

République Algérienne Démocratique et Populaire

Université Abou Bekr-Belkaid– Tlemcen

Faculté des Sciences

Département d'Informatique

Mémoire de fin d'études

Pour l'obtention du diplôme de Master en Informatique

Option : Modèles Intelligents et Décision (M.I.D)

Thème

*Étude comparative des méthodes de segmentation
d'images cérébrales*

Réalisé par :

-Mr Menni Sidi Mohammed.

-Mr Hadjadj Mohammed Anes.

Présenté le 03/07/2022 devant le jury composé de :

- Mr Berrabah Sid Ahmed (Président)*
- Mme Meziane Tani Souad (Encadreur)*
- Mr Benziane Yaghomrasan (Examineur)*

Année Universitaire: 2021-2022

Remerciement

Nous tenons tout d'abord à remercier «الله» le TOUT PUISSANT et miséricordieux, qui nous a donné la force, le courage et la patience d'accomplir ce modeste travail.

*En second lieu, nous tenons à remercier notre Encadrante, Madame **Meziane Tani Souad**, pour ses précieux conseils, son aide durant toute la période du travail et pour tout le soutien et l'orientation.*

*Nous exprimons notre grand respect aux honorables membres de jury **Mr Berrabah Sid Ahmed**, Maitre de Conférences à l'université Abou-Bekr Belkaïd de Tlemcen, et **Mr Benziane Yaghomrasan**, Maitre de Conférences à l'université Abou-Bekr Belkaïd de Tlemcen, qui ont accepté d'évaluer ce travail.*

Nous remercions aussi nos parents et nos proches pour l'amour et le soutien constant qu'ils nous ont témoigné tout au long de notre parcours. Merci à toutes et tous nos ami(e)s pour leurs encouragements.

SOMMAIRE

Remerciement

LISTE DES FIGURES

LISTE DES TABLEAUX

Introduction générale	1
<i>Chapitre I. Anatomie du cerveau, IRM et tumeur cérébrale</i>	<i>3</i>
Introduction.....	4
<i>Section I.....</i>	<i>5</i>
I. L'anatomie du cerveau	5
I.1. Système nerveux central	5
I.1.1. Les Hémisphères Cérébraux	5
I.1.2. Le cervelet.....	6
I.1.3. Le tronc cérébral	6
I.1.4. La moelle épinière.....	7
I.1.5. Les principaux tissus cérébraux.....	7
I.2. Techniques d'imagerie cérébrale.....	8
I.2.1. Imagerie fonctionnelle	8
I.2.2. Imagerie structurelle	9
<i>Section II</i>	<i>12</i>
II. L'imagerie cérébrale pour le diagnostic des tumeurs.....	12
II.1. Les Tumeurs cérébrales	12
II.1.1 Définition	12
II.1.2 Tumeur et cancer.....	12
II.1.3 Classification des tumeurs cérébrales	12
II.1.3.1 Tumeurs primitives	13
II.1.3.2 Tumeurs secondaires.....	13
II.1.4 Imageries cérébrales et le diagnostic des tumeurs	13
II.1.4.1 Scanner	13
II.1.4.2 l'imagerie par résonance magnétique (IRM).....	14
II.2. IRM	14
II.2.1 Définition	14
II.2.2 Pondérations et Séquence IRM	15
II.2.3 IRM et Tumeur cérébrale	16
Conclusion	17

<i>Chapitre II. Méthodes de segmentation d'images</i>	18
Introduction	19
<i>Section 1</i>	20
I. La segmentation d'images	20
1. Définition de segmentation	20
2. Segmentation d'images cérébrales	20
<i>Section 2</i>	22
II. Etat de l'art : Techniques de segmentation	22
1. Différentes approches de segmentation	22
1.1 Approches région	22
1.1.1. Seuillages	22
1.1.2. Croissance de régions	23
1.1.3. Division/fusion (split & merge)	24
1.1.4. Méthodes de classification	25
1.1.4.1. K-means	25
1.1.4.2. Fuzzy c-means	26
1.1.5. Réseaux de neurones	27
1.2 Approches contours	28
1.2.1. Méthodes dérivatives	28
1.2.2. Modèles déformables	29
1.3 Approches Structurelles	30
1.3.1. Ligne de Partage des Eaux	30
1.3.2. Morphologie mathématique	31
1.4 Forme	32
1.4.1. Modèle actif de forme (ASM)	32
1.4.2. Modèle actif d'apparence (AAM)	33
1.4.3. Contours Actifs	34
2. Critères d'évaluation de la segmentation	35
2.1. Indice de similarité de Dice	36
2.2. Indice de similarité de Jaccard	36
2.3. Sensibilité et spécificité	37
2.4. Occurancy	38
2.5. Coefficient de corrélation de Matthews (MCC)	38
2.6. F-measure	38
Conclusion	39
<i>Chapitre 3</i>	40

<i>Implémentation et résultats</i>	40
1. Introduction	41
2. Méthodologie	41
2.1. Présentation de la base de données	41
2.2. Choix des méthodes	42
2.3. Implémentation	43
2.3.1. Prétraitements	43
2.3.2. Interface graphique	43
2.3.4. Évaluation des résultats de la segmentation	46
2.3.4.1. L'évaluation de l'algorithme k-means	47
2.3.4.2. L'évaluation de l'algorithme des contours actifs	49
2.3.4.3. L'évaluation de l'algorithme FCM	51
3. Conclusion	53
Conclusion générale	54
Références	
Abstract	

LISTE DES FIGURES

Chapitre I Anatomie du cerveau, IRM et tumeur cérébrale

Figure 1. 1: Décomposition de la surface corticale en cinq lobes : lobe frontal (bleu), lobe temporal (violet), lobe pariétal (vert), lobe occipital (jaune) et lobe limbique (rouge)	6
Figure 1. 2: Les principaux tissus cérébraux sur une IRM.....	7
Figure 1. 3: images scanner et images IRM	9
Figure 1. 4: les trois coupes du cerveau	10
Figure 1. 5: Coupe axiale du cerveau. On distingue la couche superficielle de substance grise et la couche profonde de substance blanche.....	10
Figure 1. 6: Coupe sagittale du cerveau passant par le plan inter-hemispherique	11
Figure 1. 7 : Coupe coronale du télencéphale.....	11
Figure 1. 8: exemple d'IRM cérébrale	14
Figure 1. 9 : Plans axial, coronal et sagittal (de gauche à droite) sur une acquisition en T1 .	15
Figure 1. 10: (a) image pondérée en T1, (b) image pondérée en T2.....	16

Chapitre II. Méthodes de segmentation d'images

Figure 2. 1: Segmentation par seuillage simple : (a) image originale, (b) image binaire (seuil=0.6), (c) image binaire (seuil=0.5).....	22
Figure 2. 2: Croissance progressive d'une région.....	23
Figure 2. 3: Segmentation d'une image en régions par Division-Fusion	24
Figure 2. 4: Structure d'un neurone artificiel. Le neurone calcule la somme de ses entrées puis cette valeur passe à travers la fonction d'activation pour produire sa sortie	27
Figure 2. 5: Segmentation par approches dérivatives : (a) image originale, (b) filtre Prewitt, (c) filtre Canny.....	29
Figure 2. 6: Principe du contour actif (SNAKE)	29
Figure 2. 7: Principe de la Ligne de Partage des Eaux.....	31
Figure 2. 8: Segmentation par gradient morphologique	32
Figure 2. 9: la méthode AAM incluant à la fois la forme et la texture	34
Figure 2. 10: Evolution du contour actif d'un état initial au résultat final	34
Figure 2.11 : Présentation de l'indice de Jaccard en 3D, aussi appelé VOE(Volume Overlap Error).....	36

Chapitre III. Implémentation et résultats

Figure 3. 1: Images originales.....	42
Figure 3. 2: Interface graphique	43
Figure 3. 3: Courbe d'évaluation de K-means	48
Figure 3. 4: Courbe d'évaluation des contours actifs.....	50
Figure 3. 5: Résultat de segmentation par contours actifs sans filtre final	51
Figure 3. 6: Résultat de segmentation par contours actifs sans modifications	51
Figure 3. 7: Courbe d'évaluation de FCM	53

LISTE DES TABLEAUX

Tableau III. 1: résultats de la segmentation.....	45
Tableau III. 2: évaluation de K-means	48
Tableau III. 3: évaluation de contours actifs.....	50
Tableau III. 4: évaluation de FCM	52

Introduction générale

Explorer l'intérieur du cerveau humain sans opérer, a toujours intrigué l'homme. Cette action est de nos jours possible grâce aux progrès scientifiques et technologiques dans le domaine médical. Les principaux facteurs qui contribuent à rendre possibles ces actions sont principalement l'évolution des matériels et des techniques d'imagerie, Les outils cliniques permettant l'observation de la zone cérébrale sont aujourd'hui nombreux. Parmi l'ensemble de ces techniques l'imagerie par résonance magnétique (IRM). Cette technique exploite les propriétés magnétiques des tissus et permet une observation de qualité de l'anatomie cérébrale

L'une des opérations primordiales pour tout traitement automatique des images est évidemment la segmentation. Elle consiste à partitionner l'image en plusieurs régions, pour la rendre plus simple et plus significative à interpréter. 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. Plusieurs Algorithmes de segmentation ont été proposés dans la littérature.

Dans ce mémoire, nous nous sommes intéressés à la comparaison et l'évaluation de trois principales techniques de segmentation, dans le cadre de la détection automatique des tumeurs dans des images cérébrales. Ces techniques sont les suivantes : La méthode des contours actifs, Fuzzy C-Means(FCM) et K-Means.

Dans le contexte des IRM cérébrales, L'évaluation visuelle du résultat de la segmentation n'est pas toujours sûre, Pour cela, le besoin d'une interprétation automatique qui permet d'assister les médecins dans leur prise de décision s'est fait ressentir.

Ce mémoire se compose de trois chapitres.

Le premier chapitre est consacré à la présentation des différentes notions liées au contexte de notre étude. Il rappelle quelques notions d'anatomie du cerveau humain, les principes fondamentaux de la technique de l'imagerie par résonance magnétique, et présente la démarche médicale du diagnostic des tumeurs cérébrales et la diversité de ces tumeurs.

Le second chapitre est une revue des principales méthodes de segmentation des images présentes dans la littérature. Un intérêt particulier est porté pour les images médicales plus exactement aux images IRM cérébrales. Nous avons classé ces techniques en quatre grandes

catégories qui sont les approches opérant sur les contours, celles reposant sur un paradigme de régions, celles basées sur la forme, et enfin celles utilisant une approche structurale.

Le troisième chapitre est dédié à la présentation notre application qui est consacré à la présentation et la comparaison des résultats des trois méthodes de segmentation proposés. Différents critères d'évaluation proposés dans la littérature sont utilisés pour évaluer nos résultats ce qui nous permettra d'évaluer notre travail.

La conclusion et les perspectives de ce travail seront présentées à la fin du mémoire.

Chapitre I.
*Anatomie du cerveau, IRM et tumeur
cérébrale*

Chapitre I Anatomie du cerveau, IRM et tumeur cérébrale

Introduction

Dans ce chapitre, nous présentons certaines caractéristiques du cerveau et de la tumeur utiles pour détecter, segmenter et interpréter les tumeurs cérébrales. En se basant sur l'imagerie par résonance magnétique (IRM).

Ce chapitre commence par un aperçu de l'anatomie du cerveau et des principaux tissus du cerveau pour illustrer le contenu des images dont le but est démontrer les différentes régions du cerveau qui sont importantes dans le diagnostic des tumeurs cérébrales. La deuxième étape décrit les tumeurs cérébrales et leurs composantes connexes et se termine par une présentation de l'imagerie par résonance magnétique.

Section I.**I. L'anatomie du cerveau****I.1. Système nerveux central**

Le cerveau c'est l'étage le plus élevé dans la hiérarchie fonctionnelle du système nerveux central. Il est spécialement développé chez l'homme. Son poids moyen est de 1400 à 1800 grammes. [1]

Au sens strict du terme, le cerveau comprend deux parties appelées les hémisphères cérébraux. Dans le langage courant, le cerveau (ou encéphale) englobe également les structures proches des hémisphères : tronc cérébral, cervelet, hypothalamus, hypophyse, etc. [2]

I.1.1. Les Hémisphères Cérébraux

Les hémisphères cérébraux forment les parties les plus volumineuses du cerveau. Ils sont deux : un hémisphère droit et un hémisphère gauche. On parle souvent de cerveau droit et de cerveau gauche.

Les hémisphères contrôlent l'ensemble de nos fonctions mentales supérieures : mouvements volontaires, pensée, apprentissages, mémoire, etc.

Chaque hémisphère est lui-même partagé en quatre zones appelées lobes, dans lesquels ces différentes fonctions sont gérées : le lobe frontal, le lobe pariétal, le lobe temporal et le lobe occipital.

D'une manière générale, l'hémisphère droit commande le côté gauche du corps et inversement. Cependant, la répartition des fonctions à l'intérieur des lobes n'est pas totalement figée. Certaines fonctions sont gérées dans des zones différentes selon les personnes. Ainsi, la zone du langage est généralement située dans le lobe temporal gauche chez les droitiers, alors qu'elle peut être située des deux côtés chez les gauchers. [2]




Figure 1. 1: Décomposition de la surface corticale en cinq lobes : lobe frontal (bleu), lobe temporal (violet), lobe pariétal (vert), lobe occipital (jaune) et lobe limbique (rouge). [12]

I.1.2. Le cervelet

Le cervelet est un centre nerveux régulateur de la fonction motrice, au sens large (mouvement + posture + équilibre).

Il est placé dans la fosse crânienne postérieure ou fosse cérébelleuse de la boîte crânienne. Il est disposé sous une forte toile fibreuse dépendant de la dure-mère et appelée la tente du cervelet. Pour lui-même il est recouvert par les 3 méninges classiques. Il est entouré par l'espace sous-arachnoïdien contenant le liquide céphalo-rachidien. Autour du cervelet, cet espace constitue des cavités plus vastes appelées : citernes.

Dans cet espace étroit et rigide, les pathologies expansives (vasculaires, infectieuses et surtout, tumorales), ont un retentissement rapide sur le tronc cérébral.

