



Mémoire de Master

Présenté au

Département : Génie Électrique

Domaine : Sciences et Technologies

Filière : Télécommunications

Spécialité : Systèmes des Télécommunications

Réalisé par :

Mme Baziz Naoual

Et

Melle Rai Zohra

Thème

Classification des images tumorales cérébrales

Soutenu le: 30/10/2021

Devant la commission composée de :

Mr : DJEBIRI Mustapha	M.A.A	Univ. Bouira	Président
Mr : CHELBI SALIME	M.A.A	Univ. Bouira	Rapporteur
Mr : DIB RIAD	M.A.A	Univ. Bouira	Rapporteur
Mr : KASMI Reda	M.C.A	Univ. Bouira	Examineur

Dédicaces 1

De tout mon coeur, je dédie ce travail :

A mes chers parents, pour leur bienveillance, leur aide et leur

soutien tout au long de mes études.

*A mon frère **Achraf abd el kader***

*A mes soeurs **Nada et khaoula***

*A mes **grands-parents**, mes oncles, mes tantes, mes cousins, cousines et*

toute ma grande famille

*A la famille **RAI** et la famille **LAMRI***

*A mes très chères copines, ma second famille : **Nawal, Faiza, Asma, Ilham***

d'être toujours à mes côtés :

Naila, Fatma, Bouchra, Houria

zohra

Dédicaces 2

Je dédie ce modeste travail :

A Mes chers parents, pour votre soutien constant et votre patience

qui m'ont permis d'arriver là. Merci pour votre confiance

renouvelée sans cesse.

A Mes frères et mes sœurs, vous êtes la joie de ma vie .Merci de

tout mon cœur car sans votre soutien et votre patience je n'en serai

jamais arrivée là. Je vous souhaite une vie pleine de réussite

et de bonheur, DIEU nous garde toujours une famille unie.

A la famille Baziz et la famille Malouane

Tous mes amis, pour leur support moral et leur encouragement tout au long

de mes études, bonne continuation et bon courage pour la suite.

Mon cher binôme, Zohra.

Mon marie, Sid ali

Remerciements

*Avant tout, nous tenons à remercier **ALLAH** qui nous a donné l'aide, le pouvoir et la patience pour finaliser ce mémoire. Nous remercions les membres De jury qui ont acceptés D'évaluer ce travail*

Nous tenons à remercier vivement nos chers parents.

*Nous tenons à remercier nos encadreur **Mr. CHELBI Salim** pour leurs conseils et orientations tout au long d'élaboration de ce travail et pour leurs aides précieuses et les enseignants de département Génie électrique de l'université de bouira.*

Nous tenons aussi à remercier tous ceux qui ont, de près ou de loin, aidé à rendre ce travail possible, que ce soit par des idées ou par des Encouragements

Résumé

La classification consiste à regrouper les pixels d'une image en sous-groupes tout en respectant une similarité et une uniformité selon des critères prédéfinis, c'est une étape de décision après l'étape de segmentation.

Notre travail s'intéresse essentiellement à la segmentation par approche classification et d'étudier les différents algorithmes de classification non supervisées à savoir : k-means, le FCM (Fuzzy C-Means) et ces deux variantes (FCM-S1 et FCM-S2) et ARKFCM. Nous nous sommes intéressés à ce dernier algorithme en vue de l'appliquer sur des images IRM de cerveau en vue de segmenter les différents tissus et plus précisément à la détection de la tumeur cérébrale afin d'extraire les principales caractéristiques après l'application de la transformée en ondelette (DWT) suivie de l'application de l'analyse des composantes principales (ACP). Ces caractéristiques sont utilisées dans l'étape apprentissage lors de la classification via le classifieur SVM afin de classer la tumeur bénigne ou maligne.

Mots clés : la segmentation ARKFCM, Imagerie IRM, la transformé en ondelette(DWT), ACP, SVM, la tumeur bénigne et maligne,

Table des Matières

Remerciements	I
Résumé	II
Table des Matières	III
Liste des Figures.....	V
Liste des Tableaux.....	V
Listes des Acronymes et Symboles	VI

Introduction Générale **1**

Chapitre 1 : Traitement d'images et imagerie IRM

1.1.Introduction	2
1.2.Traitement d'image	2
1.2.1.Caractéristique d'une image numirique	2
1.2.1.1.L'mage.	2
1.2.1.2.Le pixel.....	3
1.2.1.3.Résolution.....	4
1.2.1.4.Histogramme d'une image.....	4
1.2.1.5.Luminance	4
1.2.1.6.Contraste.....	5
1.2.1.7.Image aux niveaux de gris	5
1.2.1.8.Image couleur	5
1.2.2. Chaîne d'analyse et de traitement d'images	6
1.3. Imagerie par résonance magnétique.....	7
1.3.1. Principe de l'imagerie par résonance magnétique	7
1.3.1.1 Principe générale	7
1.3.2. Les différents IRM	8
1.3.2.1. IRM anatomique.....	8
1.3.2.2. IRM fonctionnelle	8
1.3.3. Observation de cerveau	9
1.4. Anatomie cérébrale	9
1.4.1. L'encéphale	10
1.4.2. Le cerveau	10
1.4.3. Cervelet.....	11
1.4.4. Tronc cérébrale.....	12
1.5. Les tissus du cerveau.....	12
1.5.1. La matière grise (MG).....	12

1.5.2. La matière blanche (MB)	12
1.5.3. Le liquide céphalo-rachidien (LCR)	12
1.6. Lésions cérébrales	13
1.6.1. Tumeur cérébrale	14
1.7. Conclusion.....	15

Chapitre 2 : Segmentation et classification d'image

2.1.Introduction	16
2.2.Définition de la segmentation	16
2.2.1. Méthodes de segmentation d'images.....	17
2.2.1.1. Segmentation par approche contour	17
2.2.1.2. Segmentation par approche région	17
2.2.1.3. Segmentation par classification de pixels	20
2.3. les méthodes des classifications.	26
2.3.1 classification par GMM (Gaussian mixture modèle : modélisation par mélange gaussiennes).....	26
2.3.1.1. définition	26
2.3.1.2. application de la GMM à la classification du LOS/ NLOS.....	26
2.3.2 Méthode SVM « Support Vector Machine ».	27
2.4. Conclusion.....	28

Chapitre3 : Application et résultats

3.1Introduction	29
3.2.processus de classification de la tumeur	30
3.1.1 base de données utilisées.....	31
3.2.2 Operations morphologiques	31
3.2.3.segmentation par ARKFCM.....	32
3.3. Extraction des caractéristiques.....	33
3.3.1 Transformée en ondelettes discrète	34
3.3.2 Matrice de cooccurrence	35
3.4 classification par SVM (support vector machine).....	38
3.5.Résultat et discussion	39
3.6. Conclusion.....	41
Conclusion Générale	42
Références	43

Liste des Figures

Fig. 1.1 Image numérique.....	3
Fig. 1.2 Illustration d'un pixel.....	3
Fig. 1.3 Une image cérébrale avec son histogramme.....	4
Fig. 1.4 Etapes du processus d'analyse d'images... ..	6
Fig. 1.5 Schéma fonctionnel de l'IRM.....	8
Fig. 1.6 Les différentes courbes du cerveau	9
Fig. 1.7 Le système nerveux central humain.....	10
Fig. 1.8 Structure générale d'un cerveau humain.....	11
Fig. 1.9 Les principales substances.. ..	13
Fig. 1.10 Image IRM normale et en présence d'une tumeur.....	14
Fig. 2.1 Image IRM segmentée par une approche région	19
Fig. 2.2 Recherche d'un hyperplan	28
Fig. 3.1 Processus de classification.....	30
Fig. 3.2 Image avec tumeur et le résultat de segmentation par.	32
Fig. 3.3 Résultat de l'opération morphologique sur la tumeur.. ..	32
Fig. 3.4 Processus d'extraction des caractéristiques de la tumeur.....	33
Fig. 3.5 Arbre de décomposition niveau 3.. ..	34
Fig. 3.6 Transformée ondelettes Discrète s'applique à une image.. ..	34
Fig. 3.7 L'interpolation géométrique des SVM linéaires.....	38
Fig. 3.8 Phase de classification de la tumeur par les SVM.. ..	39

Liste des Tableaux

Tab.3.1. Résultats de la classification des tumeurs présentes dans les images IRM	40
Tab.3.2. Taux de classificatio.....	41

Listes des Acronymes et Symboles

• Acronymes

IRM	Imagerie par Résonance Magnétique
RGB	Rouge, Vert , Bleu
LCR	Le liquide céphalo-rachidien
MG	La matière grise
MB	La matière blanche
RMN	Résonance Magnétique Nucléaire
FCM	Le Fuzzy C-means
ARKFCM	Adaptively Regularized Kernel Fuzzy C Means
GMM	Gaussian Mixture Model
PDF	La fonction de densité de probabilité
EM	Expectation Maximisation
NLOS	Sans lign de vue(Non Line Of Sight)
LOS	Signal à vue(Line Of Sight)
SVM	Support Vector Machine
IDM	Moment de différence inverse

• Symboles

ε	Seuil représenant l'erreur de convergence.
φ	paramètre de régularisation adaptatif

Introduction Générale

Le cerveau humain est complexe, et peut être le sujet de nombreuses anomalies provoquant des symptômes et des problèmes neuropsychologiques qui affectent le système nerveux central. A cet effet, l'exploration du cerveau est plus que nécessaire et appuyée avec l'émergence de nouvelles méthodes d'imagerie médicale. Il existe plusieurs outils cliniques permettant de surveiller les régions cérébrales, à savoir, les scanners à rayons X, la mesure de densité tomographique et la mesure de densité tomographique, l'imagerie par résonance magnétique (IRM). Ce dernier est le plus couramment utilisé dans les routines cliniques.

Le traitement d'images numériques désigne les différentes techniques utilisées afin d'extraire des informations pertinentes qui aident les médecins à faire le diagnostic et le choix de traitement pour prévenir le développement d'éventuelles maladies du cerveau.

A travers ce travail on vise de traiter des images IRM qui est un outil important pour détecter des maladies (la présence d'une tumeur), c'est dans ce contexte que s'inscrit ce travail qui est divisé en trois chapitres :

Le premier chapitre donne des généralités sur les images, les bases du traitement d'images, l'imagerie IRM, et on termine par une présentation de l'anatomie cérébrale.

Dans le deuxième chapitre, nous allons expliquer les différentes approches de la segmentation d'images, nous avons détaillé les méthodes Kmeans, Fcm avec ces variantes et le ARKFCM, ce dernier sera utilisé dans notre application et on le termine par une présentation de quelques méthodes de classification. à savoir, les SVM et les GMM.

Dans le dernier chapitre nous avons présenté les différents organigrammes des algorithmes utilisés dans la segmentation pour cerner et détecter la tumeur et cela pour extraire les différentes caractéristiques qui alimenteront la bibliothèque d'apprentissage lors la classification avec classificateur linéaire SVM pour classer ces tumeurs et prendre une décision si c'est une tumeur bénigne ou tumeur maligne.

Chapitre 1:

Traitement d'images et imagerie IRM

1.1. Introduction :

Le traitement d'images est un domaine très vaste qui a connu, et qui connaît encore, un Développement important depuis quelques dizaines d'années. On désigne par traitement d'images numériques l'ensemble des techniques permettant de modifier une image numérique afin d'améliorer ou d'en extraire des informations et cela dans divers domaines à savoir : télédétection, médicale intelligence artificielle...etc.

De ce fait, le traitement d'images est l'ensemble des méthodes et techniques opérant sur celles-ci, dans le but de rendre cette opération possible, plus simple, plus efficace et plus Agréable, d'améliorer l'aspect visuel de l'image et d'en extraire des informations jugées Pertinentes.

Ce chapitre est réparti en deux parties, nous commençons par le traitement d'images et citer quelques notions de base de l'imagerie et la deuxième partie est une présentation du principe des images à résonance magnétique, le principe de leurs acquisitions suivies après d'un aperçu sur l'anatomie cérébrale saine et tumorale quicorrespond aux données que nous allons utiliser.

