

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

UNIVERSITE MOULOU D MAMMERI DE TIZI-OUZOU



FACULTE DU GENIE ELECTRIQUE ET D'INFORMATIQUE
DEPARTEMENT D'ELECTRONIQUE

Mémoire de fin d'études De MASTER ACADEMIQUE

Domaine: **Sciences et Technologies**

Filière: **Génie électrique**

Spécialité: **électronique biomédicale**

Présenté par

DEKKICHE Slimane

Encadré et Proposé par :

Mr.MOHIA Yacine

Thème

Segmentation d'image médicales basées sur une coopération FCM et Level Set

Soutenu en 30/10/2015. Devant le jury :

M^{elle} : SLIMANI.S

Mr: MOHIA.Y

Mr: HAMAG.S

Mr: IDJRI.B

Présidente

Promoteur

Examineur

Examineur

Promotion: 2014/2015

Remerciement

Je tiens à remercier le bon dieu de m' avoir accordé la force et le courage de mener a terme ce mémoire.

Je remercie, sincèrement, Mr. MOHIA. Yacine pour l'intéressante documentation qu'il a mise à ma disposition, pour sa patience et surtout pour sa confiance et pour toutes les commodités et aisances qu'il ma apportées durant mon étude.

Mes remerciements et gratitudes s' adressent aussi aux messieurs le président et les membres de jury d' avoir accepté d' examiner mon travail.

Sans omettre bien sur de remercier profondément à tous ceux qui ont contribué de prés ou de loin à la réalisation du présent travail.

Listes des figures

Figure I.1: La position des quatre lobes dans le cerveau.....	4
Figure I.2: Acquisition des images IRM	11
Figure I.3: Les différentes coupes de cerveau	11
Figure II.1: Formulation des « Level set »	22
Figure II.2: Résultat de la segmentation par la méthode croissance de région	27
Figure II.3: Résultat de la segmentation par la methode split and merge	28
Figure II.4: Résultat de la segmentation par k-means pour le nombre de classe (K=3)	32
Figure II.5: Résultat de la segmentation par k-means pour le nombre de classe (K=4)	32
Figure II.6: Résultat de la segmentation par k-means pour le nombre de classe (K=5)	33
Figure II.7: Résultat de la segmentation par FCM.	38
Figure III.1: Prétraitement	42
Figure III.2: Initialisation de la courbe initiale.....	43
Figure III.3: Initialisation de la courbe	43
Figure III.4: Evolution de la courbe de déformation	45
Figure III.5: Evolution de la courbe de déformation	46
Figure III.6: Evolution de la courbe de déformation	46
Figure III.7: Détection de la partie tumorale par la méthode coopérative entre FCM et Level Set pour des coupes axiales.	47
Figure III.8: Détection du cerveau par la méthode coopérative entre FCM et Level set pour Des coupes axiales	50
Figure III.9: Détection de la partie tumorale par la méthode coopérative entre FCM et Level Set pour des coupes coronales.	51
Figure III.10: Détection de la partie tumorale par la méthode coopérative entre FCM et Level Set pour des coupes sagittales.	51

Sommaire

Introduction générale.....	1
----------------------------	---

Chapitre I : contexte médicale

I. Introduction.....	3
II. Description macroscopique et microscopique du cerveau	3
II .1. Description macroscopique	3
II.2. Description microscopique	4
III. Les tissus du cerveau	4
III.1. La substance grise.....	4
III.2. La substance Blanche	4
III.3. Les meninges	5
III.4. Le liquide Céphalo-rachidien	5
III.5. Lésions cérébrales	5
IV.2. Tumeur cérébrale primaire et tumeur cérébrale métastatique ou secondaire.....	6
IV.3. Tumeurs cérébrales bénignes et tumeurs cérébrales malignes	6
IV.3.1. Les tumeurs cérébrales bénignes.....	6
IV.3.2. Les tumeurs cérébrales malignes	7
IV.4. Signes et symptômes associés à la présence de tumeurs cérébrales.....	7
V. Le diagnostic des tumeurs cérébrales.....	8
V.1. Examen clinique.....	8
V.2. Examens complémentaires	8

V.3. La biopsie cérébrale	8
V.4. Imagerie médicale.....	8
V.4.1. Imagerie par résonance magnétique (IRM)	8
V.4.1.1. Principales composantes d'IRM	9
V.4.1.2. Acquisition des images IRM.....	10
V.4.1.3. Les artefacts	11
VI. Segmentation d'images de RMN cérébrales : segmentation en matières ou en structures	12
VII. Conclusion.....	13

Chapitre II : Segmentation des images IRM cérébrales

I. Introduction.....	14
II. Définition de la segmentation.....	14
III. Approche frontière (contour)	14
IV. Les contours actifs.....	18
IV.1. Présentation du modèle du contour actif.....	18
IV.2. Force d'image	19
IV.3. Approche variationnelle et géométrique	20
V. Le contour actif géométrique (Level set).....	21
V.1. Représentation en courbes de niveau	21
V.2. Le modèle de Level set	22
V.3. Principe général.....	23
V.4 Formulation énergétique	24
VI. Approche region VI.1. Segmentation par seuillage.....	25
VI.2. Segmentation par croissance de région (région growing).....	27
VI.3. Segmentation par division/rassemblage (split and merge)	27
VII. Segmentation par classification	28
VII.1. Méthodologie de la classification	30

VII.3. Algorithme k-means	30
VIII. Classification floue FCM (Fuzzy C-Means)	30
VIII.1. Description de l'algorithme FCM	30
VIII.2. L'algorithme Fuzzy C-means (FCM).....	36
VIII.3. Solution du problème d'optimisation.....	37
VIII.4. Defuzzification.....	38
VIII.5. Application de la methode FCM	38
IX. Comparaison entre k-means et FCM.....	39
X. Conclusion	40

**Chapitre III : Méthodes coopératives entre level set et la classification floue
FCM**

I. Introduction.....	41
III. Base de Donnée	41
IV. Application de la méthode de Level set.....	41
IV.1. Le prétraitement	41
IV.2. Initialisation de la fonction Level set	42
IV.3. Evolution de la fonction ensemble de niveau (Level Set).....	43
VI.4. Résultats et interprétation.....	45
V. Méthode Coopérative entre Level set et la classification floue FCM.....	48
V.1. La coopération entre FCM et Level set.....	49
V.2. Résultat et interprétation.....	49
V.3. Inconvénient de la methode	52
VI. Conclusion	52
Conclusion générale	53

Introduction générale

Introduction générale

L'imagerie par résonance magnétique (IRM) a connu un véritable essor ces dernières années. Cette modalité d'imagerie est devenue un outil de plus en plus important en médecine du cerveau ou dans la recherche en neurosciences cognitives. En effet, les champs d'exploration que cette technique offre sont larges: l'IRM anatomique qui permet d'observer avec une résolution fine les tissus cérébraux, l'IRM fonctionnelle qui offre la possibilité de visualiser l'activité cérébrale et l'IRM de diffusion qui permet d'explorer l'aspect de la connectivité des aires cérébrales. Pour diagnostiquer certaines maladies liées à des lésions cérébrales internes, le médecin doit analyser des images médicales. Pour étudier l'évolution d'une tumeur, il est nécessaire de connaître avec exactitude les changements survenus sur ces images. L'interprétation visuelle des IRM cérébrales, n'est pas toujours sûre. C'est pour cela que le besoin d'une interprétation automatique qui permet d'assister les médecins dans leur prise de décision s'est fait ressentir.

Ainsi, pour une identification et un diagnostic fiables, dans le domaine médical, la précision est primordiale. En termes d'analyse d'images, il est plus que nécessaire que la segmentation soit précise. Les possibilités de traitement automatique de ces images s'avèrent pourtant délicates, car des capacités aussi banales pour l'œil humain que la reconnaissance d'un objet posent de réelles difficultés pour l'outil informatique.

La segmentation d'images est un traitement de bas niveau, elle intervient au cœur de la discipline appelée « analyse ou traitement d'image ». C'est sans doute la clef de voûte de ce domaine, mais également la partie qui pose le plus de problèmes et qui s'avère la plus difficile à automatiser.

L'objectif de notre travail est de concevoir une méthode de segmentation d'images médicales, plus particulièrement des images IRM du cerveau. Notre méthode extrait les différentes principales matières composantes le cerveau (le cerveau, la tumeur...etc.).

Il existe plusieurs algorithmes de segmentation d'images, selon le cas à résoudre. Or chaque méthode possède ses avantages et ses limites d'utilisation. Dans notre travail, nous utilisons une méthode coopérative, de manière à n'utiliser que les avantages des différentes méthodes. En effet, nous tirons parti d'une méthode de segmentation utilisant l'image dans sa globalité pour la segmenter, combinée à un algorithme qui permet de tenir compte des caractéristiques locales de l'image. Nous exploitons une segmentation basée sur la logique floue ainsi que la méthode de Level set.

Ce mémoire s'articule autour de trois chapitres qui nous permettront de présenter les différents aspects de notre travail.

Le premier chapitre est dédié au cadre d'application de ce mémoire. Il introduit les termes et concepts essentiels pour appréhender l'analyse des images IRM cérébrales. Nous y présentons quelques notions d'anatomie du cerveau, qui

permettront d'introduire les principes de l'imagerie par résonance magnétique cérébrale.

Nous avons ensuite présentes dans le chapitre deux, les méthodes de segmentation d'images, ou nous avons décrit un certain nombre de méthodes classiques de segmentation, soit par approche contour ou par approche région.

Le chapitre trois est consacré à la présentation des résultats par l'algorithme que nous avons implémenté (méthode coopérative entre Level set et la classification floue FCM). Nous exposons également les différents cas particuliers que nous avons rencontrés à l'issue de cette segmentation. Nous terminons ce travail par une conclusion générale.

Chapitre I
Contexte médicale

I. Introduction

Dans ce chapitre préliminaire, nous d'écrivons le cadre biomédical de notre travail. Nous commençons par une description macroscopique est microscopique du cerveau, nous présentons, ensuite, les différentes lésions et les tumeurs qui peuvent l'affecter, leurs symptômes ainsi que leurs diagnostic. Nous terminons ce chapitre par une présentation du principe de base du système d'acquisition permettant d'obtenir d'excellentes images cérébrale : il s'agit de l'imagerie par résonance magnétique nucléaire (IRM).

II. Description macroscopique et microscopique du cerveau**II .1.Description macroscopique**

Le cerveau humain est un organe impair de forme schématiquement ovoïde à grand axe antéropostérieur, dont le volume moyen est de 1100 **cm³** chez la femme et de 1400 **cm³** chez l'homme. Le poids du cerveau varie de 1400 à 1800 gramme. Il occupe la boîte crânienne, mais il n'est pas en contact directe avec la cavité osseuse. Il baigne dans le liquide cérébro-spinal a l'intérieur d'une enceinte liquidienne.

Il comprend plusieurs régions : les deux hémisphères cérébraux, le cervelet, en relation les unes avec les autres et avec les organes ou d'autres parties du corps. Le tronc cérébral est sous le cervelet et met en communication le cerveau avec la moelle épinière qui se trouve dans la colonne vertébrale.

Le cerveau est forme de deux hémisphères cérébraux, d'aspect plisse dont la substance blanche, interne, est recouverte d'un cortex cérébral gris, d'épaisseur variable. Trois sillons plus accentues (scissure de Sylvius, sillon de Rolando, sillon perpendiculaire), divisent chaque hémisphère en quatre lobes (frontal, temporal, pariétal, occipital) comprenant chacun un certain nombre de circonvolutions (figure I.1) :

- Le lobe frontal ;
- Le lobe pariétal, sépare du lobe frontal par le sillon central ;
- Le lobe occipital, sépare du lobe pariétal par la fissure Pareto-occipital ;
- Le lobe temporal, sépare du lobe frontal par la vallée Sylvianne ;

Le cerveau commande la plupart des fonctions du corps : la respiration, la contraction des muscles, les battements du cœur et les informations sensorielles : la vision, l'ouïe, toucher, l'odorat et le goût. Il est constitue de cellules nerveuse, les neurones, et de cellules qui en assurent le soutien, la Protection et la nutrition, les cellules gliales. La multiplication des cellules gliales, et non de celle des neurones résultent les principaux cancers du cerveau.

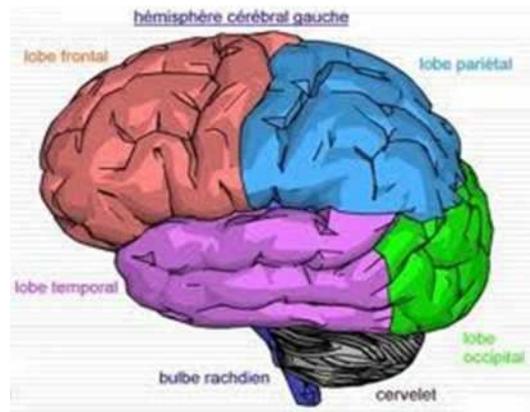


Figure I.1 : La position des quatre lobes dans le cerveau

II.2. Description microscopique

D'un point de vue microscopique, le tissu nerveux se compose de cellules nerveuses (neurones) et de cellules gliales (cellules de soutien et de protection) qui dérivent de l'ectoderme. Les vaisseaux et les méninges n'appartiennent pas au tissu nerveux et dérivent du mésoderme.

Le neurone est la cellule qui constitue l'unité fonctionnelle du névraxe. Les neurones sont de 10 à 50 fois nombreuses que les cellules gliales. Le système nerveux humain comprend environ 100 milliards de neurones. Les neurones assurent la transmission d'un signal ou ce qu'on appelle l'influx nerveux.

Le système nerveux central est constitué de la moelle épinière logée dans le canal vertébral, et de l'encéphale qui est constitué du tronc cérébral, du cervelet et du cerveau. L'ensemble flotte dans un coussin protecteur de liquide céphalorachidien(LCR).

III. Les tissus du cerveau

Lorsqu'on observe le cerveau, on remarque que ce dernier est principalement constitué d'une substance blanche et une substance grise.

III.1. La substance grise

On désigne sous le nom de substance grise la partie des tissus du système nerveux central composée essentiellement des corps cellulaires et de l'arbre dendritique des neurones ainsi que de certaines cellules gliales. Dans l'encéphale, la substance grise est située en périphérie, c'est-à-dire autour de la substance blanche.

III.2. La substance Blanche

La substance blanche contient les axones qui sont les prolongements des neurones. Ces prolongements particulièrement sont entourés d'une gaine de myéline et de cellules de nature non

nerveuse participant a la structure du tissu interstitiel neuronal : la névroglie. Le rôle de la substance blanche est d'assurer la conduction de l'influx nerveux.

III.3. Les meninges

L'encéphale est entouré des couches protectrices appelées les méninges. Elles sont constituées de trois membranes successives:

- La plus interne de ces membranes est la pie-mère : fine, compacte, elle 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 (le LCR circule entre celle-ci et la pie-mère).
- La membrane la plus externe est la dure-mère : dure et résistante, elle est formée de tissu conjonctif qui protège les couches sous-jacentes des oses.

III.4. Le liquide Céphalo-rachidien:

Le liquide cérébro-spinal (LCS) ou encore liquide céphalo-rachidien (LCR) est un liquide corporel transparent dans lequel baignent le cerveau et la moelle épinière. Il est contenu dans les méninges, plus précisément entre la pie-mère (qui recouvre le système nerveux central) et l'arachnoïde (qui tapisse le versant interne de la dure-mère). C'est également le liquide qui circule dans les quatre ventricules cérébraux, à l'intérieur du cerveau, et dans le canal central de la moelle épinière. Il est constitué de 99 % d'eau.

Le liquide céphalo-rachidien absorbe et amortit les mouvements ou les chocs qui risqueraient d'endommager le cerveau.

III. Lésions cérébrales

Une lésion cérébrale est une lésion qui touche le cerveau. En général, il s'agit d'une destruction plus ou moins étendue du tissu nerveux entraînant un déficit dans la perception, la cognition, la sensibilité ou la motricité en fonction du rôle que jouait la région atteinte dans l'architecture neurocognitive. Cette lésion peut être de nature diverse : ischémique, hémorragique, compressive par un processus expansif de type tumoral ou un hématome.