I.1.3. Le tronc cérébral

C'est le segment du névraxe qui est placé au-dessus de la moelle, sous le cerveau et en avant du cervelet, au centre de la fosse crânienne postérieure. Le tronc cérébral est une portion dilatée du névraxe. Il présente à décrire 3 parties qui sont :

- La moelle allongée (bulbe rachidien)
- Le pont (protubérance annulaire)
- Le mésencéphale (pédoncules cérébraux)

I.1.4. La moelle épinière

C'est un cordon de tissu nerveux situé dans le canal vertébral et s'étendant de la première vertèbre cervicale à la deuxième vertèbre lombaire. Il a 43 cm de long chez l'adulte et pèse une trentaine de grammes.

La moelle présente deux renflements : un renflement cervical et un renflement lombaire qui correspondent à la naissance des plexus (plexus brachial et plexus lombo-sacré). [1]

I.1.5. Les principaux tissus cérébraux

– **Le liquide céphalo-rachidien (LCR)** : le liquide céphalo-rachidien ou cérébrospinal (en anglais cérébro-spinal fluid) est une substance qui entoure le cerveau et remplit les ventricules cérébraux. Il permet de protéger le cerveau des chocs en jouant un rôle d'amortisseur, et assure des fonctions importantes dans le transport des hormones entre les différentes régions du cerveau.

– **La matière grise (MG)** : la matière grise constitue la partie des tissus du système nerveux central concentrant les corps cellulaires des neurones et des cellules gliales. Elle apparaît de couleur plus foncée que le reste des tissus (Figure 1.2) et elle est présente principalement au niveau du cortex cérébral, du cortex cérébelleux, dans les noyaux gris centraux, dans les noyaux du tronc cérébral et à l'intérieur de la moelle épinière. La matière grise constitue le cœur du traitement de l'information nerveuse : réception des messages, élaboration des réponses et l'analyse complexe des informations.

– **La matière blanche (MB)** : la partie interne du cerveau qui contient des fibres nerveuses myélinisées, elle est de couleur blanchâtre et brillante (couleur de la myéline). Le rôle de la substance blanche est de garantir la bonne circulation des informations entre les différentes parties du système nerveux. [15]




Figure 1. 2: Les principaux tissus cérébraux sur une IRM.[15]

I.2. Techniques d'imagerie cérébrale

I.2.1. Imagerie fonctionnelle

L'imagerie fonctionnelle rend compte de l'activité des zones cérébrales durant certaines tâches (parole, mouvement, etc.). Elle est autant utilisée en recherche fondamentale qu'en clinique, pour identifier des foyers épileptiques (réseaux de neurones à l'origine des crises d'épilepsie) ou pour repérer des zones du cerveau devant être épargnées lors d'une opération chirurgicale.

- **L'EEG** (Électroencéphalogramme) est une méthode non invasive. Elle mesure les ondes électriques qui reflètent l'activité du cerveau. Plusieurs électrodes sont disposées sur le cuir chevelu. On n'obtient non pas une image mais des tracés d'activité pour chaque électrode, c'est-à-dire pour chaque zone du cerveau étudiée.
- **La TEP** (Tomographie par émission de positons, scintigraphie, PETscan) est une technique basée sur l'utilisation d'une molécule radioactive injectée en intraveineuse. Des capteurs externes mesurent ensuite les différentes quantités de rayonnements émis dans la zone où elle se trouve. En fonction de la molécule marquée radioactivement, cette méthode permet de mettre en évidence différents paramètres : la consommation d'énergie (glucose), le débit sanguin, la synthèse d'une hormone (dopamine, par ex.)... qui reflètent l'activité cérébrale.
- **L'IRMf** (Imagerie par résonance magnétique fonctionnelle) permet d'enregistrer les variations de flux sanguin dans des petites zones du cerveau. On peut ainsi en déduire la consommation d'oxygène dans le cerveau et donc les zones du cerveau en activité (pour localiser les aires du langage ou de motricité avant une intervention chirurgicale, afin de ne pas les léser).
- **La MEG** (Magnétoencéphalographie) mesure des champs magnétiques dus à l'activité électrique des neurones. Ces champs magnétiques sont très faibles, c'est pourquoi la machine est ultra-sensible et très protégée du magnétisme ambiant naturel. La MEG permet de visualiser les structures profondes du cerveau de façon plus précise que l'IRMf. [3]

I.2.2. Imagerie structurelle

L'imagerie structurelle permet d'étudier l'anatomie du cerveau et tout ce qui peut la perturber (tumeur, hémorragie, déformation pathologique, etc.). Elle se révèle très utile au diagnostic médical.

- **Le Scanner** (tomographie, tomodensitométrie, CT-Scan) repose sur l'utilisation de rayons X permettant de réaliser une série de radiographies prises en coupe puis associées par ordinateur. On peut injecter par voie intraveineuse au patient des produits de contraste comme l'iode, pour améliorer le rendu des images (des tumeurs, par exemple).
- **L'IRM** (Imagerie par résonance magnétique) utilise les champs magnétiques et les propriétés des molécules d'eau dans le cerveau. Cet examen est plus long mais plus précis que le scanner. Là aussi, un produit de contraste peut être utilisé. Il est utile en cas d'accident vasculaire cérébral, de cancer, ou de maladies dégénératives du cerveau... [3]




Figure 1. 3: images scanner et images IRM.

I.3. Différentes coupes

On distingue trois axes anatomiques pour pouvoir réaliser les différentes coupes de cerveau, que serviront à une observation du cerveau en deux dimensions

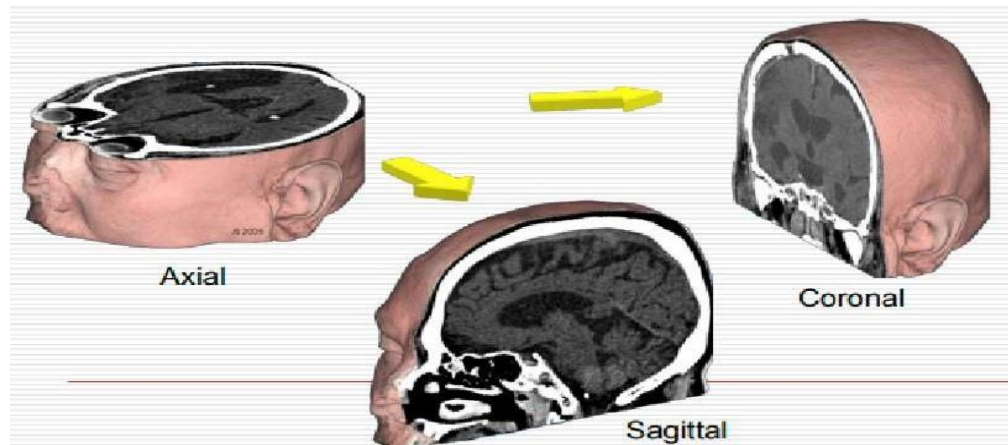


Figure 1. 4: les trois coupes du cerveau.

- **Coupes axiales**

Ces coupes correspondent à un plan horizontal, en IRM elles correspondent à un plan perpendiculaire à l'axe du champ magnétique principal.




Figure 1. 5: Coupe axiale du cerveau. On distingue la couche superficielle de substance grise et la couche profonde de substance blanche [12]

- **Coupes sagittales**

Ceux-ci sont des vues latérales du cerveau. Elles sont effectuées dans des plans parallèles au plan inter hémisphérique.

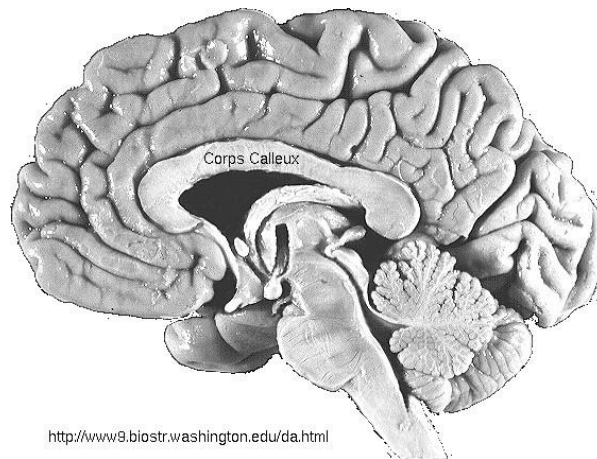


Figure 1. 6: Coupe sagittale du cerveau passant par le plan inter-hemispherique [12]

- Coupes coronales

Perpendiculaires aux coupes axiales et sagittales, il s'agit des vues frontales du cerveau.

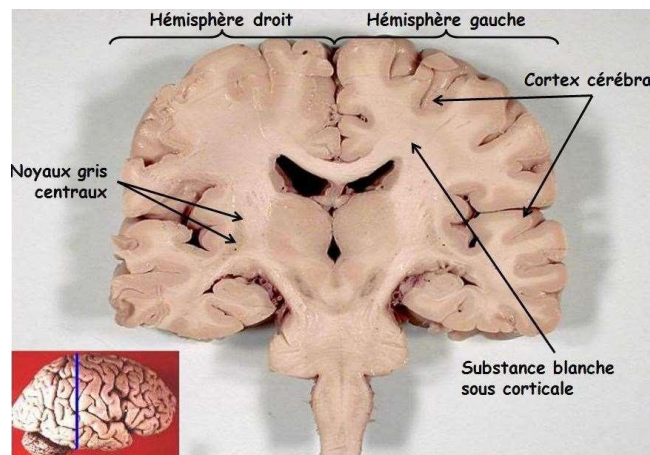


Figure 1. 7 : Coupe coronale du télencéphale

Section II.**II. L'imagerie cérébrale pour le diagnostic des tumeurs****II.1. Les Tumeurs cérébrales****II.1.1 Définition**

Une tumeur cérébrale est une croissance cellulaire dans le cerveau, qui peut être de nature bénigne (non cancéreuse) ou maligne (cancéreuse). Elle peut être d'origine cérébrale ou avoir envahi le cerveau après s'être développée dans une autre région de l'organisme (métastase). Les examens d'imagerie peuvent détecter des tumeurs cérébrales, mais une biopsie de la tumeur est souvent nécessaire pour la confirmation. [4]

II.1.2 Tumeur et cancer

Tumeur et cancer se ressemblent, car dans les deux cas, il s'agit d'un dérèglement de la production cellulaire. Les cellules, qui ont un temps de vie et de mort habituellement, dysfonctionnent et cessent de mourir. Le résultat, c'est une prolifération qui provoque une grosseur dans les tissus. Ce phénomène est commun à la tumeur et au cancer.

La différence essentielle entre la tumeur et le cancer réside dans la dangerosité du processus de surproduction cellulaire. L'amas de cellules qui se forme dans le tissu est, selon plusieurs critères, considéré comme dangereux ou non. Dans le cas d'une tumeur bénigne, un chirurgien peut aisément extraire la masse sans danger pour le patient. Et dans le cas d'une tumeur maligne et donc d'un cancer, les cellules se sont infiltrées et ne peuvent pas être aisément retirées. La tumeur devient invasive. Le traitement dans ce cas diffère et impliquera une ablation large ou, dans les cas plus graves, de la chimiothérapie ou radiothérapie. [11]

II.1.3 Classification des tumeurs cérébrales

Il existe deux principaux types de tumeurs cérébrales :

- **Essentielle** : Ces tumeurs ont pour origine des cellules intracrâniennes ou des cellules de structures voisines du cerveau. Elles peuvent être bénignes ou malignes.
- **Secondaire** : Ces tumeurs sont des métastases. C'est-à-dire qu'elles se sont développées dans une autre région de l'organisme et se sont diffusées au cerveau. Ainsi, elles sont toujours malignes.

II.1.3.1 Tumeurs primitives

Tumeurs primitives les plus fréquentes :

- Gliomes (notamment astrocytomes, oligodendrogliomes et glioblastomes) et épendymomes
- Médulloblastomes
- Méningiomes
- Neurinomes de l'acoustique
- Les gliomes représentent 65 % de toutes les tumeurs cérébrales primitives.

Les tumeurs bénignes portent le nom des cellules ou des tissus spécifiques dont elles sont issues. Par exemple, l'hémangioblastome provient de vaisseaux sanguins (« hema » signifie vaisseaux et les hémangioblastes sont les cellules qui se développent au niveau de l'endothélium vasculaire). Certaines tumeurs bénignes proviennent de cellules de l'embryon (cellules embryonnaires), dès le début du développement du fœtus. Ces tumeurs peuvent être présentes à la naissance.

II.1.3.2 Tumeurs secondaires

Les métastases cérébrales sont beaucoup plus fréquentes que les tumeurs primitives. Plus de 80 % des personnes atteintes de métastases cérébrales ont plus d'une métastase.

Les métastases issues d'autres parties du corps peuvent se propager dans une seule région du cerveau ou dans différentes parties du cerveau. De nombreux types de cancers peuvent se propager vers le cerveau.[4]

II.1.4 Imageries cérébrales et le diagnostic des tumeurs

II.1.4.1 Scanner

Principalement scanner (ou tomодensitométrie TDM). Il est efficace pour identifier 80% des tumeurs. Le scanner peut confirmer la présence de la tumeur et indiquer l'emplacement et la taille de la tumeur si nécessaire. Grâce aux rayons X, vous pouvez utiliser un scanner pour prendre une image de votre cerveau. Avant le test, un produit de contraste contenant de l'iode est injecté dans la veine du patient pour rendre la tumeur plus visible. Le patient s'allonge alors sur une table placée au centre d'un grand anneau qui émet des radiations. L'examen dure environ 20 minutes.

II.1.4.2 l'imagerie par résonance magnétique (IRM)

Permet d'identifier les tumeurs qui n'auraient pas été repérées sur les images du scanner, Cet examen est plus sensible et remplace progressivement le scanner en premier lieu. Les images obtenues décrivent mieux la localisation exacte, la taille et la propagation potentielle de la tumeur à d'autres structures du système nerveux (méninges, moelle épinière, etc.) et de recueillir des données qui faciliteront les traitements locaux utilisés ultérieurement (chirurgie et/ou radiothérapie).

