

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université SAAD DAHLAB Blida
Faculté des Sciences
Département d'informatique



Mémoire de Fin d'Etudes

Mémoire Présenté par :

Djelali Leila Lalini Chahrazed

En vue d'obtenir le diplôme de master

Domaine : Mathématique et informatique

Filière : Informatique

Spécialité : Informatique

Option : Ingénierie de logiciel

Thème

Extraction des attributs pour la classification des tumeurs cérébrale

Soutenu le :

- | | |
|--------------------|-----------|
| M. Cherif zahar. A | Président |
| Mme. Ghribi | Examineur |
| M. Hadj Yahia. O | Promoteur |
| Mme. Alim. F | Encadreur |
| M. Abdelaziz. M | Encadreur |

Année universitaire : 2015/2016

MA-004-348-1

REMERCIEMENT

Nous tenons tout d'abord à remercier ALLAH tout puissant de nous avoir donné le courage et la force pour la réalisation de ce modeste travail.

Nous exprimons notre grande reconnaissance et remerciement à nos encadreurs Mr. Mohamed abd el Azziz et Mme. ALIM Fatiha pour leurs aides, leurs sollicitudes, leurs conseils et de nous avoir orienté et mis à notre disposition tous les moyens nécessaires durant notre travail.

Nous exprimons également notre gratitude à notre promoteur Mr. Haj yahya ouhid.

Et enfin, nous remercier tous les enseignants de département d'informatique.

Merci

DEDICACE

Avec les sentiments de la plus profonde humilité Je dédie ce travail

*À mes très chers parents ABD RHIM et FATMA pour leur amour, leurs sacrifices
et leur efforts consentis,*

À mes regrettés grands-parents,

À ma grand-mère Kheira,

À mes frères Mohamed et Amine,

À mes sœurs Kheira, Zineb et Djamila,

À mon regrettable oncle Mohamed qui nous a quitté cette année

À mes neveux Abdel kader, Abdel Rahim, Mohamed Amine et ma nièce Nada

À toute ma famille LALINI et KHEMISSI,

À ma belle famille IDDER, et à mes beaux parents Azzedine et Hakima

À mon mari Yazid qui a été toujours présent pour m'aider et m'encourager.

À ma très chère amie Amina,

Enfin à tous mes amis que je n'ai pas cités et à tous ceux qui me connaissent

Chahrazed

DEDICACE

Je dédie ce travail

À mes chères parents **Mouloud** et **Fatma** qui me conseille et me pousse vers le plus sublime but dans la vie, comme ils ont toujours agi tenacement afin de surmonter toutes les difficultés.

À mon cher frère **Sofiane**, mes chères sœurs **Soraya** et **Rym** pour son soutien moral et ses sacrifices le long de ma formation.

À ma chère sœur **Ahlem** et son mari **Fouzi**.

À mes belles nièces **Minissa** et **Lina**.

À mes grande mères, mes tantes et à mes oncles.

À tous mes amis et tous ceux qui me sont chers.

Leila

Résumé

L'objectif de ce travail est d'extraire les attributs de la texture de l'image IRM pour la classification automatique des tumeurs cérébrales malignes ou bénignes. Nous avons utilisé deux méthodes d'extraction des paramètres statistique, la première est la matrice de cooccurrence de niveau de gris en 2D (GLCM 2D) et la deuxième est la matrice de cooccurrence de niveau de gris en 3D (GLCM 3D), la dernière il été utilisé pour améliorer la performance de la classification, pour manipuler les information du matrice de cooccurrence nous avons utilisé les quatorze paramètres de Haralick, et pour améliorer les résultats, nous avons ajouté un paramètre qui nous a donné le meilleur taux de classification 89.90% en 3D et 88.89% en 2D.

Mots clés: Extraire les attributs, texture, image IRM, classification automatique, tumeurs cérébrales, méthodes d'extraction des paramètres statistique, matrice de cooccurrence, GLCM 2D, GLCM 3D, classification, paramètres de Haralick.

Abstract

The objective of this work is to extract attributes of texture from MRI image for the automatic classification of brain tumors which are malignant or benign. We have chose to use two methods of a statistical extraction, the first one is the 2D co-occurrence matrix (2D GLCM) method and the second is the 3D co-occurrence matrix (3D GLCM), the latest it been used to enhance the classification, To manipulate GLCM information we have used the fourteen parameters of Haralick,

and to improve the results we added a parameter which gave us the best classification rate 89.90% in 3D and 88.89% in 2D.

Keywords: extract attributes, texture, MRI image, the automatic classification, brain tumors, methods of a statistical extraction, co-occurrence matrix , 2D GLCM, 3D GLCM, classification, parameters of Haralick.

الملخص:

الهدف من هذا العمل هو استخراج الخصائص التركيبية من صور الرنين المغناطيسي لأجل تصنيف آلي للأورام الدماغية إلى صفيين: خبيثة أو حميدة. اخترنا لذلك استعمال طريقتين إحصائيتين هما: 2D GLCM ولأجل تحسين التصنيف

استعملنا 3D GLCM. كما أضفنا للطريقتين إعداد جديد ليقوم هو الآخر بتحسين التصنيف بطريقة ملحوظة.

الكلمات المفتاحية: استخراج الخصائص التركيبية, صور الرنين المغناطيسي, تصنيف, الأورام الدماغية, طريقة إحصائية,

إعداد, 3D GLCM, 2D GLCM.

TABLE DES MATIÈRES

Introduction générale.....	01
-----------------------------------	-----------

Chapitre 01 : Contexte Médical

Introduction.....	03
1.1. Anatomie de l'encéphale.....	04
1.1.1. Cerveau.....	04
1.1.2. Cervelet.....	06
1.1.3. Tronc cérébral.....	06
1.2. Tumeur Cérébrale	07
1.2.1. Nature de tumeur cérébrale.....	07
1.2.1.1. Les tumeurs bénignes.....	07
1.2.1.2. Les tumeurs malignes.....	07
1.2.2. Localisation des tumeurs cérébrales.....	08
1.2.2.1. Les tumeurs cérébrales primaires.....	08
1.2.2.2. Les tumeurs secondaires.....	09
1.2.3. Les symptômes de la tumeur cérébrale.....	09
1.2.3.1. Maux de tête.....	09
1.2.3.2. Crises d'épilepsie.....	10
1.2.3.3. Troubles fonctionnels.....	10
1.2.4. Facteur de risque des tumeurs cérébrales.....	12
1.2.4.1. L'environnement.....	12
1.2.4.2. Les substances chimiques.....	12
1.2.4.3. Les champs électromagnétiques.....	12
1.2.4.4. L'hérédité.....	13
1.2.4.5. Les virus.....	13

1.2.5. Traitement des tumeurs cérébrales.....	13
1.2.5.1. Corticothérapie.....	14
1.2.5.2. Traitement antiépileptique.....	14
1.2.5.3. Chirurgie.....	14
1.2.5.4. Radiothérapie	14
1.2.5.5. Chimiothérapie.....	15
1.3. L'imagerie par résonance magnétique IRM	15
1.3.1. Paramètres de séquence.....	16
1.3.1.1. Temps d'écho.....	16
1.3.1.2. Temps de répétition.....	16
1.3.2. Séquences IRM.....	17
1.3.2.1. Image pondérée en densité de protons (ρ).....	17
1.3.2.2. Image pondérée en T2.....	17
1.3.2.3. Image pondérée en T1.....	17
1.3.3. Observation du cerveau.....	17
Conclusion.....	18

Chapitre 02 : Etat de L'art des techniques d'extraction des paramètres et la classification