1.2. Traitement d'images

Manipuler l'image, c'est de la traiter comme un tableau d'entier à deux dimensions chaque élément est appelé de pixel. Ces processus s'appliquent toujours aux images en niveaux de gris, et ils s'appliquent également aux images en couleur. On distinguera plusieurs étapes de traitement (acquisition, prétraitement, segmentation...) [2]

1.2.1. Caractéristiques d'une image numérique

1.2.1.1. L'image

Le mot image, du latin imago désigne la représentation visuelle d'un objet par différents moyens ou supports, le dessin, la peinture, la sculpture, la photographie, le film...etc. La numérisation est le processus qui permet de passer de l'état d'image physique qui est caractérisé par l'aspect continu du signal qu'elle représente à l'état d'image numérique qui est caractérisé par l'aspect discret. Cette opération permet son exploitation dans différents domaines.

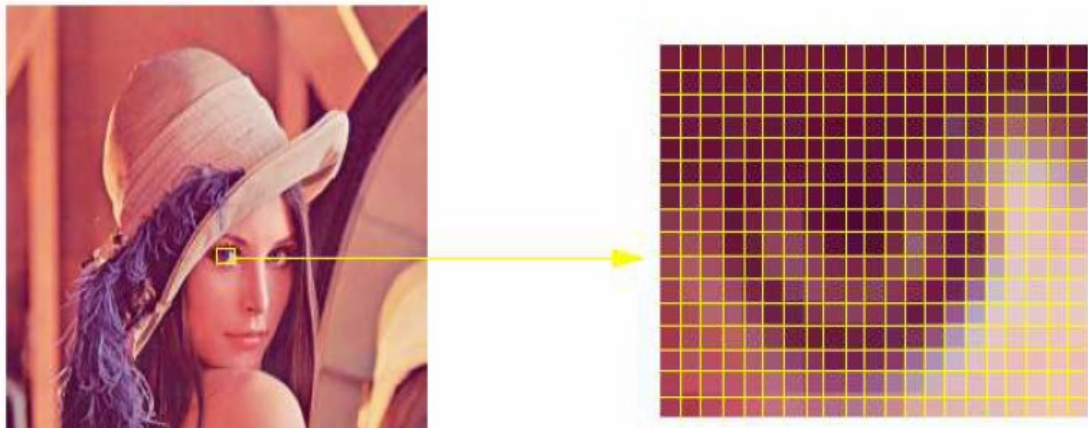


Figure 1.1: Image numérique

1.2.1.2. Le pixel

Le nom "pixel", provient de l'expression anglaise "Picture element", qui a comme signification "élément d'image" ou "point élémentaire".

Le pixel est l'unité de base et le plus petit élément constitutif d'une image numérique, Il constitue l'unité minimale adressable par le contrôleur vidéo. A chaque pixel est associée une couleur, elle-même décomposée en 3 composantes primaires qui sont le Rouge, le Vert et le Bleu (RGB).

Les pixels ont une forme rectangulaire proche du carré comme le montre la figure suivante :




Figure 1.2: Illustration d'un pixel.

Ici, la couleur associée est le vert et on voit bien la forme rectangulaire voire carrée de cet élément de base d'une image numérique

1.2.1.3.Résolution

C'est la clarté ou la finesse des détails obtenus dans une image, la résolution est exprimée en Nombre de pixels par unité de mesure (pouces ou centimètres). Plus le nombre est grand, meilleure est la résolution [3].

1.2.1.4.Histogramme d'une image

L'histogramme des niveaux de gris d'une image est un graphique sous la forme d'une courbe qui met en valeur la répartition des pixels d'une image selon leur luminosité offrant ainsi une visualisation de l'exposition d'une photo. Un simple exemple est représenté sur la figure 1.3.

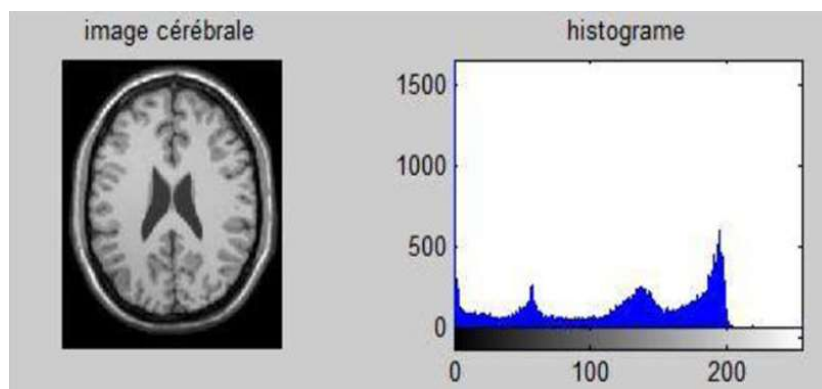


Figure 1.3 : Une image cérébrale avec son histogramme [1].

1.2.1.5.Luminance

Il s'agit de la luminosité du point dans l'image. Il est également défini comme le quotient de l'intensité lumineuse d'une surface divisé par l'aire apparente de cette surface, pour les observateurs au loin, la luminosité des mots est remplacée par une brillance, qui correspond à l'éclat d'un objet. Les caractéristiques d'une bonne luminosité sont [3] :

- Images lumineuses (brillantes) ;
- Bon contraste : évitez d'avoir tendance à Blanc ou noir ; ces images entraîneront une perte de détail de la zone Sombre ou clair
- L'absence de parasites

1.2.1.6. Contraste

C'est l'opposition évidente entre les deux zones de l'image, ou plus exactement, l'opposition évidente entre les zones sombres et lumineuses de l'image. Le contraste est défini comme La luminosité des deux zones de l'image. Si L_1 et L_2 sont le degré de luminosité Dans les deux zones adjacentes A_1 et A_2 de l'image, le contraste C est défini par le rapport[3] :

$$C = \frac{L_1 - L_2}{L_1 + L_2} \quad (1.1)$$

1.2.1.7. Image aux niveaux de gris

Pour les images en niveaux de gris, chacun de ces pixels peut prendre une valeur dans l'intervalle $[0 \ 255]$, allant du noir représenté par « 0 » au blanc représenté par « 255 », en passant par tous les niveaux de gris

1.2.1.8. Image couleur

Généralement les images couleurs sont basées sur trois couleurs primaires : Rouge, Vert et Bleu (RVB) (RGB en anglais), et utilisent typiquement 8 bits pour chaque composante de couleur, donc chaque pixel nécessite $3 \times 8 = 24$ bits pour coder les trois composantes, et chaque composante de couleur peut prendre l'une des valeurs de l'intervalle $[0 \dots 255]$, Il en résulte qu'une image en couleurs est en pratique trichrome et elle est représentée par trois fonctions $f_1(x, y)$, $f_2(x, y)$ et $f_3(x, y)$ traduisant les intensités des trois composantes au point (x, y) .

Si possible de convertir l'image RVB en niveau de gris selon plusieurs méthodes la plus simple est de faire **gris** = $\frac{\text{bleu} + \text{vert} + \text{rouge}}{3}$ c'est l'équivalent d'affecter la couleur gris à chacune des trois composants RVB.

1.2.2. Chaîne d'analyse et de traitement d'images

Le processus d'analyse et de traitement d'image se décompose en plusieurs étapes :




Figure 1.4 : Etapes du processus d'analyse d'images.

Le premier procédé dans ce processus est l'acquisition d'une scène comme le montre la ci-dessus, cette étape consiste à discrétiser l'image réelle afin d'être traité par l'ordinateur. Cette opération engendre des pertes d'informations affectant la qualité d'image. De ce fait l'image doit passer par un prétraitement afin de restaurer les informations dégradées.

Après le prétraitement de l'image, vient l'étape de segmentation qui est une opération de bas niveau et qui joue un rôle fondamentale. Elle a pour but de partitionner une image en régions ou à détecter leurs frontières.

Cette étape est la plus importante, la qualité de son résultat conditionne les autres opérations dites de haut niveau telle que la décision et la description de l'image. Nous allons détailler ultérieurement.

Ensuite, viennent les traitements de haut niveau, telles que la description de l'image, la classification, la reconnaissance des formes et les décisions qui pourront être prises à partir des résultats fournis par la segmentation.

1.3. Imagerie par résonance magnétique

L'imagerie par résonance magnétique est une technique d'imagerie médicale basée sur le phénomène de résonance magnétique nucléaire. Un examen qui permet de compléter le diagnostic de certaines pathologies, fournissant des images tridimensionnelles d'une partie du corps, notamment du cerveau et en coupe bidimensionnelle de grande précision anatomique, les images faites sont des images dynamiques permettant au chirurgien en l'occurrence de visualiser la pathologie et de proposer un traitement adéquat.

L'IRM est le seul examen qui permet de voir s'il y a eu un accident vasculaire, grâce à sa capacité de voir à l'intérieur du cerveau lui-même. Elle utilise un champ magnétique (aimant) et des ondes radio. Aucune radiation ionisante n'est émise. Son principe consiste à réaliser des images du corps humain grâce aux nombreux atomes d'hydrogène qu'il contient [4]

1.3.1. Principe de l'imagerie par résonance magnétique (IRM)

1.3.1.1 Principe générale

L'IRM est une technique d'investigation très performante, parfaitement indolore et sans danger [5]. L'IRM n'utilise pas de rayons X, elle est basée sur le principe de la résonance magnétique des protons du corps humain au sein d'un champ électromagnétique. Ce dernier est créé par un aimant géant en forme de tunnel au sein duquel le patient est placé¹. Des ondes électromagnétiques provoquent une aimantation spécifique des noyaux d'hydrogène présents en proportions diverses dans les tissus selon leur teneur en eau. Le signal émis par les protons, lors de leur retour à leur état de base, est à l'origine de la création des images. Les images obtenues sont traitées par de puissants logiciels qui permettent de reconstruire les différentes coupes. Ces images sont visualisées sur un écran puis transformées en clichés radiographiques (Figure. 1.5).

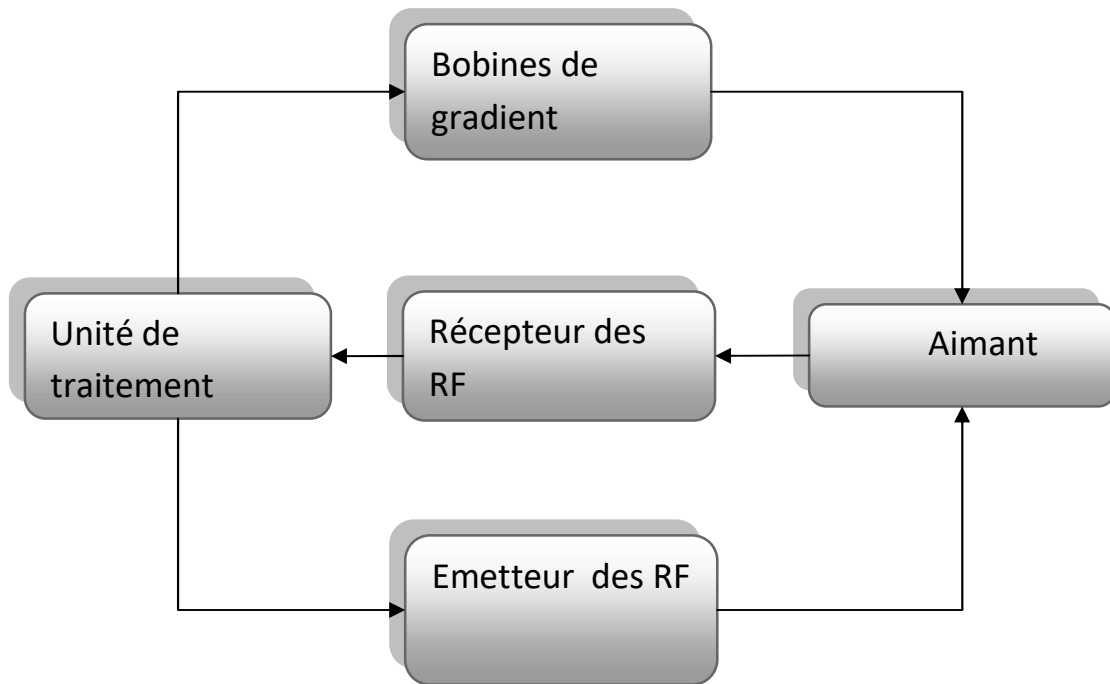


Figure. 1.5 : Schéma fonctionnel de l'IRM.