En réalité, le processus d'IRM est similaire au processus de scanner, mais au lieu d'un rayonnement, un champ électromagnétique est utilisé. [5]




Figure 1. 8: exemple d'IRM cérébrale

II.2. IRM

Au niveau cérébral, l'IRM est l'examen de routine dans la recherche d'une tumeur, d'un accident vasculaire ou d'une sclérose en plaques. L'IRM est de loin supérieure au scanner dans la recherche des lésions du parenchyme cérébral. De par sa possibilité de fournir des images dans les 3 plans, l'IRM est particulièrement adaptée à la recherche de pathologie de l'hypophyse. L'IRM permet également d'étudier les artères du cou et du cerveau.

II.2.1 Définition

L'imagerie par résonance magnétique (IRM) est un type d'imagerie diagnostique. L'appareil d'IRM balaie l'encéphale en « tranches » afin de produire des images. Chaque image montre une « tranche » ou un niveau différent de l'encéphale. On les appelle aussi des images de coupe transversale. Ces images sont interprétées par un médecin spécialisé qui porte le titre de radiologue. La machine d'IRM ne fonctionne pas avec des radiations ou des radiographies.

Chapitre I Anatomie du cerveau, IRM et tumeur cérébrale

On utilise un aimant, des ondes radio et un ordinateur afin de produire les images. L'IRM est bruyante, mais elle ne fait pas mal. Un certain nombre de courts balayages composent une étude d'IRM complète. Chaque balayage peut prendre entre une et dix minutes. Le temps total nécessaire à une étude d'IRM complète est d'une à deux heures. On peut réaliser une IRM pour toutes les parties du corps.[6]

Des exemples d'images IRM du cerveau obtenues dans le plan axial, sagittal et coronal sont donnés ci-dessous.




Figure 1. 9 : Plans axial, coronal et sagittal (de gauche à droite) sur une acquisition en T1 [13]

II.2.2 Pondérations et Séquence IRM

Le temps de répétition (TR) est l'intervalle de temps entre deux excitations. Le temps d'écho est l'intervalle de temps entre l'excitation et la survenue du signal IRM. Une séquence IRM est un ensemble d'impulsion excitatrices dont les paramètres (TE, TR par exemple) sont ajustés pour obtenir des images ayant un contraste donné (T1 ou T2 par exemple).

Dans une image pondérée en T1, la graisse apparaît hyperintense (couleur claire) et l'eau hypointense. Les tissus sont ordonnés par niveaux de gris croissants en LCR, MG et MB.

Dans une image pondérée en T2, l'eau apparaît hyperintense (couleur claire) et la graisse un peu plus sombre que l'eau. Les tissus sont ordonnés par niveaux de gris croissants en MB, MG et LCR.

Dans une image pondérée en densité de protons (DP), pour un TR long et un TE court, on obtient une séquence pondérée en densité de protons DP. Les tissus sont ordonnés par niveaux de gris croissants en MB, MG et LCR. [7]




Figure 1. 10: (a) image pondérée en T1, (b) image pondérée en T2

II.2.3 IRM et Tumeur cérébrale

En imagerie par résonance magnétique (IRM), on a recours à de puissantes forces magnétiques et à des ondes radioélectriques pour produire des images en coupes des organes, tissus, os et vaisseaux sanguins du corps. Un ordinateur assemble les images en clichés à 3 dimensions. On considère que l'IRM est la meilleure façon de chercher une tumeur au cerveau ou à la moelle épinière. On peut avoir recours à d'autres types d'IRM dont ceux qui suivent.

- **L'ARM** (angiographie par résonance magnétique) met en évidence la structure des vaisseaux sanguins dans le cerveau et est utile à la planification de la chirurgie.
- **La SRM** (spectroscopie par résonance magnétique) fait ressortir certaines caractéristiques des tumeurs au cerveau qu'on ne voit pas clairement à l'IRM. Elle peut aider à établir le type possible de tumeur et peut être employée après le traitement afin de déterminer si une région anormale est une tumeur ou du tissu cicatriciel.
- **L'IRM de perfusion** (perfusion par résonance magnétique) révèle la quantité de sang traversant différentes parties du cerveau et peut donner une idée de la rapidité à laquelle la tumeur se développe. Elle peut aider à déterminer quel est le meilleur emplacement pour une biopsie et on peut y avoir recours après le traitement afin de savoir si une région anormale est une tumeur ou du tissu cicatriciel.[8]

Conclusion

A travers ce chapitre, nous avons tout d'abord présenté l'anatomie du cerveau et ses principaux tissus, aussi nous avons cité les différentes techniques utilisées dans l'imagerie médicale cérébrale que ce soit anatomique ou fonctionnelle, et parmi ces techniques là nous avons cité l'imagerie par résonance magnétique (IRM) qui est une technique d'imagerie médicale très utile pour l'observation du cerveau. Car c'est la méthode d'imagerie qui, dans la plupart des cas, donne les informations les plus riches (la résolution spatiale habituelle est de l'ordre du millimètre).

L'exploitation de ces images médicales nécessite un traitement de bas niveau tel que la segmentation, Dans la littérature, différentes méthodes de segmentation des IRM cérébrales ont été développées. Elles feront l'objet du prochain chapitre.

Chapitre II.

Méthodes de segmentation d'images

Introduction

La segmentation est une étape très importante pour l'analyse des données d'images. Elle vise à décomposer complètement ou partiellement une image en régions qui possèdent une corrélation forte avec les objets d'intérêt à détecter dans l'image. Elle permet ensuite de visualiser et de quantifier ces objets.

Dans ce chapitre, nous allons d'abord introduire la notion de la segmentation puis nous présentons les différentes approches de segmentation des images qui existent dans la littérature, ensuite, nous portons notre étude sur les approches de segmentation d'images cérébrales.

Section I.

I. La segmentation d'images

1. Définition de segmentation

C'est la division d'une unité anatomique en plusieurs éléments selon Larousse, et en imagerie c'est une opération de traitement d'image qui vise à regrouper des pixels selon des critères prédéfinis.

2. Segmentation d'images cérébrales

Une segmentation du tissu cérébral consiste à séparer les différents tissus tumoraux, tels que la tumeur, l'œdème et la nécrose, ainsi que les tissus normaux tels que la matière grise, la matière blanche et le liquide céphalo-rachidien. La segmentation est facilitée par l'utilisation de plusieurs types d'IRM. Les images pondérées en T1, T2 sont notamment couramment employées en clinique. Ces deux types de séquences peuvent être complétés par d'autres types d'IRM, telles que les séquences utilisant un produit de contraste tel que le Gadolinium, FLAIR, et les images de perfusion, de diffusion et spectroscopique.[17]

La segmentation des IRM cérébrales présente des spécificités par rapport à d'autres domaines d'applications de la segmentation, comme la segmentation d'images satellitaires, ou d'images faciales [16]. Ces spécificités sont liées aux particularités des objets à segmenter (l'anatomie du cerveau) et au processus d'acquisition des IRM. Ces spécificités sont caractérisées par :

– **Information d'intensité insuffisante** : plusieurs structures cérébrales peuvent avoir la même intensité pour une modalité donnée, ce qui engendre une difficulté de distinction de transition entre les tissus. L'utilisation simultanée de plusieurs modalités permet de pallier ce type de problème.

– **Connaissances a priori** : la position et la forme de quelques structures cérébrales internes/externes est assez prédictible. Ce qui permet d'utiliser ces connaissances a priori afin de faciliter la tâche de segmentation (supervisée). A noter que pour d'autres structures qui présentent une forte variabilité anatomique, l'utilisation de connaissances a priori pour guider la segmentation, pose des problèmes et perturbera le résultat final.

– **Nature des images IRM** : plusieurs artefacts apparaissent en IRM qui sont typiques à cette imagerie : le bruit lié au mouvement, l'effet de volume partiel et l'inhomogénéité de la radio fréquence RF. [16]

*Section 2.***II. Etat de l'art : Techniques de segmentation****1. Différentes approches de segmentation****1.1 Approches région**

Les approches régions visent à partitionner l'image en un ensemble de régions homogènes selon un ou plusieurs critères de similarité, ces critères sont des caractéristiques intrinsèques des régions qui peuvent être extraites (texture du mouvement, la couleur, niveau du gris). Pour cela il existe différentes techniques que nous allons présenter dans ce qui suit.

1.1.1. Seuillages

C'est l'une des techniques les plus simples et les plus anciennes utilisées en segmentation, qui suppose que l'image est composée de régions avec différentes gammes de niveau de gris. Une procédure de réglage du seuil détermine une valeur d'intensité appelée seuil. Dans la plupart des cas, le seuil est déterminé à partir de l'histogramme. L'opération de seuillage facilite la séparation des différentes régions contenues dans l'image et qui correspondent aux différents pics de l'histogramme. Il existe trois types de seuillage : local, global, et dynamique.[24]

L'opération de binarisation (seuillage simple), consiste à mettre à zéro tous les pixels dont le niveau de gris est inférieur à une valeur appelée seuil S , et à la valeur maximale les autres pixels. Ainsi le résultat du seuillage est une image binaire contenant des pixels noirs et blancs.




Figure 2. 1: Segmentation par seuillage simple : (a) image originale, (b) image binaire (seuil=0.6), (c) image binaire (seuil=0.5).[19]

Dans [19], Moussa a cité quelques travaux effectués sur les méthodes de segmentation par seuillage qui ont été appliquées à la segmentation des IRM cérébrales, Mais pour ce qui concerne la segmentation des tumeurs, les méthodes par seuillages sont peu nombreuses.

Malgré ces avantages, les méthodes de segmentation par seuillages ne semblent pas adaptées pour segmenter les principales structures anatomiques et les éventuelles pathologies. Leur utilisation nécessite, en particulier, la prise en compte d'informations locales, liées au voisinage d'un pixel. [21]

1.1.2. Croissance de régions

Les méthodes de segmentation par croissance des régions sont des techniques simples et ascendantes. Elles utilisent les caractéristiques colorimétriques dans la définition des attributs d'homogénéité des régions et les relations spatiales dans la définition de la connexité des ensembles de points.

Généralement, l'algorithme de croissance de régions définit au départ des regroupements initiaux de points. Un regroupement initial peut être un pixel, une petite région (résultat d'une pré-segmentation par exemple). Après cette initialisation, un parcours itératif des regroupements est lancé pour accroître les régions.

Dans cette propagation itérative, deux conditions doivent être prise en considération :

1. Le regroupement est ajouté à une région en cours de constitution s'il y a une relation de voisinage entre eux et on ajoute aux pixels déjà regroupés certains pixels voisins.
2. L'accroissement ne peut se faire que si les regroupements satisfont les critères d'homogénéité vis-à-vis de la région. [23]




Figure 2. 2: Croissance progressive d'une région

Tout comme les méthodes à base de seuillage, les approches de segmentation par croissance de régions sont simples à implémenter mais parfois gourmandes en temps de calcul. Leur avantage réside dans la prise en compte des informations contextuelles, qui permet la connexité des zones segmentées. Alors que la disposition des germes initiaux représente un inconvénient. En effet, celle-ci nécessite quasi-systématiquement l'intervention d'un

opérateur, en particulier lorsqu'il s'agit de détecter des tumeurs, qui, par définition, n'ont pas de localisation a priori dans le cerveau, et sur lesquelles nous ne disposons d'aucune connaissance anatomique. [55]

1.1.3. Division/fusion (split & merge)

L'algorithme split & merge été proposé par Horowitz et Pavlidis en 1974 [25] Dans la première étape, ou division, on teste d'abord le critère de similarité sur l'image entière, si le critère est vérifié, alors l'image est considérée comme segmentée. Sinon, l'image initiale sera découpée en blocs plus petits (généralement en 4 quadrants) et le processus est réappliqué sur chacun des nouveaux blocs obtenus. Dans la deuxième étape, ou fusion, à partir d'un graphe d'adjacence, si l'union de deux régions voisines vérifie le critère d'homogénéité, alors, on fusionne ces régions et on met à jour le graphe d'adjacence. [19]

L'algorithme de cette méthode se résume comme suit :

- Appliquer la méthode de division en construisant le QuadTree dans le sens racine vers feuilles.
- Parcourir l'arbre obtenu dans le sens feuilles vers racine en fusionnant les régions similaires au sens d'un prédicat de regroupement.

Ainsi on obtient une description structurale de l'image avec des régions connexes de taille maximale [26], comme illustré dans la figure 2.3

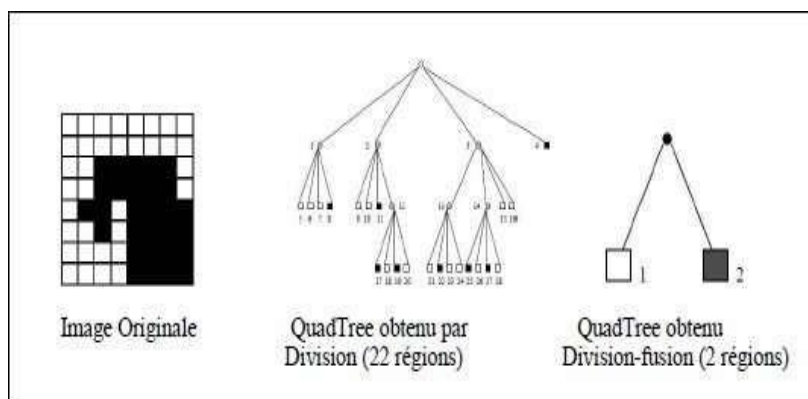


Figure 2. 3: Segmentation d'une image en régions par Division-Fusion [27]

L'inconvénient de la méthode split & merge réside dans le choix de l'ordre dans lequel on commence la phase de fusion. [19]. Cette méthode n'a pas été utilisées pour la segmentation d'IRM cérébrales.

1.1.4. Méthodes de classification

1.1.4.1. K-means

L'algorithme des k-moyennes classe les objets selon leurs attributs en k parties (ou clusters) en supposant que les attributs des objets forment un espace vectoriel. L'objectif est de minimiser la variance intra-cluster [14] :

$$(1.1) \dots \dots \dots V = \sum_{i=1}^K \sum_{x_i \in S_i} |x_i - \mu_i|^2$$

ou S_i , $i = 1, 2, \dots, k$ sont les k clusters et μ_i est le centroïde ou point moyen des points $x_j \in S_i$.