Introduction.....	19
2.1. Texture.....	19
2.1.1. Type de texture.....	19
2.1.2. Méthodes d'extraction des paramètres de texture.....	20
2.1.2.1. Approches Statistiques.....	21
2.1.2.1.1. Attributs statistique du premier ordre.....	21
2.1.2.1.2. Attributs statistique du second ordre.....	21
2.1.2.1.3. Attributs statistique d'ordre supérieur.....	21
2.1.2.2. Les méthodes structurelles.....	21

2.1.2.3. Les méthodes basées sur un modèle.....	22
2.1.2.4. Les méthodes fréquentielles.....	22
2.1.3. Matrice de cooccurrence.....	22
2.1.3.1. Matrice de cooccurrence 2D.....	22
2.1.3.2. Matrice de cooccurrence 3D.....	24
2.1.4. Attributs d'Haralick extraits des matrices de cooccurrences	25
2.2. La classification	28
2.2.1. Les méthodes de classification.....	29
2.2.1.1. K plus proches voisins	29
2.2.1.2. L'analyse en composantes principales (PCA).....	29
2.2.1.3. L'analyse discriminante.....	30
2.2.1.4. Machines à Vecteurs de Support (SVM)	30
2.2.1.4.1. Fonctionnement des SVM.....	32
2.2.1.4.2. Hyperplan optimal.....	32
2.2.1.4.3. Vecteurs de support.....	32
2.2.1.4.4. La marge.....	32
2.2.1.4.5. Linéarité et non-linéarité	33
2.2.1.4.6. Cas non linéaire.....	33
2.2.2. Avantage et Inconvenant des méthodes de classification.....	34
Conclusion.....	36

Chapitre 03 : L'extraction des paramètres et la classification des tumeurs cérébrales

Introduction.....	37
3.1. Système d'extraction des paramètres texturés	37
3.2. Base de données.....	39
3.3. Normalisation.....	39
3.4. Extraction des paramètres.....	41

3.4.1. Binairisation du masque.....	42
3.4.2. Extraction de la tumeur.....	42
3.4.3. Scaling.....	43
3.4.4. Matrice de cooccurrence.....	45
3.4.4.1. Matrice de cooccurrence 2D.....	45
3.4.4.2. Matrice de cooccurrence 3D.....	46
3.5. Extraction des paramètres.....	47
3.6. Classification.....	47
3.6.1. Choix de la méthode.....	47
3.7. Méthodologie du SVM.....	48
3.7.1. Phase d'apprentissage.....	49
3.7.2. Phase de test.....	50
3.7.3. Choix du modèle.....	50
3.7.4. Méthodes d'évaluation de classification.....	50
Conclusion.....	52

Chapitre 04 : Implémentassions, expérimentation et interprétation des résultats

Introduction.....	53
4.1. Environnement de travail.....	53
4.1.1. Matériel.....	53
4.1.2. Langage.....	53
4.2. Sélection des attributs d'extraction des paramètres texturaux.....	54
4.3. Classification.....	63
Conclusion.....	65
Conclusion générale.....	66

LISTE DES FIGURES

Chapitre 01 : Contexte Médical

Figure 1.1. Structure anatomique de l'encéphale.....	04
Figure 1.2. Les lobes du cerveau.....	05
Figure 1.3. Images des tumeurs bénignes.....	07
Figure 1.4. Images des tumeurs malignes.....	08
Figure 1.5. Coupe sagittale du cerveau.....	11
Figure 1.6. Image d'un appareil d'IRM.....	16
Figure 1.7. Coupes IRM du cerveau : plan axial, coronal et sagittal (De gauche à droite)...	18

Chapitre 02 : Etat de L'art des techniques d'extraction des paramètres et la classification

Figure 2.1. Exemple d'une texture périodique.....	20
Figure 2.2. Exemple d'une texture aléatoire.....	20
Figure 2.3. Huit pixels plus proches voisins de 'X' utilisé pour calculer la matrice de cooccurrence selon 4 directions.....	23
Figure 2.4. Principe des SVM : (a) Recherche de l'hyperplan optimal, (b) Hyperplan optimal, marge et vecteurs supports.....	31
Figure 2.5. Données linéairement et non linéairement séparable.....	33
Figure 2.6. Transformation non linéaire de données.....	34

Chapitre 03 : L'extraction des paramètres et la classification des tumeurs cérébrales

Figure 3.1. Architecture globale de notre système.....	38
Figure 3.2. Exemple d'image de la base de données (BRATS 2014) :a) image IRM en T2 cas maligne, b) image IRM en T2 cas bénign.....	39
Figure 3.3. Processus de l'extraction des paramètres.....	41
Figure 3.4. Exemple du masque binariser.....	42

Figure 3.5. Etape de multiplication.....	43
Figure 3.6. Exemple de calcul la matrice de cooccurrence 2D.....	45
Figure 3.7. Exemple de calcul de la matrice de cooccurrence 3D.....	46
Figure 3.8. Organigramme de processus de classification.....	49

Chapitre 04 : Implémentassions, expérimentation et interprétation des résultats

Figure 4.1. Influence des caractéristiques sur des masses malignes 3D.....	61
Figure 4.2. Influence des caractéristiques sur des masses bénignes 3D.....	61
Figure 4.3. Influence des caractéristiques sur des masses malignes 2D.....	62
Figure 4.4. Influence des caractéristiques sur des masses bénigne 2D.....	62
Figure 4.5. Histogramme de La précision de classification pour le noyau RBF.....	64
Figure 4.6. Histogramme de La précision de classification pour le noyau polynomial.....	64

LISTE DES TABLEAUX

Chapitre 01 : Contexte Médical

Tableau 1.1. Différence entre les tumeurs malignes et bénignes	08
---	----

Chapitre 02 : Etat de L'art des techniques d'extraction des paramètres et la classification

Tableau 2.1 .Les quatre directions	23
---	----

Tableau 2.2. Les treize directions	24
---	----

Tableau 2.3. Avantages et inconvénients des méthodes de classification.....	35
--	----

Chapitre 03 : L'extraction des paramètres et la classification des tumeurs cérébrales

Tableau 3.1. Critère d'évaluation de la classification.....	51
--	----

Tableau 3.2. Matrice de confusion.....	52
---	----

Chapitre 04 : Implémentassions, expérimentation et interprétation des résultats

Tableau 4.1. Tableau des paramètres de masses malignes 3D.....	55
---	----

Tableau 4.2. Tableau des paramètres de masses bénignes 3D.....	56
---	----

Tableau 4.3. Tableau des paramètres de masses bénignes 2D.....	57
---	----

Tableau 4.4. Tableau des paramètres de masses malignes 2D.....	58
---	----

Tableau 4.5. Tableau des paramètres de masses bénignes 2D après l'amélioration.....	59
--	----

Tableau 4.6. Tableau des paramètres de masses malignes 2D après l'amélioration.....	59
--	----

Tableau 4.7. Tableau des paramètres de masses bénignes 3D après l'amélioration.....	60
--	----

Tableau 4.8. Tableau des paramètres de masses malignes 3D après l'amélioration.....	60
--	----

Tableau 4.9. Taux de classification pour chaque méthode d'extraction de Caractéristique....	63
--	----

Depuis une quarantaine d'années, l'exploration du cerveau a connu une effervescence essentiellement due à l'apparition des nouvelles modalités d'imagerie médicale. Parmi les outils cliniques permettant l'observation de la zone cérébrale, on peut citer de façon non exhaustive le scanner à rayons X, l'imagerie par résonance magnétique (IRM), la tomographie, la scintigraphie, ... etc. Parmi l'ensemble de ces techniques, l'IRM est de plus en plus utilisée en routine clinique. Cette technique non invasive, qui exploite les propriétés magnétiques des structures, permet en effet une observation de qualité de l'anatomie cérébrale. L'image obtenue, de haute résolution, permet une localisation précise des différentes structures.