1.3.2. Les différents IRM

1.3.2.1. IRM anatomique

En médecine, on applique souvent le **RMN** aux noyaux d'hydrogène, élément présent en abondance dans l'eau et les graisses des tissus biologiques. C'est la structure anatomique que l'on visualise ainsi, et on parle alors d'**IRM** anatomique.

1.3.2.2. IRM fonctionnelle

Avec le développement de techniques ultra rapides d'acquisition et de traitement de données, il est devenu possible de réaliser des images **RMN** en des temps suffisamment brefs pour suivre certains aspects du métabolisme. On parle alors d'**IRM** fonctionnelle. En imagerie cérébrale on applique la résonance magnétique à l'hémoglobine dont les propriétés magnétiques différentes légèrement selon que cette molécule est liée ou non à l'oxygène. On accède donc à l'activité cérébrale en réalisant des images où est visualisé le contraste entre les régions riches en oxyhémoglobine et les régions du flux sanguin.

1.3.3. Observation de cerveau

Le cerveau peut être représenté par des coupes bidimensionnelles selon plusieurs angles, il existe principalement trois axes anatomiques qui permettent de réaliser des coupes dites axiales, sagittales, et frontales [6].

1. La coupe axiales (ou transverse) représente une vue de dessus du cerveau. Elle correspond à un plan perpendiculaire au champ magnétique statique.

2. La coupe sagittale est relative à un plan parallèle au plan inter hémisphérique, il s'agit des vues latérales du cerveau.

3. La coupe frontale (ou coronale) est une vue de face du cerveau, elle est acquise sur le plan perpendiculaire aux coupes axiales et sagittales




Figure.1.6: Les différentes courbes du cerveau [2].

1.4. Anatomie cérébrale

Le système nerveux central est constitué de l'encéphale (cerveau, cervelet et le tronc cérébral) et de la moelle épinière. L'ensemble flotte dans un coussin protecteur de liquide céphalorachidien (LCR) [7].




Figure 1.7: Le système nerveux central humain [3].

1.4.1. L'encéphale

Situé dans la cavité crânienne, l'encéphale est isolé dans des parois osseuses par les méninges. Il comprend quatre parties, le cerveau, le diencéphale, le tronc cérébral [8].

1.4.2. Le cerveau

Le cerveau humain est un organe impair de forme schématiquement ovoïde à grand axe antéropostérieur, dont le volume moyen est de 1100 cm³ chez la femme et de 1400 cm³ chez l'homme. Le poids du cerveau varie de 1400 à 1800 gramme. Il occupe la boîte crânienne, mais il n'est pas en contact direct avec la cavité osseuse. Il baigne dans le liquide cérébro-spinal à l'intérieur d'une enceinte liquidienne [9].

Le cerveau est composé des hémisphères cérébraux, du cervelet et du tronc cérébral. Les hémisphères cérébraux sont constitués d'une portion profonde, la substance grise, qui comporte les corps cellulaires, d'une portion superficielle. La substance blanche, qui comporte les axones des cellules, et des ventricules, contenant le liquide cébrospinal [10].

Trois sillons plus accentués (scissure de Sylvius, sillon de Rolando, sillon perpendiculaire), divisent chaque hémisphère en quatre lobes (frontal, temporal, pariétaloccipital) comprenant chacun un certain nombre de circonvolutions [11] :

- Le lobe frontal.
- Le lobe pariétal, séparé du lobe frontal par le sillon central.
- Le lobe occipital, séparé du lobe pariétal par la fissure pariéto-occipital.
- Le lobe temporal, séparé du lobe frontal par la vallée Sylvienne.

Le cerveau commande la plupart des fonctions du corps : la respiration, la contraction des muscles, les battements du cœur et les informations sensorielles : la vision, l'ouïe, toucher, l'odorat et le goût. Il est constitué de cellules nerveuses, les neurones, et de cellules qui en assurent le soutien, la protection et la nutrition, les cellules gliales. La multiplication des cellules gliales, et non de celle des neurones résultent les principaux cancers du cerveau[12].




Figure 1.8 : Structure générale d'un cerveau humain [4].

1.4.3. Cervelet

Le cervelet est situé au-dessous du cerveau et en arrière du tronc encéphalique, auquel il est uni par les pédoncules cérébelleux. Il est divisé en deux hémisphères cérébelleux, droite et gauche, réunis par une structure médiane, le vermis.

Il est divisé en trois lobes et sa surface est parcourue par des fissures. Sa face antérieure délimite avec le tronc cérébral le quatrième ventricule. Il est constitué de deux parties :

- Le cortex, couche périphérique de substance grise.
- Une partie centrale formée de substance blanche, le corps médullaire cérébelleux, et d'amas de substance grise disséminés, les noyaux du cervelet[13].

1.4.4. Tronc cérébrale

Il fait suite à la moelle et se continue en haut avec les hémisphères cérébraux. Il communique en arrière avec le cervelet Il comprend de bas en haut [14]:

- le bulbe rachidien.
- la protubérance annulaire ou pont de Varole.
- les pédoncules cérébraux, recouverts en arrière par les tubercules quadrijumeaux

1.5. Les tissus du cerveau

Le cerveau est composé de trois tissus principaux : le liquide céphalo-rachidien (LCR), la matière grise (MG) et la matière blanche (MB) [15] [16].

1.5.1. La matière grise (MG)

La matière grise (ou substance grise) correspond aux corps cellulaires des neurones

Avec Leur dense réseau de dendrites. Elle se répartit en [17] :

- une couche superficielle d'une épaisseur de quelques millimètres recouvrant le Cerveau et Le cervelet : le cortex.
- en noyaux profonds : les noyaux gris centraux

1.5.2. La matière blanche (MB)

La matière blanche (ou substance blanche) correspond à la gaine de myéline qui recouvre les axones des neurones pour en accélérer la conduction. Les axones myélinisés s'assemblent en faisceaux pour établir des connexions entre groupes de neurones [17].

1.5.3. Le liquide céphalo-rachidien (LCR)

Le liquide céphalo-rachidien (Ou liquide cérébro-spinal, LCS) est le liquide dans le quel baignent le cerveau et le cervelet. D'un volume moyen de 150ml, il est absorbé par le système veineux cérébral et continuellement renouvelé. Ses principaux rôles sont [17] :

- La protection mécanique du système nerveux central contre les chocs par Amortissement Des mouvements,
- La protection contre les infections, car il contient les médiateurs de l'immunité Humorale et Cellulaire.
- Le transport des hormones entre les différentes régions éloignées du cerveau




Figure 1.9: Les principales substances. [3]

1.6. Lésions cérébrales

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

1.6.1. Tumeur cérébrale

Le cerveau peut être le siège de plusieurs de types de tumeurs qui sont répertoriés selon les cellules qui les composent. Une tumeur est une masse issue d'une multiplication (division) accrue de cellules anormales. Elle peut être également appelée un néoplasme ou une excroissance (masse) [18].




Figure 1.10: Image IRM normale et en présence d'une tumeur.

- Les tumeurs cérébrales dites «primaires» sont celles qui se développent directement à partir des cellules du cerveau et de son enveloppe. Elles peuvent être bénignes ou malignes.
- Les tumeurs cérébrales secondaires (ou métastatiques) sont constituées de cellules provenant d'un autre organe, le plus souvent des poumons, des seins, des reins ou de la peau (mélanome). Les cellules tumorales de ces organes peuvent migrer vers le cerveau en empruntant le plus souvent la voie sanguine.

Il existe deux tumeurs cérébrales :

a) Les tumeurs cérébrales bénignes

Les tumeurs cérébrales bénignes sont constituées de cellules qui croissent lentement et qui, à l'analyse microscopique n'ont pas de caractère d'activité importante. Une tumeur cérébrale bénigne peut être soit simplement surveillée radiologiquement soit être extirpée chirurgicalement complètement ou de façon partielle. Si une tumeur bénigne n'est pas complètement enlevée, elle peut récidiver [18].

b) Les tumeurs cérébrales malignes

Les tumeurs cérébrales malignes contiennent des cellules qui se multiplient relativement vite, ces tumeurs croissent donc rapidement. Elles consomment beaucoup d'énergie, leurs contours sont mal limités et aussi elles peuvent envahir endommager des structures cérébrales importantes [19].

1.7. Conclusion

L'imagerie médicale est devenue importante en médecine, les médecins s'en servent pour appuyer leurs diagnostics et établissent des traitements nécessaires. Dans ce chapitre nous avons présenté dans la première partie les bases du traitement d'images en présentant la chaîne d'acquisition des images et nous avons énuméré quelques caractéristiques d'images en général. Dans la deuxième partie, nous avons donné un aperçu sur l'imagerie IRM, principe d'acquisition, et les différents types existants suivi d'une présentation de l'anatomie cérébrale précisant les différentes parties du cerveau, ces différents tissus cérébrales ainsi les différentes lésions et tumeurs existantes qui seront l'objet de notre travail.

Dans le prochain chapitre, nous allons présenter une étape de traitement d'images c'est la segmentation d'images avec ses différentes approches ainsi les méthodes de classification existantes.

Chapitre 2:

Segmentation et classification d'images

2.1. Introduction :

Les méthodes de segmentation d'images par classification sont issues du domaine de classification des données multidimensionnelles. En effet, de nombreuses méthodes ont été modifiées et testées afin d'obtenir celles qui s'adaptent le mieux pour la segmentation d'image. Dans ce contexte la classification permet de regrouper des pixels possédants les mêmes propriétés et les partitionner dans des classes bien définies.

La classification d'images est une application de la reconnaissance de formes en attribuant automatiquement une classe à une image. On retrouve ainsi la classification d'objets, de scènes, de textures...etc. Il existe deux types d'apprentissage, supervisé et non-supervisé. La classification, qu'elle soit son type a toujours été un outil fort employé dans le domaine de l'analyse et du traitement des images numériques, en particulier à des fins de segmentation ou d'interprétation [20].

Ce deuxième chapitre est reparti en deux parties, dans la première partie, nous allons voir la segmentation d'images et ces différentes approches. Dans la seconde partie, nous allons expliquer la base de la classification d'images en présentant les différentes méthodes .

2.2. Définition de la segmentation

La segmentation est un traitement de bas-niveau qui consiste à décomposer complètement ou partiellement une image en régions selon un critère bien déterminée (couleur, texture, niveau de gris,...) ces régions possèdent une corrélation forte avec les objets d'intérêt à détecter dans l'image [21]. Le choix d'une technique de la segmentation est liée à plusieurs facteurs comme : la nature de l'image, les conditions d'acquisition (bruit), les primitives à extraire.

En imagerie médicale, la segmentation est utilisée pour l'extraction de paramètres en cherchant souvent à séparer différentes régions anatomique et cela pour détecter les zones pathologiques.

Classiquement, on peut définir la segmentation comme étant une partition de l'image I en un nombre N de sous-ensembles R_i appelés régions, homogènes dans le sens d'un ou plusieurs critères, comme le niveau de gris, tels que [22]:

- La segmentation doit être complète (c'est-à-dire, chaque pixel doit être affecté à une classe).
- Les pixels appartenant à la même région doivent être connectés.
- Les régions doivent être disjointes.

En termes mathématiques :

a) $U_I^n = \bigcup_{i=1}^n R_i = I$

b) R_i est une région reliée, $i=1,2,\dots, n$.

c) $R_i \cap R_j = \emptyset$ pour $i \neq j$ représente une union d'ensemble disjoints.

U : représente une union d'ensemble disjoints.

Où I est l'ensemble des régions formant l'image I .

Dans un contexte médical, les régions correspondent aux différentes structures anatomiques constituant les différentes régions d'intérêt. La détermination automatique du nombre de régions N est une vraie problématique [23].