L'algorithme commence par partitionner les points en k ensembles initiaux, soit au hasard, soit en utilisant une heuristique. Il calcule ensuite le centroïde de chaque ensemble et construit une nouvelle partition en associant chaque point avec le centroïde le plus proche. S'ensuit une alternance entre calcul des centroïdes des nouveaux clusters et appariement des points avec le centroïde le plus proche jusqu'à convergence. Celle-ci est obtenue quand plus aucun point ne change de groupe (ou bien quand les centroïdes ne changent plus).

L'algorithme de K-means se résume dans les étapes suivantes [28] :

1. Partitionnement des données en k sous ensembles (non vides)
2. Calcul des centres des groupes de la partition courante
3. Les données sont affectées au groupe dont leur centre est plus proche
4. Retour à l'étape 2
5. Arrêt lorsque les groupes sont constants.

Cet algorithme est parmi les algorithmes de segmentations les plus populaires parce qu'il est extrêmement rapide en pratique, il présente le problème de la sur-segmentation, cela veut dire qu'on se retrouve avec un nombre important de classes. Nous pouvons remédier à ce problème par la méthode de fusion de régions. Il est aussi fréquent d'avoir des classes hétérogènes (non homogènes). Des méthodes existent pour corriger ce problème.

L'algorithme K-means a été largement appliqué en segmentation des images IRM, son inconvénient majeur est que la classification finale dépend de la partition initiale qui est générée aléatoirement, et l'algorithme risque d'être stagné autour d'optima locaux. Dans la

littérature, plusieurs travaux [33, 34] ont été proposés pour résoudre ce problème en améliorant la phase d'initialisation des centres de classes. Dans la méthode K-means, les pixels sont classés de façon certaine comme appartenant à une et une seule classe. Cette affirmation ne reflète pas la réalité physique des images IRM cérébrales (chevauchement des tissus, bruit, volume partiel, etc.). [19]

1.1.4.2. Fuzzy c-means

L'algorithme des c-moyennes floues (ou fuzzy c-means - FCM - en anglais) introduit par Dunn [30] et développé par Bezdek [31] généralise l'algorithme des k-moyennes en permettant la classification floue basée sur la théorie des ensembles flous

a) Présentation de l'algorithme

La fonctionnelle L à minimiser est :

$$(1.2) \dots \dots \dots L = J_w(x, v, y) = \sum_{j=1}^n \sum_{i=1}^k (x_{ij})^w \|y_j - v_i\|_A^2$$

Où n est le nombre de points à traiter, k le nombre de classes désirées, $w \in [1, +\infty[$ est le poids de fuzzy classification, $v = (v_1; \dots; v_k)$ est le vecteur des centres de classes, $\|\cdot\|_A$ est un produit scalaire où A est une matrice définie positive et $x = [x_{ij}]_{w \in \mathbb{R}^{k \times n}}$

L'algorithme suivant montre les étapes de FCM :

1. initialiser les centres.
 2. fixer le coefficient flou.
 3. calcul la partition floue initiale (La matrice d'appartenance)
 4. répéter :
 - Calcul des nouveaux centres
 - Calcul de la nouvelle partition floue
- Tant que le critère d'arrêt n'est pas vérifié.

A la fin du déroulement de FCM, une dernière étape est nécessaire lorsque le résultat souhaité est une classification dure (non floue). On parle alors de défuzzification. Cette étape considère la classe finale d'un pixel comme celle pour laquelle le degré d'appartenance est maximal.[19]

b) FCM et caractérisation des tissus cérébraux

L'algorithme FCM conventionnel a été beaucoup appliqué pour la segmentation des images IRM cérébrales. L'avantage principal de cet algorithme, et son adaptation dans le cas où les données manipulées se chevauchent ou lorsque l'information disponible est imprécise et incertaine, ce qui est le cas des images utilisées dans notre recherche. Néanmoins, FCM n'est pas robuste face au bruit et son efficacité dépend fortement de l'étape d'initialisation, qui conduit à des optima locaux si elle est mal choisie [19]. Un autre inconvénient, est que la segmentation en FCM, est déterminée uniquement par les intensités des pixels, c'est-à-dire sans prendre en compte l'information spatiale (notion de voisinage). [32]

Pour pallier les inconvénients de l'algorithme FCM, et surtout le problème d'initialisation et du bruit, plusieurs travaux de recherche ont été présentés dans la littérature, dans [28] Meziane a cité quelques travaux dont le but était à chaque fois d'améliorer des détails manquants dans l'algorithme.

1.1.5. Réseaux de neurones

Un réseau de neurones artificiels est en général composé d'une succession de couches dont chacune prend ses entrées sur les sorties de la précédente. Chaque couche i est composée de N_i neurones prenant leurs entrées sur les N_{i-1} neurones de la couche précédente. À chaque synapse est associé un poids synaptique, de sorte que les N_{i-1} sont multipliés par ce poids, puis additionnés par les neurones de niveau i , ce qui est équivalent à multiplier le vecteur d'entrée par une matrice de transformation. Mettre l'une derrière l'autre les différentes couches d'un réseau de neurones reviendrait à mettre en cascade plusieurs matrices de transformation et pourrait se ramener à une seule matrice, produit des autres, s'il n'y avait à chaque couche, la fonction de sortie qui introduit une non-linéarité à chaque étape. Ceci montre l'importance du choix judicieux d'une bonne fonction de sortie : un réseau de neurones dont les sorties seraient linéaires, n'aurait aucun intérêt. [14]

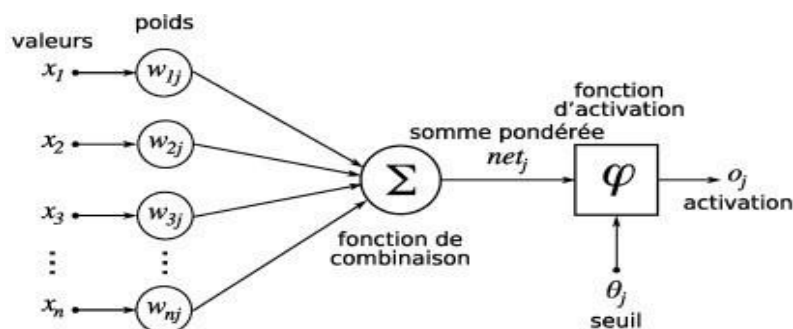


Figure 2. 4: Structure d'un neurone artificiel. Le neurone calcule la somme de ses entrées puis cette valeur passe à travers la fonction d'activation pour produire sa sortie.[14]

Dans [28,29] on a mentionné plusieurs travaux effectués sur les méthodes de segmentation par réseaux de neurones et nous pouvons en déduire ceci :

Classiquement, en segmentation d'images médicales, les réseaux de neurones sont utilisés comme classifieurs. Les poids synaptiques sont déterminés par apprentissage sur une base d'image dont le résultat de segmentation est connu, on parle alors de réseau de neurones supervisé. Souvent, les neurones d'entrées sont les différentes IRM disponibles et les neurones de sorties nous donnent alors les différentes classes recherchées. Il est en outre possible d'introduire des informations a priori en plus des volumes et donc de donner plus de robustesse à cette classification. Mais l'inconvénient majeur de cette méthode par réseaux de neurones est l'étape d'apprentissage qui demande une intervention manuelle pour donner cette vérité terrain dont le réseau a besoin pour calculer les poids synaptiques. [14]

Il existe d'autres méthodes qui font partie de l'approche région tel que la méthode des champs de Markov, La méthode Mean Shift, machines à vecteurs de support (SVM) et l'algorithme ensemble de niveau (level sets).

1.2 Approches contours

Contrairement aux approches régions, qui forment des zones uniformes, les approches contours s'appuient sur les brusques changements d'intensité (discontinuités) dans l'image pour extraire les contours de la région. Dans ce qui suit, nous nous intéressons plus particulièrement aux méthodes dérivatives et aux modèles déformables.

1.2.1. Méthodes dérivatives

Les méthodes dérivatives permettent de détecter de manière simple les ruptures dans une image ou un volume. Les contours (ou surfaces en 3D) sont assimilés à des points de forts gradients ou de dérivées secondes nulles. On retrouvera alors des opérateurs tels que les filtres de Roberts [39], de Sobel [40] ou de Prewitt [38] pour le gradient et le Laplacien pour les dérivées secondes

Il existe d'autres méthodes de détection de contour appelées méthodes optimales, comme les filtres de Canny [36], Deriche [69] ou Shen et Castan [37]

Les méthodes dérivatives, employées pour la segmentation des images IRM cérébrales, sont relativement peu nombreuses dans la littérature. Bien que rapides et ne nécessitant pas d'apport d'information a priori, elles ne permettent pas, en général, d'obtenir des contours fermés. Elles sont en effet très sensibles au bruit et à la dérive du champ radiofréquence. Leur efficacité repose sur l'existence de contrastes entre les structures recherchées. Si ceux-ci

existent effectivement au niveau de la peau ou du système ventriculaire, ils sont beaucoup moins importants au niveau de la transition matière blanche - matière grise ou encore au niveau du liquide céphalo-rachidien périphérique. Enfin, ces méthodes fournissent fréquemment de la sous- ou de la sur-segmentation. [18]




Figure 2. 5: Segmentation par approches dérivatives : (a) image originale, (b) filtre Prewitt, (c) filtre Canny.[19]

1.2.2. Modèles déformables

Un modèle déformable est une technique de segmentation permettant d'extraire un objet d'intérêt d'une image, décrit par une structure géométrique évoluant itérativement de manière à s'ajuster aux frontières des objets recherchés [20], comme dans la figure 2.6.




Figure 2. 6: Principe du contour actif (SNAKE) [20]

Le principe de base est de faire placer une courbe (en deux dimensions) formée d'une série de points mobiles dans une zone d'intérêt de l'image. La courbe se déplace jusqu'à une position d'équilibre par l'intermédiaire de forces externes (bords, etc.) et internes (morphologie, courbure, etc.) par la minimisation itérative d'une fonctionnelle. [19]

Après la consultation de certains travaux cités dans [21] nous pouvons en déduire que Les modèles déformables sont peu utilisés pour la segmentation des tumeurs cérébrales.

Les méthodes de segmentation par modèles déformables s'avèrent efficaces pour la segmentation de structures cérébrales particulières. Contrairement aux méthodes dérivatives, ces approches produisent des contours ou des surfaces fermes en raison de leur topologie flexible et de leur robustesse aux variations d'intensités. [19] Elles permettent en effet de s'adapter à la forme complexe des structures grâce à l'enrichissement des contraintes de déformation. Cependant, ces méthodes restent relativement sensibles à leur initialisation (chutes dans des minima locaux). Face à ce problème, les auteurs tendent à inclure des procédures d'initialisation automatique de façon à réduire l'influence des opérateurs et augmenter la reproductibilité des résultats. Bien qu'ayant montré leur efficacité à segmenter les tissus sains, les modèles déformables semblent moins adaptés à la segmentation automatique de zones tumorales. D'une part, la variété des localisations des tumeurs rend l'initialisation automatique du modèle délicate ; on ne peut, contrairement aux structures saines, faire appel à des informations de localisation a priori. D'autre part, dans le cas de lésions multiples, l'utilisation de contraintes internes ne permet pas de modification de la topologie du contour ou de la surface qui ne peut donc pas s'adapter aux objets recherchés. Enfin, lorsque la lésion est non homogène, le modèle déformable peut tomber dans des minima locaux, et donc ne pas converger vers la zone recherchée. [21]

1.3 Approches Structurelles

1.3.1. Ligne de Partage des Eaux

La morphologie mathématique consiste à comparer une structure inconnue à un ensemble de formes, les éléments structurants, dont on maîtrise toutes les caractéristiques. Ces comparaisons s'effectuent au moyen d'opérations booléennes telles que l'intersection et l'inclusion.

L'algorithme de la ligne de partage des eaux (LPE), proposé par Digabel et Lantuéjoul [43], utilise la description des images en termes géographiques. Une image peut en effet être perçue comme un relief si l'on associe le niveau de gris de chaque point à une altitude. Il est alors possible de définir la ligne de partage des eaux comme étant la crête formant la limite entre deux bassins versants.

Pour l'obtenir, il faut imaginer l'immersion d'un relief dans de l'eau, en précisant que l'eau ne peut pénétrer dans les vallées que par ses minima. La ligne de partage des eaux est représentée par les points où deux lacs disjoints se rejoignent au cours de l'immersion. Une des difficultés à la mise en œuvre de cette analogie intuitive est qu'elle laisse beaucoup de liberté quant à sa formalisation. Il existe deux classes principales d'implémentation : l'une est basée

sur un algorithme récursif d'immersion et une autre basée sur l'utilisation de fonctions de distances géodésiques. [14]

Leur définition algorithmique ainsi que leur analyse critique est donnée dans l'article de Roerdink et Meijster. [44]

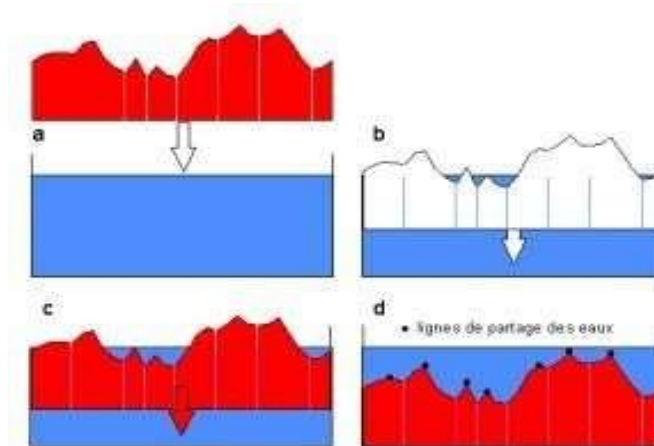


Figure 2. 7: Principe de la Ligne de Partage des Eaux.