Le médecin doit analyser des images médicales afin de diagnostiquer certaines maladies liées à des lésions cérébrales internes pour étudier l'évolution d'une tumeur, il est nécessaire de connaître avec exactitude les changements survenus sur ces images. Il n'est cependant pas toujours évident de délivrer, même pour un œil expert, un diagnostic fiable à la simple vue de ces images.

Le but majeur de l'analyse d'images médicales, et en particulier l'analyse de l'IRM du cerveau, est l'extraction de l'information clinique qui permet le diagnostic et la classification des tumeurs. Vu la gravité des tumeurs cérébrales, la détection et la segmentation des tumeurs est nécessaire, pour faciliter la tâche d'extraction d'information qui sont utilisés dans le but de classification de la gravité des tumeurs.

Problématique

Malgré les avancées technologiques dans le domaine médical et en particulier dans l'imagerie médicale, la classification des tumeurs cérébrales humaines est un problème ardu et reste un sujet de recherche de forte actualité. La difficulté à classifier une image cérébrale vient de la complexité structurelle des images IRM et du contraste souvent insuffisant pour extraire la structure d'intérêt et connaître la nature de la tumeur.

L'objectif de notre contribution dans ce projet consiste à réaliser une tâche du système d'aide au diagnostic des tumeurs cérébrales, qui rend la tâche plus facile aux médecins pour faire un diagnostic complet et fiable qui permet la bonne classification des tumeurs (bénignes ou malignes) pour déterminer la pathologie et déterminer les traitements les plus appropriés.

Le but recherché est d'extraire les caractéristiques texturales des images IRM cérébrales pour la classification des tumeurs cérébrales en deux classes Bénignes ou Malignes. Au CDTA ils nous ont recommandés d'utiliser deux méthodes d'extraction. L'une basée sur la matrice de cooccurrence de niveau de gris 2D (GLCM 2D) et l'autre basée sur la matrice de cooccurrence de niveau de gris 3D (GLCM 3D). Cette dernière est utilisée pour améliorer les résultats de classification des tumeurs cérébrale.

Ce travail est structuré en quatre chapitres :

- **Le chapitre. 1 :** Contexte médical

Dans ce chapitre nous présentons les notions essentielles liées à l'anatomie de cerveau et à technique d'imagerie à résonance magnétique IRM.

- **Le chapitre. 2:** État de L'art des techniques d'extraction des paramètres texturaux et de la classification

Dans ce chapitre nous présentons un état de l'art sur les différentes méthodes d'extraction d'attributs de la texture ainsi que les différentes méthodes de classification.

- **Le chapitre 3 :**L'extraction des paramètres et la classification des tumeurs cérébrales

Dans ce chapitre nous présentons l'analyse texturale des images cérébrales et, spécifions les paramètres utilisées pour l'extraction des caractéristiques suivie d'une classification par les machines à support de vecteurs (SVM).

- **Le chapitre. 4 :** Implémentassions, expérimentation et interprétation des résultats

Ce chapitre s'appuie sur les résultats obtenus afin de tester notre application sur une base d'images cérébrales BRATS 2014, ainsi que l'évaluation des performances des méthodes utilisé.

Nous achèverons notre mémoire par une conclusion générale et perspective.



CHAPITRE 1
Contexte Médical

Introduction

Le cerveau est un organe complexe et fascinant. Il est le siège de notre personnalité, de notre pensée et de notre parole. Lorsqu'il est touché, nous sommes atteints dans ce que nous avons de plus intime. C'est une réalité à laquelle nous sommes rarement préparés et qui suscite de nombreuses questions et l'apparition d'une foule de sentiments. Le cerveau peut être touché par plusieurs maladies, parmi les plus dangereuses de ses maladies c'est les tumeurs cérébrales.

La tumeur cérébrale est une maladie rare et très hétérogène. Une tumeur du cerveau se définit par une prolifération anormale et excessive de cellules, bénignes ou malignes, formant une masse à l'intérieur du crâne.

Etant donnée la variabilité des tissus intra-crâniens, la variabilité des diagnostics de tumeurs cérébrales est presque infinie.

En effet, il n'y a pas qu'une tumeur du cerveau, mais des tumeurs au cerveau. Celles-ci se distinguent par leur nature - définie par le type de cellules qui constitue la tumeur - et leur localisation : hémisphères cérébraux (les plus fréquentes chez l'adulte), tronc cérébral, hypophyse, cervelet, etc.

En fonction de cette typologie, l'expression clinique, l'évolution et la prise en charge de la tumeur du cerveau diffèrent. Aussi difficile que puisse être ce diagnostic, les tumeurs du cerveau ne sont pas toutes des cancers. De même qu'on considère, parmi les tumeurs dites « malignes », des degrés d'agressivité différents. Certaines étant considérées comme bas grade, pour les moins agressives, et de haut grade, pour celles qui le sont davantage.

Dans ce chapitre, nous allons présenter un aperçu général sur l'approche médicale de l'imagerie du cerveau, pour situer le contexte dans lequel l'application que nous cherchons à développer va être utilisée. Nous présentons l'anatomie du cerveau, la tumeur cérébrale, des changements bénins et malins qui peuvent se produire et enfin nous décrivons comment interpréter une image cérébrale.

1.1 Anatomie de l'encéphale [KML, 15][SCA, 16][VUM, 16] [CNA, 10]

L'encéphale est le centre de contrôle du corps, il est situé dans la boîte crânienne. Le poids de l'encéphale est d'environ 1,6 kg chez l'homme adulte tandis qu'il est d'environ 1,45 kg chez la femme.

L'encéphale est constitué de 3 parties principales soit le cerveau, le cervelet et le tronc cérébral. Le cerveau surplombe le cervelet qui joue un rôle dans l'équilibre et la coordination des mouvements et le tronc cérébral qui le relie à la moelle épinière.

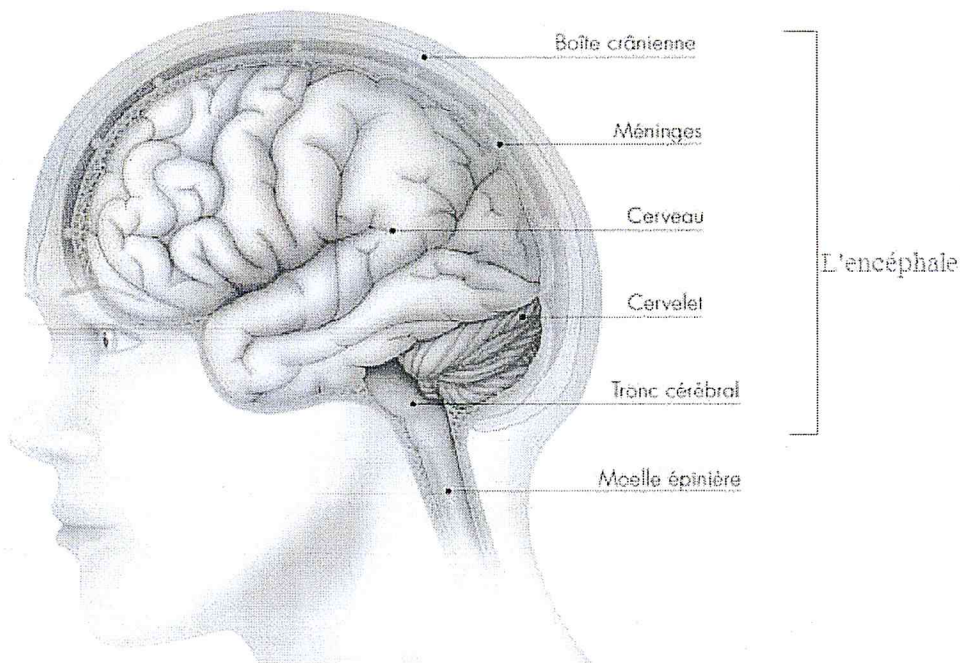


Figure 1. 1 Structure anatomique de l'encéphale [KML, 15].