Après l'âge de vingt ans, nous perdons chaque jour des milliers de neurones. Il existe en outre un certain nombre de maladies, telles que la maladie de Parkinson, la maladie d'Alzheimer et les tumeurs du cerveau, qui augmentent cette dégénérescence cellulaire.

Les neurones peuvent aussi être endommagés par une blessure à la tête ou par un problème d'irrigation des tissus cérébraux (attaque ou accident vasculaire cérébral). Enfin, il peut arriver que

les chirurgiens soient obligés de retirer une partie des tissus en procédant à l'ablation d'une tumeur cérébrale.

Lorsque des cellules d'une région spécifique sont lésées, les troubles observés correspondent aux fonctions organiques normalement assurées par cette région. Dès que la pathologie est plus diffuse et que des cellules meurent, quelle que soit leur localisation, on constate l'apparition de troubles démentiels (perte des fonctions cérébrales globales), de pertes de la mémoire, troubles de personnalité ou du comportement et du raisonnement. Ces symptômes peuvent entraîner des symptômes psychologiques tels qu'un isolement social, des modifications brusques de l'humeur, de l'anxiété, des oublis et une négligence de soi. Les sujets, victimes de ces troubles, sont généralement conscients, du moins au début ; car, à mesure que les neurones sont détruits.

Dans les cas où un nombre limité de neurones disparaissent dans une région particulière du cerveau, les manifestations sont moins graves. La nature des dysfonctionnements dépend alors de la position exacte des lésions. Toutefois, le cerveau étant un organe très complexe et aux interconnexions multiples, il n'est pas aisé de désigner une région spécifique comme responsable d'une fonction donnée.

Dans ce qui précède, nous avons présenté des généralités sur les lésions cérébrales. Dans ce qui suit, nous d'écrivons, les tumeurs du cerveau.

IV.1. Développement des tumeurs cérébrales

Les multiples recherches sur les facteurs environnementaux et héréditaires ne permettent pas, à l'heure actuelle, de définir clairement la relation entre ces facteurs et le développement d'une tumeur cérébrale. Par ailleurs, les recherches progressent dans un certain nombre de nouveaux domaines tels que les oncogènes (gènes spécifiques associés au cancer) et la production anormale de facteurs de croissance spécialisés. Rarement, les tumeurs cérébrales se développent en relation avec des maladies familiales (génétiquement transmises) telles que la neurofibromatose, la maladie de Von Hippel Lindau ou la sclérose tubéreuse de Bourneville.

IV.2. Tumeur cérébrale primaire et tumeur cérébrale métastatique ou secondaire

Les tumeurs cérébrales primaires sont celles qui se développent dans les cellules spécialisées qui constituent le cerveau et son enveloppe.

Les tumeurs cérébrales métastatiques proviennent d'un autre organe tel que les poumons, les seins, les reins ou la peau.

IV.3. Tumeurs cérébrales bénignes et tumeurs cérébrales malignes

IV.3.1. Les tumeurs cérébrales bénignes

Elles sont constituées de cellules qui croissent lentement et qui, a l'analyse microscopique n'ont pas de caractère d'activité importante. Une tumeur cérébrale bénigne peut être soit simplement surveillée radiologiquement soit être extirpée chirurgicalement complètement ou de façon partielle. Si une tumeur bénigne n'est pas complètement enlevée, elle peut récidiver.

IV.3.2. Les tumeurs cérébrales malignes

Elles sont Classées « cancéreuses », définissent certaines tumeurs primaires ainsi que toutes les lésions cérébrales métastatiques. Elles sont constituées de cellules qui se divisent relativement vite. Ces tumeurs croissent donc rapidement et peuvent envahir et endommager les structures cérébrales importantes. Elles peuvent être traitées par la chirurgie, la radiothérapie, la chimiothérapie ou la combinaison de celles-ci.

IV.4. Signes et symptômes associés a la présence de tumeurs cérébrales

Les manifestations cliniques d'une tumeur cérébrale sont variables. En effet, elles dépendent de la localisation, du volume de la lésion et de l'hypertension intracrânienne et l'hydrocéphalie et/ou de l'ce dème associées ou non. Par exemple, IL peut s'agir de:

<ul style="list-style-type: none"> • céphalées • crises d'épilepsie • vertiges/etourdissements 	<ul style="list-style-type: none"> • déficits moteurs ou sensitifs • nausees matinales/vomissements • troubles auditifs 	<ul style="list-style-type: none"> • troubles visuels • changement de la personnalite
---	--	--

Types de tumeurs cérébrales

La classification officielle des tumeurs cérébrales, proposée par l'organisation mondiale de la sante (OMS), s'effectue selon des critères d'origine cellulaire et leur degré de malignité.

- **Les tumeurs neuroepitheliales** : représentant les tumeurs cérébrales primaires les plus fréquentes et elles prennent pour origine, soit les neurones, soit les cellules entourant les neurones (les cellules gliales).
- **Les tumeurs des nerfs périphériques** : proviennent des gaines des nerfs périphériques, qui sont composées de cellules différentes que celles que l'on trouve dans le cerveau .on trouve ces tumeurs au niveau des nerfs crâniens et des nerfs périphériques de tout Le corps.

- **Les tumeurs des méninges** : le cerveau est recouvert d'une fine toile Protectrice qui se nomme méninge est a partir de laquelle peuvent se former des tumeurs.
- **Les tumeurs germinales** : il s'agit de tumeurs rares survenant plutôt chez les enfants et jeunes adultes, dont l'origine cellulaire est germinale.
- **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.
- **Les métastases (tumeurs cérébrales les plus fréquentes)**: elles sont malignes et secondaires a une tumeur d'une autre région du corps (poumon, sein, rein, peau).

V. Le diagnostic des tumeurs cérébrales

V.1. Examen clinique

Lorsqu' un médecin suspecte une tumeur cérébrale, il va d'abord réaliser un examen clinique complet afin de localiser la zone cérébrale suspecte. En effet, chaque territoire du cerveau étant associe a une fonction spécifique de l'organisme, la détection de symptômes périphériques peut indiquer qu'elle est la zone du cerveau qui est touchée.

V.2. Examens complémentaires

En fonction de l'état du patient, d'autres examens peuvent se révéler nécessaires. Une ponction lombaire qui consiste à prélever un peu de liquide céphalo-rachidien au moyen d'une aiguille, une artériographie au cours de laquelle on injecte du produit iode dans les artères du cerveau de façon a mieux précisé leur trajet.

V.3. La biopsie cérébrale

La biopsie consiste a effectuer un prélèvement chirurgical d'un fragment de la tumeur. Cet acte très délicat est réalise par un chirurgien au bloc opératoire sous anesthésie générale. L'objectif est Les risques directs sont par contre bien présents, essentiellement avec le geste chirurgical (infection, hémorragie...) ou ce qui l'entoure (l'anesthésie notamment).

V.4. Imagerie médicale

Cet examen sera complet par des techniques d'imagerie : scanner et IRM cérébraux. Dans notre travail, nous nous intéressons aux images cérébraux acquissent par l'imagerie par résonance magnétique nucléaire (IRM), car elle nous permet d'obtenir d'excellentes images du cerveau. Dans ce qui suit nous présentons le principe général d'IRM.

V.4.1. Imagerie par résonance magnétique (IRM)

L'imagerie par résonance magnétique nucléaire (IRM) est une technique d'imagerie médicale d'apparition récente, non invasive et sans effets secondaires permettant d'avoir une vue 2D ou 3D d'une partie du corps, notamment du cerveau. Elle est basée sur le phénomène physique de résonance magnétique nucléaire. Il s'agit simplement d'observer la résonance magnétique nucléaire (RMN) des protons de l'eau contenus dans l'organisme. Le principe consiste à mesurer l'aimantation des tissus biologiques et à reconstruire une image à partir de ces aimantations. Cette dernière est induite par l'hydrogène, qui s'y trouve en abondance dans le corps humain.

Le patient placé dans un puissant champ magnétique, tous les atomes d'hydrogène s'orientent dans la même direction : ils sont alors excités par des ondes radio durant une très courte période. À l'arrêt de cette stimulation, les atomes restituent l'énergie accumulée en produisant un signal qui est enregistré et traité sous forme d'image par un système informatique.

Après arrêt de la stimulation, les atomes d'hydrogène restituent cette énergie qui se dissipe dans différents plans de l'espace sous l'action du champ magnétique de l'aimant. L'énergie est alors captée par d'autres antennes (antennes réceptrices) puis analysée par un ordinateur. Suivant la composante en eau des tissus analysés, leurs pathologies éventuelles, les images seront différentes et l'ordinateur réalise des images en noir et blanc d'une très grande sensibilité et très précieuses pour le diagnostic, notamment en matière de pathologie tumorale ou infectieuse. Il est ainsi possible de réaliser des coupes de n'importe quelle partie du corps, dans tous les plans de l'espace.

V.4.1.1. Principales composantes d'IRM

Un système d'imagerie par résonance magnétique est constitué principalement des éléments suivants :

- l'aimant (il existe trois types) qui produit le champ \vec{B}_0 .
- les bobines de gradient de champ magnétique qui permettent le codage du signal dans l'espace.
- des antennes (émission des ondes RF et réception du signal).
- Et un ordinateur performant qui assure la synchronisation, l'acquisition et le traitement des signaux afin de reconstruire l'image.

a. L'aimant : est au cœur du fonctionnement de l'appareil IRM. Son rôle est de produire le champ magnétique principal appelé B_0 qui est constant et permanent. L'unité de mesure de la puissance du champ magnétique de l'IRM est le Tesla.

b. Les bobines de gradient de champ magnétique

Ce sont trois bobines métalliques enfermées dans un cylindre en fibres de verre et placées autour du tunnel de l'aimant. On les nomme respectivement : bobine X, bobines-Y et bobine Z. Le passage d'un courant électrique dans ces bobines crée des variations d'intensité du champ magnétique dans le tunnel, de façon linéaire, dans le temps et dans l'espace. En fonction de sa géométrie, chaque bobine fait varier le champ magnétique selon un axe spécifique :

- la bobine X selon l'axe droite-gauche ;
- la bobine Y selon l'axe avant-arrière ;
- la bobine Z selon l'axe haut-bas.

Elles permettent notamment de sélectionner une épaisseur et un plan de coupe (transversal, frontal, sagittal ou oblique) et d'effectuer la localisation spatiale des signaux dans ce plan.

C. Les antennes

Elles sont capables de produire et/ou capter un signal de radiofréquence (R.F.). Elles sont accordées pour correspondre à la fréquence de résonance de précession des protons qui se trouvent dans le champ magnétique :

Les antennes sont très variables et peuvent être catégorisées de trois manières différentes :

- Selon leur géométrie : volumique et surfacique.
- Selon leur mode de fonctionnement : émettrice-réceptrice ou réceptrice seule (on parle aussi de réceptrice pure).

Selon l'association ou non de différents éléments d'antennes : linéaire, en quadrature de phase ou en réseau phase.

D. Le calculateur

Un processeur vectoriel assure la gestion de l'ensemble de l'acquisition et du traitement. Il commute les gradients, contrôle les séquences d'impulsions, recueille les signaux, effectue la transformée de Fourier (FFT) et stocke sur un support magnétique l'image sur une matrice de pixels.

E. Les blindages

En IRM, on parle de blindages pour certains dispositifs destinés au confinement des champs magnétiques produits par la machine et à l'isolement de celui-ci des champs magnétiques extérieurs qui viendraient perturber l'acquisition.

Il permet des acquisitions synchronisées sur un autre signal périodique (comme ECG, rythme respiratoire).

V.4.1.2. Acquisition des images IRM

L'IRM permet d'obtenir des images numériques en trois dimensions d'une précision inférieure au millimètre, du cortex, de la substance blanche, du liquide céphalo-rachidien et des noyaux gris centraux.

Deux paramètres réglables cliniquement entrent en jeu lors de l'acquisition : le temps de répétition des séquences d'impulsion (TR), et le temps d'écho (TE). Une acquisition effectuée avec des temps TR et TE courts est dite en T1 (Figure I.2.a).

Lorsque ces deux temps sont longs, elle est dite en T2 (Figure I.2.b). Enfin lorsque TR est long et TE est court, elle est dite en rho ou densité de proton.

Toute l'acquisition peut être caractérisée par rapport à ces trois types particuliers. Ainsi, on parle d'image pondérée en T1 si l'acquisition se rapproche plus de type d'acquisition en T1 que des deux autres types : de façon similaire, on parle d'acquisition pondérée en T2 ou en ρ . De plus, on peut renforcer le signal de certaines structures sur les séquences pondérées en T1 grâce à l'utilisation d'un agent de contraste tel que le gadolinium.

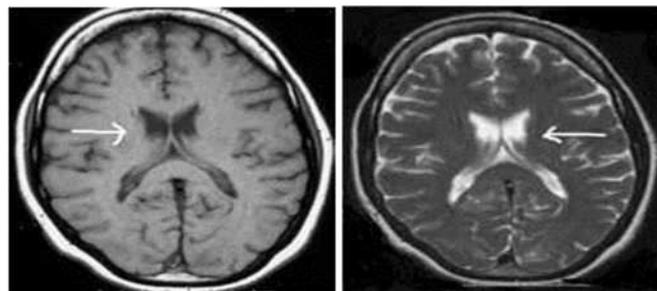


Figure I.2: Acquisition des images IRM ;(a) : Acquisition pondérée en T1 ;
(b) : Acquisition pondérée en T2

Au niveau cérébral, l'IRM permet également d'étudier les artères du cou et du cerveau (figure I.3).

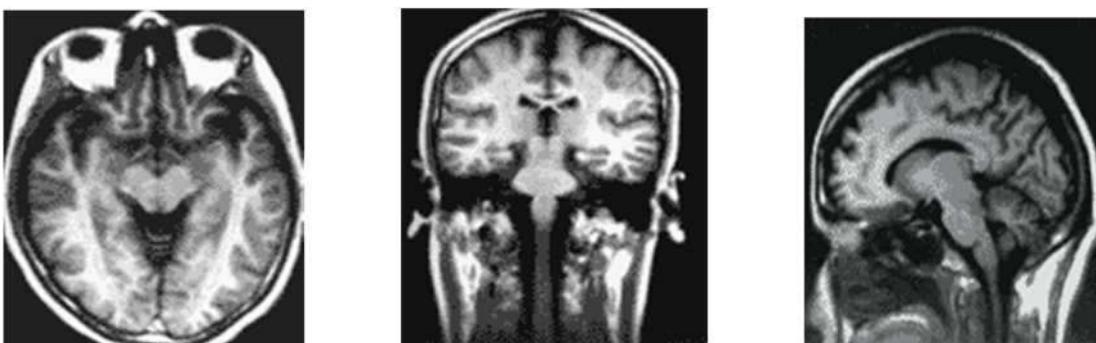


Figure I.3: Les différentes coupes du cerveau, (a) : Coupe axiale,
(b) Coupe coronale, (c) : Coupe sagittale.

V.4.1.3. Les artefacts

Les artefacts en IRM peuvent déformer l'image anatomique réelle et/ou simuler un processus pathologique. Les artefacts sont dus aux :

a. Artefact de mouvement

L'artefact de mouvement est un des artefacts les plus fréquemment rencontrés. Il se constitue lorsqu'il y a translation dans l'espace du segment étudié au cours de l'acquisition. IL y a deux types de mouvements rencontrés:

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

Ils ont pour conséquence la dispersion du signal : image floue de la structure en mouvement.

c. Inhomogénéités RF

Les inhomogénéités dans les champs magnétiques principaux et dans le champ génère par les impulsions RF peuvent provoquer une inhomogénéité, dans la distribution des intensités de l'image obtenue en IRM, qui handicape les approches purement photométriques. Ce type d'artefacts n'est pas foncièrement gênant pour clinicien. Par contre il peut être problématique pour un système de traitement d'image automatique.

d. Volume partiel

La notation de volume partiel n'est pas propre à l'IRM, mais concerne toutes les techniques d'imagerie. Ces artefacts sont liés à la résolution des images. Ainsi, au niveau d'une interface entre deux tissus, dans la direction de la sélection de coupe, l'utilisation de coupe fine permet de bien séparer les tissus. En revanche, une coupe plus épaisse contient, à la fois, les deux tissus : le signal résultant sera alors une moyenne du signal des tissus, d'où une perte d'information en termes de contraste. Il en résulte également une perte de la résolution spatiale puisque le signal des petites structures va être moyen avec celui des structures adjacentes, ce qui peut les rendre invisibles ou peu distinctes.

e. Le bruit :

Le bruit d'image est la présence d'informations parasites qui s'ajoutent de façon aléatoire aux détails dans les images acquises. Il est plus particulièrement visible dans les zones peu éclairées, où le rapport signal/bruit est faible. Il a pour conséquence la perte de netteté dans les détails.