Cette technique est souvent associée à une méthode de fusion de régions puisqu'elle donne une sur-segmentation de l'image. Dans [14] Lecoeur et Barillot ont détaillé quelques travaux que nous avons trouvés intéressants :

“ On trouve cette utilisation conjointe dans [45] pour des images multi-dimensionnelles et notamment des IRM de cerveaux. Peng et coll. proposent d'utiliser une immersion multi-degré pour améliorer l'algorithme LPE [46]. Betser et coll. utilisent la LPE dans un contexte de segmentation hiérarchique [47].”

1.3.2. Morphologie mathématique

La morphologie mathématique est une branche des mathématiques fondée sur l'étude des ensembles permettant d'analyser les structures géométriques. Elle permet d'étudier les objets en fonction de leur forme, taille, voisinage, et de leurs intensités (couleur, niveaux de gris, etc.) par des outils de base tels que l'érosion, la dilatation, la fermeture et l'ouverture. Ses bases théoriques ont été établies par Matheron [41] et Serra [35].

La différence symétrique entre l'image dilatée et érodée par le même élément structurant de taille unitaire donne le gradient morphologique qui est un opérateur de détection de contour et qui peut se résumer par l'équation :

$$(1.3) \dots \dots \dots grad_B(X) = \delta_B(X) - \varepsilon_B(X)$$




Figure 2. 8: Segmentation par gradient morphologique [42].

La morphologie mathématique est rarement utilisée seule pour segmenter les structures cérébrales mais fait généralement partie d'une chaîne de traitements plus complexes. À notre connaissance, il n'existe pas de méthode directe de segmentation ou de détection des tumeurs par morphologie mathématique. Cette technique, qui s'appuie sur des informations a priori concernant la forme des objets à segmenter, ne semble donc pas adaptée à la recherche de zones tumorales, celles-ci étant, par nature, caractérisées par une grande variabilité de forme.[21]

1.4 Forme

1.4.1. Modèle actif de forme (ASM)

Les Modèles actifs de forme (en anglais Active Shape Models ou ASM) [48] sont des modèles statistiques de la forme d'un objet qui se déforment itérativement pour s'adapter à un exemplaire de cet objet dans une nouvelle image. Les formes sont contraintes par un Modèle de Distribution de Points (en anglais Point Distribution Models ou PDM). Celui-ci est obtenu par un jeu d'image d'entraînement qui montre différentes formes de cet objet. On calcule ensuite les principaux modes de variations par une analyse en composante principale, ce qui nous donnera les variations autorisées de la forme, constituant ainsi un sous-espace des formes possibles pour l'objet. La forme moyenne est utilisée pour initialiser le processus puis elle est itérativement mise à jour selon deux étapes répétées jusqu'à convergence :

- On cherche le long de la normale aux points le meilleur appariement possible pour le modèle
- On met à jour les paramètres de la forme pour être le plus en adéquation avec le modèle.

La segmentation d'images cérébrales par les ASM a été envisagée par de nombreux auteurs, Duta et coll. [50] ont utilisé ce paradigme avec une base de connaissances pour segmenter les images de volumes IRM de cerveaux. Shen et coll. ont ajouté des informations locales à ce modèle pour créer un ASM adaptatif [55]. Rousson et coll. se sont intéressés à la

relation existante entre les ASM et les level sets [49]. D'autres applications peuvent être trouvées, notamment la modélisation de sillons corticaux et leur mise en correspondance ou bien encore la modélisation des aires visuelles fonctionnelles. Davatzikos et coll. proposent dans [51] d'utiliser les propriétés des transformées en ondelettes pour réaliser une segmentation par ASM hiérarchique, notamment dans le cadre des images biomédicales comme la segmentation du corps calleux.

La qualité de la segmentation étant très dépendante de l'initialisation, celle-ci doit se faire à une distance relativement faible de la cible. Pour améliorer son idée, Cootes a proposé d'inclure une information d'intensité de niveau de gris. Ce sont les Modèles Actifs d'Apparence que nous présentons ci-après.[14]

1.4.2. Modèle actif d'apparence (AAM)

Les Modèles Actifs d'Apparence sont une généralisation de l'approche ASM, mais utilisent toute l'information contenue dans la région d'image couverte par l'objet cible au lieu de ne la prendre qu'autour des arêtes modélisées. Un AAM contient un modèle statistique de la forme et l'apparence de niveau de gris de l'objet d'intérêt et peut donc se généraliser à n'importe quel exemple valide. L'appariement d'une image implique de trouver les paramètres du modèle qui minimisent la différence entre l'image et un modèle synthétique projeté sur l'image. On peut observer qu'éloigner chaque paramètre du modèle de la valeur correcte induit un motif particulier dans les résidus. Dans la phase d'apprentissage, l'AAM apprend un modèle linéaire de la relation entre le déplacement des paramètres et les résidus induits. Pendant la recherche, ces résidus sont mesurés et on utilise le modèle pour corriger les paramètres courants, permettant ainsi un meilleur appariement. Celui-ci est obtenu après seulement quelques itérations même si l'initialisation est pauvre. [14]

L'inconvénient le plus gênant des AAM est probablement le fait qu'elles synthétisent des apparences nouvelles par combinaison linéaire d'apparences connues. Ainsi, tout changement structurel non représenté dans la base d'entraînement ne pourra être reproduit. Par exemple, les AAM ne pourront pas créer un visage dont l'un des yeux est fermé si aucune image de la base ne contient une telle configuration. Si le système doit pouvoir gérer les clins d'œil, il faut obligatoirement que l'entraînement inclut un nombre suffisant de clins d'œil. Cela rend le travail d'étiquetage lourd, d'autant plus que chaque configuration doit être suffisamment représentée. [56]

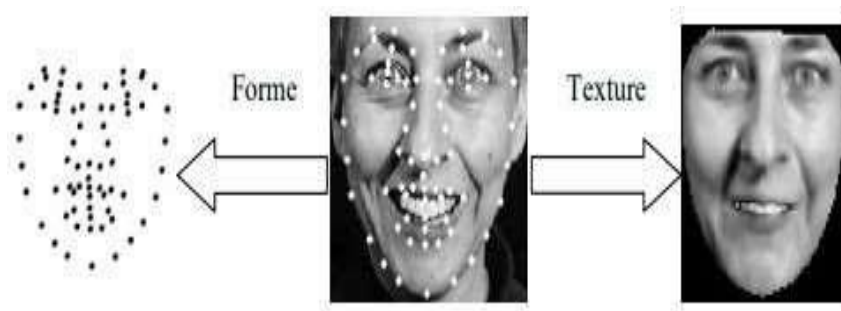


Figure 2. 9: la méthode AAM incluant à la fois la forme et la texture.

1.4.3. Contours Actifs

Les contours actifs sont définis par une courbe du plan qui se déforme d'un état initial pour converger vers un état final, qui sera le résultat de segmentation (les frontières de l'objet) comme le montre la figure 2.10




Figure 2. 10: Evolution du contour actif d'un état initial au résultat final [23]

A partir de cette définition, on peut dire que la spécification de ce modèle de contours actifs revient à spécifier un ensemble des critères :

Une position initiale doit être définie au début de segmentation par une courbe ou une forme adoptée. Cette initialisation peut être manuelle comme dans la proposition de Kass [57] ou automatique.

La déformation du contour est la conséquence d'une optimisation de la fonctionnelle d'énergie attachée au contour actif. Dans le premier modèle de Kass , deux types d'énergies sont définis pour évoluer le contour : énergie interne de régularisation et énergie externe de l'image à segmenter. Le modèle incorpore d'autres contraintes sous la forme d'autres types d'énergies.

La convergence revient à définir la technique de minimisation de la fonctionnelle d'énergie. D'une manière formelle, le contour actif proposé par Kass est une courbe C paramétrée par

l'abscisse curviligne $p \in [A, B]$. L'évolution du contour actif au sein d'une image I est obtenue en minimisant la fonctionnelle suivante :

$$(1.4) \dots \dots E(C) = \alpha \int_B^A |C'(p)|^2 dp + \beta \int_B^A |C''(p)|^2 dp - \lambda \int_B^A |\nabla I(C(p))| dp$$

α, β et λ sont des coefficients positifs

Les deux premiers termes imposent une contrainte interne de régularité sur le contour, tant que le dernier terme est lié aux données externes c'est-à-dire l'image :

Le premier terme définit l'élasticité de la courbe et permet au contour actif de résister à l'étirement. Si cette énergie de continuité est annulée ($\alpha = 0$) alors le contour actif peut être discontinue.

Le deuxième terme est une contrainte de rigidité, et lorsque $\beta = 0$ le contour actif peut présenter une courbure en saillie.

La troisième énergie définie par le dernier terme attire le contour actif vers les points de forts gradients de l'image. [23]

Modèles des contours actifs :

- Balloon-snake [60]
- GVF snake [58]
- Contours actifs non paramétriques [61]
- Contour actif basé région [62] [59]

2. Critères d'évaluation de la segmentation

L'évaluation objective et quantitative des résultats joue un rôle important dans la segmentation d'image [63]. Les critères d'évaluation permettent d'évaluer la satisfaction du diagnostic nécessaire à la visualisation et à la quantification. Les références, souvent sont des atlas, qualifiés "gold standard" ou "ground truth" (vérité terrain) fournies par l'anatomie pathologique.

Pour mesurer quantitativement la qualité d'une segmentation, nous sommes dans le cas où une référence (segmentation idéale) est disponible. La démarche qui en découle réside dans la comparaison des résultats de segmentation avec cette référence. Les critères les plus usuels font appel à des notions ensemblistes : faux positifs et faux négatifs. Ces indices qui sont employés fréquemment pour mesurer les erreurs absolues du résultat de segmentation sont définis ainsi :

- **Faux positifs**, quand la méthode de segmentation a trouvé des pixels qui ne figurent pas dans l'image de référence. Ils sont notés FalsePos.
- **Faux négatifs**, où l'image référence a indiqué des pixels que la méthode de segmentation n'a pas trouvé, ils sont notés FalseNeg.
- **Vrais positifs**, où l'image de référence possède des pixels que la méthode de segmentation indique aussi, ils sont notés TruePos.
- **Vrais négatifs**, où l'image de référence n'a pas indiqué des pixels et la méthode de segmentation non plus, ils sont notés TrueNeg.[17]

Dans ce mémoire, Nous nous intéressons aux critères qui ont été utilisés pour comparer les méthodes de segmentation d'images cérébrales tels que :

2.1. Indice de similarité de Dice

Dice : Dice Index, détaillé dans Akhondi-Asl & Warfield (2011)

$$(1.5) \dots\dots\dots \text{Dice}(U, V) == 100 \times \frac{2 \times |U \cap V|}{|U| + |V|}$$

$$(1.6) \dots\dots\dots \text{Dice} = \frac{2 \times TP}{(2 \times TP + FP + FN)}$$

Se rapprochant de l'indice de Jaccard défini en équation 1.8, il s'agit également d'un indice de similarité entre deux objets et il est utilisé dans de nombreuses contributions scientifiques. La différence principale est que, contrairement à l'indice de Jaccard, il ne vérifie pas l'inégalité triangulaire stipulant que $|U + V| \leq |U| + |V|$. En effet, son dénominateur est supérieur ou égal à la somme des distances $|U + V|$, ce qui peut occasionner un risque de chevauchement des aires. Cela implique que l'indice de Dice va sur-estimer la vraie valeur de similarité. Il est donc intéressant pour comparer des résultats entre eux mais ne permet pas de valider un résultat de similarité. [68]

2.2. Indice de similarité de Jaccard

JJ : Jaccard Index, détaillé dans Akhondi-Asl & Warfield (2011)

$$(1.7) \dots\dots\dots \text{jaccard}(U, V) = 100 \times \frac{|U \cap V|}{|U \cup V|}$$

$$(1.8) \dots\dots\dots \text{Jaccard} = \frac{\text{Dice}}{(2 - \text{Dice})}$$

Il permet de calculer la similarité entre deux formes en déterminant la surface qu'elles ont en commun par rapport à leur surface totale. La figure 2.11 présente son utilisation sur deux volumes. Il est généralement couplé à la différence relative de volume ou de surface définie en

équation 1.7. Il est souvent utilisé pour classer des algorithmes dans différents concours d'imagerie médicale, notamment dans les grands concours organisés chaque année. [68]

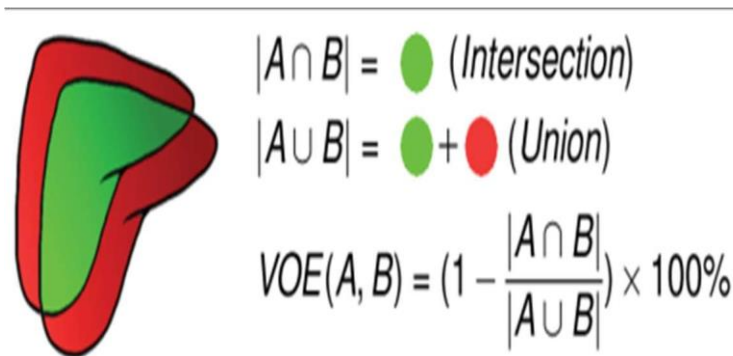


Figure 2.11 :Présentation de l'indice de Jaccard en 3D, aussi appelé VOE (Volume Overlap Error)

2.3. Sensibilité et spécificité

Lorsqu'une décision binaire doit être effectuée (le pixel ou voxel appartient ou non au modèle désiré), Warfield et al. (2004) définit des paramètres de performances binaires : la sensibilité (p_j) et la spécificité (q_j) pour la modélisation j . Pour cette partie, nous définissons : [68]

$i \in \{1, \dots, N\}$ un pixel ou voxel d'une image de taille N ;

$j \in \{1, \dots, r\}$ une segmentation ;

D_{ij} , la matrice de taille $N \times r$ de décision pour la segmentation j au pixel ou voxel i , c'est-à-dire la décision de chacun des experts ;

T , le vecteur référence de taille N contenant pour chaque pixel i la décision binaire, représentant le vecteur de décision final, c'est-à-dire la segmentation supposée être la plus probable ;

Le paramètre de sensibilité p_j pour la segmentation j représente le pourcentage de vrai positif, c'est-à-dire la probabilité d'avoir une bonne décision sachant qu'elle l'est réellement ;

$$(1.9) \dots \dots \dots P_j = \Pr(D_{ij} = 1 | T_i = 1)$$

$$(1.10) \dots \dots \dots \text{Sensitivity} = \frac{TP}{(TP + FN)}$$

• le paramètre de spécificité q_j pour la segmentation j représente le pourcentage de faux négatif, c'est-à-dire la probabilité d'avoir une décision négative sur un point n'appartenant pas au contour : [68]

$$(1.11) \dots \dots \dots q_j = \Pr(D_{ij} = 0 | T_i = 0)$$

$$(1.12) \dots \dots \dots \text{Specitivity} = \frac{TN}{(TN + FP)}$$

2.4. Occuracy

En passant à des métriques globales ayant trois entrées ou plus de M en entrée, de nombreux chercheurs considèrent le calcul de la précision comme la méthode standard à suivre. La précision, en fait, représente le rapport entre les instances correctement prédites et toutes les instances du jeu de données : [65]

$$(1.13) \dots \text{Occuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

2.5. Coefficient de corrélation de Matthews (MCC)

En tant que mesure alternative non affectée par le problème des ensembles de données déséquilibrés, le coefficient de corrélation de Matthews est une méthode de matrice de contingence pour calculer le coefficient de corrélation produit-moment entre les valeurs réelles et prédites. En ce qui concerne les entrées de M, MCC se lit comme suit : [66]

$$(1.14) \dots \text{MCC} = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(VP + FP) \cdot (VP + FN)}}$$

2.6. F-measure

La précision de la classification est largement utilisée car il s'agit d'une seule mesure utilisée pour résumer les performances du modèle.

