- [S10] http://www.tsi.telecom-paristech.fr/pages/enseignement/ressources/beti/symetrie_centre/index.htm
- [S11] www.irit.fr/ACTIVITES/EQ_TCI/EQUIPE/dalle/.../16-Hough.pdf