VI. Segmentation d'images de RMN cérébrales : segmentation en matières ou en structures :

Lors de la segmentation des images IRM cérébrales, plusieurs niveaux de description peuvent être choisis selon que l'on s'intéresse pour une application donnée :

- au tissu présent en chacun des pixels : trois matières sont alors essentiellement prises en compte, le liquide céphalo-rachidien, la matière grise ou la matière blanche (auxquels on peut ajouter l'air, la peau, le muscle et l'os si l'on s'intéresse aux matières présentes à l'extérieur du cerveau).
- a la structure cérébrale ou a la région de cette structure que le pixel contient majoritairement : on cherche alors principalement a délimiter le cortex et les noyaux centraux (constitués de matière grise), ou a discriminer le liquide céphalo-rachidien présent à l'intérieur des sillons corticaux, de celui présent dans chacun des ventricules. La description peut, dans ce cas, être d'une complexité variable, selon que l'on cherche ou non à définir des subdivisions des structures anatomiques (par exemple en cherchant a distinguer les différents sillons du cortex) et selon que la description permet de distinguer ou non les différentes aires cérébrales (les hémisphères, les lobes cérébraux, ...).

Dans les deux cas, la présence d'artefacts inhérents au processus d'acquisition rend la segmentation des images plus complexe.

Face a ces difficultés, il est parfois nécessaire d'introduire des connaissances a priori sur :

- la radiométrie des tissus d'une part, afin de segmenter l'image en matières : ces connaissances concernent la forme des distributions d'intensité des tissus.
- l'anatomie cérébrale d'autre part, afin de segmenter l'image en structures anatomiques : ces connaissances concernent alors la forme et la localisation des structures.

VII. Conclusion

Dans les paragraphes précédents, nous avons montrés que malgré tout le soin apporté a l'acquisition, l'information contenue dans l'image peut être perturbée par des phénomènes extérieurs. Dans ce contexte, le traitement d'image devient indispensable. Parmi ces méthodes, la segmentation a pour but de partitionner ou segmenter l'image en un ensemble de régions cohérentes.

De ce fait, dans le prochain chapitre, nous effectuons une rétrospective des différentes méthodes de segmentation d'images et plus particulièrement la segmentation d'images IRM cérébrales.

Chapitre II
Segmentation des images IRM
cérébrales

I. Introduction

La segmentation d'image joue un rôle prépondérant dans le traitement d'image et dans la vision par ordinateur. Cette étape se situe entre d'une part l'acquisition de l'image et son amélioration et d'autre part sa description et la prise de décision finale conséquente. Elle doit réaliser la tâche difficile d'extraire à partir d'une image numérique des informations 'utiles' permettant de localiser et d'éliminer les entités présentes dans l'image. Le but de toutes les méthodes de segmentation est l'extraction d'attributs pour caractériser les objets. Ces attributs correspondent à des points d'intérêt ou à des zones caractéristiques de l'image.

Dans ce chapitre nous allons présenter dans la première partie, la notion générale de la segmentation en analysant de manière plus précise les techniques du contour actif. Nous intéressons par le biais à la méthode d'ensemble de niveau. Dans la deuxième partie, nous décrivons les méthodes de segmentation en région. Nous nous intéressons dans cette partie à des méthodes de classifications telles que K-means et FCM.

II. Définition de la segmentation

La segmentation est un traitement de bas-niveau qui consiste à effectuer une partition de l'image en régions homogènes par rapport à un ou plusieurs critères. Les régions obtenues se distinguent les unes des autres par des différences significatives selon ces mêmes critères. Après ces étapes, nous pouvons introduire un traitement sectoriel de différentes manières.

La segmentation consiste à extraire des points, des lignes ou des régions. Le choix d'une technique de la segmentation est liée à plusieurs facteurs comme : la nature de l'image, les conditions d'acquisition (bruit), les primitives à extraire (contour, texture,...).

La segmentation fait référence aux notions de similarité comme les perçoit, le système visuel humain et ceci donne naissance à deux approches couramment qualifiées d'approche « région » et d'approche « frontière ».

III. Approche frontière (contour)

Dans une image numérique, les contours se situent entre les pixels appartenant à des régions ayant des intensités moyennes différentes ; il s'agit de contours de type « saut d'amplitude ». Un contour peut également correspondre à une variation locale d'intensités présentant un maximum ou un minimum ; il s'agit alors de contour « en toit ».

La notion de « frontière » est associée à une variation d'intensité ou à une discontinuité entre les propriétés de deux ensembles connexes de points.

Donne l'approche locale de détection de contour consiste à balayer l'image avec une fenêtre de finissant la zone d'intérêt. A chaque position, un opérateur est appliqué sur les pixels de la fenêtre afin d'estimer s'il y a une transition significative au niveau de l'attribut choisi. A partir des pixels susceptibles d'appartenir à un contour, il faut ensuite extraire des contours fermes.

Les approches dérivatives

Les approches dérivatives sont les plus immédiates pour détecter et localiser les variations du signal. Les contours sont assimilés aux points de fort gradient ou de dérivée seconde nulle.

a) Opérateurs dérivatifs du premier ordre

1) Gradient

Pour une image $I(x, y)$, le vecteur gradient au point de coordonne (x, y) est donnée par :

$$\nabla I(x, y) = \left(\frac{\partial I}{\partial x}, \frac{\partial I}{\partial y} \right) t$$

Le module de gradient:

$$|\nabla I(x, y)| = \sqrt{\left(\frac{\partial I}{\partial x} \right)^2 + \left(\frac{\partial I}{\partial y} \right)^2}$$

Pour les images digitales, les dérivées directionnelles sont approchées par des simples différences finies:

$$|\nabla I(i, j)| = \sqrt{\left(\frac{\Delta I}{\Delta i} \right)^2 + \left(\frac{\Delta I}{\Delta j} \right)^2}$$

Ou encore :

$$|\nabla I(i, j)| = \max \left\{ \left| \frac{\Delta I}{\Delta i} \right|, \left| \frac{\Delta I}{\Delta j} \right| \right\}$$

$$\frac{\partial I}{\partial x} = \frac{\Delta I}{\Delta i} = I(i, j) - I(i, j-1) : \text{différence horizontale}$$

$$\frac{\partial I}{\partial y} = \frac{\Delta I}{\Delta j} = I(i, j) - I(i-1, j) : \text{différence verticale}$$

Remarque : notons que ces opérateurs sont particulièrement sensibles au bruit.

2) Opérateurs de Prewitt et de Sobel :

Pour ces opérateurs les dérivées directionnelles horizontale et verticale s'expriment sous la forme :

$$\frac{\Delta I}{\Delta j} = h_j * I(i, j) \text{ et } \frac{\Delta I}{\Delta i} = h_i * I(i, j)$$

$$h_j = \begin{bmatrix} 1 & 0 & -1 \\ c & 0 & -c \\ 1 & 0 & -1 \end{bmatrix} \text{ et } h_i = \begin{bmatrix} 1 & c & 1 \\ 0 & 0 & 0 \\ -1 & -c & -1 \end{bmatrix}$$

Les matrices h_j et h_i sont appelées aussi masques, sont les noyaux de convolution de filtres à réponse impulsionnelle finie.

Les masques de Prewitt sont définis par $c=1$ et les masques de Sobel par $c=2$.

Rappelons que la relation entre convolution et corrélation peut être traduite par l'expression :

$$h * I(i, j) = \sum_{m=-M}^M \sum_{n=-N}^N h(m, n) \cdot I(i - m, j - n)$$

Où h est un noyau de convolution de taille $(2M + 1) \times (2N + 1)$.

3) Opérateur de Roberts

Les masques de Roberts sont des versions de Δx et Δy ayant subi une rotation de -45 degrés.

Ce sont de simples différences de niveaux de gris, sans aucun lissage :

$$\frac{\Delta I}{\Delta j} = I(i + 1, j + 1) - I(i, j)$$

$$\text{ET } \frac{\Delta I}{\Delta i} = I(i + 1, j) - I(i, j + 1)$$

Les masques de convolution de Robert sont :

$$\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \text{ et } \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$$

Le module du gradient présente des valeurs les plus élevées au niveau des frontières et quasi nulles sur les régions uniformes.

b) Opérateurs dérivatifs du deuxième ordre

Les contours peuvent être localisés par les passages par zéros du Laplacien

$$\Delta I(x, y) = \frac{\partial^2(x, y)}{\partial x^2} + \frac{\partial^2(x, y)}{\partial y^2}$$

➤ Opérateur du Laplacien

L'approximation discrète la plus simple du Laplacien calculée sur un voisinage de 3 x 3, correspond aux masques suivants :

$$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}, \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \text{ ou } \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

c) Opérateurs optimaux

L'opérateur de Sobel introduit une pondération au niveau des moyennes locales calculées de chaque cote du pixel central. Plusieurs travaux ont cherché à optimiser cette pondération. Canny, en 1983, a postulé trois critères de bonne détection de contours :

- Robustesse au bruit
- Bonne localisation,
- Faible multiplicité des maxima dus au bruit.

En supposant qu'un contour peut se modéliser comme un échelon perturbé par un bruit blanc additif, Canny a traduit chaque critère en termes mathématiques, ces critères utilisés ensuite, pour optimiser le filtre de lissage $f(x)$ et le filtre différentiel correspondant :

$$g(x) = \frac{\partial f(x)}{\partial x}$$

L'optimisation de la robustesse au bruit et de localisation, sous la contrainte d'une distance moyenne minimale entre les réponses multiples, a donné un filtre différentiel g qui rassemble la première dérivée d'une gaussienne.

IV. Les contours actifs

Le modèle de contours actifs se présente sous la forme d'une courbe (fermée ou non) dont l'initialisation est située à proximité du contour recherché et dont l'évolution s'effectue selon un processus itératif de déformation contrôlé par un test de convergence. La convergence du contour actif vers la frontière recherchée est très généralement vue comme une condition de stabilité mais on peut également la percevoir sous un aspect de rupture de modèle par détection de changement d'état d'évolution du contour au travers des différentes itérations.

Le critère selon lequel le processus de déformation fait évoluer le contour a été initialement associé à la recherche d'une minimisation d'une fonctionnelle directement interprétable en terme de contraintes physiques : raideur, élasticité, attache aux données.

III.1. Présentation du modèle du contour actif

Se fondant sur une représentation paramétrée, le contour actif est assimilé à une courbe C représentée selon les notations suivantes :

$$C = \{v(s, t) = (x(s, t), y(s, t)) ; s \in [a, b] \text{ et } t \in [0, T]\}$$

Où a et b désignent les extrémités (fixes, mobiles, confondus ou non) du contour, s désigne l'abscisse curviligne le long du contour, t désigne la variable temporelle et $v(s, t)$ désigne le point courant.

Cette courbe se déplace selon un processus itératif de déformation contrôlé par un test de convergence. Le processus de déformation est lié à la minimisation d'une fonctionnelle d'énergie, construite de telle sorte qu'un minimum local se trouve à la frontière de l'objet à détecter. Cette fonctionnelle énergie, notée $E(C)$, s'exprime par :

$$E(c) = E \text{ interne}(c) + E \text{ externe}(c) + E \text{ image}(c)$$

L'énergie interne est contrôlée l'aspect de la courbe C , et qui permet de garder la cohésion de l'objet, grâce à la somme de deux termes :

$$E \text{ interne}(c) = \int_a^b \alpha(s) \left| \frac{\partial v(s)}{\partial s} \right|^2 ds + \int_a^b \beta(s) \left| \frac{\partial^2 v(s)}{\partial s^2} \right|^2 ds$$

Où la quantité $\left| \frac{\partial v(s)}{\partial s} \right|^2$ agit sur la longueur de la courbe alors que la quantité $\left| \frac{\partial^2 v(s)}{\partial s^2} \right|^2$ agit sur la courbure. La courbe doit être suffisamment lisse et rigide.

Ou les coefficients $\alpha(s)$ et $\beta(s)$ permettent de pondérer les termes liés respectivement à la raideur et à l'élasticité.

- L'énergie externe sert à introduire, par l'intermédiaire de l'utilisateur, des informations de haut niveau. Ceci se traduit par la présence de forces de répulsions en certains points de la courbe ou par la présence de forces d'élasticité simulant l'allongement d'un ressort entre deux points de la courbe. Les informations de haut niveau peuvent être associées à la présence de frontières préalablement détectées (contraintes) ou de points de contrôles (points de passage obligés).
- L'énergie d'image fait intervenir les caractéristiques images que l'on cherche à mettre en valeur. Dans le cas précis où l'on cherche à mettre en valeur les zones de fort contraste, on peut choisir une énergie image par la relation :

$$E_{\text{image}}(C) = -\int_a^b |\nabla(g_\sigma * I(v(s)))| ds$$

Où $|\nabla(g_\sigma * I(v(s)))|$ représente le gradient de l'image I au voisinage de la courbe $v(s)$.

Où ∇ désigne le gradient et g_σ le filtre de gauss d'écart type σ .

Un maximum d'énergie sera atteint si la courbe passe par les points de gradient maximal de l'image lissée par un filtre de gauss.

IV.2. Force d'image

Il existe différentes forces externes : la force image à laquelle peuvent être associées des forces d'optimisation du processus.

La force externe de base (ou force image) est exprimée à partir de l'image et prend des petites valeurs au niveau des contours. Soit une image $I(x, y)$. Pour déformer le modèle vers les contours, la force image est exprimée par :

$$F_{\text{ima}}(x, y) = -\gamma(s) |\nabla[G_\sigma * I(x, y)]|^2$$

Où $\gamma(s)$ représente le coefficient de viscosité, ∇ l'opérateur gradient et $G(x, y)$ une fonction Gaussienne bidimensionnelle de variance σ . Le paramètre γ permet de définir l'étendue de l'attraction voulue mais s'il est choisi trop grand, il peut causer des erreurs de localisation. En général, nous utilisons la formule suivante :

$$F_{\text{ima}}(x, y) = -\gamma(s) \frac{|\nabla I(x, y)|}{|\nabla I(x, y)|}$$

Pour que le contour actif trouve correctement les contours significatifs, il faut alors initialiser le contour à proximité du contour souhaité. Ce qui a une grande influence sur l'évolution du contour :

- Si le contour initial n'est pas proche du contour réel, il n'est pas attiré par celui-ci (arrêt sur des pics de gradient dus au bruit).
- Si le contour n'est pas soumis à aucune force, le contour se rétracte sur lui-même.

IV.3. Approche variationnelle et géométrique

a) Approche variationnelle

L'approche variationnelle consiste à formuler une fonctionnelle d'énergie J dont la minimisation par calcul des variations fournira l'équation d'évolution du contour actif $C(t)$. La fonctionnelle est composée de termes d'énergie, ou critères, qui sont intrinsèques (contraintes internes sur $C(t)$) ou extrinsèques (attachés aux données). Alors que les critères intrinsèques sont souvent basés sur la frontière définie par $C(t)$, les critères extrinsèques sont soit basés sur les frontières ou les régions. Nous utiliserons cette dichotomie opérée sur les critères extrinsèques pour différencier les contours actifs basés sur l'information de frontière de ceux basés sur l'information de région. La technique de descente de gradient est traditionnellement utilisée pour déduire l'équation d'évolution du contour C à partir du calcul des variations :

$$\frac{\partial c}{\partial t} = - \frac{\partial j}{\partial c}$$

Un contour actif évoluant selon l'équation (II.22) tendra à minimiser l'énergie J dont le minimum correspond à la segmentation des objets recherchés dans l'image.

b) Approche géométrique

Lorsqu'un mode de représentation implicite ou explicite a été choisi, il convient de déterminer la vitesse normale $v_N(x, t)$ qui permettra de déformer le contour actif. La détermination de ce champ vectoriel de vitesse est le point crucial des contours actifs puisque leur habilité à segmenter l'objet d'intérêt représenté dans une image.