2.2.1. Méthodes de segmentation d'images

Dans la littérature il existe trois types d'approche de segmentation à savoir, l'approche de contour, l'approche de région, et l'approche classification.

2.2.1.1. Segmentation par approche contour

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

La notion de « frontière » est associée à une variation d'intensité ou à une discontinuité entre les propriétés de deux ensembles connexes de points. Donc l'approche locale de détection de contour consiste à balayer l'image avec une fenêtre définissant la zone d'intérêt.

A chaque position, un opérateur est appliqué sur les pixels de la fenêtre afin d'estimer s'il y a une transition significative au niveau de l'attribut choisi. A partir des pixels susceptibles d'appartenir à un contour, il faut ensuite extraire des contours fermés. [24]

2.2.1.2. Segmentation par approche région

Les approches régions visent à créer une partition de l'image en un ensemble de régions homogènes au sens d'un ou plusieurs critères. On recherche donc à rassembler les pixels par critères de similarité. Par la suite, nous nous intéressons plus particulièrement aux méthodes à base de seuillages, puis aux méthodes par croissance de régions et finalement aux méthodes fondées sur la morphologie mathématique.

a. Seuillages

Les méthodes de segmentation par seuillages visent à discriminer les individus (pixels) en fonction de leurs niveaux radiométriques (niveaux de gris). Elles supposent donc, de manière implicite, que l'intensité des structures est suffisamment discriminante pour permettre leur bonne séparation. Le plus souvent, les seuils sont déterminés à l'aide d'une analyse d'histogrammes.

Si ces méthodes sont simples à mettre en œuvre [25], on remarque cependant qu'elles nécessitent bien souvent des post-traitements. Ainsi, dans [26] où la problématique est de segmenter le cerveau sur des images pondérées en T_1 , un seuillage automatique fondé sur l'analyse de l'histogramme de l'image est utilisé pour discriminer le cerveau du fond de l'image. Cette méthode, testée sur des données simulées et réelles, est jugée, par les auteurs, simple, rapide et efficace. La segmentation de plusieurs volumes correspondant à un même sujet a montré des résultats satisfaisants.

Les méthodes de segmentation par seuillage sont des méthodes rapides et simples à mettre en œuvre. Néanmoins, elles échouent lorsque les régions de recherche sont insuffisamment contrastées, c'est-à-dire que les niveaux radiométriques des structures anatomiques se recouvrent. Le recouvrement des niveaux radiométriques entre les différentes structures (volume partiel), limitant les performances de ces méthodes [25]. Toutefois, des solutions peuvent être mises en place. De plus, l'absence de prise en compte de contraintes de voisinage rend ces méthodes très sensibles aux bruits, les régions obtenues pouvant alors être sémantiquement peu cohérentes. Enfin, même si théoriquement les méthodes à base de seuillages peuvent s'appliquer à des volumes *multi modales*, elles n'exploitent en général qu'une seule pondération [27].

En dépit de leurs avantages, les méthodes de segmentation par seuillages ne sont pas adaptées pour segmenter les principales structures anatomiques. Leur utilisation nécessite, en particulier, la prise en compte d'informations locales, liées au voisinage d'un pixel.

b. Croissance de régions

Les algorithmes dits croissance de régions sont fondés sur l'agrégation progressive des pixels à partir d'un point initial appelé « germe », selon un critère. Les points voisins du germe sont successivement examinés. S'ils vérifient le critère d'agrégation, ils sont inclus à la région et deviennent à leur tour un germe.

Dans le cas contraire, ils sont rejetés. Le critère est le plus souvent un critère local basé sur les niveaux radiométriques des pixels.

Dans [28], Thiran *et al.* proposent une méthode de croissance de régions pour la segmentation du cerveau à partir des images IRM tridimensionnelles.

La segmentation obtenue permet alors des rendus des surfaces cérébrales. Dans [29], le ventricule latéral et le troisième ventricule sont segmentés par croissance de régions et morphologie mathématique. La croissance de régions est guidée par des connaissances anatomiques a priori sur le système ventriculaire.

Tout comme les méthodes à base de seuillages, les segmentations par croissance de régions sont simples à mettre en œuvre, mais parfois coûteuses en temps de calcul. Leur avantage réside dans la prise en compte des informations contextuelles par le mécanisme de croissance et dans la possibilité d'introduire des informations de plus haut-niveau. Néanmoins, leur inconvénient est lié à la disposition des germes initiaux. En effet, celle-ci nécessite l'intervention d'un opérateur. Enfin, nous notons leur utilisation restreinte au contexte monomodal [25].




Figure 2.1 : Image IRM segmentée par une approche région.

c. Morphologie mathématique

La morphologie mathématique est une branche des mathématiques fondée sur l'étude des ensembles permettant d'analyser les structures géométriques. Ses bases théoriques ont été établies par Matheron [30] et Serra [31].

Les outils de base de la morphologie mathématique (érosion, dilatation, fermeture, ouverture. . .) se retrouvent fréquemment dans des méthodes de segmentation de l'enveloppe cérébrale. Ainsi dans [26], Brumer utilise des érosions, dilatations et étiquetages en composantes connexes à la suite de seuillages afin de déconnecter les structures non cerveau de la structure cerveau et d'affiner le masque initial.

Cette méthode est reprise dans [32], en ajoutant quelques opérations morphologiques de façon à garantir une meilleure robustesse aux variations anatomiques et des acquisitions. Toujours dans [32], Géraud propose, à la suite de la segmentation du cerveau, de coupler seuillages et morphologie mathématique pour segmenter successivement le liquide céphalo-rachidien (ventricules et liquide des sillons) et la matière grise (cortex et noyaux de gris centraux) sur des images pondérées en T_1 . Les résultats obtenus sont jugés très corrects par l'auteur. Il modère toutefois ses propos du fait de la dépendance successive des segmentations et de la nécessité des connaissances des niveaux radiométriques pour la détermination des seuils.

La morphologie mathématique est rarement utilisée seule pour segmenter les structures cérébrales [33] mais fait généralement partie d'une chaîne de traitements plus complexe.

2.2.1.3.Segmentation par classification de pixels

La Classification est un processus qui permet de rassembler les pixels d'une image dans des sous-ensembles qui présentent une similitude et une uniformité selon un critère prédéfini, on parle de partitionnement ou de clustering (classe). Cette approche s'appuie sur les concepts de la logique floue [34].

Les méthodes de classification sont issues des méthodes statistiques multidimensionnelles. Il n'existe pas une méthode de classification qui peut s'appliquer à tout type d'image et qui peut fournir un partitionnement optimal. Ce qui explique la grande diversité de méthodes de classification qui existe dans la littérature. Le choix d'une méthode est déterminé par différents facteurs tels que le nombre de classes attendues, la forme des classes extraites ou encore le chevauchement ou non des classes [35].

a. Méthodes supervisées

Les méthodes de classification supervisées supposent la connaissance a priori de l'appartenance de chaque échantillon de l'ensemble d'apprentissage à une classe donnée, ce qui revient à supposer une connaissance a priori sur l'image à segmenter. Dans notre cas, il s'agit la segmentation des images médicales IRM cérébrales. La classification supervisée de ces images nécessite à la création d'une base d'apprentissage pour chaque classe et pour chaque patient ce qui est en elle-même une tâche très fastidieuse pour les experts. C'est pour cette raison qu'on s'intéresse aux méthodes non supervisées.

b. Méthodes non supervisées (Automatiques)

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

La mesure de proximité est calculée sur tous les attributs, il n'y a donc pas de réduction de l'espace de représentation. Comme il n'y a pas d'exemples d'apprentissage, si certains attributs utilisés sont non représentatifs des classes recherchées, le résultat pourra être médiocre. [22]

• Les K-means ou k-moyennes

C'est l'un des algorithmes le plus connu et le plus utilisé en classification non supervisée du fait de sa simplicité de mise en œuvre. Il vise à produire un partitionnement des pixels de manière à ce que les pixels d'une même classe soient semblables et les pixels issus de deux classes différentes soient dissemblables. Chaque classe de la partition est définie par ses objets et son centroïde.

Le principe de K-means est de choisir aléatoirement un ensemble de centres fixé a priori et de chercher itérativement la partition optimale. Chaque individu (également appelé centroïde ou centroid en anglais) est associé au centre le plus proche, après l'affectation de toutes les données la moyenne de chaque classe est calculée, elle constitue les nouveaux représentants des groupes, lorsqu'on aboutit à un état stationnaire (aucune donnée ne change de groupe) l'algorithme est arrêté.

Le principe des K-means est de minimiser la fonction objective :

$$J(x, v) = \sum_{i=1}^n \sum_{k=1}^c \|x_i - v_k\|^2 \quad (2.1)$$

- c est le nombre de classe.
- N est le nombre de données.
- n est le nombre de donnée de chaque classe.
- v_k est le centre de classe i .
- $\| \cdot \|$: est la norme Euclidienne qui mesure la similarité entre un pixel et un autre.

Tenant compte de la nouvelle fonction objectif (1), la mise à jour des centres des classes v se fait avec l'équation (2.2):

$$v_k = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.2)$$

-L'algorithme des K-means

L'algorithme suivant résume les étapes principales pour l'exécution :

Etape 1 : Choisir aléatoirement les C centres initiaux $v_1, v_2, v_3, \dots, v_C$ à partir des points $\{x_1, x_2, \dots, x_N\}$

Etape 2 : Assigner $x_i = 1 \dots N$ à la classe k ; $k = 1 \dots c$ si :

$\|x_i - v_k\| \leq \|x_i - v_p\|$; $p = 1, \dots, C$ Avec : $i \neq p$

Etape 3 : Mettre à jour les centres des classes par la formule (2).

Etape 4 : Répéter de l'étape 2 et 3 jusqu'à atteindre la convergence : $v_k^* = v_k$; $k = 1, \dots, c$.

- **Les c-moyenne flous ou fuzzy c-means (FCM)**

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

$$J = \sum_{i=1}^c \sum_{k=1}^n U_{ik}^m d^2(x_k, v_i) \quad (2.3)$$

Avec :

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

Les degrés d'appartenance doivent satisfaire les conditions suivantes :

$$0 \leq U_{ik} \leq 1, \forall i \in [1, n], \forall k \in [1, n]$$

$$\sum_{i=1}^c U_{ik} = 1 ; \forall k \in [1, n] \quad (2.4)$$

$$0 < \sum_{k=1}^n U_{ik} < n ; \forall i \in [1, n] \quad (2.5)$$

Les degrés d'appartenance U_{ik} et le centroïde v_i s'exprime comme suit :

$$U_{ik} = \frac{(d(x_k, v_i))^{\frac{2}{m-1}}}{\sum_{j=1}^c (d(x_k, v_j))^{\frac{2}{m-1}}} \quad (2.6)$$

$$v_i = \frac{\sum_{k=1}^n U_{ik}^m x_k}{\sum_{k=1}^n U_{ik}^m} \quad (2.7)$$

-L'algorithme des FCM

L'algorithme suivant résume les étapes principales pour l'exécution :

Etape 1 : Fixer les parametres :

C : nombre de classe.

ε : Seuil représenant l'erreur de convergence.

m : Degré de flou.

Etape 1 : initialiser la matrice de degrés d'appartenances U par des valeurs aléatoires dans l'intervalle [0 1].

Etape 3 : Mettre à jour la matrice prototype v par la relation (2.7).

Etape 4 : Mettre à jour la matrice de degrés d'appartenance par la relation (2.6).

Répéter les étapes 3 et 4 jusqu' a satisfaction du critère d'arrêt suivant :

$$\|U^{ancien} - U^{nouveau}\|$$

-Les FCM-S, c-moyennes floues avec contrainte spatiale

Ces FCM intègrent l'information spatiale avec deux techniques différentes, la moyenne et la médiane.