F-Measure offre un moyen de combiner à la fois la précision et le rappel en une seule mesure qui capture les deux propriétés.

A eux seuls, ni la précision ni le rappel ne racontent toute l'histoire. Nous pouvons avoir une excellente précision avec un rappel terrible, ou alternativement, une précision terrible avec un excellent rappel. La mesure F fournit un moyen d'exprimer les deux préoccupations avec un seul score.

Une fois que la précision et le rappel ont été calculés pour un problème de classification binaire ou multiclasse, les deux scores peuvent être combinés dans le calcul de la mesure F.

La mesure F traditionnelle est calculée comme suit : [67]

$$(1.15) \dots \text{Mesure } F = \frac{(2 \times \text{Précision} \times \text{Rappel})}{(\text{Précision} + \text{Rappel})}$$

$$(1.16) \dots \text{Fmeasure} = \frac{2 \times TP}{(2 \times TP + FP + FN)}$$

Conclusion

Dans ce chapitre, nous avons présenté un état de l'art des différentes techniques de segmentation d'images IRM cérébrales. Nous avons mis en évidence la diversité de ces approches selon la technique qui les régit. Ainsi, nous l'avons classé en quatre catégories principales : contours, régions, formes et structures

Dans le chapitre suivant, nous avons choisis de tester trois techniques de segmentation d'image à savoir le K-means, le FCM et les contours actifs sur les images IRM cérébrales.

Chapitre 3.

Implémentation et résultats

1. Introduction

La segmentation des images IRM cérébrales est une problématique complexe, pour cela divers méthodes ont été proposé dans la littérature.

Dans ce chapitre, nous avons comparé les résultats de segmentation de trois principales méthodes à savoir le K means , le FCM et les contours actifs, notre choix s'est porté sur ces méthodes car c'est les plus utilisées dans la segmentation des images IRM cérébrale et en particulier la segmentation de la tumeur.

Afin de mesurer la qualité de la segmentation, nous avons utilisé plusieurs critères d'évaluation proposés dans le chapitre précédent.

2. Méthodologie

2.1. Présentation de la base de données

Les images sur lesquelles nous avons travaillé dans le cadre de ce mémoire, sont acquises d'une base qui offre 4578 images IRM qui présente 2449 images avec tumeur et 2079 images saines, cette base est disponible sur le site :

<https://www.kaggle.com/datasets/preetviradiya/brian-tumor-dataset>.

Afin de tester et de comparer les performances des trois algorithmes, nous avons choisi 10 images de cette base qui présente des tumeurs à des stades différents et qui se situe dans des endroits différents, ces images sont présentées dans la figure 1 :




Figure 3. 1: Images originales.

Les deux images **Image01** et **Image03** contiennent des tumeurs faciles à détecter visuellement mais avec deux différents niveaux de gris ce qui rend le résultat dépendant de plusieurs traitements. Tandis que dans **Image02** la zone d'intérêt est mitigée avec une autre zone sans tumeur. Pour les images **Image06**, **Image07** et **Image10**, elles sont pondérées en densité de protons, et finalement nous avons ajoutés les images **Image04**, **Image05**, **Image08** et **Image09** au hasard chacune différente de l'autre.

2.2. Choix des méthodes

Parmi les méthodes proposées dans le chapitre précédent nous avons choisi trois méthodes : **Fuzzy C-Means**, **K-Means** et les **contours actifs**, ces trois algorithmes ont tous été appliqués pour la segmentation des images IRM cérébrales, donc nous avons voulu tester leurs performances sur notre base d'images cérébrale afin de déterminer la meilleure technique à partir des résultats obtenus.

2.3. Implémentation

2.3.1. Prétraitements

Pour chaque algorithme nous avons utilisé un prétraitement différent :

Dans l'algorithme K-means, nous avons utilisé la technique de diffusion anisotrope dans l'étape de filtrage pour réduire le bruit de l'image sans supprimer de grandes parties du contenu de l'image ce qui augmente la possibilité de détection de tumeurs. Pour FCM nous avons implémenté une méthode qui règle La taille d'image en 150×150 . Nous avons utilisé aussi l'algorithme génétique (AG) avec ces paramètres (Population, époque, facteur de mutation), AG est un algorithme de recherche basé sur les mécanismes de la sélection naturelle et de la génétique. Il combine une stratégie de "survie des plus forts" avec un échange d'information aléatoire structuré, il comporte trois opérations algébriques simples : (Sélection, Reproduction, Mutation). Enfin pour Les contours actifs, nous avons utilisé un filtre pour Convertir l'image en niveaux de gris par la fonction `rgb2gray`.

2.3.2. Interface graphique

Nous présentons dans la figure 3.2 L'interface de notre application.

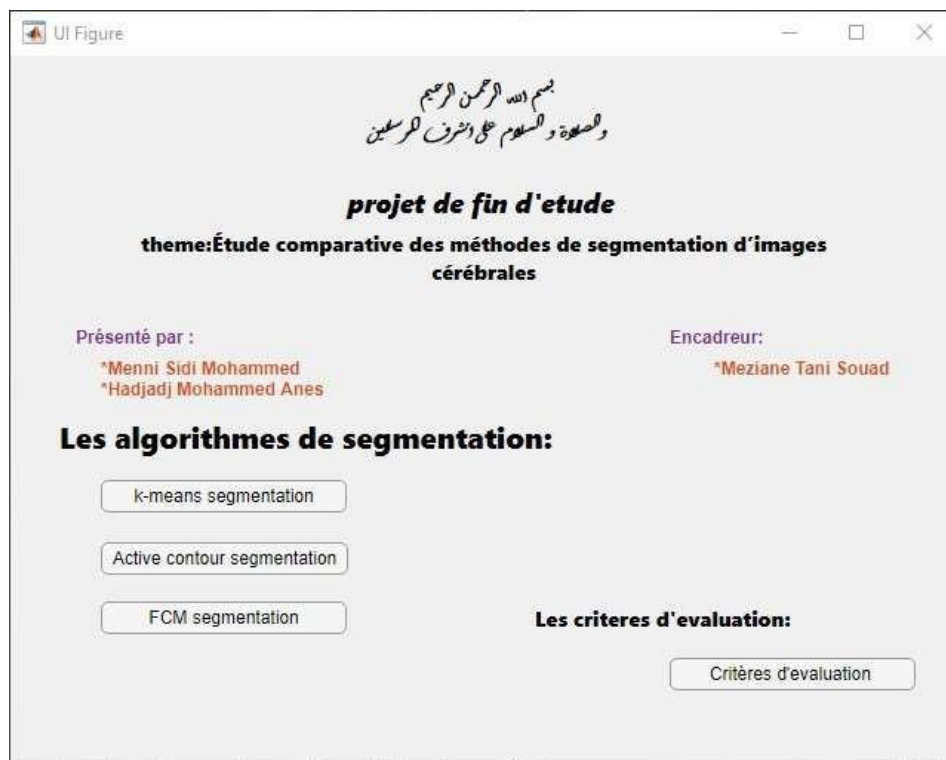
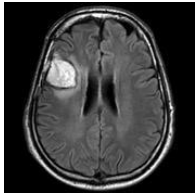
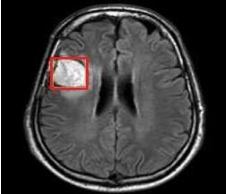
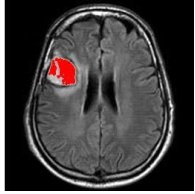
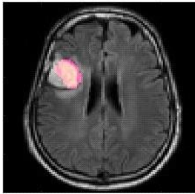
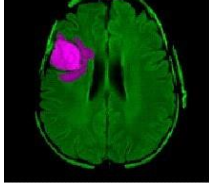
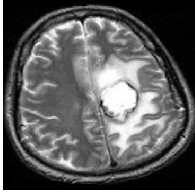
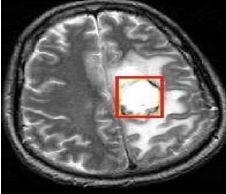
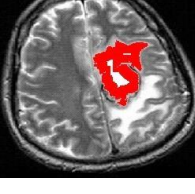
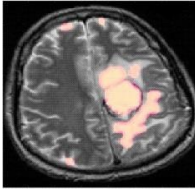
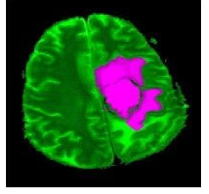
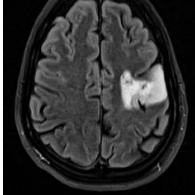
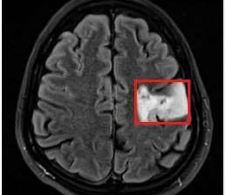


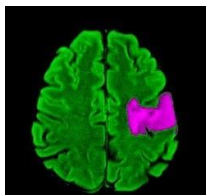
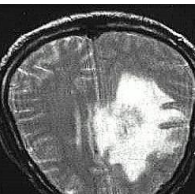

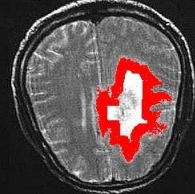
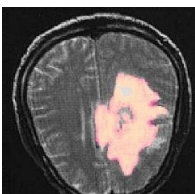
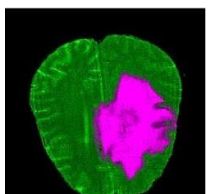
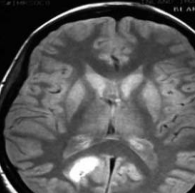
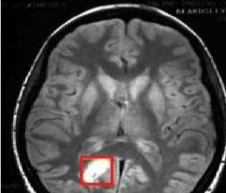
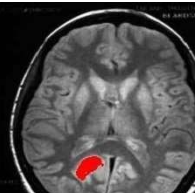
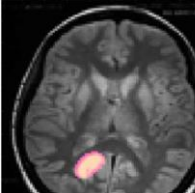
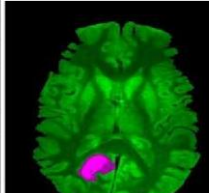


Figure 3. 2: Interface graphique.

Dans cette interface nous avons mis un bouton pour chaque algorithme, pour les trois algorithmes on doit faire une évaluation en cliquant sur le bouton critère d'évaluation.

2.3.3. Résultats et discussion

Le tableau III .1 regroupe les résultats obtenus, dans la première colonne nous trouvons les images avant tout type de traitement, la deuxième contient les images après consultation du radiologue, les colonnes restantes contiennent les images segmentées par les trois algorithmes.

Image à traiter	Résultat souhaité	Résultat obtenu par k-means	Résultat obtenu par FCM	Résultat Obtenu par contours actifs
				
				
				
				
				




Tableau III. 1: résultats de la segmentation.

On remarque pour les deux images **Image01** et **Image03** que les deux algorithmes de classification **k-means** et **FCM** arrivent à détecter facilement la tumeur mais pas entière à cause du petit écart d'intensité à l'intérieure de la tumeur par contre l'algorithme **des Contours Actifs** isole la tumeur et même les petites zones non tumorales qui entourent la tumeur. Pour l'image **Image02** déjà d'une première vue ça parait difficile de distinguer la tumeur de la zone qu'elle se situe sur. Les **K-means** n'arrive pas à isoler la tumeur toute seule et cela dépend de quelques paramètres dans l'algorithme Même chose pour **FCM** mais avec un pourcentage plus élevé.

L'algorithme des **Contours Actifs** comme dans l'image précédente étend la zone d'intérêt vers les zones non tumorales qui entourent la tumeur.

Nous avons pris aussi des images pondérées en densité de protons (DP) : **Image06, Image07 et Image10**, et c'est bien ce qui pose problème dans **FCM**, l'algorithme sélectionne toute régions (nous parlons du liquide céphalo-rachidien (LCR)) là où le niveau de gris est élevé. L'un des avantages de FCM est de graduer l'appartenance des points aux différentes classes. Ceci permet en particulier de prendre en compte les effets de volumes partiels, mais dans des cas particuliers comme le nôtre, ça devient un inconvénient puisque les régions d'intérêts ressemblent au liquide céphalo-rachidien ou toute zone similaire.

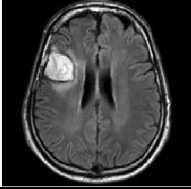
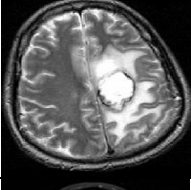
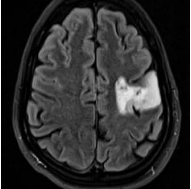

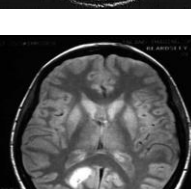
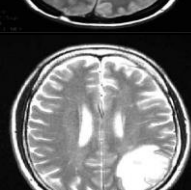
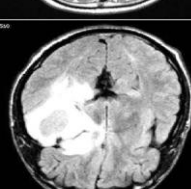
Les quatre dernières images **Image04, Image05, Image08 et Image09**, Ont été parfaitement segmenté par les trois algorithmes, juste quelques petits dépassements de surface par FCM dans Image08 et Image09, nous pensons que le même problème précédent se présente.