L'approche géométrique, par analogie avec la Physique, ou par des considérations purement mathématiques, établit directement l'équation d'évolution du contour actif.

Le terme d'attaché aux données de l'image est une fonction g pondérant la vitesse normale. Dans leurs expériences, les auteurs utilisent un terme basé sur les frontières de l'objet à segmenter : lorsque le contour atteint des zones de gradient élevé de l'image, la

fonction de pondération tend vers zéro. L'expression de la vitesse normale est donnée par l'équation suivante :

$$Vn = g(|\nabla I|)(k + c)$$

Le principal problème de cette approche est la sensibilité à l'initialisation du contour actif.

La suite de cette étude s'intéresse à la représentation dite implicite des contours actifs.

La représentation implicite, encore appelée représentation par courbe de niveaux ou représentation Level set, présente moins de contraintes quant à la géométrie des objets qui peuvent être irréguliers (présences de fortes courbures) et dont la topologie peut changer en cours de convergence.

V. Le contour actif géométrique (Level set)

La méthode du Level set décrit à travers une fonction scalaire φ définie sur une grille fixe. L'équation d'évolution, formalisée sous la forme d'une équation à la dérivée partielle (EDP) d'évolution de courbe, est contrainte par un champ de vitesse imposé dans le sens du contour. Ce champ est construit de manière à attirer le modèle vers les objets à extraire dans l'image sous contraintes de régularisation géométriques [13].

La normale et la courbure du Contour en chaque point sont facilement définies à partir des propriétés différentielles géométriques de cette présentation.

V.1. Représentation en courbes de niveau

Dans le cas des contours actifs, la courbe à l'instant $t+1$ est déduit de la courbe à l'instant t , ce qui implique une paramétrisation intrinsèque à la courbe. Par contre dans le cas des courbes de niveaux, la propagation de la courbe est déduite à partir de la propagation de φ . La courbe $c(t)$ change alors de topologie sans problème de paramétrisation. Dans cette technique c est l'intersection de $(\varphi(t))$ avec le Plan défini par $\varphi = 0$, la forme de cette intersection peut être quelconque.

L'équation décrivant l'évolution de la fonction φ par rapport au temps s'écrit alors :

$$\forall x \in C(t), \frac{\partial \varphi(x(t))}{\partial t} = 0$$

Il vient alors :

$$\frac{\partial \varphi(x,t)}{\partial t} + \left\langle \nabla \varphi(x,t), \frac{\partial (x(t))}{\partial t} \right\rangle = 0$$

En remplaçant par :

$$\frac{\partial(x(t))}{\partial t} = V(x, t)N(x, t)$$

Ou V est la vitesse d'évolution

L'équation devient :

$$\varphi(x, t) = -\langle \nabla\varphi(x, t), V(x, t)N(x, t) \rangle$$

On décomposant l'expression, on a finalement :

$$\varphi(x, t) = -\langle \nabla\varphi(x, t), V(x, t)N(x, t) \rangle \geq 0 \tag{II.28}$$

Cette équation permet une bonne mise en œuvre des contours déformables. En effet, les changements de topologie sont gères automatiquement. Ainsi, si l'image contient plusieurs objets, le contour se scinde au cours de son évolution pour englober chaque objet séparément. Le contour peut également se déformer pour s'ajuster a des formes complexes (avec excroissances par exemple), ce que ne peuvent pas faire les snakes.

Le modèle de Level set

Dans le modèle d'origine des contours actifs, la courbe est représentée par une liste de points et d'évolution de la courbe par la variation des coordonnées de ces points.

Elle introduit un modèle géométrique, puis notion de contour géodésique. Malladi implémente une évolution de la courbe basée sur un schéma de «Level set » qui permet de gérer automatiquement les changements de topologie.

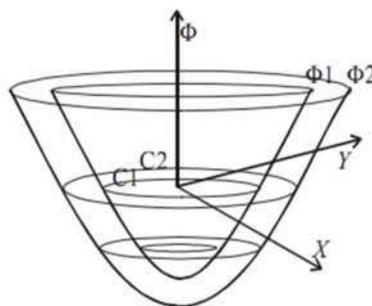


Figure II.1 : formulation des «level sets »

En rapport avec la figure II. 1, pour une courbe fermée C dans le plan d'équation $\Phi=0$, on peut construire une fonction $\Phi(x, y)$ telle que $\Phi(x, y) < 0$ a l'intérieur de C, $\Phi(x, y) > 0$ a l'extérieur de C et $\Phi(x, y) = 0$ sur C. La courbe C est appelée « level set » de Φ . Deux fonctions $\Phi : \Phi_1$ et Φ_2 chacune avec leur « Level sets » C_1 et C_2 apparaissent sur la figure II.1 Si, on suppose, dans le plan $\Phi=0$, qu'une courbe évolue de C_1 a C_2 , avec une certaine

fonction de vitesse, au lieu de faire évoluer la courbe, il est possible d'obtenir le même résultat en faisant évoluer une fonction Φ correspondante :

1. Faire $\Phi = \Phi_1$ pour qui le « level set » est C_1 ;
2. Faire décroître graduellement Φ vers Φ_2 ainsi le « level set » se déplace graduellement de C_1 vers C_2 .

Il est possible de réaffecter les propriétés souhaitées de C_1 et C_2 comme propriétés d'évolution de Φ_1 et Φ_2 .

V.3. Principe général

Considérons une image, notée I , et définie dans le domaine Q ,

$$I: \Omega \subset \mathbb{R}^2 \rightarrow [0,1]$$

$$m = (x, t)^T \rightarrow I(x, y)$$

Cette image peut être appréhendée comme une partition de N régions R ; homogènes par rapport à des caractéristiques données (contraste, texture,...) :

$$\forall i \in \{1, 2, \dots, N\}: R \subset \Omega$$

$$R_1 \cup R_2 \dots \dots \cup R_N = \Omega$$

$$\forall (i, j) \in \{1, 2, \dots, N\} \times \{1, 2, \dots, N\} / i = j: R_i \cap R_j = \emptyset$$

Notons $\gamma(p)$ une courbe fermée définie dans Ω et paramétrée arbitrairement par un vecteur, noté p . La région délimitée par ce contour est notée R_γ .

La méthode des contours actifs en deux dimensions se fonde sur un modèle déformable, en considérant la courbe $\gamma(p)$ dynamique, c'est-à-dire $\gamma(p) = \gamma(p, t)$.

Ce modèle doit évoluer vers les frontières de la région recherchée R . Le problème est donc de trouver le vecteur p qui vérifie $R_\gamma = R_i$. Afin de contraindre la progression du modèle, une énergie E lui est associée. Elle est composée de la somme d'un terme d'attachement aux données et d'un terme de régularisation. Le système minimise cette énergie en la convertissant en énergie cinétique jusqu'à la vérification d'un critère d'arrêt. Ce problème

d'énergie peut être formulé par un équilibre de force, correspondant à un problème numérique de descente de gradient :

$$\frac{\partial \gamma(p, t)}{\partial t} = F \text{ avec } \begin{cases} \partial \gamma(p, t = 0) = \gamma_0(p) \\ F = \frac{\delta E}{\delta \gamma} \end{cases}$$

Dans ce modèle, trois degrés de liberté sont laissés au choix de l'utilisateur :

- la représentation de la courbe, qui peut être explicite, paramétrique ou implicite ;
- la définition de la fonction d'énergie, qui se fonde sur des contraintes géométriques et/ou des données extraites de l'image (gradient, paramètres de texture, information temporelle, ...);
- l'initialisation de la méthode qui influe sur la solution trouvée du fait de la non-convexité éventuelle de la fonction d'énergie.

Dans la majorité des cas, l'énergie attachée au modèle peut être écrite comme une combinaison de fonctionnelles intégrales curviligne et surfacique.

V.4 Formulation énergétique

a) Energie intégrale curviligne

Cette énergie de contour peut être exprimée comme une intégrale simple le long du contour d'une fonction f dépendant des caractéristiques de l'image :

$$E_b = \int_{\gamma} f(m) da(m)$$

Cette forme d'énergie conduit au champ de vitesse :

$$F_b = [\nabla \cdot (f(m)n)]n = [f(m)k - \nabla f(m) \cdot n]n$$

Où n est le vecteur normal unitaire, K la courbure euclidienne et ∇ l'opérateur de gradient.

b) Energie intégrale surfacique

Une énergie régionale peut s'exprimer comme une intégrale double sur un sous-domaine de Q d'une fonction g des caractéristiques de l'image :

$$E_{\gamma} = \iint_{R_{\gamma}} g(m, R_{\gamma}) dm$$

VI. Approche region

La notion de « région » fait référence a des groupements de point ayant des propriétés communes. Les méthodes de l'approche région aboutissent directement a une partition de l'image, chaque pixel étant affecte a une région unique.

Donc, la segmentation par approche région consiste a rechercher des ensembles de pixels connexes ayant des caractéristiques de luminosité commune.

a) Définition

Voisinage ET métrique associée.

Le voisinage d'un point est défini comme l'ensemble de point situe a $d \leq 1$ du point considère métrique :

$$d_4(p, q) = |i_p - i_q| + |j_p - j_q| \Rightarrow \text{Voisinage : } V_{4(p)} = \{q \in S, d_4(p, q) \leq 1\} \quad (\text{II.35})$$

$$d_8(p, q) = \max(|i_p - i_q|, |j_p - j_q|) \Rightarrow \text{Voisinage : } V_{8(p)} = \{q \in S, d_8(p, q) \leq 1\} \quad (\text{II.36})$$

b) Formalisme

Soit I une image bidimensionnelle de taille $n \times n$ et E une partition de l'image initiale I.

Définition :

$$\begin{aligned} E &= R_1, R_2, R_3, \dots, R_n \\ I &= \cup R_i (\forall i = 1, \dots, n) \end{aligned}$$

Soit P un prédicat d'homogénéité applique sur un ensemble de pixel, alors E est une segmentation de I selon P si : $P(R_i) = \text{vrai}$ (R_i homogène)

$$P(R_i \cup R_j) = \text{faux} \quad \forall i \neq j \quad (\text{II.37})$$

VI.1. Segmentation par seuillage

La segmentation par seuillage utilise l'histogramme pour extraire les différentes régions de l'image.

Le seuillage est une technique simple, non contextuelle, globale, qui repose sur une mesure quantitative d'une grandeur. Il permet de classer les pixels en deux catégories, ceux dont la mesure est inférieure au seuil (S) et ceux dont la mesure excède ou égale le seuil.

$$g(x, y) = \begin{cases} 0 & \text{si } f(x, y) < s \\ 1 & \text{si } f(x, y) \geq s \end{cases}$$

La transformation produit une image binaire. Les techniques de seuillage présentent de nombreuses variantes. Le seuillage peut être manuel, adaptatif ou bien automatique (basé sur la méthode d'Otsu).

a) Méthode d'Otsu

La méthode développée par Otsu ne s'applique que dans le cas de la binarisation; segmentation d'image en deux catégories (le fond et les objets).

L'idée est de chercher un seuil permettant d'obtenir les deux classes en minimisant une fonction de coût. On va alors essayer diverses valeurs de seuil et choisir celui qui sépare l'histogramme de façon optimale en deux classes (qui minimise la variance intra-classe). En supposant que le nombre de niveaux de gris est 256 et que l'histogramme est noté $h(i)$. Alors on peut définir une mesure de variance intra-classe par:

$$\sigma^2_{intra}(s) = t_1(s) \cdot \sigma_1^2(s) + t_2(s) \cdot \sigma_2^2(s)$$

$$\text{Avec } t_1(s) = \sum_{i=0}^{s-1} h(i) \quad \text{et} \quad t_2(s) = \sum_s^{255} h(i)$$

$\sigma_1^2(s)$: Variance des pixels dont le NG est $<$ seuil S

$\sigma_2^2(s)$: Variance des pixels dont le NG est \geq seuil S

$$\sigma^2_{intra}(s) = \sum_{i=0}^{s-1} h(i) \cdot (i - \mu_1)^2 + \sum_s^{255} h(i) \cdot (i - \mu_2)^2$$

μ_1 et μ_2 sont les moyennes des NG de chaque classe.

On peut alors essayer toutes les valeurs du seuil S possibles et on garde celui qui rend $\sigma^2_{intra}(s)$ minimum.

VI.2. Segmentation par croissance de région (région growing)

- La méthode de croissance de régions est une méthode de fusion.
- L'image est décomposée en primitives 'régions' (une région = un seul pixel).
- Celles-ci sont ensuite regroupées de manière itérative selon un ou plusieurs critères de similarité, jusqu'à ce qu'il n'y ait plus de fusion possible.

a) Application de la méthode de croissance de région

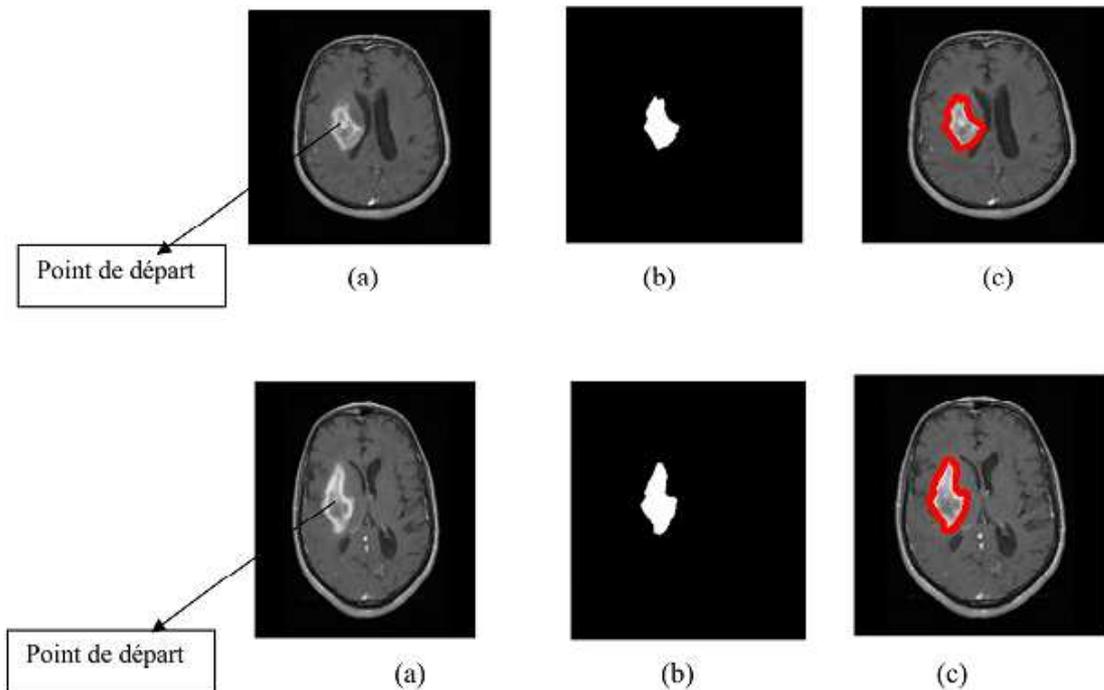


Figure II.2: Résultat de la segmentation par la méthode croissance de région, (a): image originale, (b): image binaire, (c): image segmentée.

b) Interprétation des résultats

L'approche que nous proposons se base sur la méthode de croissance de région. Elle a prouvé son efficacité dans la segmentation d'image médicale. Cela s'explique par le fait que c'est une méthode simple à initialiser et rapide.

On remarque que cette méthode ne s'intéresse pas de lisser le contour de la région segmenter. Contrairement à d'autres méthodes comme les contours actifs.

Segmentation par division/rassemblage (split and merge)

Le processus est décomposé en deux étapes :

- **Division** : analyse de chaque région R_i . Si celle-ci ne vérifie pas le critère d'homogénéité, alors on divise cette région en blocs (le plus généralement en 4 quadrants) et on réitère le processus sur chaque sous-région prise individuellement.