1.1.1 Cerveau

Le cerveau contrôle la plupart des fonctions de l'organisme. Il est l'une des trois parties composant l'encéphale, la plus volumineuse, la plus complexe. Il pèse environ 1,3 kg et représente 2% du poids du corps (ce qui explique l'emploi fréquent du mot « cerveau » plutôt que « encéphale » dans le langage courant).

Le cerveau est divisé en deux moitiés appelées hémisphère cérébral gauche et hémisphère cérébral droit, qui sont reliés par un pont de fibres nerveuses appelé corps calleux.

Chaque hémisphère cérébrale contrôle la moitié du corps se trouvant du côté opposé (la moitié droite commande le côté gauche du corps tandis que la moitié gauche du cerveau commande le côté droit du corps).

La partie externe du cerveau s'appelle cortex cérébral, ou substance grise. C'est la région du cerveau où les cellules nerveuses établissent des connexions, appelées synapses, qui commandent l'activité cérébrale. La partie interne du cerveau contient les corps isolants (myélinisés) des cellules nerveuses (axones), qui transmettent l'information entre l'encéphale et la moelle épinière. Cette partie interne est appelée substance blanche puisque l'isolant qui entoure les axones lui donne une teinte blanchâtre.

Le cerveau est divisé davantage en 4 sections appelées lobes qui comprennent les lobes frontal (devant), pariétal (sur le dessus), temporal (sur le côté) et occipital (à l'arrière).

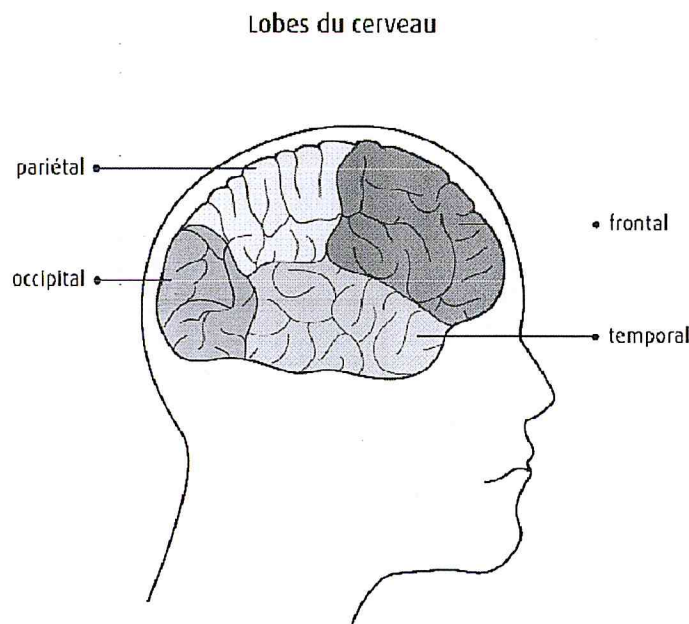


Figure 1. 2 Les lobes du cerveau [SCA, 16].

Chaque lobe a des fonctions différentes :

- Le lobe frontal contrôle les mouvements, la parole, le comportement, la mémoire, les émotions et le fonctionnement intellectuel, comme la réflexion, le raisonnement, la résolution de problèmes, la prise de décisions et la planification.
- Le lobe pariétal contrôle les sensations comme le toucher, la pression, la douleur et la température. Il commande aussi l'orientation spatiale (compréhension de la taille, de la forme et de la direction).
- Le lobe temporal contrôle l'ouïe, la mémoire et les émotions. Le lobe temporal gauche commande aussi la parole.
- Le lobe occipital contrôle la vision.

1.1.2 Cervelet

Le cervelet est la deuxième plus grosse partie de l'encéphale. Il se situe sous le cerveau, dans la partie arrière de l'encéphale. Il est un centre nerveux régulateur de la fonction motrice, au sens large (mouvement + posture + équilibre) [BGO, 10]. Il reçoit des informations directement du cerveau et de la moelle épinière qu'il intègre simultanément pour conférer le geste voulu. [FSC, 16]

Le cervelet est divisé en 2 parties, ou hémisphères, et contient de la substance grise et de la substance blanche, tout comme le cerveau.

Le cervelet est responsable :

- des mouvements
- de la posture
- de l'équilibre
- des réflexes
- des actions complexes (marcher, parler)
- de la collecte de l'information sensorielle provenant du corps

1.1.3 Tronc cérébral

Le tronc cérébral est un faisceau de tissu nerveux situé à la base de l'encéphale. Il relie le cerveau à la moelle épinière et transmet des messages entre les différentes parties du corps et l'encéphale.

Le tronc cérébral se compose de trois régions :

- mésencéphale
- protubérance annulaire
- bulbe rachidien

Le tronc cérébral contrôle :

- la respiration
- la température du corps
- la pression artérielle
- la fréquence cardiaque
- la faim et la soif

Les nerfs crâniens émergent du tronc cérébral et contrôlent les sensations du visage, les mouvements des yeux, l'ouïe, la déglutition, le goût et la parole.

1.2 Tumeur Cérébrale [PAS, 16][HDO, 10]

Une tumeur cérébrale est une masse de cellules anormales qui se multiplient dans le cerveau de façon incontrôlée.

1.2.1 Nature de tumeur cérébrale

Il existe deux grands types de tumeurs cérébrales selon leur nature cancéreuse ou non.

1.2.1.1 Les tumeurs bénignes

Les tumeurs bénignes ne sont pas cancéreuses, c'est à dire qu'elles n'envahissent pas les organes voisins et ne font que les repousser, elles ont un développement généralement limité Elles se forment assez lentement et restent le plus souvent isolées des tissus cérébraux voisins. Elles ne se propagent pas à d'autres parties du cerveau ni à d'autres organes et sont généralement plus faciles à extraire par chirurgie que les tumeurs malignes. Cependant, certaines tumeurs pourtant bénignes demeurent inextirpables du fait de leur localisation.




Figure 1.3 Images des tumeurs bénignes [BDD, 14].

1.2.1.2 Les tumeurs malignes

Les tumeurs malignes font exactement le contraire : elles envahissent toute la région, infiltrant les organes avoisinants et surtout elles envoient des métastases dans d'autres endroits du corps. Il n'est pas toujours facile de les distinguer des tissus voisins. De ce fait, il est parfois difficile de les extraire entièrement sans endommager le tissu cérébral avoisinant.




Figure 1.4 Images des tumeurs malignes [BDD, 14].

La différence entre une tumeur maligne et bénigne est présentée dans le tableau suivant:

Tumeur Bénigne	Tumeur Maligne
<ul style="list-style-type: none"> • Bien limité. • Encapsulé. • Histologiquement semblable aux tissus d'origine (bien différenciée). • Cellule régulière. • Croissance lente. • Refoulement sans destruction des tissus voisins. • Pas de récurrence locale après exérèse complète. • Pas de métastase 	<ul style="list-style-type: none"> • Mal limitée. • Non encapsulée. • Plus ou moins semblable au tissu d'origine. • Cellules irrégulières (cellules cancéreuses). • Croissance rapide. • Envahissement des tissus voisins. • Exérèse complète difficile. Récurrence possible après exérèse supposée complète. • Métastase.

Table 1.1: Différence entre les tumeurs malignes et bénignes [KNZ, 15].