Le fonction objective est exprimée par :

$$Jm = \sum_{i=1}^c \sum_{j=1}^n U_{ij}^m \|x_j - v_i\|^2 + a \sum_{i=1}^c \sum_{j=1}^n U_{ij}^m \|\bar{x}_j - v_i\|^2 \quad (2.8)$$

Le degré d'appartenance U_{ij} et centroïde v_i s'exprime comme suit :

$$U_{ij} = \frac{(\|x_j - v_i\|^2 + a\|\bar{x}_j - v_i\|^2)^{\frac{-1}{m-1}}}{\sum_{i=1}^C (\|x_j - v_i\|^2 + a\|\bar{x}_j - v_i\|^2)^{\frac{-1}{m-1}}} \quad (2.9)$$

$$v_i = \frac{\sum_{j=1}^n U_{ij}^m (x_j - a\bar{x}_j)}{(1-a) \sum_{j=1}^n U_{ij}^m} \quad (2.10)$$

-L'algorithme des FCM-S

L'algorithme suivant résume les étapes principales pour l'exécution :

Etape 1 : Fixer les parametres :

C : nombre de classe.

ε : Seuil repréenant l'erreur de convergence.

m : Degré de flou.

Etape 1 : initialiser la matrice de degrés d'appartenances U par des valeurs aléatoires dans l'intervalle [0 1].

Etape 3 : Calculer le prototype v par la relation (2.10).

Calculer J_m par la relation (2.8) en utilisant la médiane (\bar{x}_j) pour le FCM-S2 ou la moyenne (\bar{x}_j) pour le FCM-S1.

Etape 4 : Mettre à jour la matrice de degrés d'appartenance par la relation (2.9).

Calculer \bar{J}_m par la relation (2.8).

Etape 5 : Répéter les étapes 3 et 4 jusqu'à satisfaction du critère d'arrêt qui est exprimé par :

$$|\bar{J}_m - J_m| < \varepsilon$$

-Algorithme de ARKFCM (adaptively Regularized Kernel Fuzzy C Means)

Un FCM basé sur un noyau régularisé de manière adaptative a été proposé pour améliorer le FCM pour une meilleure précision de segmentation. En effet, sa structure est composée de trois algorithmes qui utilise l'hétérogénéité des échelles de niveaux de gris dans le voisinage des pixels de l'image à segmenter et utilise cette mesure pour les informations contextuelles locales et remplacent la distance euclidienne standard par des fonctions radiales gaussienne (GRBF).

Les principaux avantages dont l'adaptabilité au contexte local et la robustesse améliorée pour préserver les détails de l'image ainsi la réduction des temps de calculs.

La distance euclidienne $\|x_k, v_j\|$ est remplacée par une fonction $\|\phi(x_k) - \phi(v_i)\|$ qui est définie par :

$$\|\phi(x_k) - \phi(v_i)\| = k(x_k, x_k) + k(v_i, v_i) - 2k(x_k, v_i) \quad (2.11)$$

Où ϕ est une équation non linéaire et k le noyau (GRDF)

$$K(x_k, v_i) = \exp\left(-\frac{\|x_k - v_j\|^2}{2\delta}\right) \quad (2.12)$$

La fonction de ARKFM devient comme suit:

$$J = 2\left[\sum_{k=1}^N \sum_{j=1}^C \mu_{kj}^m (1 - k(x_k, v_j))\right] + \sum_{k=1}^N \sum_{j=1}^C \phi_k \mu_{kj}^m (1 - k(\bar{x}_k, v_j)) \quad (2.13)$$

Le degré d'appartenance est :

$$\mu_{kj} = \frac{((1 - k(x_k, v_j)) + \phi_k (1 - k(\bar{x}_k, v_j)))^{-1/(m-1)}}{\sum_{i=1}^C ((1 - k(x_k, v_j)) + \phi_k (1 - k(\bar{x}_k, v_i)))^{-1/(m-1)}} \quad (2.14)$$

$$v_i = \frac{\sum_{k=1}^N \mu_{kj}^m (K(x_k, v_j) x_k + \phi_k K(\bar{x}_k, v_j) \bar{x}_k)}{\sum_{k=1}^N \mu_{kj}^m (k(x_k, v_j) + \phi_k k(\bar{x}_k, v_j))} \quad (2.15)$$

-L'algorithme des ARKFCM

L'algorithme suivant résume les étapes principales pour l'exécution :

Etape 1 : Fixer les paramètres :

C : nombre de classe.

ε : Seuil représentant l'erreur de convergence.

m : Degré de flou.

Etape 1 : initialiser la matrice de degrés d'appartenances U par des valeurs aléatoires dans l'intervalle $[0, 1]$.

Etape 3 : Calculer le paramètre de régularisation adaptatif ϕ_i

Etape 4 : Mettre à jour la matrice de degrés d'appartenance par la relation (2.14). Calculer les nouveaux centres par la relation (2.15)

Etape 5 : Répéter les étapes 4 et 5 jusqu'à satisfaction du critère d'arrêt qui est exprimé par :

$$|J_m^{t+1} - J_m^t| < \varepsilon \quad (2.16)$$

2.3.les méthodes des classifications

2.3.1. classification par GMM (Gaussian mixture modèle : modélisation par mélange gaussiennes)

2.3.1.1.définition

Le modèle de mélange gaussien (GMM) est une fonction de densité de probabilité de paramètre exprimée comme une somme pondérée des densités de composantes gaussienne. Le GMM est généralement utilisé comme modèle de paramètre de la distribution de probabilité de mesure ou de caractéristique continues dans un système de reconnaissance biométrique, comme une caractéristique spectrale liée à un chemin de parole dans un système de reconnaissance de locuteur.

Les paramètres GMM sont estimés à partir des données d'apprentissage à l'aide d'un algorithme de maximisation des attentes (EM) itératif.

2.3.1.2. application de la GMM à la classification du LOS/ NLOS

Les composantes LOS et NLOS suivent souvent une certaine distribution de probabilité, de sorte que le mélange de leurs distributions de probabilité peut être utilisé pour la classification des canaux en attribuant des points de données non étiquetés (signaux non identifiés) à une distribution de probabilité spécifique, à savoir LOS ou NLOS. La fonction de densité de probabilité (PDF) de la fonction sélectionnée contenant les composantes NLOS et LOS peut être modélisée sous forme de distributions gaussiennes, respectivement. Dans ce cas, leur modèle de mélange est également un modèle gaussien, qui peut être utilisé pour classer les composants LOS et NLOS. Par conséquent, une fois que les paramètres pour déterminer le modèle de mélange gaussien sont obtenus, une reconnaissance sans visibilité direct sera effectuée.

Les paramètres de la distribution de probabilité sont généralement déterminés à l'aide de l'algorithme EM (Expectation Maximisation), car les techniques d'optimisation basées sur le gradient sont difficiles à calculer la densité de probabilité mixte. Les fonctions LOS et NLOS peuvent être combinées dans un modèle de mélange gaussien. Par conséquent, pour la composante LOS, $k=1$, et pour la composante NLOS, le modèle de mélange gaussien avec $k=2$ peut être exprimé comme suit :

$$P(X_n) = \sum_{k=1}^2 w_k N(X_n | \mu_k, \theta_k) \quad (2.17)$$

Où

w_k est le coefficient de mélange ou aussi appelé poids pour chaque distribution gaussienne. Les coefficients de mélange satisfont toujours aux conditions ci-dessous :

$$0 \leq w_k \leq 1 \quad (2.18)$$

$$\sum_{k=1}^2 w_k = 1 \quad (2.19)$$

$X_n = (X_{n1}, X_{n2}, X_{n3} \dots \dots X_{nD}), 1 \leq n \leq N$, n est l'index de l'échantillon de données, N est le nombre total d'échantillons de données et D est le nombre de fonctions. Chaque point de données peut être exprimé comme suit :

$$N(X_n | \mu_K, \theta_K) = \frac{\exp\left\{-\frac{1}{2}(X_n - \mu_K)^T \theta_K^{-1} (X_n - \mu_K)\right\}}{(2\pi)^{\frac{D}{2}} |\theta_K|^{-\frac{1}{2}}} \quad (2.20)$$

Où la probabilité gaussienne, $N(X_n | \mu_k, \theta_k)$ pour $k = 1$ est appelée composante LOS et pour $k = 2$ est appelée composante NLOS du GMM.

En bref, un GMM est contrôlé par un ensemble de trois paramètres : vecteurs moyens $\{\mu_1, \mu_2\}$ matrices de covariance $\{\theta_1, \theta_2\}$ et coefficients de mélange $\{w_1, w_2\}$. Pour distinguer les composantes LOS et NLOS, nous devons estimer les vecteurs moyens $\{\mu_1, \mu_2\}$ et les matrices de covariance $\{\theta_1, \theta_2\}$ pour les deux distributions. L'algorithme de maximisation des attentes évalue les paramètres des variables latentes de manière itérative et c'est l'une des techniques les plus élégantes pour l'estimation paramétrique dans l'apprentissage automatique.

2.3.2. Méthode SVM « Support Vector Machine »

Les machines à vecteurs de supports sont un ensemble de techniques d'apprentissage supervisé. Ces techniques sont destinées à résoudre des problèmes de discrimination et de régression.

L'objectif des méthodes SVM est de chercher un hyper-plan dont la distance minimale aux exemples d'apprentissage est maximale, on utilise les points les plus proches et ces points sont dit vecteurs de support. On appelle cette distance « marge » entre l'hyperplan et les exemples. Comme on cherche à maximiser cette marge. [36] [37]

Le schéma ci-dessous (Figure 2.2) présente la recherche d'un hyperplan séparant deux ensembles de points

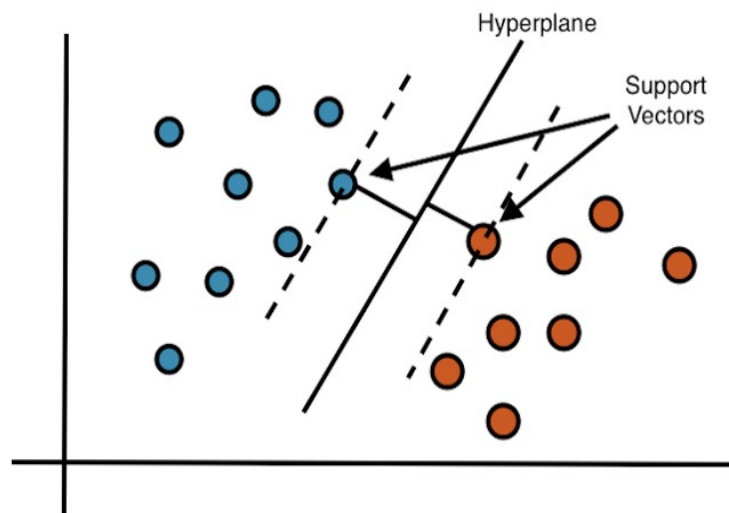


Figure 2.2. Recherche d'un hyperplan [5]

2.4.Conclusion

Dans ce chapitre, nous avons donné un aperçu sur les différentes approches de la segmentation d'images, à savoir: les approches basées contour, basées région et les approches basées classification. Nous avons vu que la segmentation permet de regrouper des objets (individus ou variables) en un nombre limité de groupes ou de classes (segmentes, ou cluster).

Nous avons présenté les différentes méthodes de segmentation les plus utilisées pour la segmentation des images médicales.

Dans la deuxième partie, nous avons présenté quelques méthodes de classification à savoir : la méthode GMM (Gaussian Mixture Model) et la méthode SVM (Support Vector Machines) nous nous sommes intéressés à la dernière méthode SVM pour classer nos données.

Dans le suivant chapitre nous allons appliquer les méthodes de segmentation afin d'extraire la tumeur et avoir les différentes caractéristiques afin qu'on puisse faire un apprentissage pour une éventuelle classification.