- **Rassemblement** : Si l'union de deux régions voisines (R_i, R_j) vérifie le critère d'inhomogénéité: fusion des régions.
- Soit R_i ($i = 1, \dots, n$) un ensemble de régions effectuant la partition d'une image, et soit P un Prédicat mesurant l'homogénéité de ces régions.
- Si $P(R_i) = \text{faux}$: R_i non homogène (subdivision des régions ou split).
- Si $P(R_i \cup R_j) = \text{vrai}$ ($i \neq j$ et $R_i \cup R_j = \text{ensemble connexe}$): R_i et R_j sont homogènes et doivent être fusionnées (fusion des régions ou merge).
- *a) Application de la méthode de division fusion*

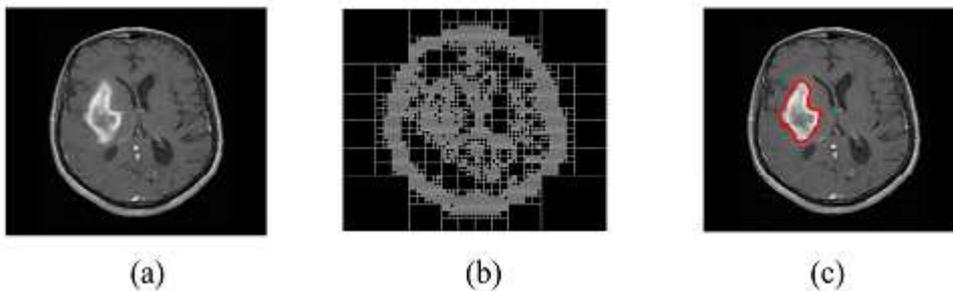


Figure II.3: Résultat de la segmentation par la méthode split and merge, (a): image initiale, (b): application de l'algorithme de division, (c): image segmentée après l'étape de fusion.

b) Interprétation des résultats :

- Dans cette application nous avons utilisés la méthode split and merge pour la segmentation des images cérébrales. Nous avons passés par deux étapes :
La division: analyse de chaque région R_i . Si celle-ci ne vérifie pas le critère d'homogénéité, alors on divise cette région en blocs (le plus généralement en 4 quadrants) et Ton réitère le processus sur chaque sous-région prise individuellement.
- Dans la 2eme partie on s'intéresse à l'application de la technique de fusion : Si l'union de 2région voisines (R_i, R_j) vérifie le critère d'homogénéité : fusion de régions.

Cette méthode "division/fusion" ne donne pas un bonne résultat car nos images (images cérébrales) sont floues et nécessitent un lissage.

VII. 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.

VII.1. Méthodologie de la classification

La mise en œuvre d'une procédure de classification, ayant pour objectif de classer automatiquement des objets. Cette méthode comporte généralement deux phases fondamentales:

- une phase d'apprentissage dont le but est de déterminer un espace de représentation des objets et de rechercher les paramètres discriminants capables de caractériser chaque classe d'objets ;
- une phase de reconnaissance au cours de laquelle on attribue à une classe chacun des objets inconnus dans l'espace de représentation déterminé durant l'apprentissage.

La classification peut être supervisée ou non supervisée.

a) Méthodes supervisées

Les méthodes de classification supervisées supposent la connaissance a priori de l'appartenance de chaque échantillon de l'ensemble d'apprentissage à une classe donnée, ce qui revient à supposer une connaissance a priori sur l'image à segmenter.

Dans notre cas, il s'agit de la segmentation des images médicales IRM cérébrales. La classification supervisée de ces images nécessite la création d'une base d'apprentissage pour chaque classe et pour chaque patient ce qui est en elle-même une tâche très fastidieuse pour les experts. C'est pour cette raison qu'on s'intéresse aux méthodes non supervisées.

b) Méthodes non Supervisées (Automatiques)

La méthode de classification non supervisée a pour but de trouver des partitions d'un ensemble d'individus en fonction de critères de proximité de leurs vecteurs d'attributs dans l'espace de représentation. Elles sont utilisées pour effectuer une classification en aveugle et, ainsi pour réaliser une segmentation sans connaissances a priori sur l'image. Il est par conséquent nécessaire de prendre quelques précautions. La mesure de proximité est calculée

Sur tous les attributs, il n'y a donc pas de réduction de l'espace de représentation. Comme il n'y a pas d'exemples d'apprentissage, si certains attributs utilisés sont non représentatifs des classes recherchées, le résultat pourra être médiocre.

VII.2. Méthodes de classification

La majorité des algorithmes de classification peuvent être divisés en deux catégories :

a) Classification hiérarchique:

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

b) Classification non hiérarchique (partitionnelle):

Il n'y a pas de hiérarchie. Dans la plupart de ces méthodes, le choix a priori du nombre de classes est nécessaire. Les points d'initialisation peuvent être des points du nuage pris au hasard ou les centres roides d'une partition préalable. Les classes obtenues n'ont pas plus d'importance les unes que les autres.

Nous distinguons deux types de classification partitionnelle :

- classification dure
- classification floue

Dans la suite de ce paragraphe, nous présentons la méthode de classification k-Means (k moyennes) et nous présentons ensuite, les méthodes de classification basée sur la théorie des sous-ensembles flous.

VII.3. Algorithme k-means

L'algorithme k-means est l'algorithme de clustering le plus connu et le plus utilisé, du fait de sa simplicité de mise en œuvre. Il partitionne les données d'une image en K clusters. Contrairement à d'autres méthodes dites hiérarchiques, qui créent une structure en « arbre de clusters » pour décrire les groupements, k-means ne crée qu'un seul niveau de clusters. L'algorithme renvoie une partition des données, dans laquelle les objets à l'intérieur de chaque cluster sont aussi proches que possible les uns des autres et aussi loin que possible des objets des autres clusters. Chaque cluster de la partition est défini par ses objets et son centroïde.

Le k-means est un algorithme itératif qui minimise la somme des distances entre chaque objet et le centroïde de son cluster. La position initiale des centres roides conditionne le résultat

final, de sorte que les centroïdes doivent être initialement placés le plus loin possible les uns des autres de façon à optimiser l'algorithme. Le résultat est un ensemble de clusters compacts et clairement séparés, sous réserve qu'on ait choisi la bonne valeur K du nombre de clusters.

Les principales étapes de l'algorithme k -means sont:

1. Choix aléatoire de la position initiale des K clusters.
2. Affecter les objets à un cluster suivant un critère de minimisation des distances (généralement selon une mesure de distance euclidienne).
3. Une fois tous les objets placés, recalculer les K centroïdes.
4. Répéter les étapes 2 et 3 jusqu'à ce que plus aucune réaffectation ne soit faite.

a. Algorithme :

Soit $X = \{X_k / k=1, \dots, n\}$ un sous-ensemble d'un espace n -dimensionnel. Une partition de X en c classes peut être représentée par des sous-groupes mutuellement disjoints $C_1 \dots C_c$ tel que $C_1 \cup \dots \cup C_c = X$.

Chaque vecteur X_k est assigné à une et seulement une classe qui lui est la plus proche.

La fonction objective correspondante s'exprime sous la forme :

$$J = \sum_{i=1}^c \sum_{k=1}^n U_{ik} d^2(x_k, v_i) \quad (\text{II.43})$$

Où :

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

L'indicateur d'appartenance s'exprime comme suit :

$$u(x_k, v_i) = \{1 \text{ si } d(x_k, v_i) = \min_c d(x_k, v_c) \text{ ou } 0 \text{ sinon}\}$$

L'optimisation se fait de manière itérative.

b. Application de la methode k-means

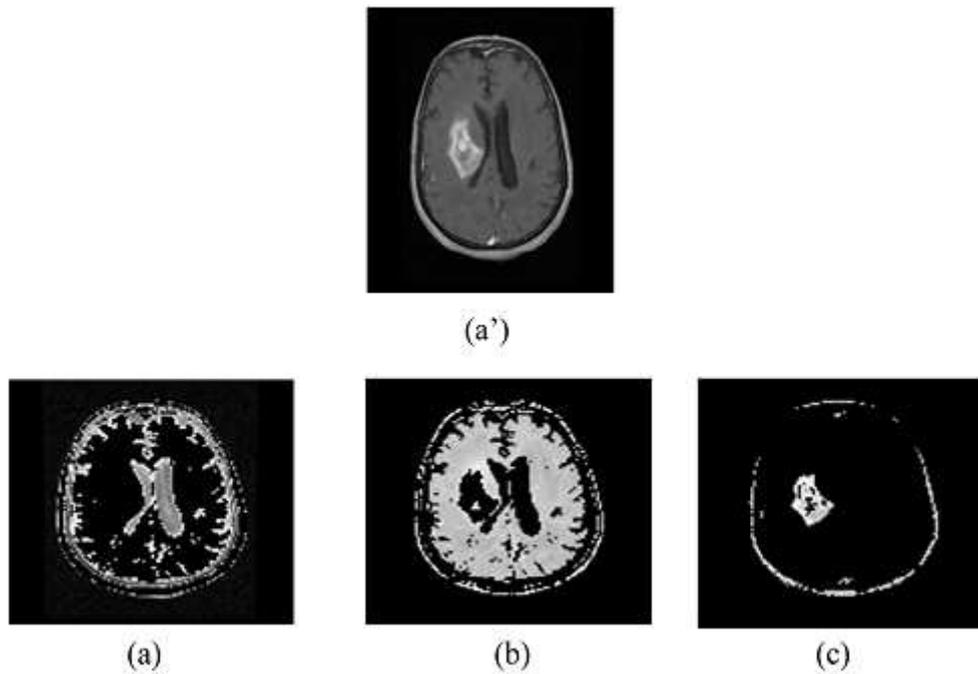


Figure II. 4: Résultat de la segmentation par k-means pour le nombre de classe ($K=3$),

(a) : image initiale, (a) : 1 classe, (b) : 2 classe, (c) : 3 classe.

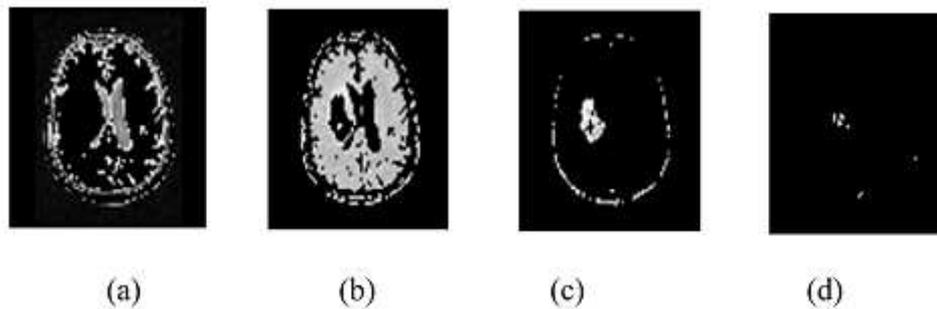


Figure II. 5: Résultat de la segmentation par k-means pour le nombre de classe ($K=4$),

(a) : 1er classe, (b) : 2eme classe, (c) : 3eme classe, (d) : 4eme classe.

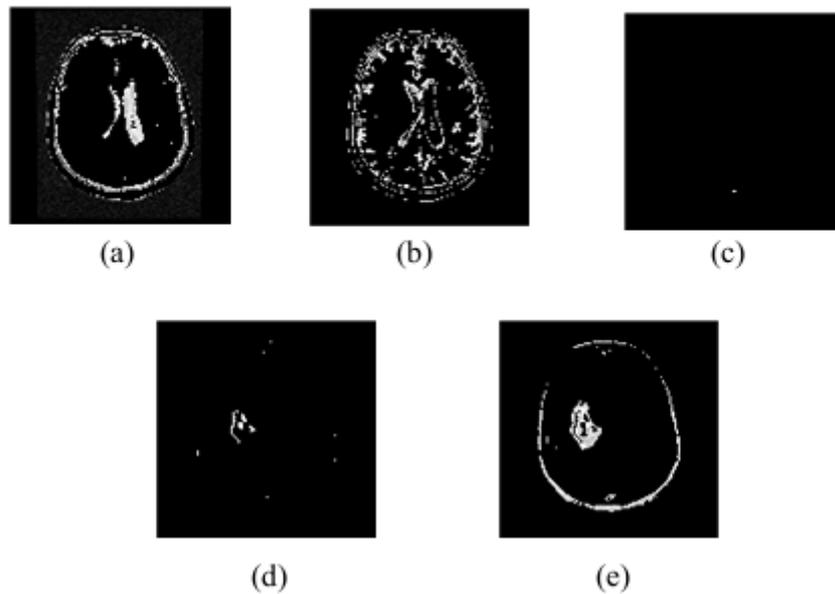


Figure .II.6: Résultat de la segmentation par *k*-means pour le nombre de classe ($K=5$),
 (a) : 1er classe, (b) : 2eme classe, (c) : 3eme classe, (d) : 4^{eme} classe, (e) : 5eme classe.

1) Interprétation des résultats

On remarque que la tumeur apparaît bien dans ces résultats lorsqu'on utilise l'algorithme de *k*-means. L'utilisation plusieurs fois de l'algorithme *k*-means donne des résultats différents, à cause que ces attributs sont non représentatifs des classes recherchées et le résultat pourra être médiocre.

L'algorithme classique de *k*-means laisse un paramètre libre : le nombre de clusters, ce qui dans le cas de la segmentation d'images correspond au nombre d'intensités utilisées pour représenter l'image. Généralement le choix de *k* est fait empiriquement en sélectionnant la valeur de *k* qui minimise l'énergie. Différents critères permettent d'estimer le nombre de clusters en minimisant la distance intra-classes et à maximiser la distance interclasses (par exemple pour la segmentation d'images couleurs).

VII.4. La classification floue

Le principe de la classification floue est d'affecter un élément à classer non pas à une classe comme dans les approches classiques (*k*-means), mais à toutes les classes avec un certain degré.

Ce principe découle de ce qu'on appelle la logique floue, qui est venue compléter la logique classique.

a) La logique floue:

Dans la vie de tous les jours, nous trouvons dans des situations où les informations dont nous disposons ne sont pas toujours précises. Dans le domaine de la science aussi, des imprécisions peuvent être vues ; par exemple lorsqu'on veut établir une valeur qui caractérise le degré de similarité de deux formes.

L'être humain est habitué à utiliser des informations entachées d'incertitudes et d'imprécision dans la vie de tous les jours, il utilise ces informations incomplètes, raisonne avec elles et prend des décisions. Dans le domaine scientifique, il a été nécessaire de créer une logique qui admette des valeurs de vérité en dehors de l'ensemble {vrai, faux} pour pouvoir tenir compte et manipuler ce genre d'information incomplète.

Lukasiewicz propose en 1920 une logique ayant les trois valeurs de vérité suivantes : "Vrai", "faux" et "doute". Ces valeurs ont été représentées par l'ensemble {0, 1, 0.5}, étant ensuite étendues à l'intervalle [0,1].

Néanmoins c'est Zadeh, qui a partir de l'idée d'appartenance partielle d'un élément à plusieurs classes, a introduit la logique floue.

b) La théorie des sous-ensembles flous

La théorie des sous-ensembles flous et les outils de raisonnement qui en découlent, proposent un cadre formel qui permet de modéliser le langage naturel et de gérer l'imprécis et l'incertain. Cette théorie est basée sur la notion de degré d'appartenance. Ces degrés sont des valeurs qui expriment l'appartenance incertaine d'un pixel à une région. Le degré d'appartenance se situe dans l'intervalle [0,1] et les classes obtenues ne sont pas forcément disjointes.

Dans ce cas, les données X_j ne sont plus assignées à une classe unique, mais à plusieurs classes i par l'intermédiaire de degrés d'appartenance μ_{ij} .

Classification floue FCM (Fuzzy C-Means)

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. La classification floue assigne donc, non pas à un pixel une étiquette relative à une classe unique, mais son degré d'appartenance à chacune des classes. Ces valeurs expriment l'appartenance incertaine d'un pixel à une région et sont appelées degrés d'appartenance. Le degré d'appartenance se situe dans l'intervalle [0, 1] et les classes obtenues ne sont pas forcément disjointes. Dans ce cas,

les données X_j ne sont plus assignées à une classe j unique, mais à plusieurs par l'intermédiaire de degrés d'appartenance U_{ij} du vecteur x_j à la classe i . Le but des algorithmes de classification est non seulement de calculer les centres des classes B mais aussi l'ensemble des degrés d'appartenance des vecteurs aux classes.