1.2.2 Localisation des tumeurs cérébrales

Les tumeurs cérébrales se distinguent aussi selon leur localisation, on distingue :

1.2.2.1 Les tumeurs cérébrales primaires

Les tumeurs cérébrales primaires, sont celles qui prennent naissance dans le cerveau. Elles peuvent être bénignes (non cancéreuses) ou malignes (cancéreuses). Leur dénomination provient du tissu cérébral dans lequel elles se développent.

Parmi les tumeurs malignes les plus fréquentes on retrouve :

- Les tumeurs gliales, ou gliomes (tumeurs malignes) représentant 50 à 60 % de l'ensemble des tumeurs cérébrales. Elles se forment à partir des cellules gliales, cellules intervenant comme structure de soutien des cellules nerveuses (neurones).
- Les médulloblastomes (tumeurs malignes), se développent à partir de la moelle épinière au stade embryonnaire. Ce sont les tumeurs cérébrales les plus courantes chez les enfants.
- Enfin, parmi les tumeurs primaires bénignes, plus rares que les tumeurs primaires malignes, on retrouve les hémangioblastomes, les méningiomes, les adénomes hypophysaires, les ostéomes, les pinéalomes, etc.

1.2.2.2 Les tumeurs secondaires

Les tumeurs secondaires ou métastatiques sont malignes (cancéreuses) et proviennent d'autres organes où existe un cancer et dont les cellules tumorales ont migré vers le cerveau et s'y multiplient. Les cellules tumorales sont transportées par le sang et se développent le plus souvent à la jonction entre la substance blanche et la substance grise du cerveau. Ces tumeurs secondaires sont plus fréquentes que les tumeurs primaires. D'ailleurs, on estime que 25 % des personnes décédées de cancers de toutes natures sont porteuses de métastases cérébrales. Parmi les tumeurs les plus fréquemment à l'origine de métastases cérébrales : le cancer du sein, le cancer du poumon, le cancer de la peau (mélanome), le cancer du rein, le cancer du côlon, etc.

1.2.3 Les symptômes de la tumeur cérébrale [INC, 16] [ART, 11] [SCA, 16] [KML, 15] [ESV, 16]

Les symptômes provoqués par une tumeur du cerveau sont très variables. Ils dépendent du volume de la tumeur, de la vitesse à laquelle elle se développe et surtout de son emplacement.

Les signes et symptômes peuvent apparaître soudainement ou se manifester graduellement et s'aggraver au fil du temps. Les symptômes apparaissent sont :

1.2.3.1 Maux de tête

Les maux de tête (ou céphalées) constituent le symptôme le plus fréquent, quel que soit le type de tumeur cérébrale. Ils se manifestent souvent le matin, parfois accompagnés de nausées et/ou de vomissements.

Ces maux de tête sont provoqués par une augmentation de la pression à l'intérieur du crâne, appelée hypertension intracrânienne. Cette hypertension a trois causes possibles. Elle peut être due :

- à un gonflement du cerveau tout autour de la tumeur, appelé œdème cérébral.
- à une compression du cerveau par la tumeur. En augmentant de volume, la tumeur appuie sur le cerveau, provoquant ce que les médecins appellent un effet de masse.
- à une mauvaise circulation du liquide céphalo-rachidien. Ce liquide est produit en continu dans les ventricules du cerveau et circule autour et à l'intérieur du crâne et de la colonne vertébrale. Par son volume, la tumeur peut bloquer cette circulation. Au lieu de s'écouler normalement, le liquide céphalo-rachidien s'accumule dans les ventricules qui se dilatent et provoquent une hypertension.

1.2.3.2 Crises d'épilepsie

Lorsque la tumeur se développe à la surface du cerveau, elle peut perturber l'activité des neurones et déclencher des crises d'épilepsie chez une personne qui n'en a jamais connues auparavant.

Les crises d'épilepsie sont comparables à des décharges électriques ou à des courts-circuits entre les neurones. Elles sont imprévisibles et généralement brèves (1 à 2 minutes). Mais elles peuvent être impressionnantes pour les proches.

Selon les cas, les symptômes varient. Il peut s'agir notamment de :

- Pertes de conscience s'accompagnant de chute, de perte d'urine, de morsure de la langue ou de convulsions.
- Mouvements soudains et involontaires des bras et des jambes.
- Raideur des muscles.
- Sensations étranges ou inhabituelles, de déjà vu ou une odeur désagréable (de grillé par exemple) que le patient est le seul à sentir.
- Sentiment soudain de peur.
- Absences (la personne cesse quelques instants son activité, puis la reprend comme si de rien n'était).

1.2.3.3 Troubles fonctionnels

Lorsqu'une tumeur se développe à l'intérieur du crâne, elle risque d'abîmer le cerveau ou de gêner son fonctionnement. Selon la zone où elle se développe, elle provoque des symptômes très différents.

D'une manière générale, une tumeur située du côté droit du cerveau cause des troubles dans le côté gauche du corps, et inversement. Une tumeur dans le lobe pariétal droit, par exemple, peut provoquer des sensations d'engourdissement dans le côté gauche du corps.

Tous ces symptômes ne sont pas forcément synonymes de tumeur du cerveau. C'est leur durée et leur persistance qui doivent alerter et faire consulter le médecin.

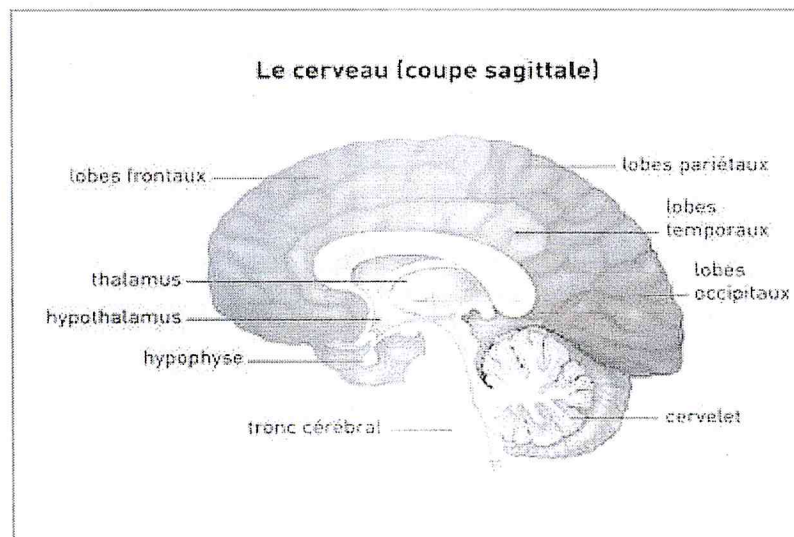


Figure1.5 Coupe sagittale du cerveau [IDC, 16].

Les principaux symptômes possibles sont, en fonction de l'endroit où la tumeur est située :

- **Lobes frontaux:** changement de personnalité, diminution de l'émotivité, confusion ; difficulté à agir, à marcher, à parler, perte de l'odorat.
- **Lobes pariétaux:** Difficulté à choisir des mots, à faire des phrases, problèmes de lecture ou d'écriture, difficultés d'orientation (trouver son chemin par exemple), sensation d'engourdissement d'un côté du corps...
- **Lobes occipitaux:** perturbations de la vue.
- **Lobes temporaux:** difficulté à parler, troubles de la vision, de la mémoire, de l'audition, difficulté à reconnaître et à nommer quelque chose que l'on voit par exemple.
- **Thalamus :** douleur, difficulté à réaliser certains mouvements.
- **Région de l'hypothalamus et de l'hypophyse:** troubles hormonaux (absence de règles par exemple), troubles de la vision.
- **Tronc cérébral:** troubles de la marche, engourdissement de la moitié du corps, manque de coordination des mouvements, paralysie d'un côté du visage, vision double, difficulté pour avaler, perte de l'audition.