Chapitre 3:

Application et résultats

3.1.Introduction

La détection de la structure du cerveau est l'une des étapes de base de l'analyse des images IRM. Elle sépare les différents tissus cérébraux et d'éventuelles maladies cérébrales, telles que la présence de tumeurs. Une bonne segmentation aide le praticien à prendre la décision finale avant la chirurgie. Afin de détecter les tumeurs, compte tenu de ses performances de segmentation, nous utilisons l'algorithme ARKFCM décrit dans le chapitre précédent. Le processus d'extraction du cerveau nous fournit une estimation préliminaire des principaux tissus (MG, MB, LCR, image de fond et tumeur). Par la suite, la sélection de la partie représentant la tumeur nous permet d'extraire un ensemble de caractéristiques utilisées pour classer en tumeurs bénignes ou en tumeurs malignes

3.2. Processus de classification de la tumeur

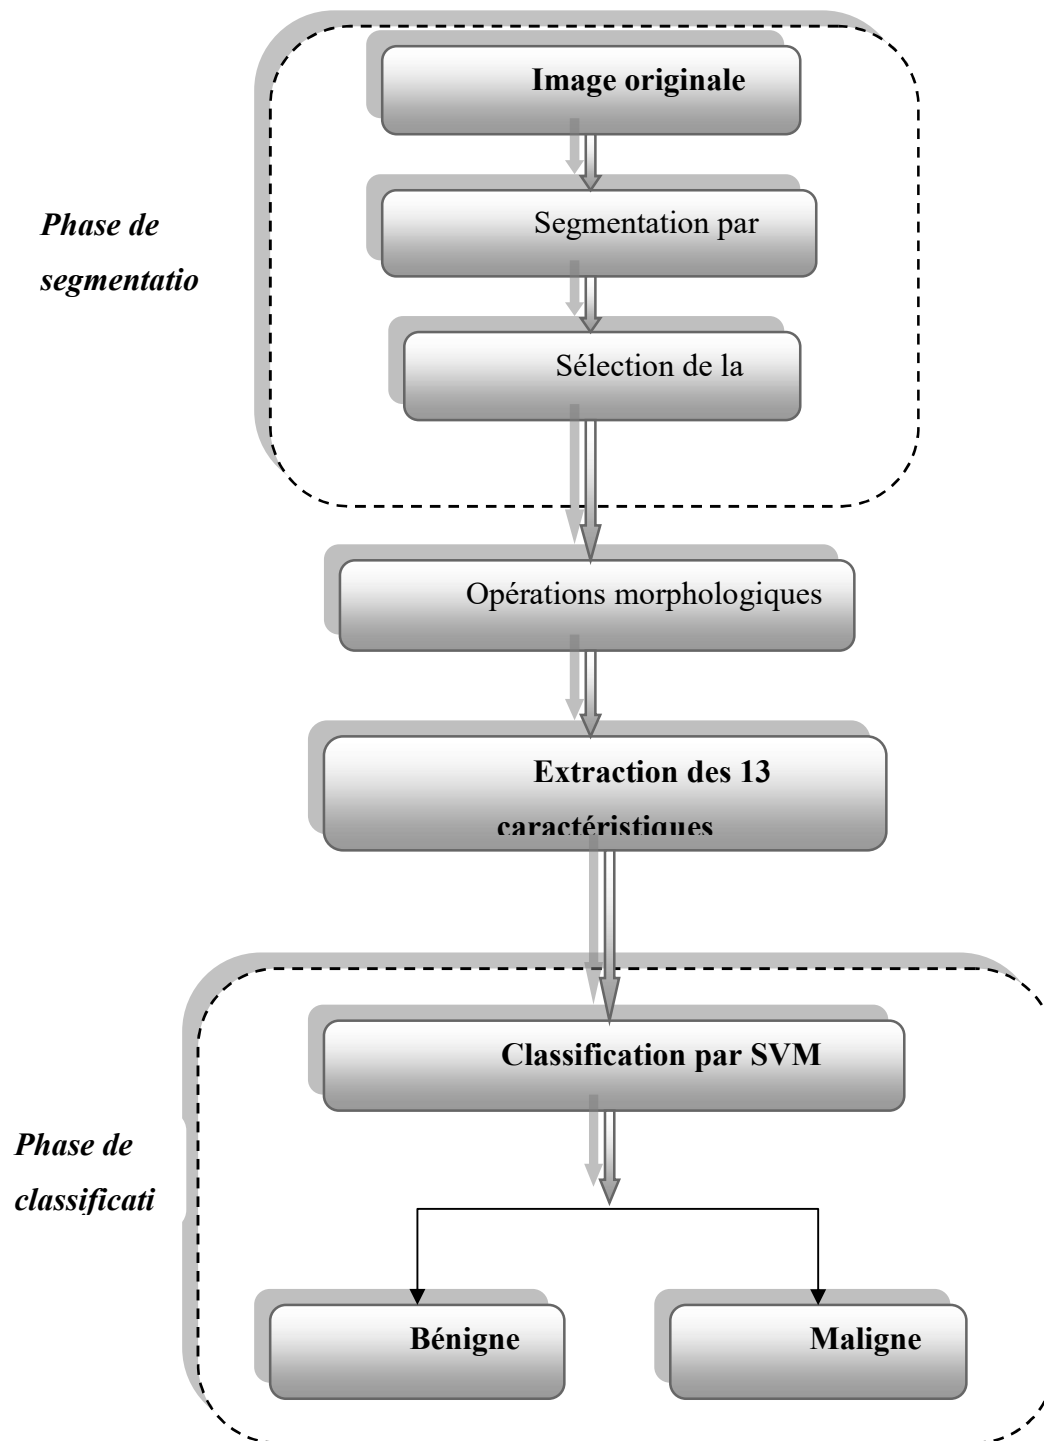


Figure 3.1 : Processus de classification.

3.2.1. Base de données utilisées

Dans ce travail, la base de données utilisée se compose d'images IRM cérébrales de dimensions 256X256 pixels, ont été téléchargés à partir du site web de la HarvardMedicalSchool (<http://med.harvard.edu/AANLIB/>).

3.2.2. Operations morphologiques

Le traitement d'image morphologique est un ensemble d'opérations non linéaires liées à la forme ou à la morphologie des caractéristiques de l'image. Les opérations morphologiques sur une image binaire vont créer une nouvelle image binaire dans laquelle les pixels ont des valeurs non nulles. Manipulation morphologique pour transformer les images[38].

a) Érosion

L'érosion est définis (pour une image binaire en noir et blanc) comme:

$$\epsilon_B(A) = A \ominus B \quad (3.1)$$

Où : A correspond à l'image binaire à traiter et B l'élément structurant avec lequel on parcourt l'image. L'érosion a pour effet d'éliminer les objets ou certaines parties d'objets dont la taille est inférieure à celle de l'élément structurant. Certains objets connectés peuvent également être séparés

b) Dilatation

La dilatation est définis (pour une image binaire en noir et blanc) comme:

$$\delta_B(A) = A \oplus B \quad (3.2)$$

Où : A correspond à l'image binaire à traiter et B l'élément structurant avec lequel on parcourt l'image.

A l'inverse de l'érosion, la dilatation a pour effet d'augmenter la taille des objets, et de fusionner certains d'entre eux, lorsque la distance qui les sépare est inférieure à la taille de l'élément structurant

3.2.3.Segmentation par ARKFCM

Dans la première étape, nous appliquons l'algorithme ARKFCM pour segmenter les images IRM avec des tumeurs dans le cerveau et extraire toutes les catégories contenues dans les images sélectionnées




Figure 3.2 Image avec tumeur et le résultat de segmentation par ARKFCM.

En sélectionnant la classe représentant la tumeur et en appliquant les opérations morphologiques, nous aurons le résultat suivant (figure 3.3).



Figure 3.3:Résultat de l'opération morphologique sur la tumeur.

3.3.Extraction des caractéristiques

Afin d'extraire les caractéristiques représentantes au mieux la tumeur nous procédons à l'extraction de ces caractéristiques uniquement à partir de la classe représentant la tumeur.

Le processus d'extraction du vecteur de caractéristiques de référence est représenté par l'organigramme suivant (figure 3.4).

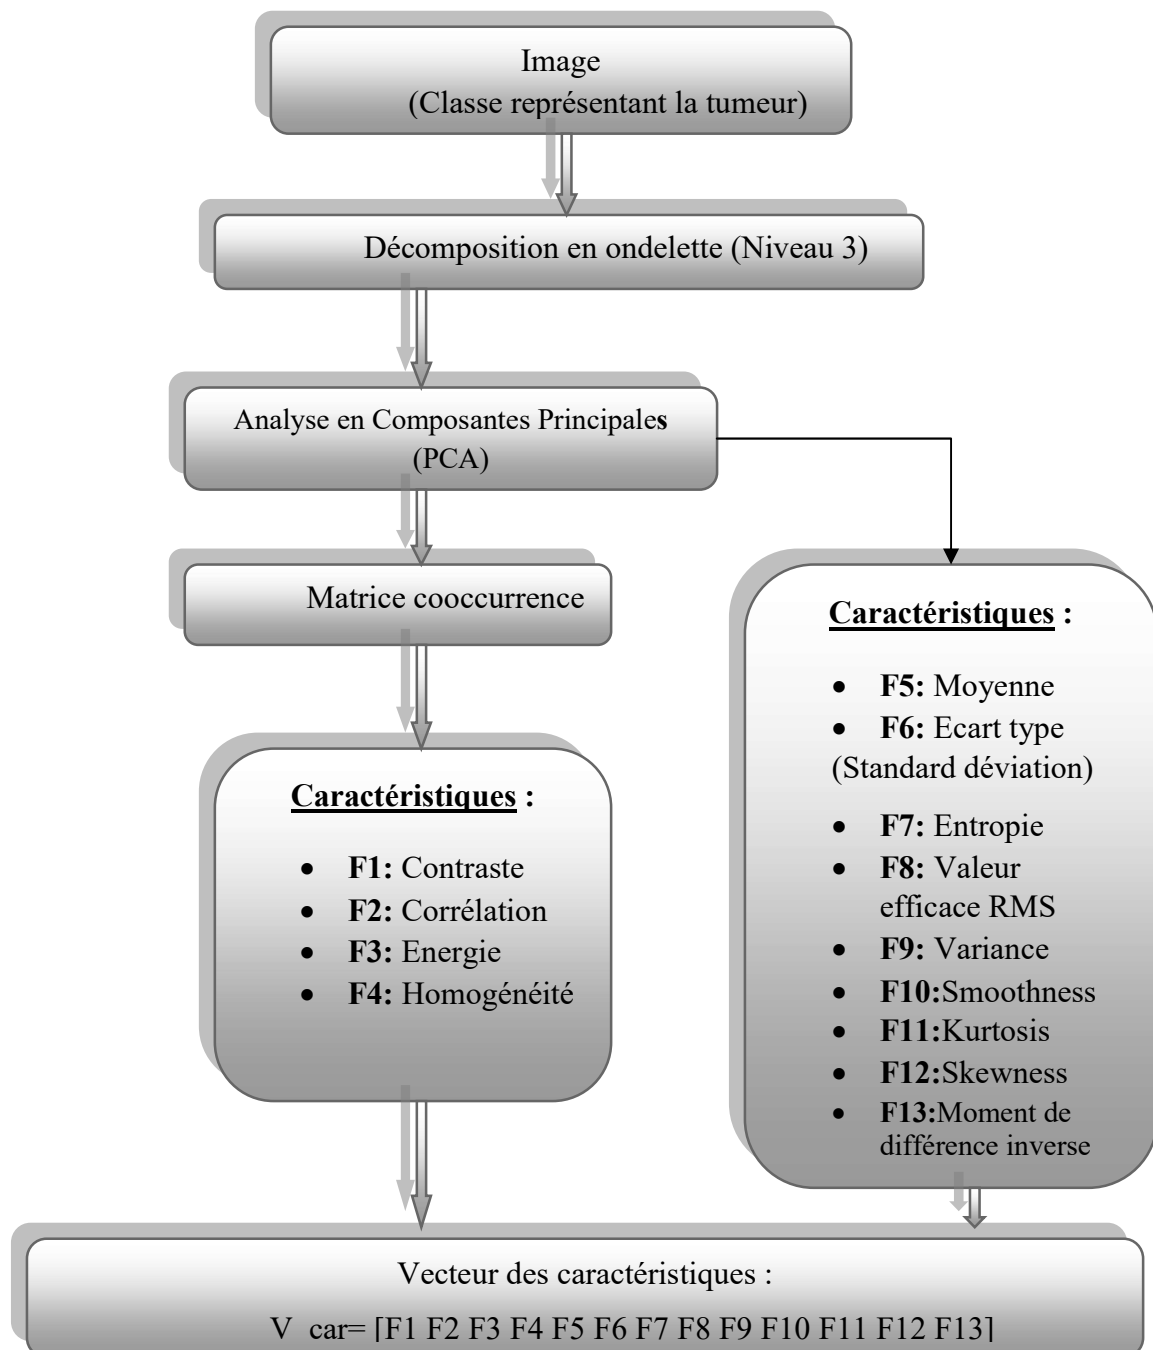


Figure 3.4:Processus d'extraction des caractéristiques de la tumeur.