Parmi ces dix images : K-means a réussi à segmenter sept d'entre elles, FCM cinq et l'algorithme des contours actifs huit. D'une première expérience on peut en déduire que K-means et les contours actifs ont presque une même performance avec une meilleure précision pour les contours actifs. FCM échoue dans des situations particulières comme nous l'avons déjà mentionné.

2.3.4. Évaluation des résultats de la segmentation

Afin de valider les résultats de segmentation obtenus, nous avons calculé huit critères d'évaluation (**Accuracy, Sensitivity, Fmeasure, Precision, MCC, Dice, Jaccard, Specitivity**) pour les dix images précédentes pour chaque algorithme. Et les résultats sont illustrés dans les tableaux : **Tableau III.2, Tableau III.3, Tableau III.4.**

2.3.4.1. L'évaluation de l'algorithme k-means

IMAGES	images	Accuracy	Dice	Fmeasure	Jaccard	MCC	Precision	Sensitivity	Specitivity
	Image 01	0.9428	0.9417	0.9417	0.8899	0.8856	0.9440	0.9395	0.9461
	Image 02	0.5908	0.9325	0.4870	0.3295	0.3577	0.3219	0.4870	0.9657
	Image 03	0.9004	0.8861	0.8862	0.7956	0.7979	0.8969	0.8756	0.9201
	Image 04	0.8399	0.8094	0.8094	0.6798	0.6767	0.7595	0.8662	0.8229
	Image 05	0.9129	0.9194	0.9194	0.8508	0.8253	0.9036	0.9357	0.8870
	Image 06	0.8935	0.9101	0.9101	0.8350	0.7795	0.9092	0.9110	0.8682
	Image 07	0.9115	0.9114	0.9114	0.8372	0.8293	0.9684	0.8607	0.9685

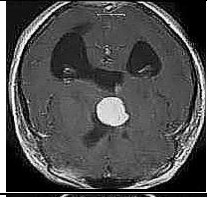
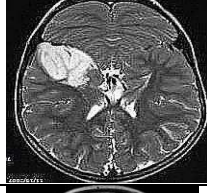
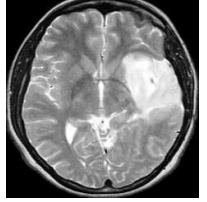
	Image 08	0.9076	0.5917	0.5917	0.4201	0.5398	0.6071	0.5770	0.9510
	Image 09	0.8382	0.7353	0.7353	0.5814	0.6239	0.6812	0.7987	0.8537
	Image 10	0.9539	0.9569	0.9569	0.9174	0.9085	0.9783	0.9365	0.9750

Tableau III. 2: évaluation de K-means


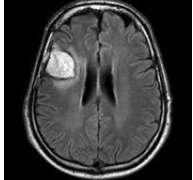
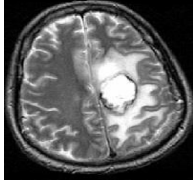
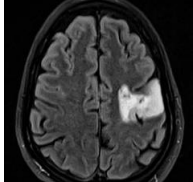

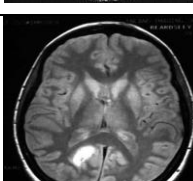
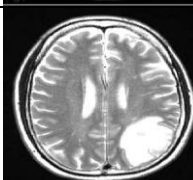



Figure 3. 3: Courbe d'évaluation de K-means

On remarque sur la courbe et d'après les critères d'évaluation que la méthode de segmentation k-means a détecté 70 % des tumeurs avec succès (7 images >65%). On remarque aussi que quelques critères donnent des résultats contradictoires avec la première analyse, comme dans "Image08". Les trois critères **Accuracy**, **Sensitivity**, **precision** chacun a évalué 7 images

correctement (si on fixe un seuil de 0.6) nous pouvons dire que c'est de bons résultats par rapport aux autres critères.

2.3.4.2. L'évaluation de l'algorithme des contours actifs

IMAGES	Accuracy	Dice	Fmeasure	Jaccard	MCC	Precision	Sensitivity	Spicity
	0,6500	0,4668	0,4668	0,3045	0,3899	0,9312	0,3115	0,9777
	0,9423	0,9482	0,9504	0,9630	0,8819	0,9504	0,9056	0,9382
	0,6596	0,4369	0,4369	0,2795	0,3302	0,8159	0,2983	0,9465
	0,7181	0,5298	0,5298	0,3604	0,3918	0,7668	0,4048	0,9205
	0,6135	0,4445	0,4445	0,2858	0,3625	0,9381	0,2913	0,9782
	0,5915	0,4773	0,4773	0,3134	0,3849	0,9826	0,3152	0,9919
	0,6512	0,5341	0,5341	0,3643	0,4042	0,9085	0,3782	0,9573

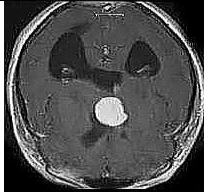
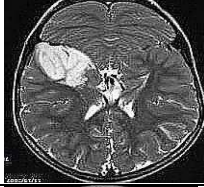
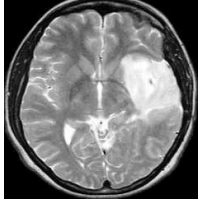
	0,7323	0,2675	0,2675	0,1544	0,1439	0,1959	0,4213	0,7731
	0,6962	0,3887	0,3887	0,2412	0,1943	0,4481	0,3432	0,8345
	0,6322	0,4965	0,4965	0,3303	0,4181	0,9842	0,3320	0,9936

Tableau III. 3: évaluation de contours actifs




Figure 3. 4: Courbe d'évaluation des contours actifs

Pour cette situation, on voit le contraire de ce qu'on a remarqué dans la partie précédente, le résultat est catastrophique pour quelques critères, ça paraît illogique d'une première vue mais après notre analyse nous avons constaté que c'était un problème d'affichage et de coloration et ça n'a rien à voir avec la segmentation, on a confirmé notre jugement par la figure ci-dessous qui présente le résultat de la segmentation par l'algorithme des contours actifs mais avec une petite modification sur l'image segmentée (le filtre d'affichage supprimé), voici le nouveau résultat :

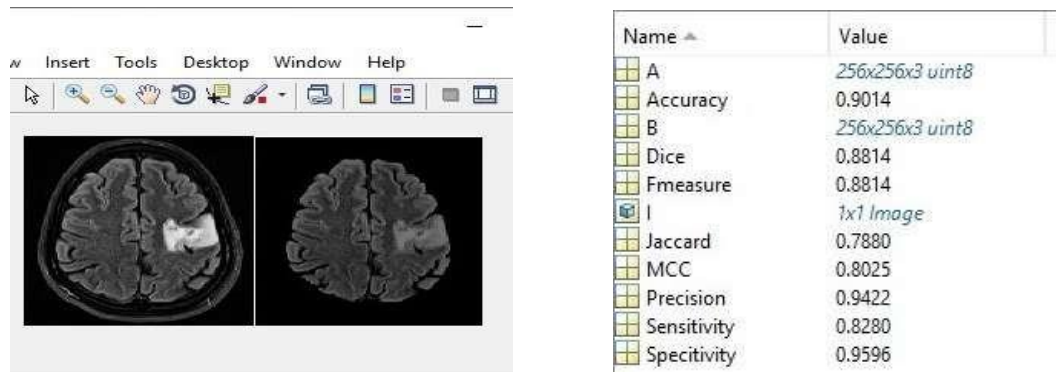


Figure 3. 5: Résultat de segmentation par contours actifs sans filtre final

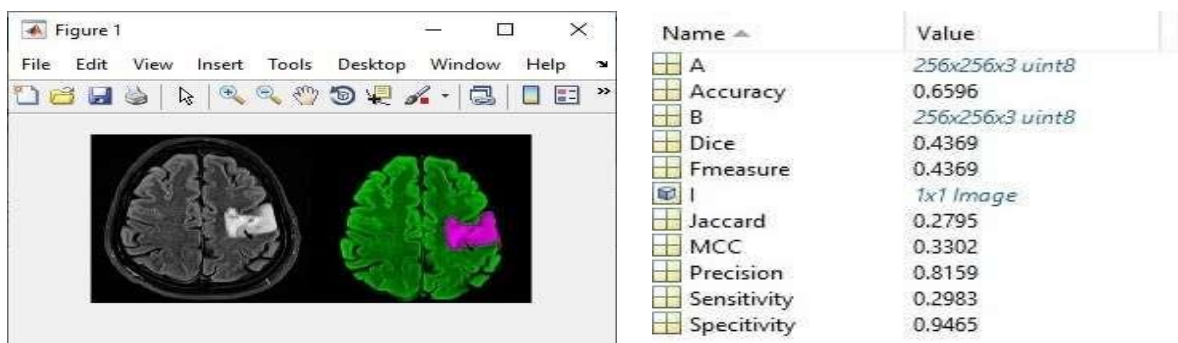
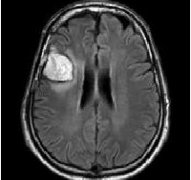
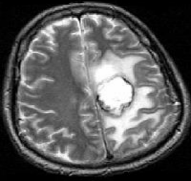


Figure 3. 6: Résultat de segmentation par contours actifs sans modifications

Donc d’après ce qu’on voit nous pouvons confirmer notre première analyse et dire que l’algorithme des contours actifs est un algorithme qui donne de très bons résultats dans la segmentation d’images cérébrales.

2.3.4.3. L’évaluation de l’algorithme FCM

IMAGES	Accuracy	Dice	Fmeasure	Jaccard	MCC	Precision	Sensitivity	Specitivity
	0,9222	0,9220	0,9220	0,8553	0,8448	0,9097	0,9346	0,9102
	0,7830	0,6367	0,6367	0,4671	0,5571	0,9285	0,4845	0,9759

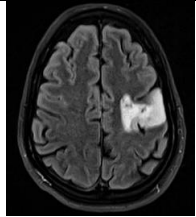
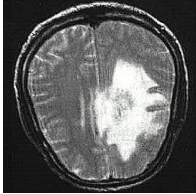
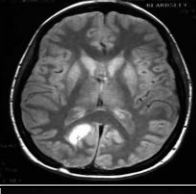
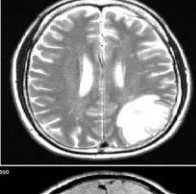
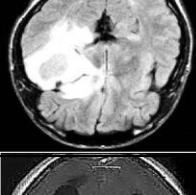
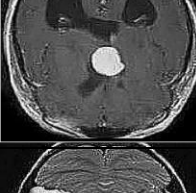

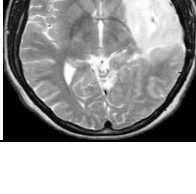
	0,8729	0,8590	0,8590	0,7529	0,7437	0,8438	0,8748	0,8714
	0,9323	0,9421	0,9421	0,8905	0,8609	0,9502	0,9341	0,9297
	0,9524	0,9603	0,9603	0,9239	0,9014	0,9470	0,9741	0,9210
	0,5188	0,3398	0,3398	0,2047	0,0942	0,6256	0,2333	0,8420
	0,9745	0,9760	0,9760	0,9530	0,9488	0,9732	0,9787	0,9698
	0,9478	0,7666	0,7666	0,6215	0,7379	0,7970	0,7384	0,9753
	0,8538	0,6950	0,6950	0,5326	0,6188	0,8415	0,5920	0,9563
	0,9771	0,9791	0,9791	0,9590	0,9538	0,9786	0,9795	0,9742

Tableau III. 4: évaluation de FCM




Figure 3. 7: Courbe d'évaluation de FCM

Les critères les plus précis sont : **Fmeasure, sensitivity et MCC**, chacun a évalué plus de 6 images correctement (si on fixe un seuil de 0.6). On remarque sur la courbe et d'après les critères d'évaluation que la méthode de segmentation FCM a détecté 50 % des tumeurs avec succès (5 images >65%), donc La première analyse est confirmée.

Les critères qui ont donnés de bons résultats sur FCM sont : **Fmeasure, sensitivity et MCC**. sur K-means : **Accuravy, sensitivity, precision**, le critère **sensitivity** est cité comme étant un des critères idéals pour les deux algorithmes, donc nous pouvons le considérer comme le meilleur d'entre eux.

3. Conclusion

Dans ce chapitre nous avons réalisé une série de tests. Les critères d'évaluations qui ont été mis en application pour évaluer les résultats des algorithmes ont permis de confirmer ce qui a été citer dans la première partie du chapitre, K-means a permis une meilleure segmentation par rapport à FCM, la méthode des contours actifs est la méthode la plus puissante et qui a donné les meilleurs résultats.

Conclusion générale

L'objectif de notre travail était de réaliser une segmentation sur des images par résonance magnétique cérébrales (les tumeurs cérébrales plus précisément). Dans un premier temps, nous nous sommes attachées à présenter le contexte de notre étude. Nous avons tout d'abord décrit la démarche clinique du diagnostic des tumeurs cérébrales. Puis, nous avons présenté la technique de l'imagerie par résonance magnétique et observé sa relation avec la détection des tumeurs cérébrales.

Ensuite, nous avons proposé un état de l'art des différentes techniques de segmentation d'images d'IRM cérébrales. Puisque la qualité du résultat est intrinsèquement subjective et que la finalité d'utilisation de la segmentation obtenue influe sur la perception de qualité de ce résultat, le choix d'une technique plutôt qu'une autre est assez ardu.

Nous avons finalement choisi trois algorithmes qui ont tous été appliqués pour la segmentation des images IRM cérébrales : les contours actifs, Fuzzy C-Means(FCM) et K-Means, vu que nous avons voulu tester leurs performances sur notre base d'images de tumeurs cérébrale.

La principale contribution de ce travail de mémoire porte sur une comparaison entre les trois méthodes. L'implémentation de ces algorithmes nous a permis de faire des tests sur des images cérébrales et d'évaluer les résultats obtenus suivant huit critères. Les résultats obtenus montrent que le K-means est meilleur que le FCM. Mais l'algorithme des contours actifs reste le meilleur des trois algorithmes et donne des résultats proches à la réalité, les résultats obtenus sont satisfaisants avec la plupart des images de la base.