- **Cervelet:** manque de coordination qui peut perturber la marche, les gestes ou la parole, tremblements pendant l'action.

1.2.4 Facteur de risque des tumeurs cérébrales [INC, 16]

Bien que les causes des tumeurs cérébrales soient encore mal connues. On ne sait pas pourquoi, à un moment donné, les cellules se multiplient de manière incontrôlée jusqu'à former une tumeur.

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

1.2.4.1 L'environnement

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

Ces études portent principalement sur :

- L'influence de certaines substances chimiques, comme les pesticides ;
- Les conséquences de l'exposition à des champs électromagnétiques, comme les téléphones portables, les lignes à haute tension ou certains appareils électroménagers.

1.2.4.2 Les substances chimiques

Plusieurs substances chimiques sont reconnues comme cancérigènes, c'est-à-dire pouvant favoriser la survenue d'une tumeur cancéreuse du cerveau. Il s'agit de substances chimiques utilisées dans différentes activités professionnelles, telles que la fabrication de caoutchouc synthétique et de certains médicaments, la production de polyvinyle, de pétrole brut et de produits dérivés du pétrole, l'industrie nucléaire et l'armement, et enfin la manipulation de pesticides. Ces substances présentent un risque pour les personnes qui y sont exposées à des doses élevées et pendant une longue durée.

1.2.4.3 Les champs électromagnétiques

Le risque lié à l'exposition régulière à des champs électromagnétiques est encore en cours d'évaluation. Les spécialistes n'ont pas clairement déterminé si cette exposition peut entraîner des tumeurs du cerveau.

Quant à l'utilisation de téléphones portables, un principe de précaution s'impose. Les études ne sont pas définitivement tranchées, mais elles vont dans le sens d'un risque possible en particulier chez l'enfant et l'adolescent.

Par précaution, il est donc conseillé de limiter l'utilisation du téléphone portable et de ne pas le garder sur soi. Pendant les communications, l'utilisation d'une oreillette est recommandée.

1.2.4.4 L'hérédité

La grande majorité des tumeurs du cerveau n'ont aucun lien héréditaire. Ce n'est pas parce qu'une personne a une tumeur du cerveau que les autres membres de sa famille ont un risque accru de développer le même type de tumeur.

Un risque héréditaire existe néanmoins pour deux types de tumeurs du cerveau : le neurinome et le neurofibrome. Ces tumeurs représentent moins de 5 % de l'ensemble des tumeurs du cerveau.

Ce sont des tumeurs bénignes, qui se développent sur le nerf auditif, reliant le cerveau et l'oreille. Ces tumeurs sont souvent liées à une maladie génétique appelée neurofibromatose.

La neurofibromatose n'entraîne pas systématiquement une tumeur du cerveau.

1.2.4.5 Les virus

Selon les études scientifiques actuelles, il n'y a pas de lien entre les virus et l'apparition d'une tumeur du cerveau.

Seul le virus du sida (le VIH), qui affaiblit les défenses de l'organisme, peut favoriser de façon indirecte l'apparition d'une tumeur appelée lymphome du cerveau.

1.2.5 Traitement des tumeurs cérébrales [PAS, 16]

Les traitements varient selon le type de tumeur, sa taille et son emplacement. Il existe différentes possibilités de traitements, qui peuvent être proposés seuls ou associés les uns aux autres : chirurgie, radiothérapie, chimiothérapie. Selon les cas, ils visent à éliminer la totalité de la tumeur, à réduire le risque de récurrence, à contenir le développement de la tumeur, à soulager et prévenir les symptômes provoqués par la tumeur.

Le choix et l'ordre des traitements dépendent de nombreux facteurs :

- La gravité apparente de la tumeur ;
- Le type de tumeur ;
- La localisation et l'étendue de la tumeur ;
- L'âge et l'état de santé général du patient.

1.2.5.1 Corticothérapie

Les corticoïdes oraux (Médrol, Solupred, Cortancyl) ou parentéraux (Solumédrol) sont fréquemment utilisés en neuro-oncologie. Outre une action anti tumorale propre (lymphome cérébral primitif), les corticoïdes agissent essentiellement sur l'œdème péri tumoral ; par ce biais, ils permettent une réduction de l'hypertension intracrânienne et une amélioration fonctionnelle rapide (réduction des déficits et des crises comitiales).

1.2.5.2 Traitement antiépileptique

Un traitement antiépileptique est nécessaire à titre prophylactique pendant la période périopératoire et chez les patients ayant présenté une crise inaugurale ou continuant à souffrir de crises itératives. Sauf rares exceptions (métastases de mélanome), il n'est pas indiqué au long cours chez les patients dont l'histoire ne comporte aucune crise. Le choix du traitement utilisé ne présente pas de spécificité ; les médicaments les plus fréquemment utilisés en première intention sont l'acide valproïque (Dépakine) et la carbamazépine (Tégrétol) en monothérapie. Ils nécessitent une surveillance des effets secondaires.

1.2.5.3 Chirurgie [PAS, 16] [KML, 15]

La chirurgie est le traitement de référence des tumeurs cérébrales, qu'elles soient bénignes ou malignes. Si la tumeur est accessible, la première option consiste à retirer partiellement ou totalement la tumeur afin d'obtenir ou de favoriser la guérison. C'est le moyen thérapeutique majeur dans le traitement des tumeurs cérébrales.

1.2.5.4 Radiothérapie [KML, 15] [PAS, 16]

La radiothérapie est l'un des traitements les plus utilisés dans la prise en charge des tumeurs cérébrales primitives. Elle utilise des rayons ionisants dont la forte énergie permet de tuer les cellules cancéreuses. Dans certains cas, la radiothérapie est dirigée vers la tumeur uniquement. Dans d'autres, l'ensemble du cerveau est irradié, après une chirurgie par exemple, pour détruire les cellules tumorales restantes, ou lorsque plusieurs tumeurs sont logées dans le cerveau et ne peuvent être retirées par chirurgie. Enfin, on utilise la radiothérapie en cas de tumeur non entièrement extraite.

1.2.5.5 Chimiothérapie [KML, 15]

La chimiothérapie consiste à administrer des médicaments qui détruisent les cellules tumorales. Elle est parfois la seule option thérapeutique possible, notamment lorsque la tumeur est inopérable. Elle peut être utilisée seule ou en association avec la radiothérapie, avant ou après l'opération. Avant l'opération, elle permet de réduire le volume tumoral pour faciliter le geste chirurgical. Après l'opération, son rôle est de détruire les cellules cancéreuses résiduelles.

1.3 L'imagerie par résonance magnétique IRM [FJA, 10] [JME, 14]

L'IRM est une technique de diagnostic médical puissante qui fournit des images bi ou tridimensionnelles et en coupe de grande précision anatomique. Elle est une technique radiologique récente, non invasive et sans effets secondaires connus, l'IRM consiste principalement à mettre en résonance les atomes (les protons) d'hydrogène des tissus biologiques à analyser. Pour faire simple, cette technique se base sur le fait que notre corps est composé en grande partie d'eau (à 70%). Lorsqu'on place ces molécules d'eau dans un puissant champ magnétique, leurs protons vont s'orienter dans une même direction.

Ces atomes vont ensuite être stimulés par des ondes radios pendant un court instant et rentrer en résonance. Lorsque cette stimulation est interrompue, elles restituent l'énergie accumulée en produisant une onde électromagnétique de « résonance ». Ce signal sera recueilli par des récepteurs de l'appareil et transmis à un système informatique qui l'enregistrera et le traitera pour reconstituer les images de la structure anatomique analysée.