3.3.1. Transformée en ondelettes discrète

Cette méthode peut être considérée comme une nouvelle avancée dans le domaine de l'analyse du signal (par rapport à la transformée de Fourier) car elle offre la possibilité de générer des informations locales en termes de temps et de fréquence. Il existe plusieurs types d'ondelettes, la plus importante est l'ondelette de Harr, qui est la plus simple et est généralement l'ondelette préférée dans de nombreuses applications. La transformée en ondelettes discrète décompose le signal $x(n)$ en deux signaux, le coefficient approximatif $Ca(n)$ et la composante de détail $Cd(n)$. Ce processus est appelé décomposition de premier niveau. Le processus de décomposition peut être itéré par des approximations successives de décomposition afin de décomposer le signal en différents niveaux de résolution. L'ensemble du processus est appelé arbre de décomposition en ondelettes, comme le montre la figure 3.5.

Une transformation en ondelettes discrète est appliquée à l'image, en filtrant Lignes et colonnes continues. A un niveau donné, la décomposition produit une approximation LL du signal original et trois types de détails (LH horizontal, HL vertical et HH diagonal). Utilisez plusieurs niveaux de décomposition pour explorer les caractéristiques de l'image à plusieurs niveaux de résolution (du plus fin au plus grossier). Dans notre algorithme, la décomposition à 3 niveaux de l'ondelette "Daubechie" est utilisée pour extraire des caractéristiques




Figure 3.5: Arbre de décomposition niveau 3




Figure3.6: Transformée ondelettes Discrète s'applique à une image

3.3.2. Matrice de cooccurrence

Une matrice de cooccurrence est une matrice de taille $N \times N$, où N est le nombre de niveaux de gris dans l'image. Pour le déplacement d (translation), un élément (i, j) de la matrice est défini par le nombre de pixels en d de l'image de niveau de gris j situé au pixel de niveau de gris i .

Les matrices de cooccurrence contiennent une masse très importante d'informations et sont donc difficilement manipulables, de ce fait, Plusieurs indices ont été proposé par Haralick qui correspondent à des caractères descriptifs des textures peuvent être calculés à partir de ces matrices. Plusieurs caractéristiques de texture peuvent être extraites à partir de la GLCM comment : le contraste, la corrélation, l'énergie et l'homogénéité.

Dans ce qui suit, nous allons présenterles treize (13) caractéristiques (F1 à F13) que nous utiliserons durant le processus de classification de la tumeur :

a) F1: Contraste

La différence de valeurs d'intensité entre un pixel et son voisin sur toute l'image est appelée contraste. Le contraste est calculé à l'aide de l'équation suivante:

$$\sum_{i,j} |i - j|^2 p(i, j) \quad (3.3)$$

b) F2: Corrélation

La corrélation définit la façon dont deux valeurs de pixels dépendent l'une de l'autre sur une considération linéaire de l'image entière. Elle varie de -1 à 1

$$\sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j} \quad (3.4)$$

c) F3: Energie

L'énergie est également connue sous le nom d'uniformité de l'image qui est la somme des éléments au carré de la matrice GLCM. La gamme d'énergie varie de 0 à 1.

$$\sum_{i,j} p(i, j)^2 \quad (3.5)$$

d) F4: Homogénéité

L'uniformité des éléments de distribution du GLCM à ses diagonales, qui varie de 0 à 1, est appelée homogénéité de l'image

$$\sum_{i,j} \frac{p(i, j)}{1 + (i - j)^2} \quad (3.6)$$

Dans ce qui suit, nous allons présenter les autres caractéristiques (F5 à F13) que nous utiliserons durant le processus de classification de la tumeur

e) F5: La moyenne

Les valeurs d'intensité moyennes des pixels sont indiquées par cette caractéristique. N: dimension de l'image

$$\frac{1}{N} \sum_{i,j} p(i, j) \quad (3.7)$$

f) F6: Ecart type (Standard deviation)

Il indique la variabilité des niveaux de gris, c'est-à-dire, le changement du contraste, m : valeur moyenne de p(i,j).

$$\sqrt{\sum_{i=0}^{l-1} (i - m)^2 p(i, j)} \quad (3.8)$$

g) F7: Entropie

Ce paramètre mesure le désordre dans l'image. Contrairement à l'énergie, l'entropie atteint de fortes valeurs lorsque la texture est complètement aléatoire (sans structure apparente). Elle est fortement corrélée (par l'inverse) à l'énergie.

$$- \sum_{i,j} p(i, j) \log p(i, j) \quad (3.9)$$

h) F8: Valeur efficace (RMS)

Le RMS fournit la moyenne arithmétique des carrés des valeurs moyennes (le long de chaque ligne ou colonne).

$$\sqrt{\frac{1}{N} \sum_{i,j} p(i, j)^2} \quad (3.10)$$

i) F9: Variance

La variance mesure l'hétérogénéité de la texture. Elle augmente lorsque les niveaux de gris diffèrent de leur moyenne. La variance est indépendante du contraste.

$$\sum_{i,j} (i + j - m)^2 * p(i, j) \quad (3.11)$$

j) F10: Smoothness

La mesure du contraste du niveau de gris est décrite comme la douceur relative.

$$1 - \frac{1}{1 + \sum_{i=0}^{l-1} (i-m)^2 p(i,j)} \quad (3.12)$$

k) F11: Kurtosis

Le pic ou la planéité d'une distribution de probabilité par rapport à la distribution normale fournit la mesure du kurtosis d'une image

$$\sum_{i=0}^{l-1} (i-m)^4 p(i,j) \quad (3.13)$$

l) F12 : Coefficient d'asymétrie (Skewness)

L'asymétrie est une mesure de l'asymétrie des données autour de la moyenne de l'échantillon. La valeur d'asymétrie peut être positive ou négative ou indéfinie

$$\sum_{i=0}^{l-1} (i-m)^3 p(i,j) \quad (3.14)$$

m) F13 : Moment de différence inverse (IDM)

IDM représente la texture de l'image. Sa valeur varie de 0 à 1, où 0,0 représente une image hautement texturée et 1,0 représente des images non texturées

$$IDM = \sum_{i,j} \frac{p(i,j)}{1+(i+j)^2} \quad (3.15)$$

- Après avoir réalisé l'extraction des caractéristiques on construit le vecteur caractéristiques V-car.

$V_car = [F1, F2, F3, F4, F5, F6, F7, F8, F9, F10, F11, F12, F13]$.

3.4. Classification par SVM (Support Vector Machines)

Cette technique est une tentative de séparer deux types de méthodes de classification. La méthode recherche ensuite l'hyperplan qui sépare les deux catégories (tumeurs bénignes et malignes), en s'assurant que la limite entre les points de données les plus proches des deux catégories est la plus grande. L'intérêt de cette méthode réside dans la sélection de vecteurs supports, qui représentent les vecteurs discriminants pour la détermination de l'hyperplan

La figure 3.7 montre l'interpolation géométrique de la SVM linéaire. Ici, les hyperplans H1, H2 et H3 sont utilisés pour diviser les points de données en deux catégories. L'hyperplan H1 a une grande marge au niveau des vecteurs de support S11, S12, S13, S21, S22 et S23, ce qui permet d'obtenir une classification parfaite. Mais H2 et H3 ne peuvent pas réaliser une bonne classification car ils n'ont pas la plus grande marge




Figure 3.7: L'interpolation géométrique des SVM linéaires[5]




Figure 3.8: Phase de classification de la tumeur par les SVM.

3.5 Résultats et discussion

Dans ce qui suit, nous avons appliqué toutes les étapes précédentes sur (20) images (09 bénignes et 10 malignes) afin de classifier la tumeur obtenue en segmentant les quatresimages IRM restantes comme images test par l'algorithme ARKFCM

Le tableau ci-dessous montre les résultats obtenus :

- La première colonne présente les images originales qui sont les images IRM test contenant la tumeur suivi d'une mention de son type (maligne ou bénigne).
- La deuxième colonne représente les images segmentées par la méthode d'ARKFCM.
- La troisième colonne présente les tumeurs extraite.
- La quatrième et dernière colonne présente les résultats finals de la classification SVM indiquant si la tumeur est maligne ou bénigne.

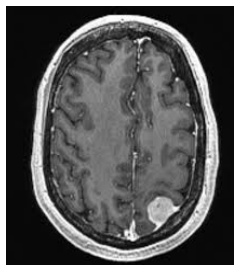

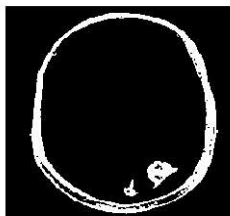
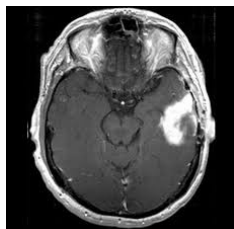
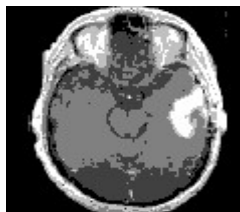

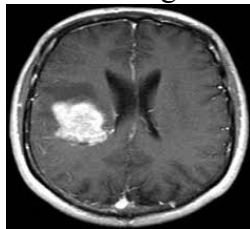
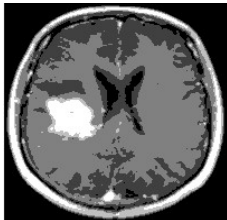
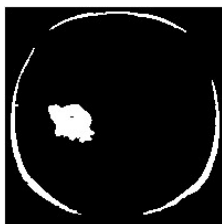
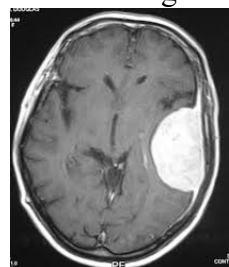

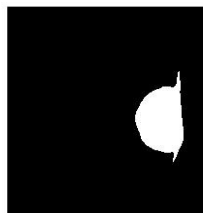
Type de Tumeur	Image segmenté (ARKFCM)	Tumeur extraite	Résultats de classification par les SVM	
Bénigne				<u>Bénigne</u>
Bénigne				<u>Bénigne</u>
Maligne				<u>Bénigne</u>
Maligne				<u>Maligne</u>

Tableau 3.1 : Résultats de la classification des tumeurs dans les images test IRM.

➤ Discussion des résultats

D'après notre travail effectué, nous avons sélectionné 19 images entre maligne et bénigne pour un apprentissage par SVM et cela après une segmentation de la tumeur existante par l'algorithme ARKFCM.

Après extraction des tumeurs, sur les quatre images test, nous avons trouvé que (03 images) étaient bien classées. Dans la classification des tumeurs bénignes, nous avons finalement obtenu (02 images) sur les (02)images utilisées, le taux correct était de 100%. Pour les tumeurs malignes, nous avons (01)image sur les (02) des images utilisées, soit 50% comme pourcentage

Classification	Bénigne	Maligne
Nombre des images	02	02
Taux de classification (%)	100	50

Tableau 3.2 : Taux de classification.

3.6. Conclusion

Les tumeurs cérébrales sont la principale cause de décès. En effet, plusieurs recherches et de nombreuses techniques sont utilisées pour bien détecter ces tumeurs. Dans notre travail, nous avons proposé une méthode dans laquelle nous appliquons d'abord la segmentation basée sur ARKFCM comme algorithme de segmentation pour extraire les tumeurs. Après l'extraction de certaines nombre de caractéristiques de ce dernier (13), et en utilisant la bibliothèque d'apprentissage combinée au classificateur linéaire SVM, nous classons ces tumeurs dans les images IRM test en deux catégories : les tumeurs bénignes et les tumeurs malignes. A partir des résultats obtenus, nous avons remarqué que le système proposé a réussi à obtenir une classification satisfaisante dans la limite du nombre des images utilisées dans l'étape d'apprentissage.