Nos résultats qui donnent la localisation des tumeurs pourront servir de prétraitement pour une classification des tissus tumoraux. En termes de perspectives, il est intéressant :

- d'implémenter l'algorithme de contour actif dans un vrai logiciel, qui pourra être exploité et utilisé dans un système de reconnaissance automatique des tumeurs cérébrales par les experts dans le domaine médical pour renforcer la prise de décision finale.
- d'intégrer les deux autres coupes d'IRM (coupes sagittale et coronales), qui sont aussi utilisées dans le milieu clinique pour le diagnostic des tumeurs.

Références

I) Webographie

- [1] <https://www.anatomie-humaine.com/-neuro-anatomie-fonctionnelle-.html>
- [2] <https://www.e-cancer.fr/patients-et-proches/les-cancers/tumeurs-du-cerveau/le-cerveau/les-differentes-parties>
- [3] <https://www.frm.org/nos-publications/innovation-et-sante/imagerie-cerebrale-percer-les-mysteres-du-cerveau>
- [4] <https://www.msmanuals.com/fr/accueil/troubles-du-cerveau,-de-la-moelle-epiniere-et-des-nerfs/tumeurs-du-systeme-nerveux/presentation-des-tumeurs-du-systeme-nerveux>
- [5] <https://www.fondation-arc.org/cancer/cancer-cerveau/symptomes-diagnostic-cancer>
- [11] https://www.maxisciences.com/maladie/quelle-est-la-difference-entre-une-tumeur-et-un-cancer_art43267.html
- [7] https://www.info-radiologie.ch/resonance_magnetique.php
- [6] [https://www.aboutkidshealth.ca/fr/article?contentid=1334&language=french\(definition](https://www.aboutkidshealth.ca/fr/article?contentid=1334&language=french(definition)
- [8] <https://cancer.ca/fr/cancer-information/cancer-types/brain-and-spinal-cord/diagnosis>
- [66] <https://bmcgenomics.biomedcentral.com/articles/10.1186/s12864-01964137>
- [67] <https://deepai.org/machine-learning-glossary-and-terms/f-score>

II) Bibliographie

- [12] o. Dameron. Modélisation, représentation et partage de connaissances anatomiques. 2003.
- [13] capelle-laizé, a. S. (2003). Segmentation d'images irm multi-échocs tridimensionnelles Pour la détection des tumeurs cérébrales par la théorie de l'évidence (doctoral dissertation, Poitiers).
- [14] jérémy lecoeur, christian barillot, « segmentation d'images cérébrales : état de l'art », institut national de recherche en informatique et en automatique, 2007.
- [15] Yves morin, jean-pierre wainsten, and véra lemaire. Larousse médical. Larousse, paris, 2006

- [16] Marcel bosc. Contribution à la détection de changements dans des séquences irm 3d Multimodales. Phd thesis, louis pasteur university, strasbourg, alsace, france, 2003.
- [17] Weibei Dou, « segmentation d'images multispectrales basée sur la fusion d'informations : application aux images irm », Thèse en vue de l'obtention du doctorat, université de caen/basse-normandie, 2006.
- [18] s. Dellepiane. Image segmentation : errors, sensitivity and uncertainty. In 13th IEEE Engineering in medicine and biology society, volume 13, pages 253–254, 1991.
- [19] moussa semchedine, « contribution à la segmentation d'images médicales par les algorithmes bio-inspirés » Thèse pour l'obtention du diplôme de doctorat, université ferhat abbas – sétif 1-, année 2018.
- [20] kessour islam, tali imane, « simulation de contours actifs par la colonie de Fourmis », thèse pour l'obtention du diplôme d'ingénieur d'état en informatique, école Nationale supérieure d'informatique, 2011.
- [21] anne-sophie capelle-laizé. Three dimensional multi-echoes mr segmentation for the Detection of brain tumours by evidence theory. Phd thesis, université de poitiers, December 2003.
- [22] sophie capelle : « segmentation d'images irm multi-échos tridimensionnelles pour la détection Des tumeurs cérébrales par la théorie de l'évidence », thèse doctorat faculté des sciences Fondamentales et appliquées univ de poitiers, 2002
- [23] Fekir Abdelkader, « contribution à la segmentation d'une séquence d'images: application à l'imagerie médicale », Thèse en vue de l'obtention de diplôme de doctorat en sciences, université des sciences et de la technologie d'oran mohamed boudiaf, 2016.
- [24]: wedad. Salem, ahmed f. Seddik, hesham f. Ali, computers and systems Department, electronics research institute, cairo, egypt. Biomédical engineering Department, helwan university, egypt.
- [25] s. L. Horowitz and t. Pavlidis. Picture segmentation by a directed split-and-merge Procedure. In proceedings of the 2nd international joint conference on pattern Recognition, copenhagen, denmark, pages 424–433, 1974.
- [26] ATTAR Tassadit, BENTAYEB Nawel, « segmentation des images irm cérébrales », université mouloud mammeri de tizi ouzou, 2015.
- [27] : touhara mohamed essalah, yahiaoui faouzi « segmentation des images

Médicales 2d et 3d par les modèles déformables géométriques (implicites) fondés sur les Ensembles de niveaux (level sets) » mémoire de fin d'étude pour l'obtention du diplôme D'ingénieur d'état en informatique, école nationale supérieure d'informatique, 2012.

[28] Meziane Abdelfettah, « étude et comparaison des méthodes de segmentation d'image cérébrales » ,Mémoire pour l'obtention du diplôme de magister en informatique, université abou bekr belkaid tlemcen, 2011.

[29] Moussa Semchedine, « système coopératif hybride de classification dans un sma : « application à la segmentation d'images irm », Mémoire fin d'étude pour l'obtention du diplôme magister, université farhat abbas – setif (ufas), année 2007.

[30] j. C. Dunn. A fuzzy relative of the isodata process and its use in detecting compact Well-separated clusters. *Journal of cybernetics*, 3(3) :32–57, 1973.

[31] james c. Bezdek. *Pattern recognition with fuzzy objective function algorithms*. Kluwer Academic publishers, norwell, ma, usa, 1981.

[32] a.n. benaichouche, h. Oulhadj, and p. Siarry. Improved spatial fuzzy c-means Clustering for image segmentation using pso initialization, mahalanobis distance and postsegmentation correction. *Digital signal processing*, 23(5) :1390 – 1400, 2013.

[33] mothd belal al-daoud. A new algorithm for cluster initialization. In the second world Enformatika conference, wec'05, istanbul, turkey, cdrom, pages 74–76, 2005.

[34] m. Emre celebi, hassan a. Kingravi, and patricio a. Vela. A comparative study of Efficient initialization methods for the k-means clustering algorithm. *Expert systems with Applications*, 40(1) :200 – 210, 2013.

[35] jean serra. *Image analysis and mathematical morphology*. Academic press, inc., orlando, Fl, usa, 1983.

[36] john canny. Finding edges and lines in images. Technical report, cambridge, ma, usa, 1983.

[37] j. Shen and s. Castan. An optimal linear operator for edge detection. In *international Conference on vision and pattern recognition*, pages 321–331, 1986.

[38] j.m.s prewitt. *Picture processing and psychophysics, chapter object enhancement and Extraction*, pages 75–149. Academic press, new york, 1970.

[39] l.g. roberts. *Machine perception of three-dimensional solids, chapter optical and electrooptical information processing*, pages 159–197. Mit press, cambridge, 1965.

- [40]i. Sobel. Neighbourhood coding of binary images for fast contour following and general Array binary processing. *Computer graphics and image processing*, 8:127–135, 1978.
- [41] g. Matheron « random sets and integral geometry ». Wiley, new york, 1965.
- [42] y.-t. Hsiao, c.-l. Chuang, j.-a. Jiang et c.-c. Chien : a contour based image segmentation algorithm using morphological edge detection. Dans *iee international conference On systems, man and cybernetics*, volume 3, pages 2962–2967, 10-12 oct. 2005.
- [43] h. Digabel et c. Lantujoul : iterative algorithm. *Quantitative analysis of microstructures In materials sciences*, 1:85–99, 1978.
- [44] j. Roerdink et a. Meijster : the watershed transform : definitions, algorithms and Parallelization strategies. *Fundamenta informaticae*, 41(1-2):187–228, 2000.
- [45] j. Thiran, v. Warscotte et b. Macq : a queue-based region growing algorithm for Accurate segmentation of multi-dimensional digital images. *Signal processing*, 60(1):1–10, 1997.
- [46] s. Peng et l. Gu : a novel implementation of watershed transform using multi-degree Immersion simulation. Dans *international conference of the engineering in medicine and Biology society*, pages 1754–1757, septembre 2005.
- [47] j. Betser, s. Delest et r. Bon : unbiased watershed hierarchical 3d segmentation. Dans *Visualization, imaging, and image processing*, 2005.
- [48] t. Cootes et c. Taylor : active shape models - smart snakes. Dans *proceedings of british Machine vision conference*, 1992.
- [49] m. Rousson, n. Paragios et r. Deriche : active shape models from a level set perspective. *Rapport de recherche 4984, inria*, 2003.
- [50] n. Duta et m. Sonka : segmentation and interpretation of mr brain images using an Improved knowledge-based active shape model. Dans *information processing in medical Imaging*, pages 375–380, 1997.
- [51] c. Davatzikos, x. Tao et d. Shen : hierarchical active shape models, using the wavelet Transform. *Ieee transactions on medical imaging*, 22(3):414–423, mars 2003.
- [55] d. Shen, e. Herskovits et c. Davatzikos : an adaptive-focus statistical shape model for Segmentation and shape modeling of 3-d brain structures. *Ieee transactions on medical Imaging*, 20(4):257–270, avril 2001.

- [56] nicolas eveno : « segmentation des lèvres par un modèle déformable analytique » thèse doctorat, institut polytechnique de grenoble, 2003.
- [57] Kass, A., Witkin and D. Terzopoulos, snakes : active contour models, international journal of computer vision (55), pp 321-331, 1988.
- [58] C. Xu and J. L. Prince. "snakes, shapes, and gradient vector flow". Ieee trans. On image processing 7(3), pp 359-369, march 1998.
- [59] S. Jehan-Besson. Modèles de contours actifs basés régions pour la segmentation d'images et de vidéos. Thèse de doctorat de l'université de nice - sophia antipolis, france, 2003.
- [60] I.D. Cohen, on active contours and balloons, cvgip : image understanding (53), pp 211–218, 1991.
- [61] R. Malladi, J. A. Sethian and B. C. Vemuri, shape modeling with front propagation : a level set approach, ieee transactions on pattern analysis and machine intelligence (17), pp 158–175, 1995.
- [62] T. Chan et L. Vese. Active contours without edges. Ieee transactions on image processing 10(2), pp 266-276, 2001.
- [63] Y.J. et al Zhang. – objective and quantitative segmentation evaluation and comparison. Signal processing, vol. 39, n3, 1994, pp. 43–54.
- [64] Matthew C. Clark, Lawrence O. Hall, Dmitry B. Goldgof, Robert. Velthuizen, F. Reed Murtagh, Martin S. Silbiger. – automatic tumor segmentation using Knowledge-based techniques. Ieee transactions on medical imaging, vol. 17, n2, 1998, Pp. 187–201.
- [65] <https://bmcbgenomics.biomedcentral.com/articles/10.1186/s12864-019-6413-7>
- [68] Pierre Laurent « plateforme d'évaluation multi-critères pour les algorithmes de traitement d'images médicales », école de technologie supérieure, université du québec, année 2017.
- [69] R. Deriche. Optimal edge detection using recursive filtering. In international conference On computer vision, 1987.

Abstract :

Image segmentation is a very important operation in the image processing chain since it contributes directly to diagnosis and decision-making, particularly in the medical field.

In this thesis, we have focused our study on the automatic segmentation of cerebral MRI images and in particular the segmentation of the tumor. Among the methods presented, we are interested in three algorithms: fuzzy c-means (FCM), K-means, and the active contours algorithm. The objective of our work is to implement these three techniques in order to evaluate their effectiveness during the diagnostic aid process, compare their performance, and highlight the advantages and disadvantages of each algorithm.

Keywords:

Automatic segmentation, K-means, Active Contours, FCM, segmentation assessment, braintumors.

Résumé :

La segmentation de l'image est une opération très importante dans la chaîne de traitement d'images puisqu'elle contribue directement dans le diagnostic et la prise de décision, notamment dans le domaine médical.

Dans ce mémoire, nous avons focalisé notre étude sur la segmentation automatique des images IRM cérébrales et en particulier la segmentation de la tumeur. Parmi les méthodes présentées, nous nous sommes intéressés à trois algorithmes : c-moyennes floues (FCM), K-means, et l'algorithme des contours actifs. L'objectif de notre travail est de mettre en œuvre ces trois techniques afin d'évaluer leurs efficacités lors du processus d'aide au diagnostic, comparer leurs performances, et mettre en évidence les avantages et les inconvénients de chaque algorithme.

Mots clés : segmentation automatique, K-means, Contours actifs, FCM, évaluation de la segmentation, tumeurs cérébrales.

ملخص:

يعد تجزئة الصور عملية مهمة للغاية في سلسلة معالجة الصور لأنها تساهم بشكل مباشر في التشخيص واتخاذ القرار، لا سيما في المجال الطبي. في هذه الأطروحة، ركزنا دراستنا على التجزئة التلقائية لصور التصوير بالرنين المغناطيسي للدماغ وعلى وجه الخصوص تقسيم الورم. من بين الطرق المقدمة، نحن مهتمون بثلاث خوارزميات: (FCM, Fuzzy- c-means, K-means, Active Contours). الهدف من عملنا هو تنفيذ هذه التقنيات الثلاثة من أجل تقييم فعاليتها أثناء عملية المساعدة التشخيصية ومقارنة أدائها وإبراز مزايا وعيوب كل خوارزمية.

الكلمات الرئيسية

التقسيم التلقائي، K-means، Active Contours، FCM، تقييم التجزئة، أورام المخ.