Ce système permet d'obtenir des séries en coupe de la partie à explorer dans tous les plans de l'espace, suivant une épaisseur variable. Une image s'obtient en quelques millisecondes. Le système informatique va attribuer une certaine couleur à chaque gradient du signal émis, de façon à reproduire en trois dimensions l'image de la composition chimique des tissus analysés, et donc de leur nature. Cette technique d'imagerie fournit une résolution de contraste largement supérieure à celle de l'échographie, la radiographie ou le scanner



Figure 1. 6 Image d'un appareil d'IRM

1.6.1 Paramètres de séquence [BAL, 11]

Les paramètres de séquence sont les paramètres que le manipulateur fixe sur la console pour définir la séquence IRM. Ils permettent de contrôler l'influence des différents paramètres tissulaires T_1 , T_2 et densité de proton dans le signal et de moduler ainsi le contraste dans l'image.

1.6.1.1 Temps d'écho

Le signal de précession libre ne peut être enregistré directement après l'excitation (déphasage parasite induit par les gradients). C'est pourquoi il est acquis sous la forme d'un écho de spin ou de gradient. Par définition, le délai entre le milieu de l'impulsion d'excitation et le sommet de l'écho est appelé temps d'écho, il est noté TE .

1.6.1.2 Temps de répétition

L'image est constituée à partir de la répétition de la même séquence avec un gradient de phase G_p d'amplitude différente. Le temps qui sépare deux répétitions est appelé temps de répétition est noté TR . Le TR , comme le TE , est un facteur de contraste. S'il est suffisamment long, l'aimantation repousse tout le signal qui ne dépend pas de la vitesse d'aimantation (donc de T_1), mais essentiellement de la densité protonique. S'il est court, le système atteint après quelques répétitions un régime stationnaire et l'aimantation tend vers une valeur d'équilibre dépendant de la vitesse d'aimantation des tissus, et donc de leur T_1 . L'image révèle ainsi les différences de T_1 entre les tissus.

1.6.2 Séquences IRM

En modifiant les valeurs des différents paramètres de séquence, une grande diversité de volumes variant par le contraste peut être acquise. Le choix de l'ensemble des paramètres est alors fonction de l'étude clinique à réaliser. On peut obtenir des images pondérées en T1, en T2, en densité de protons, etc. [ZHA, 08].

1.6.2.1 Image pondérée en densité de protons (ρ)

Pour un TR (temps de répétition) long (de l'ordre de 2s) et un TE (temps d'écho) court (de l'ordre de 20ms), la différence de densité protonique entre la substance grise et la substance blanche s'accroît. On obtient une séquence pondérée en densité de protons ρ , qui reflète la localisation et la concentration des noyaux d'hydrogène des différentes structures. Les tissus sont ordonnés par niveaux de gris croissants en matière blanche (MB), matière grise (MG) et liquide céphalo-Rachidien (LCR) [ZHA, 08].

1.6.2.2 Image pondérée en T2

Pour des TR longs (de l'ordre de 2s) et des TE longs (environ 90 ms), la décroissance du signal domine la différence de densité protonique entre tissus, et le signal est suffisant pour réaliser une image dite pondérée en T2, où les tissus sont ordonnés par niveaux de gris croissants en MB, MG, LCS [BAL, 11].

1.6.2.3 Image pondérée en T1

Pour des TR courts (de l'ordre de 600 ms), le contraste entre les tissus dépend essentiellement de leur vitesse d'aimantation, donc de T1. Pour des TE courts (environ 20 ms), les différences de décroissance du signal entre les tissus n'ont pas le temps de s'exprimer, rendant le contraste indépendant de T2. Ainsi, on obtient une image pondérée en T1, où les tissus sont ordonnés par niveaux de gris croissants en LCS, MG, MB [BAL, 11].

1.6.3 Observation du cerveau [ZEF, 16]

Le cerveau peut être observé par des coupes bidimensionnelles selon plusieurs angles de vue. Il existe principalement trois axes anatomiques qui permettent de réaliser les coupes : axiale, sagittale et frontale (**Figure 1.7**).

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

- La coupe sagittale est relative à un plan parallèle au plan inter hémisphérique. Il s'agit de vues latérales du cerveau.
- La coupe frontale (ou coronale) est une vue de face de cerveau. Elle est acquise sur le plan perpendiculaire aux coupes axiales et sagittales.

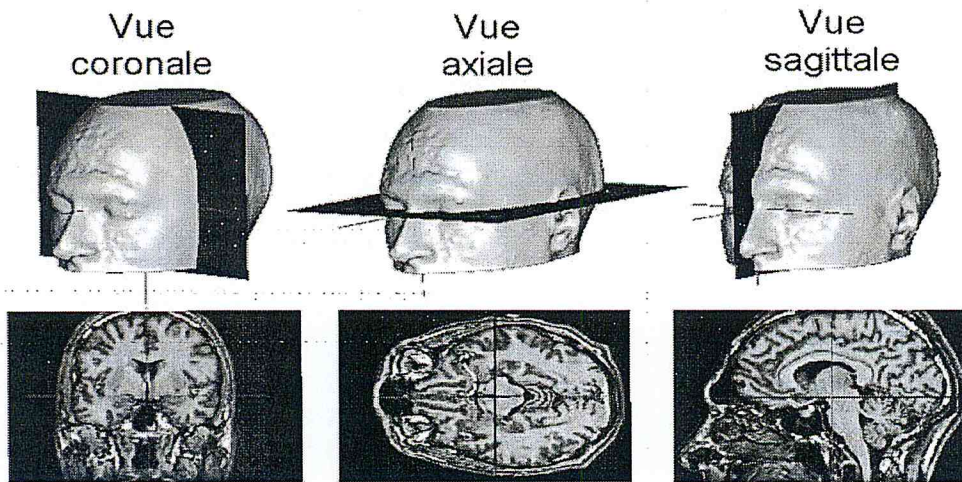


Figure 1.7 Coupes IRM du cerveau : plan axial, coronal et sagittal (De gauche à droite) [ZEF, 16].

Conclusion

Nous avons présenté dans ce chapitre les notions essentielles liées à l'anatomie du cerveau et les principales régions cérébrales. Nous avons présenté également les Tumeurs Cérébrales et leurs différentes natures, localisations et symptômes.

L'imagerie à Résonance Magnétique 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.

Le chapitre suivant, introduit les techniques de l'extraction des paramètres de l'image, adoptées dans le cas de notre étude.



CHAPITRE 2

***Etat de L'art des techniques d'extraction
des paramètres et la classification***

Introduction

Les techniques d'analyse et d'extraction des informations sont très utilisées dans le traitement des images 2D et commencent actuellement à être utilisés pour les images 3D. Ces techniques jouent un rôle très important dans plusieurs applications médicales. En général ces applications impliquent l'extraction automatique des attributs de l'image, qui permettent de caractériser les différentes pathologies étudiées. Ces caractéristiques regroupées autour des vecteurs représentant la signature de chaque image, qui sont ensuite utilisés pour une variété de tâches de classification, comme la distinction entre un tissu normal et un autre anormal.

Dans ce chapitre nous introduisons des notions de base de la texture, puis nous présentons un état de l'art sur les différentes techniques permettant de caractériser les textures afin de traiter des problèmes de classification des images IRM des tumeurs cérébrales.

2.1 Texture [BDL, 15]

On définit littéralement une texture comme suit: "répétition spatiale d'un même motif dans différentes directions de l'espace". Cette définition caractérise l'objet indépendamment d'un observateur humain donc elle est limitative. On utilise la notion de texture pour traduire un aspect homogène de la surface d'un objet sur une image. La texture se manifeste donc par une information visuelle qui permet de la décrire qualitativement à l'aide des adjectifs suivants: grossière, fine, lisse, tachetée, granuleuse, marbrée, régulière ou irrégulière [HSD, 73].