Conclusion Générale

Le traitement d'images est un domaine très large, c'est un ensemble de techniques appliquées sur des images numériques pour améliorer leurs aspects visuels ou extraire les informations jugées utiles.

L'objectif de notre travail est de classer les tumeurs dans le cerveau. Nous utilisons l'algorithme ARKFCM pour segmenter les images IRM dans le but de séparer les tissus cérébraux tel que la matière blanche MB, matière grise MG, LCR liquide céphalo-rachidien et d'éventuelles tumeurs existantes qui seront séparées ultérieurement. L'étape suivante est l'extraction des caractéristiques de chaque tumeur sous forme des vecteurs de caractéristiques (13 caractéristiques) qui sera utilisé dans l'apprentissage lors de la classification avec le classificateur SVM pour les classer en deux classes de tumeurs dans les images IRM à savoir maligne ou bénigne. Les résultats après application sur des images test sont très satisfaisants avec une précision de 75% est cela est dû à l'erreur au niveau de la segmentation.

En perspective, une amélioration de la segmentation est appliquant des algorithmes performant est plus ce que nécessaire pour améliorer les résultats de la classification.

Références bibliographiques

- [1] B.SAMIRA ‘‘ utilisation des systemes d’informations geographiques pour la mesure de la surface’’, master en télécommunication à universite abou bekr belkaid tlemcen ,2016
- [2] K.DALILA ‘‘ Classification non supervisée de pixels d’images couleur par analyse d’histogrammes tridimensionnels’’ master professionnel en Electronique industriel à Université Mouloud Mammeri De Tizi-Ouzou ,2017
- [3] Andries P. Engelbrecht, « Computational Intelligence An introduction », WILEY 2002.
- [4] J. Bittoun. Basic1998. « Principles of Magnetic Resonance Imaging ». In 15th Annul Scientific Meeting of the European Society for Magnetic Resonance in Medecine and Biology, 45–53. Geneva. Springer
- [5] A. Mekhmoukh, "Segmentation d’images IRM par améliorations de l’algorithme FCM", thèse doctorat, Université de A.mira-Béjaia le 30/01/2016
- [6] équipe la main à la pâte, “Le cerveau humain,” <http://www.fondation-lamap.org/fr/page/18710/le-cerveau-humain>, 2013.
- [7] P.Kamina « Anatomie clinique Tome 5 » Maloine, Paris ,2009
- [8] :N.W.Daesslé « Imagerie du tenseur de diffusion pour l’étude de pathologie cérébrales » thèse doctorat, Université de Rennes, 2009.
- [9] :R.L.Drake,W.vogl,A.W.M.Mitchell « Gray’s Anatomie pour les étudiants » Paris ,Elsevier,masson-SAS, 2006.
- [10] :L.William « Etude de l’évaluation des tumeurs cérébrales en IRM » cahiers d’IRM, Masson ,1989.
- [11] : <http://arc-cancer.net>
- [12] :A.Thinhinane ,B.Fatima « Segmentation d’image par classifieurs flous :appliction a l’imagerie par résonance magnétique (IRM) » Université A.Mira Béjaia, 2015.
- [13] : G.Braillon « Le système nerveux central » Doin éditeurs-Paris ; Imprimerie Lois Jean ,1984

- [14] Y. Morin, "Larousse médical," édition Larousse, 2006
- [15] M. I. R. I. Sanae, "Segmentation des structures cérébrales en IRM: intégration de Contraintes topologiques," Thèse de doctorat, Université Louis Pasteur Strasbourg, 2007
- [16] BrainWeb, Simulated Brain Database, McConnel BrainImaging Centre, Montreal Neurological Institute, McGill, 2015
- [17] : G.Braillon « Le système nerveux central » Doin éditeurs-Paris ; Imprimerie Lois Jean ,1984
- [18] :A.Sophie capelle « Segmentation d'image IRM multi-échos tridimensionnelles pour la détection des tumeurs cérébrale par la théorie de l'évidence » thèse doctorat Université de poitiers , 2003
- [19] D.Ibrahimi,H.Saou, «Segmentation Et Classification D'image : Application à L'imagerie Par Résonance Magnétique (IRM), , Université de A.mira-Béjaia ,2020.
- [20] S. Lefèvre, "Une nouvelle approche pour la classification non supervisée en segmentation d'image", Thèse de doctorat en électronique à l'université de Strasbourg, 2002.
- [21] W. Dou, "Segmentation d'images multi spectrales basée sur la fusion d'informations : application aux images IRM", Thèse de doctorat en science à L'université de CAEN, 2006
- [22] S. Oudjemia. Segmentation contextuelle d'image de documents par analyse de texture en niveaux de gris .Doctoral dissertation, Université Mouloud Mammeri de Tizi Ouzou.2011
- [23] Article «PRINCIPALES METHODES DE CLASSIFICATION NON SUPERVISEE» écrit par Anja Struyf, Mia Hubert, Peter Rousseeuw.
- [24] BELAROUCI Sara et BENMOKHTAR Sara «Méthode coopérative pour la segmentation d'images IRM cérébrales basée sur les techniques FCM et Level Set» mémoire de projet de fin d'étude pour l'obtention du : Diplôme de Master en Signaux et Images en Médecine, Université Abou Bakr Belkaid, 2011 - 2012.
- [25] Barra.V (1999), «Segmentation floue des tissus cérébraux en IRM 3D: une approche possibiliste versus autres méthodes». Thèse doctorat. Université Blaise Pascal

- [26] Brummer, M.E.; Mersereau, R.M.; Eisner, R.L.; Lewine, 1993. « Automatic detection of brain contours in MRI data sets » Medical Imaging, IEEE Transactions on (12), Page(s):153 – 166.
- [27] I. Kapouleas 1990. «Automatic detection of white matter lesions in magnetic resonance brain images». Computer Methods and Programs in Biomed.
- [28] Thiran J. P. ; Warscotte V. ; Macq B 1997. « Aqueue-based region growing algorithm for accurate segmentation of multi-dimensional digital images ».; Signal processing vol. 60, no1, pp. 1-10.
- [29] H. G. Schnack 2001 <<Automatic segmentation of the Ventricular System from MR Images of the Human Brain >> Neuroimage. 14(1pt1):95-104.
- [30] G. Matheron. 1965. « Random Sets and Integral Geometry ». Edition Wiley
- [31] J.Serra.1982<<Image Analysis and Mathematical morphology>>, volume 1. Academic Press, London.
- [32] L. Germond. 1998. « Coopération entre processus guidés par les données et les modèles pour la segmentation en *IRM* ». Technical Report RR1005-I, TIMCIMAG.
- [33] BARRA V, BOIRE JY, 2000 “Tissue Characterization on MR Images by a possibilistic Clustering on a 3D Wavele Representation”, Journal of Magnetic Resonance Imaging, 11:267-278.
- [34] A.N.Benaichouche, "Conception de métaheuristiques d’optimisation pour la segmentation d’images. Application aux images IRM du cerveau et aux images de Tomographie par Émission de positons ", thèse de doctorat université paris 12, 2012.
- [35] Lotfi A Zadeh. "Fuzzy sets". Information and control, 8(3): 338–353, 1965.

[36] Projet personnel de Géomatique, ENSG 2011,2012 «Segmentation des images de télédétection par les algorithmes de type « SVM » Support Vector Machines» présenté par M. MILLOGO Frédéric.

[37] Antoine Cornuéjols« Une nouvelle méthode d'apprentissage : Les SVM. Séparateurs à vaste marge. » Université de Paris-Sud, Orsay, 2002 Reynolds, D. A. (2009). "Gaussian Mixture Models." Encyclopedia of biometrics 741

[38] : O.Swe Zin; K.Aung Soe. “Brain tumor detection and segmentation using watershed segmentation and morphological operation”. International Journal of Research in Engineering and Technology, 2014; vol.03, n°03, PP.367-374. Disponible sur: <http://www.ijret.org> (Consulté le 15/10/2020).

Références des images

[1] : N.Azouza. « Segmentation par classification floue: application à l'imagerie par résonance magnétique ». Mémoire Master, Université de Akli Moand Oulhadje-Bouira, 2018

[2] : N. AISSOU, A . BENKACI. «Méthode coopérative pour la segmentation d'image : Application a l'imagerie médicale». Université Abderrahmane Mira-Bejaia,2016

[3] :D.A.Massinisa ,B.Sofine « Segmentation d'image IRM cérébrale par CM et ses

[4] www.ncbi.nlm.nih.gov/pmc/articles

[5] : Y. Zhang; L. Wu, "An mr brain images classifier via principal component analysis and kernel support vector machine",Progress In Electromagnetics Reseach,Vol. 130, 369-388, 2012

ملخص

يتكون التصنيف من تجميع وحدات البكسل في الصورة في مجموعات فرعية مع مراعاة الاحترام التشابه والتوحيد وفقًا لمعايير محددة مسبقًا، إنها خطوة قرار بعد خطوة التجزئة.

يركز عملنا على التجزئة حسب نهج التصنيف ودراسة خوارزميات التصنيف المختلفة غير الخاضعة للإشراف وهي: k-mean و FCM (Fuzzy C-Means) وهذين المتغيرين (FCM-S1 و FCM-S2) و ARKFCM. كنا مهتمين بالخوارزمية الأخيرة بهدف تطبيقها على صور التصوير بالرنين المغناطيسي للدماغ من أجل تقسيم الأنسجة المختلفة وبشكل أكثر دقة للكشف عن ورم الدماغ لاستخراج الخصائص الرئيسية بعد تطبيق التحويل المويجي (DWT) متبوعًا بتطبيق تحليل المكون الرئيسي (PCA). يتم استخدام هذه الخصائص في خطوة التعلم أثناء التصنيف عبر مصنف SVM لتصنيف الورم الحميد أو الخبيث.

الكلمات المفتاحية: تجزئة ARKFCM ، التصوير بالرنين المغناطيسي ، تحويل الموجة (DWT ، ACP ، SVM) ، الورم الحميد والخبيث.

Résumé

La classification consiste à regrouper les pixels d'une image en sous-groupes tout en respectant une similarité et une uniformité selon des critères prédéfinis, c'est une étape de décision après l'étape de segmentation.

Notre travail s'intéresse essentiellement à la segmentation par approche classification et d'étudier les différents algorithmes de classification non supervisées à savoir : k-means, le FCM (Fuzzy C-Means) et ces deux variantes (FCM-S1 et FCM-S2) et ARKFCM. Nous nous sommes intéressés à ce dernier algorithme en vue de l'appliquer sur des images IRM de cerveau en vue de segmenter les différents tissus et plus précisément à la détection de la tumeur cérébrale afin d'extraire les principales caractéristiques après l'application de la transformée en ondelette (DWT) suivie de l'application de l'analyse des composantes principales (ACP). Ces caractéristiques sont utilisées dans l'étape apprentissage lors de la classification via le classifieur SVM afin de classer la tumeur bénigne ou maligne.

Mots clés : la segmentation ARKFCM, Imagerie IRM, la transformée en ondelette (DWT), ACP, SVM, la tumeur bénigne et maligne

Abstract

Classification consists of grouping the pixels of an image into subgroups while respecting similarity and uniformity according to predefined criteria, it is a decision step after the segmentation step.

Our work focuses on segmentation by classification approach and to study the different unsupervised classification algorithms namely: k-means, the FCM (Fuzzy C-Means) and these two variants (FCM-S1 and FCM-S2) and ARKFCM. We were interested in the latter algorithm with a view to applying it to MRI images of the brain in order to segment the different tissues and more precisely to the detection of the brain tumor in order to extract the main characteristics after the application of the wavelet transform (DWT) followed by the application of principal component analysis (PCA). These characteristics are used in the learning step during classification via the SVM classifier in order to classify the benign or malignant tumor.

Keywords: ARKFCM segmentation, MRI imaging, wavelet transformed (DWT), ACP, SVM, benign and malignant tumor