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

$$\forall i \in \{1..C\}, \forall j \in \{1..N\} \left\{ \begin{array}{l} u_{ij} \in [0,1] \\ 0 < \sum_{j=1}^c u_{ij} < N \\ \forall j \in \{1..N\} \sum_{i=1}^c u_{ij} = 1 \end{array} \right.$$

La fonctionnelle à minimiser (II.47), et les solutions (II.48), (II.49), au problème du FCM sont décrites par les formules suivantes :

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

$$b_i = \frac{\sum_{k=1}^n u_{ik}^m \cdot x_k}{\sum_{k=1}^n u_{ik}^m}$$

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

Description de l'algorithme FCM

Fuzzy C-Means (FCM) est un algorithme de classification non-supervisée floue. Issu de l'algorithme des C-moyennes (C-means), il introduit la notion d'ensemble flou dans la définition des classes : chaque point dans l'ensemble des données appartient à chaque cluster avec un certain degré, et tous les clusters sont caractérisés par leur centre de gravité. Comme les autres algorithmes de classification non supervisée, il utilise un critère de minimisation des distances intra-classe et de maximisation des distances inter-classe, mais en donnant un certain degré d'appartenance à chaque classe pour chaque pixel. Cet algorithme nécessite la connaissance préalable du nombre de clusters et génère les classes par un processus itératif en minimisant une fonction objective. Ainsi, il permet d'obtenir une partition floue de l'image en donnant à chaque pixel un degré d'appartenance (compris entre 0

et 1) a une classe donnée. Le cluster auquel est associé un pixel est celui dont le degré d'appartenance sera le plus élevé.

Les principales étapes de l'algorithme Fuzzy C-means sont :

1. La fixation arbitraire d'une matrice d'appartenance.
2. Le calcul des centroides des classes.
3. Le réajustement de la matrice d'appartenance suivant la position des centroides.
4. Calcul du critère de minimisation et retour à l'étape 2 s'il y a non convergence de critère.

VIII.2. L'algorithme Fuzzy C-means (FCM)

L'algorithme des c-moyennes floues ou fuzzy c-means (FCM) repose sur la recherche des valeurs prises par les centroides des classes et par les degrés d'appartenance des pixels à ces classes, qui en respectant les contraintes, minimisent la fonction objectif suivante:

$$J = \sum_{i=1}^c \sum_{k=1}^n U_{ik}^m d^2(x_k, v_i)$$

Avec:

- c : le nombre de classes connu a priori.
- n : la taille du vecteur de données (nombre de pixels à classer).
- U_{ik} : le degré d'appartenance du pixel x_k à la classe i connue par son centroide v_i .
- d : le degré de similitude, il peut être la distance Euclidienne.
- m : un réel >1 appelé degré de flou. Plus m tend vers 1, plus la classification devient dure et U_{ik} se rapproche de 0 ou de 1. Inversement quand m devient trop grand il y a moins de tolérance au bruit, et la distribution des degrés d'appartenance tend à se concentrer autour de $1/c$.

➤ Notation

- Soit $X = \{x_k, k = 1, \dots, n\}$ un sous-ensemble d'un espace E , de dimension n . Nous cherchons segmenter X en c classes suivant une classification floue. Chaque classe c est caractérisée par son prototype v_i , et $V = \{v_i, i = 1 \dots c\}$ l'ensemble des prototypes des classes.

L'algorithme de la FCM tente à minimiser la fonction objective, par rapport à chaque degré d'appartenance flou et chaque prototype.

- Le rôle de l'indice de flou m est pour contrôler la contribution du bruit présent dans les données.

VIII.3. Solution du problème d'optimisation

De la même façon que pour la classification dure, l'optimisation se fait de manière itérative. Les degrés d'appartenance ou les prototypes sont d'abord initialisés, puis à chaque itération du processus, les appartenances et les prototypes sont mis à jour, et les vecteurs de données se déplacent d'une classe à une autre en vue de minimiser la fonction objectif jusqu'à stabilisation.

Les degrés d'appartenance doivent satisfaire les conditions suivantes:

- $\mathbf{0} \leq \mathbf{u}_{ik} \leq \mathbf{1} \forall i \in [1, c], \forall k \in [1, n]$
- $\sum_{i=1}^c \mathbf{u}_{ik} \forall k \in [1, n]$ relation de fermeture
- $\mathbf{0} < \sum_{k=1}^n \mathbf{u}_{ik} < n \forall i \in [1, c]$ aucune classe vide

Le degré d'appartenance \mathbf{u}_{ik} et le centroïde \mathbf{v}_i s'expriment comme suite :

$$\mathbf{u}_{ik} = \frac{(\mathbf{d}(\mathbf{x}_k, \mathbf{v}_i))^{\frac{2}{m-1}}}{\sum_{j=1}^c (\mathbf{d}(\mathbf{x}_k, \mathbf{v}_j))^{\frac{2}{m-1}}}$$

$$\mathbf{V}_i = \frac{\sum_{k=1}^n \mathbf{u}_{ik}^m \mathbf{x}_k}{\sum_{k=1}^n \mathbf{u}_{ik}^m}$$

Dans ce qui suit, nous présentons l'algorithme résumé de la méthode FCM:

1. Fixer les paramètres;

- c : nombre de classes ;
- ε : seuil représentant l'erreur de convergence (par exemple : = 0.001) ;
- m : degré de flou, généralement pris égal à 2.

2. Initialiser la matrice degrés d'appartenances \mathbf{U} par des valeurs aléatoires dans l'intervalle $[0, 1]$.

3. Mettre à jour la matrice prototype \mathbf{V} par la relation (II.52)

4. Mettre à jour la matrice degrés d'appartenances par la relation (II.51)

Répéter les étapes 3 à 4 jusqu'à satisfaction du critère d'arrêt qui est :

$$\|\mathbf{U}^{\text{ancien}} - \mathbf{U}^{\text{nouveau}}\| < \varepsilon \quad (\text{II.53})$$

VIII.4. Defuzzification :

Enfin, une ultime étape est nécessaire lorsque le résultat souhaité est une classification non floue. On parle alors de « defuzzification ». Lorsque l'on ne souhaite pas mettre en évidence les pixels ou les degrés d'appartenance sont approximativement les mêmes pour chaque classe, une façon naturelle de procéder est de considérer que la classe finale d'un pixel est celle pour laquelle le degré d'appartenance est maximal :

$$- \forall k \in [1, n] x_k \in c_j \Leftrightarrow (u_{ik} < u_{ik} \forall i \neq j \in [1, c])$$

L'étape de la defuzzification se fait après la dernière itération de l'algorithme des c-moyennes floues.

VIII.5. Application de la méthode FCM :

Pour l'algorithme de c-moyenne flou, la décision d'appartenance d'un pixel à une classe n'est prise qu'à la fin de la convergence, contrairement aux k-moyennes qui affectent un pixel à une classe à chaque itération. La FCM offre la possibilité d'agir sur la considération du bruit.

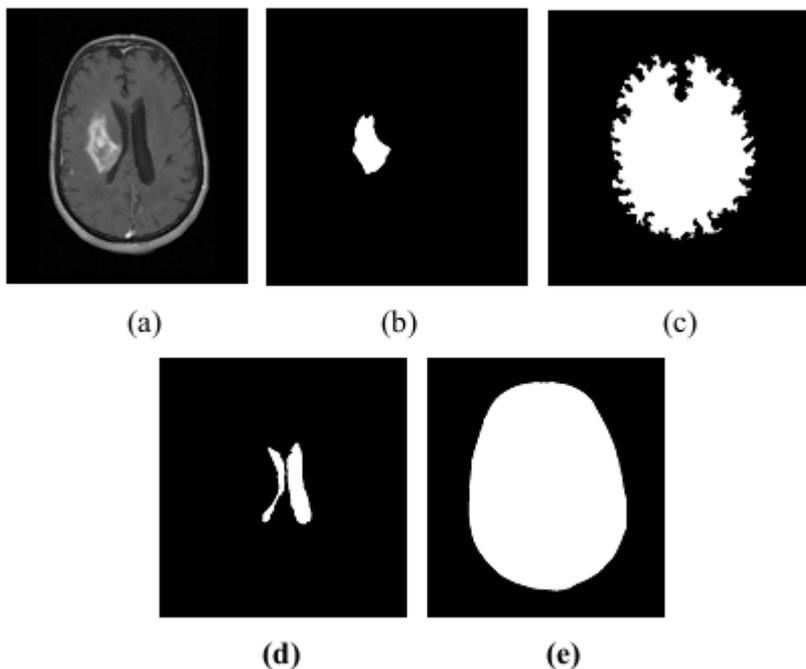


Figure II.7: Résultat de la segmentation par FCM: (a) : image originale;(b) : extraction de la tumeur;(c) : extraction du cerveau;(d) : extraction du liquide céphalo-rachidien; (e) : extraction de contour du cerveau.

2) Interprétation des résultats :

La méthode FCM a été largement utilisée pour la segmentation des images du cerveau. Cet algorithme utilise pour segmenter les régions activées (tumeurs...) du cerveau, et aussi pour détecter les zones affectivement activées qui restaient silencieuses.

Dans cette application, on s'intéresse à l'extraction des différentes parties du cerveau (la tumeur, le contour du cerveau, liquide céphalo-rachidien et la partie gris et la partie blanche). D'après les résultats obtenus on remarque que cette méthode (FCM) permet de détecter ces 4 classes à l'intermédiaire d'un degré d'appartenance et aussi grâce à la fonction de distance suivi d'un processus itératif pour minimiser cette fonction.

Cette méthode donne des meilleurs résultats pour l'extraction des différentes parties du cerveau. Comme les autres méthodes non supervisées, l'inconvénient de cet algorithme c'est comment initialiser le nombre de classes.

Comparaison entre k-means et FCM :

Nous avons testés les méthodes de segmentations Fuzzy C-means et K-means sur une série d'images en NG. D'après les résultats trouvés, k-means étant une technique d'optimisation, il s'arrête lorsqu'il y a plus de pixels à classer.

Mais l'algorithme de FCM donne une représentation floue pour chaque pixel (degré d'appartenance à chaque classe).

Nous avons pu observer que, d'une manière générale, les algorithmes étudiés donnent une bonne segmentation. Néanmoins, les images comportant des défauts donnent un résultat qui semble visuellement correct. Nous avons constaté que les deux algorithmes nécessitent une connaissance préalable du nombre de clusters. Par leur caractère itératif, ils s'avèrent inefficaces lorsque le nombre de clusters devient important.

De manière générale, nous avons pu constater que ces deux algorithmes s'avèrent efficaces lorsque les objets de l'image sont clairement séparés, mais présentant cependant deux inconvénients : d'une part, ils nécessitent le choix préalable du nombre K de clusters, ce qui rend impossible l'automatisation de la méthode ; d'autre part, ils requièrent un temps de calcul souvent élevé, du fait de leur nature itérative.

X. Conclusion :

Dans ce chapitre nous avons présente les méthodes les plus utilisee pour la segmentation des images médicales. Dans notre travail, nous nous intéressons aux techniques de classification automatique (k-moyenne et Fuzzy C-means). Nous avons vu que la segmentation par classification permet de regrouper des objets en classes. Par contre, les méthodes contextuelles (croissance de régions et division-fusion) sont utilisees pour la segmentation des images, en regroupant les objets suivant les critères d'homogénéités.

Dans le dernier chapitre nous introduirons la notion de coopération en segmentation d'images.

Au lieu d'utiliser des méthodes de segmentation classiques, il peut être intéressant de faire coopérer plusieurs approches de segmentation. L'approche que nous proposons dans ce mémoire s'inscrit dans cet axe, c'est la coopération entre l'approche des contours actifs (Level set) et l'approche de classification floue (FCM).

Chapitre III
Méthodes coopératives entre
level set et la classification
floue FCM

I. Introduction

Dans ce chapitre, nous allons développer une méthode de segmentation des images par résonance magnétique nucléaire. Cette technique est basée sur une coopération entre deux méthodes. Dans la première partie, nous allons utiliser la méthode de classification (FCM), alors que dans la deuxième phase, nous allons utiliser la méthode de Level-set pour extraire les caractéristiques locales de l'image. Les différentes étapes de cette approche (Méthode coopérative entre Level set et la classification floue FCM) sont présentées dans les sections suivantes.

III. Base de Donnée

Les images utilisées dans ce mémoire sont des images médicales codées dans le format DICOM de dimension 512x512 pixels. Les images à traiter se présentent sous la forme de coupes axiales du cerveau. Sur ces coupes la tumeur apparaît comme une tache blanche qui se situe dans la partie droite du cerveau. Les différentes tumeurs offrent une très grande variété dans leur taille, forme et couleur, ce qui explique que le diagnostic est parfois difficile à déterminer.

IV. Application de la méthode de Level set

La mise en place de méthodes de segmentation robustes est extrêmement difficile dans le cas des images étudiées; les difficultés rencontrées lors de cette opération sont en effet nombreuses et variées, elles concernent à la fois, les variations de luminosité rencontrées dans l'image, la variabilité des couleurs, font que la segmentation est difficile mais n'est pas possible pour tous les cas. Nous avons commencé ce travail par une étape de filtrage. Cette étape consiste à améliorer les images que l'on veut segmenter afin de faciliter la détection de contour par l'algorithme de Level set.

Dans cette étape, plusieurs images ont été traitées. Le processus de détection de contours par la méthode de Level set est divisé en deux étapes :

- Prétraitement et l'initialisation de la courbe.
- Evolution de la courbe

IV.1. Le prétraitement

Les images que nous avons traitées comportant une grande quantité d'informations. Elles sont généralement bruitées par des pixels indésirables, il est donc, indispensable de passer par une étape de prétraitement.

Afin d'éliminer le bruit sur ces images, nous utilisons un filtre de gauss de variance $a^2 = 1.5$, ce filtre permet d'éliminer l'effet de discrétisation qui se trouve entre les pixels et de faire un lissage de la région d'intérêt. La figure III.1 montre clairement le résultat du filtrage par le filtre de Gauss.

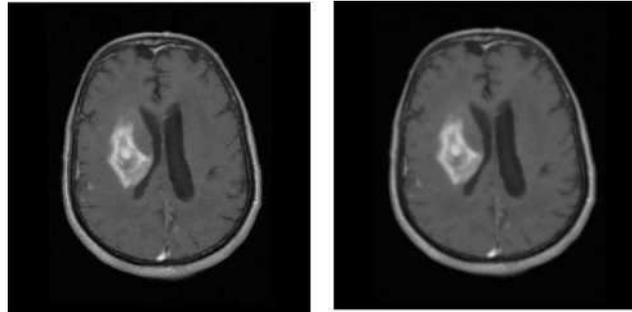


Figure III.1 : Prétraitement, (a) : image originale, (b) : image filtrée par un filtre de gauss

IV.2. Initialisation de la fonction Level set

La formulation vibrationnelle permet d'éliminer complètement le procédé de la réinitialisation. En plus, elle n'exige pas que la fonction φ soit initialisée comme une fonction de distance signée.

On pose φ_0 une fonction initiale et soit Ω_0 un sous ensemble dans le domaine Q de l'image. L'ensemble des points sur les frontières de Ω_0 est note par $d \Omega_0$.

La fonction initiale φ_0 peut être définie comme suite :

$$\varphi_0(x,y) = \begin{cases} -\rho & , (x,y) \in \Omega_0 - \partial\Omega_0 \\ 0 & , (x,y) \in \partial\Omega_0 \\ \rho & \Omega - \Omega_0 \end{cases}$$

Avec ρ : une fonction strictement positive, plus grand que 2ε , (ε étant le coefficient de la longueur pondérée).

Loin des fonctions de distance signée, on propose une fonction d'ensemble de niveau initiale qui est calculée a partir d'une région arbitraire Ω_0 dans notre image à traiter, en s'intéressant a extraire la région d'intérêt (ROI : Région of intérêts) qui représente par exemple la tumeur.

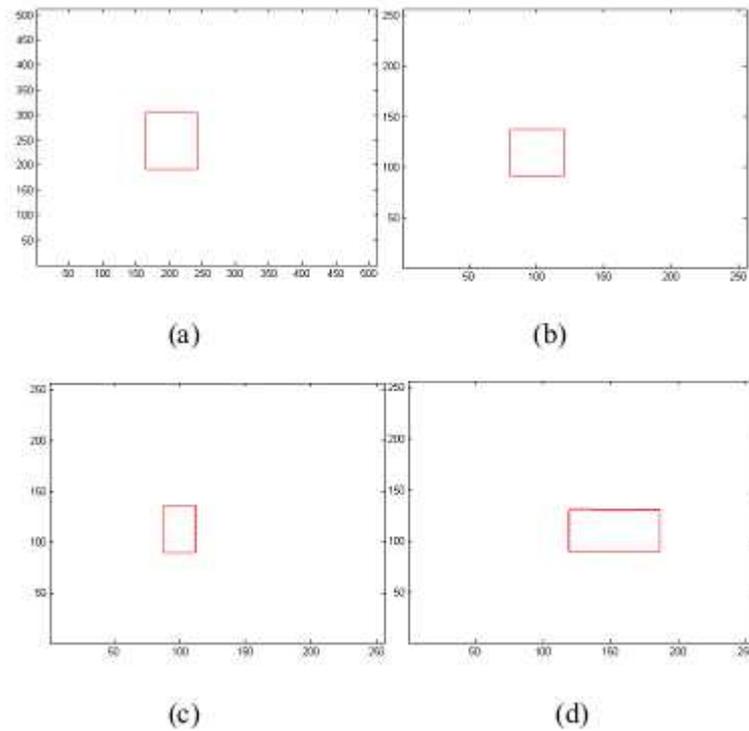


Figure III.2: Initialisation de la courbe initiale, (a):coupe axiale, (b) et (c): deux coupes Coronales, (d):coupe Sagittale.

Dans cette application le contour initial est choisi sous la forme d'un rectangle. La région d'intérêt est localisée par un contour initial (figure III.3) sous la forme d'un rectangle.

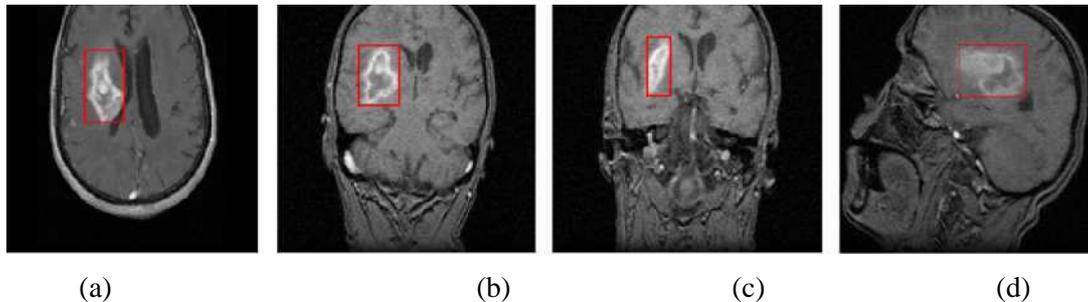


Figure III.3: Initialisation de la courbe: (a) : coupe axial, (b) et (c) : coupe coronale, (d): coupe sagittale.

Ce procédé permet d'alléger le temps de calcul et de faire une partie d'un traitement semi-automatique.

IV.3. Evolution de la fonction ensemble de niveau (Level Set)

L'évolution de la fonction ensemble de niveau (level set) est représentée par le gradient. On pratique l'implémentation de cette équations doit passer par quelques étapes :

- L'arrangement numérique.

Le choix du pas temporel (time step).

➤ **L'arrangement numérique**

La fonction de Dirac doit être légèrement lissée, ceci est possible si on utilise l'étape suivante :

L'approximation présentée dans l'équation précédente peut s'écrire d'une manière plus simple ce qui facilite beaucoup plus les calculs. Pour cela, on ne considère que les dérivées

Spatiales $\frac{\partial \varphi}{\partial x}$ et $\frac{\partial \varphi}{\partial y}$ sont approximées par la différence centrale et la dérive temporelle $\frac{\partial \varphi}{\partial t}$.

L'équation s'écrit alors [11]

$$\frac{\varphi_{i,j}^{k+1} - \varphi_{i,j}^k}{t} = L(\varphi_{i,j}^k)$$

Si on simplifie encore cette formule, on obtient l'équation suivante :

$$\varphi_{i,j}^{k+1} = t L(\varphi_{i,j}^k) + \varphi_{i,j}^k$$

➤ **Choix du pas temporel (time step)**

Le pas temporel est un paramètre très important, sa valeur influe sur la stabilité de l'évolution de la courbe. Dans notre application, ce paramètre est bien choisit pour avoir une évolution rapide. Mais un mauvais choix de ce paramètre permet d'obtenir une détection mauvaise de la courbe finale.

Afin d'obtenir une bonne détection, il est important d'initialiser le contour actif et fixer correctement les paramètres qui gèrent la déformation du modèle (T : nombre d'itérations, paramètre de lissage, etc.). Les paramètres initialises :

σ : Paramètre de Gauss pour le lissage.

ϵ : Paramètre de lissage de la fonction de Dirac, valeur par défaut : 1,5.

α : Coefficient de la longueur de pondération $L(\varphi)$.

λ : Coefficient du terme d'énergie interne, doit être inférieur à 0,25 pour assurer la stabilité.

La valeur de λ dépend de la valeur du paramètre T , avec T représente le nombre d'itération.

VI.4. Résultats et interprétation

Le logiciel utilisé dans le cadre de ce travail est le MATLAB qui est un logiciel interactif permettant d'effectuer des calculs numériques complexes particulièrement très utiles dans le domaine de Traitement d'images. Pour valider notre algorithme de segmentation (Level set), nous avons utilisé des images réelles (IRM cérébrales).

Dans cette partie, nous avons appliqué cette méthode pour détecter la partie tumorale (figure III.4)

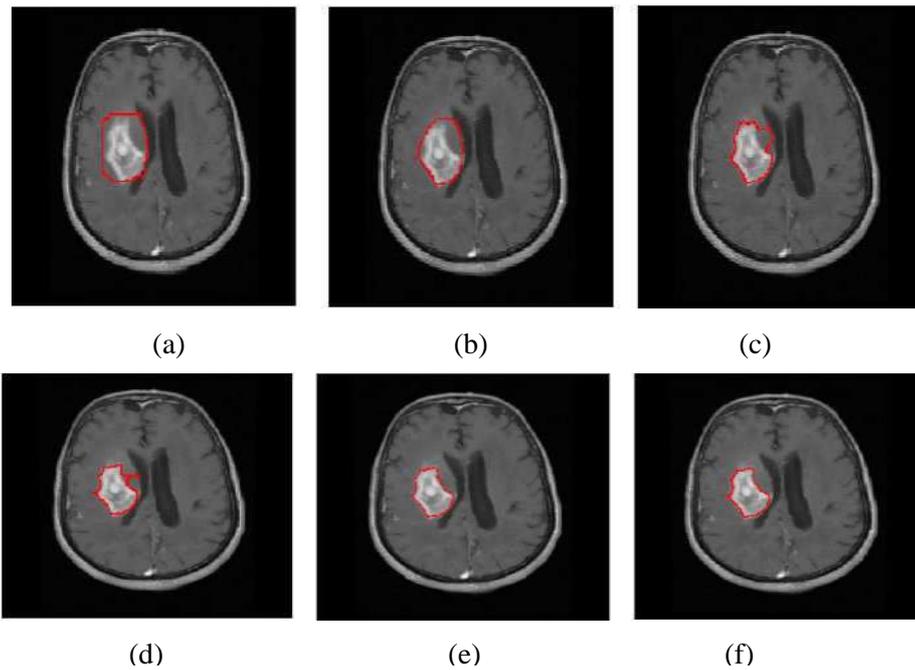


Figure III.4 : Evolution de la courbe de déformation, (a): nombre d'itération = 50, (b): nombre d'itération = 150, (c): nombre d'itération = 200, (d): nombre d'itération = 300, (e): nombre d'itération =320, (f): nombre d'itération =400.

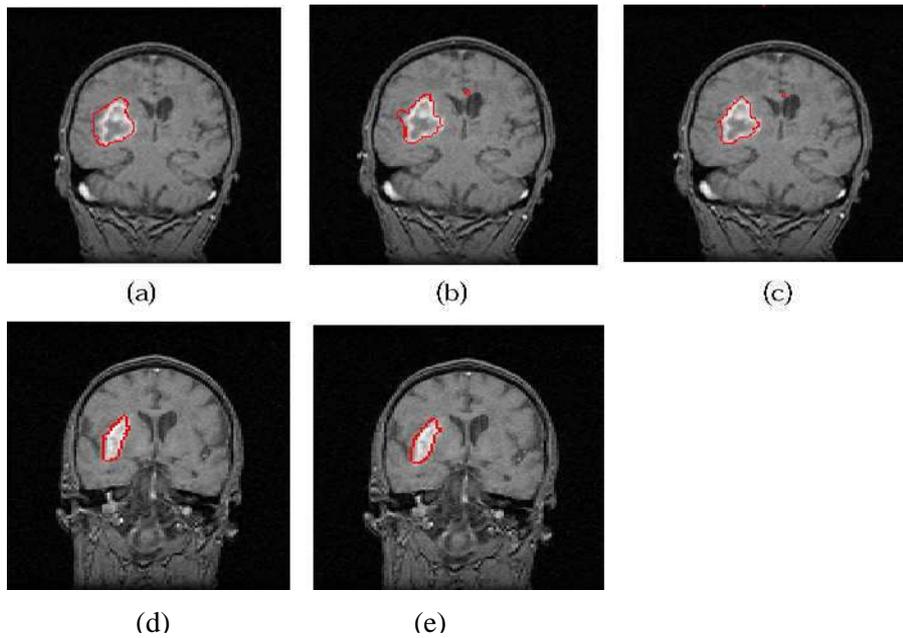


Figure III.5: Evolution de la courbe de déformation, (a): nombre d'itération = 100
(b): nombre d'itération = 400, (c): nombre d'itération = 500, (d): nombre d'itération = 200,
(e): number d'iteration =400

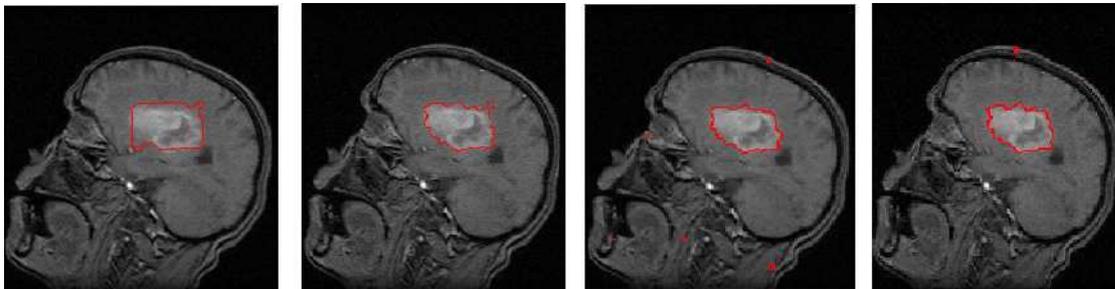


Figure III.6 : Evolution de la courbe de déformation, (a): nombre d'itération = 100
(b): nombre d'itération = 400, (c): nombre d'itération = 800, (d): nombre d'itération = 830.

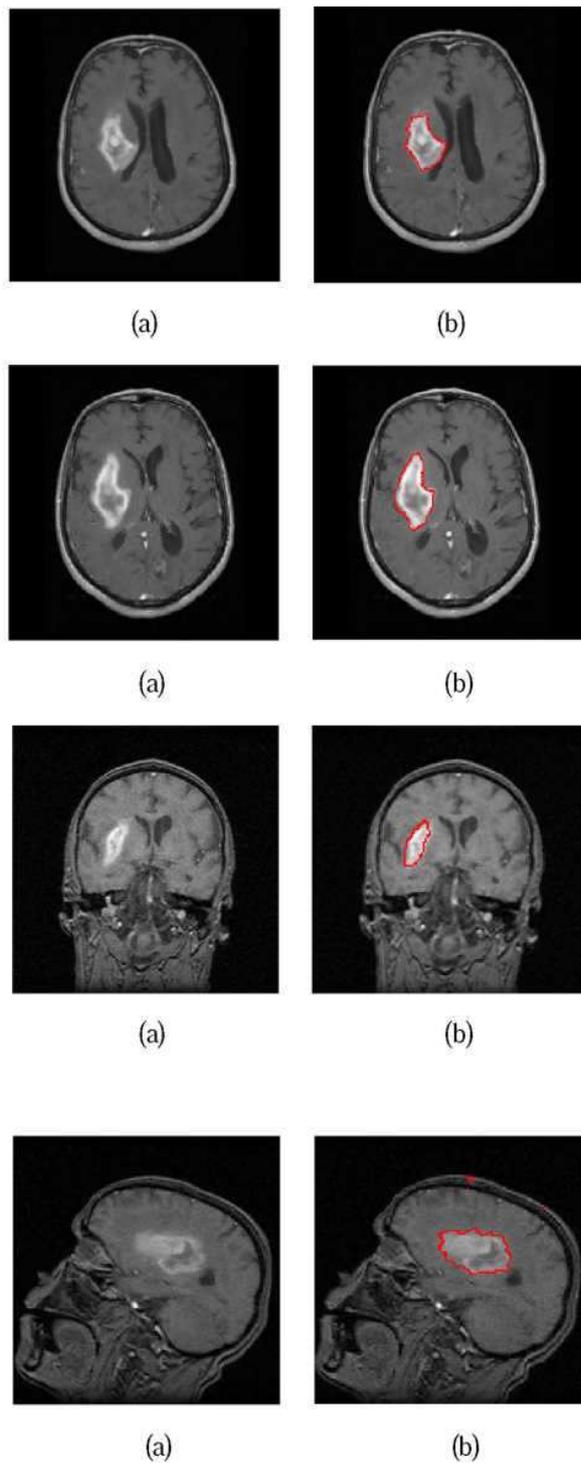


Figure III.7: Détection de la tumeur sur des coupes IRM (axiale, coronale et sagittale) par la méthode ensemble de niveaux, (a) : image originale, (b) : image segmentée

Dans cette application on s'intéresse à la détection de la partie tumorale (figure III .7) et la détection du cerveau (figure III.8) sur des coupes axiales d'IRM.

Ces résultats nécessitent un nombre d'itération important et un temps d'exécution plus grand. Nous avons choisi pour chaque image un nombre d'itération bien précis, ceci est du a la taille de la tumeur à détecter. Nous pouvons observer au cours d'exécution que la courbe initiale converge correctement vers la frontière de la tumeur. Donc pour localiser bien la tumeur, il faut initialiser bien le contour initial et les paramètres d'initialisations. Ces paramètres sont choisi suivants la taille de la tumeur à détecter.

Donc, ces résultats montrent l'efficacité de la méthode utilisée. Mais pour détecter le cerveau, pour cette détection nous avons passe par une opération de seuillage. Le résultat obtenu (image binaire) est utilise comme un contour initial pour segmenter le cerveau.

La segmentation est guidée par le choix des paramètres intrinsèque du contour actif géométrique (Level set) pour la détection de la partie tumorale. Durant tout cette étude d'application, et pour chaque image de notre base de données, nous avons utilise les même paramètres pour évoluer la courbe.

Concernant le nombre d'itération, ce paramètre change suivant la distance entre le contour initial et le contour de la partie à détecter.

Les résultats obtenus sont très satisfaisants et très encourageants malgré quelques contraintes. La difficulté trouvée dans le choix des paramètres de chaque image. En effet, le choix des paramètres du contour actif peut être parfois très couteux en temps.

Pour résoudre le problème de choix de ces paramètres initiales tel que le contour initial et son centre, on va utiliser une autre méthode de segmentation en région; cette technique appelée FCM (Fuzzy C-means).

V. Méthode Coopérative entre Level set et la classification floue FCM

Comme nous l'avons déjà mentionnée dans le chapitre II, il existe plusieurs approches de segmentation d'images, chacune agit de manière différente et utilise des attributs différents. De plus, chaque méthode ayant ses avantages et ses limites d'utilisation selon le problème a résoudre. Dans notre travail, nous visons a utiliser les avantages de plusieurs méthodes en même temps.

Ceci est réalise grâce a la coopération. En effet, les méthodes coopératives apportent une meilleure segmentation des images puisque les algorithmes émergents de la coopération prennent en compte les différentes caractéristiques de ces images.

Il existe deux types de coopération; une coopération dite « séquentielle » dans laquelle il existe une exploitation successive du résultat d'une approche pour guider une autre. Un autre type de coopération est dit « itératif » fonde sur une définition mutuelle de contraintes et qui permet une émergence de la solution.

Coopération séquentielle

Les approches par coopération séquentielle sont principalement fondées sur des principes de focalisations successives et de corrections des résultats intermédiaires. L'objectif est de réduire progressivement la difficulté du problème en le décomposant en sous-parties de plus en plus fines.

✓ Coopération itérative

Dans les approches par coopération itérative, plusieurs modules de segmentation s'exécutent simultanément. L'objectif est de construire la segmentation progressivement, en optimisant dans chaque étape les résultats obtenus par chaque. Il existe relativement peu de travaux proposant un tel type de coopération pour la segmentation d'image.

V.1. La coopération entre FCM et Level set

Dans notre travail, nous faisons coopérer entre deux méthodes de segmentation, afin de tirer parti des avantages de chacune d'elles. Dans la première partie, nous avons appliqué la méthode de classification floue FCM, qui nous permet d'agir sur l'image en utilisant des informations globales. Cette segmentation offre des cartes d'appartenance facilement interprétables. En effet, elle nous permet de connaître les régions possédant une plus grande appartenance à un tissu donné, alors que dans la deuxième partie, nous avons utilisé la méthode de Level-set, cette méthode qui nous permet de tenir en compte des caractéristiques locales de l'image.

L'approche que nous proposons dans ce mémoire est donc une approche coopérative, qui permet d'exploiter les avantages de différentes méthodes. Cette approche combine la méthode d'ensemble de niveau (Level set) avec la classification floue (FCM).

V.2. Résultat et interprétation

a) Résultat

Dans cette partie, nous avons combiné deux techniques FCM et Level set pour la détection de la partie tumorale (figure III.9, figure III.11 et figure III.13).

✓ Explication de la méthode proposée

Dans cette partie d'application, nous avons combiné deux méthodes de segmentation (Level set et FCM) dans le but de résoudre le problème de choix du contour initial.

Dans la partie d'implémentation de cette approche, nous avons éliminé la partie d'initialisation manuelle du contour et nous l'avons remplacé par l'algorithme FCM. La méthode FCM permet de classer les données d'une manière non supervisée.

Cette méthode consiste à répéter les étapes suivantes :

- Au début, en commençant par une étape de prétraitement pour améliorer le contraste et éliminer le bruit.
- Exécution de la partie FCM pour afficher les classes.
- On lance la partie FCM pour bien localiser les objets d'intérêt, ensuite on prend les contours des objets détectés par FCM, cette détection devient fiable à l'intermédiaire des opérateurs morphologiques (filtrage morphologique, dilatation, érosion, remplissage des trous). Ces contours sont utilisés dans la partie initialisation de Level set.
- Sauvegarder les résultats trouvés pour les utiliser dans les phases suivantes.
- Enfin, on lance la méthode de Level set dont le but est de visualiser les contours des objets.

1) Les images axiales

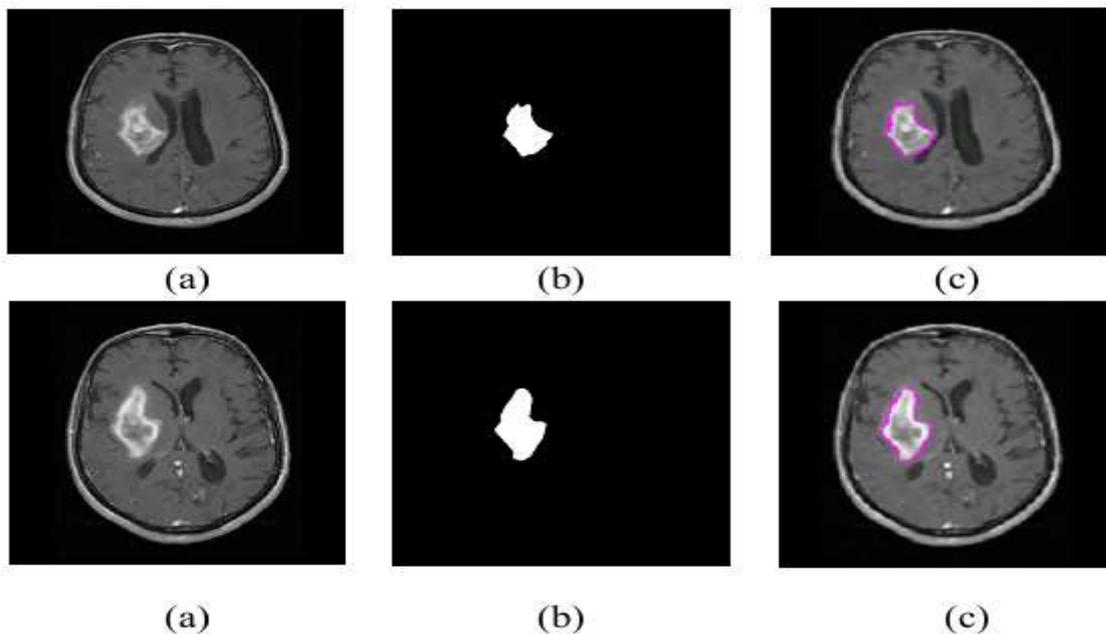


Figure III.9: Détection de la partie tumorale par la méthode coopérative entre FCM et Level set pour des coupes axiales, (a): image originale, (b): image segmentée par FCM, (c): résultat de la méthode coopérative.

2) Les images coronales

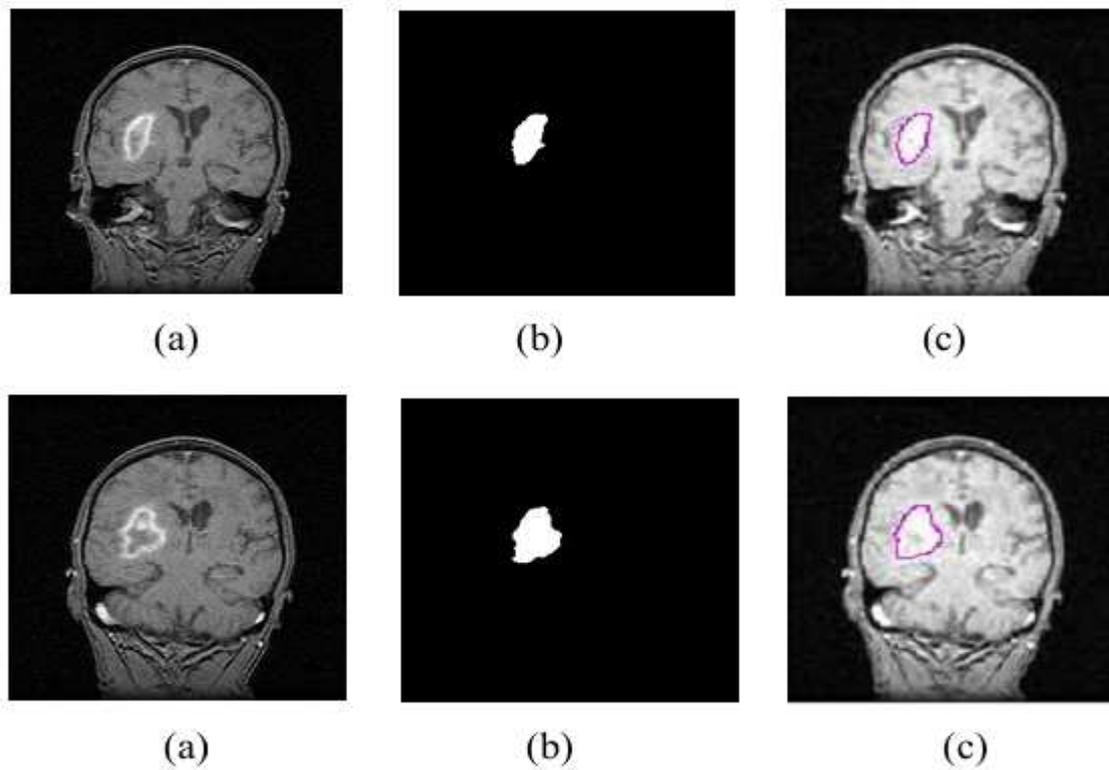


Figure III .11: Détection de la partie tumorale par la méthode coopérative entre FCM et Level set pour des coupes coronales, (a): image originale, (b) : image segmentée par FCM, (c) : résultat de la méthode coopérative.

3) Les images sagittales

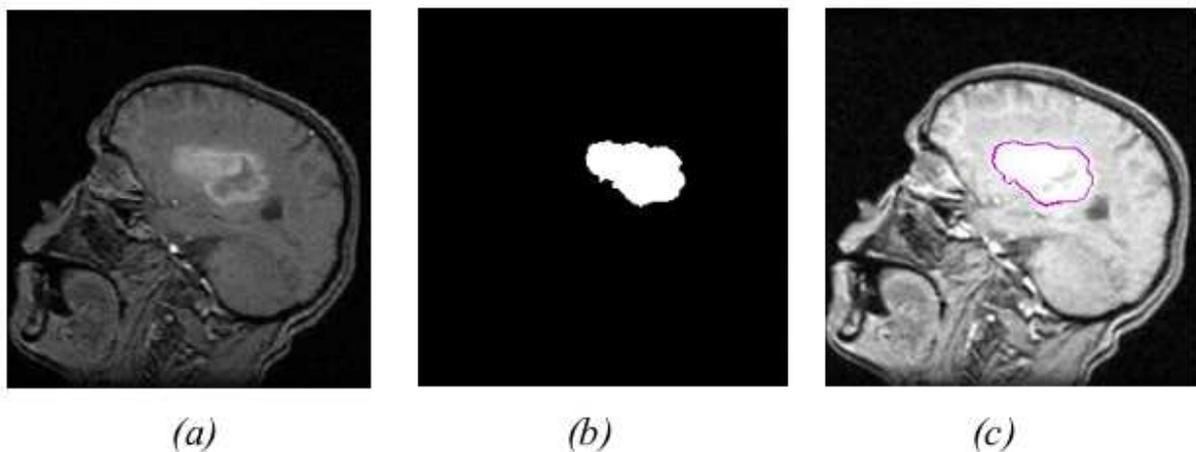


Figure III .13: Détection de la partie tumorale par la méthode coopérative entre FCM et Level set pour des coupes sagittales, (a): image originale, (b): image segmentée par FCM, (c): résultat de la méthode coopérative.

Interprétation des résultats

D'après les résultats de cette coopération, on peut dire que cette coopération donne une bonne segmentation des images IRM cérébrales. L'avantage de cette méthode traduit donc la détection de la partie tumorale et le cerveau pour les différentes coupes (axiale, sagittale coronale).

Cette méthode résout le problème de l'initialisation, cette initialisation dépend de plusieurs paramètres comme la largeur, la longueur du contour et le nombre important d'itération.

Après l'application de la logique floue (FCM) les objets sont regroupés en classes selon le nombre d'itérations et le degré d'appartenance. L'application de la méthode FCM facilite la détection des régions d'intérêts par la méthode du Level set.

V.3. Inconvénient de la méthode

Dans certains cas, l'algorithme de FCM ne fournit pas une bonne segmentation des tissus cérébraux. L'inconvénient de cette méthode ne tient pas compte que des informations globales de l'image. Dans ce cas, on peut utiliser les opérateurs morphologiques pour améliorer des résultats de FCM. Les opérateurs morphologiques utilisés sont : remplissage des trous, dilatation et érosion.

VI. Conclusion

Dans ce chapitre, nous avons présenté notre approche de segmentation basée sur une approche coopérative entre Level set et FCM. Nous avons commencé par une représentation du contour actif géométrique. Durant l'application de cette méthode plusieurs initialisations ont été effectuées dont le but est de fixer les paramètres initiaux.

Dans ce travail on s'intéresse à la coopération entre deux méthodes de segmentation, tout d'abord on introduit la notion de la classification floue (FCM), cette méthode a été appliquée sur les images améliorées. Les résultats trouvés sont considérés comme une initialisation du contour actif (Level set).

Conclusion générale

Conclusion

La segmentation des images médicales reste encore un domaine de recherche très vaste.

L'objectif de notre travail est consacré sur la segmentation des tissus cérébraux à partir d'images de résonance magnétique nucléaire, en vue de segmenter la partie tumorale et aussi le cerveau (matière blanche + matière gris).

Nous avons tout d'abord présentés l'anatomie cérébrale et la technique d'imagerie par résonance magnétique nucléaire, ainsi que les principes importants de la formation de l'image.

Une étude bibliographique a été faite sur les méthodes de segmentation d'images, nous a permis d'appréhender la diversité des méthodes de segmentation des tissus cérébraux.

Plusieurs approches de segmentation sont proposées dans la littérature, la segmentation par contour et la segmentation par région. Dans notre travail, nous avons localisés sur des méthodes utilisées pour la segmentation des structures cérébrales (croissance de région, division-fusion) et les méthodes de classification non supervisées (k-means et FCM).

Dans la première partie de ce travail, nous avons commencé par une étape de filtrage pour améliorer la qualité de l'image. Nous avons appliqués dans la deuxième étape, la méthode d'ensemble de niveau pour segmenter les différentes régions. À partir des paramètres d'initialisations, le contour évolue vers la région d'intérêt.

Dans la troisième partie, nous avons combinés entre l'algorithme FCM et l'algorithme Level pour résoudre le problème d'initialisation.

Les résultats trouvés sont satisfaisants, ce qui nous a permis de dire, que l'utilisation d'une méthode combinée entre plusieurs algorithmes de segmentation permet de donner des meilleurs résultats de segmentation.

Enfin, nombreuses images sont segmentées, cette méthode peut être appliquée pour segmenter d'autres structures cérébrales. Cette démarche peut être utilisée pour segmenter d'autres types d'images (images abdomen, images rétiniennes, etc.).

Bibliographie

[1] Nicolas Wiest- Daesslé, « imagerie du tenseur de diffusion pour l'étude de pathologies cérébrales ». Thèse présentée devant l'Université de Rennes 1 pour obtenir le grade de : Docteur de l'Université de Rennes 1 Mention Informatique, 2009.

[2] Loïc Willmann, « Étude de l'évolution des tumeurs cérébrales en IRM », cahiers d'IRM, Masson 1989.

[3] Boussedi Rym Sabine, Kenadil Meryem, « Segmentation des tumeurs cérébrales par la ligne de partage des eaux sur des images IRM », mémoire de projet de fin d'étude pour l'obtention du : Diplôme de Master en Électronique Biomédicale, 2010-2011.

[4] Soumia Hadjal, Feroui Amel, « Visualisation des images scanner en trois dimension », Mémoire de fin d'études pour l'obtention du diplôme d'ingénieur d'état en électronique biomédicale, 2007.

[5] Sanae MIRI, « segmentation des structures cérébrales en IRM: intégration de contraintes topologiques », Master 2 ISTI [R] Spécialité PARI, option IRMC 03-07/2007.

[6] Mlle Hadjer LAGUEL, « Déploiement sur une plateforme de visualisation, d'un Algorithme coopératif pour la segmentation d'images IRM basé sur les systèmes multiagents », Projet de Fin d'Étude pour l'obtention du diplôme d'ingénieur d'état de l'université des Sciences et de la Technologie Houari Boumediene, page 22-28 ,12 octobre 2010.

[7] J.-P.COCQUEREZ et S.PHILIPP, « Analyse d'images : filtrage et segmentation », page3 -266, Paris, (février 2003).

[8] J.Gomes and O.Faugeras. Reconciling distance functions and level sets .INRIA Research Report, RR-3666, Avril 1999.

[9] J.F.CANNY, «A computational approach to edge detection», IEEE Trans, pattern analysis and machine intelligence, November 1986.

Résumé

Le but de mon travail est de mettre en œuvre des techniques de segmentation permettant la détection des tumeurs cérébrales.

L'objectif de ce mémoire est de concevoir une méthode coopérative pour la Segmentation des images cérébrales. Dans ce travail, j'ai combiné la logique Floue avec la méthode de Level set pour segmenter des images du cerveau. Les Résultats trouvés sont satisfaisants, ce que me permet de dire, que l'utilisation D'une méthode combinée entre plusieurs algorithmes de segmentation permet de Donner des meilleurs résultats de segmentation.

Mots clés

IRM, Level set, classification floue, FCM, méthode coopérative.