M. Haralick [HSD, 73] élargit la définition en décrivant une texture comme un phénomène à deux dimensions: la première concernant la description d'éléments de base ou primitives (le motif) à partir des quels est formée la texture, la deuxième dimension est relative à la description de l'organisation spatiale de ces primitives.

2.1.1 Type de texture [AFA, 13] [HLO, 13]

Il existe deux types de textures :

- **les textures périodiques (structurelles)** : définies par la répétition d'un motif élémentaire de base dans différentes directions de l'espace suivant une certaine règle de placement. En effet, on s'aperçoit que la figure représente un mur de brique, elle

est composée d'un ensemble d'éléments de base (les briques) disposés relativement régulièrement de manière horizontale.




Figure 2.1 : Exemple d'une texture périodique [HLO, 13].

- **les textures aléatoires** : ont un aspect anarchique (désordonné) mais qui apparaissent homogènes par rapport à leur environnement.




Figure 2.2 : Exemple d'une texture aléatoire [GAS, 13].

M. Brodatz [AFA, 13] [HLO, 13] a établi un catalogue de texture à des fins de synthèse d'images texturées. Ce catalogue constitue aujourd'hui une référence en matière de base de test pour les chercheurs travaillant sur la texture. Il s'agit de 112 textures (sable, herbe, bulles, eau, bois, etc.) ayant chacune seize variantes différentes. Ces images sont classiquement utilisées pour valider les différentes méthodes d'analyse de texture.

2.1.2 Méthodes d'extraction des paramètres de texture

On distingue quatre grandes approches d'extraction des caractéristiques textuelles, qui s'appuient sur la statistique, la structure, le modèle, la fréquence [AFA, 13] [PLU, 09].

2.1.2.1 Approches Statistiques [LMA]

Les méthodes statistiques se fondent la plupart du temps sur les niveaux de gris des pixels et sur la description statistique de leur arrangement. Elles consistent à extraire à l'aide des outils statistiques, des paramètres texturaux. Selon l'ordre de la méthode qui est donné par le nombre de pixels mis en jeu dans le calcul de paramètres, nous pouvons citer :

2.1.2.1.1 Attributs statistique du premier ordre

L'analyse de texture par les méthodes de premier ordre se fait au niveau de pixels individuels d'une région de l'image à traiter. Les paramètres tels que la moyenne, la variance, l'entropie, etc. Sont calculés à partir de l'histogramme des intensités.

2.1.2.1.2 Attributs statistique du second ordre

Ce type de méthodes prend en considération les interactions entre les niveaux de gris de deux pixels. Parmi elles, nous retiendrons en particulier, la méthode des matrices de cooccurrence [RHA, 79]. Celle-ci sert de référence à toute nouvelle méthode de caractérisation de textures.

2.1.2.1.3 Attributs statistique d'ordre supérieur

Elles étudient les interactions entre plusieurs pixels. Comme dans le cas des méthodes du second ordre, l'information est extraite à partir des voisinages locaux des pixels de l'image. Les matrices de longueurs de plage constituent un exemple de ce type de méthodes.

2.1.2.2 Les méthodes structurelles [GMI]

Les méthodes structurelles tiennent compte de l'information structurelle et contextuelle d'une forme et sont particulièrement bien adaptées aux textures macroscopiques. Les étapes d'analyse commencent par l'identification des éléments constitutifs, puis la définition des règles de placement. Les deux structures les plus importantes sont les structures de graphe et les structures syntaxiques.

2.1.2.3 Les méthodes basées sur un modèle : [JWO, 72]

Les méthodes fondées sur un modèle décrivent la texture par la réalisation d'un processus stochastique stationnaire. Elles se fondent sur la recherche d'un modèle pour décrire ou générer une texture. Plusieurs modèles peuvent être utilisés. Les plus connus sont le modèle autorégressif, les modèles Markoviennes et les modèles fractals.

2.1.2.4 Les méthodes fréquentielles

Ces méthodes, souvent utilisées en traitement du signal, permettent d'analyser une texture en identifiant les différentes fréquences qui la composent. Parmi elles, on retrouve notamment la transformée de Fourier, les filtres de Gabor ainsi que les ondelettes [PLU, 09].

2.1.3 Matrice de cooccurrence

Dans cette partie nous allons expliquer le principe du calcul de la matrice de cooccurrence pour les image de 2 dimension (matrice de cooccurrence 2D) et également la matrice de cooccurrence pour les image de 3 dimension (matrice de cooccurrence 3D).

2.1.3.1 Matrice de cooccurrence 2D [HLO, 13] [HMA, 09]

Les matrices de cooccurrence ont été introduites par M.Haralick et M.al [HSD, 73]. La matrice de cooccurrence permet de déterminer la fréquence d'apparition des paires de valeurs de pixels situés à une certaine distance dans l'image. Elle est basée sur le calcul de la probabilité $P(N_i, N_j, d, \theta_1)$ qui représente le nombre de fois où un pixel de niveau de gris N_i apparait à une distance relative (d) d'un pixel de niveau de gris N_j et selon l'orientation de la droite reliant ces deux pixels par rapport à l'horizontal (θ_1). Les directions angulaires θ_1 classiquement utilisées sont 0° , 45° , 90° et 135° degrés. Les relations de voisinage entre pixels par rapport à l'orientation, nécessaires au calcul des matrices de cooccurrence, sont illustrées en Figure 2.3.

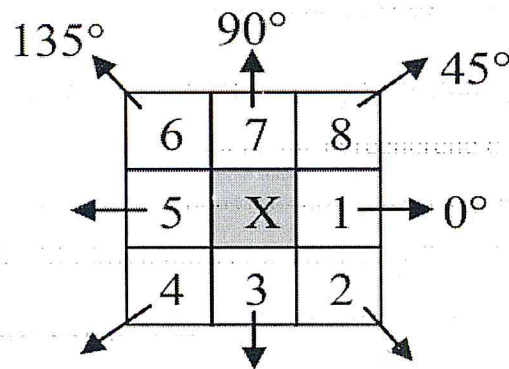


Figure 2.3 : Huit pixels plus proches voisins de 'X' utilisé pour calculer la matrice de cooccurrence selon 4 directions.

Les matrices obtenues selon ces quatre directions sont alors calculées comme dans (2.1), (2.2), (2.3) et (2.4) :

$$P(i, j, d, 0^\circ) = \# \{(k, l), (m, n) \in (N \times M)^2 \text{ tq } (k-m=0, |l-n|=d, I(k,l) = i, I(m,n) = j)\} \quad (2.1)$$

$$P(i, j, d, 45^\circ) = \# \{(k, l), (m, n) \in (N \times M)^2 \text{ tq } (k-m=d, l-n=-d) \text{ ou } (k-m=-d, l-n=d), I(k,l) = i, I(m,n) = j\} \quad (2.2)$$

$$P(i, j, d, 90^\circ) = \# \{(k, l), (m, n) \in (N \times M)^2 \text{ tq } (|k-m|=d, l-n=0, I(k,l) = i, I(m,n) = j)\} \quad (2.3)$$

$$P(i, j, d, 135^\circ) = \# \{(k, l), (m, n) \in (N \times M)^2 \text{ tq } (k-m = -d, l-n = -d) \text{ ou } (k-m = d, l-n=d), I(k,l) = i, I(m,n) = j\} \quad (2.4)$$

Où (k, l) sont les coordonnées d'un pixel de niveau de gris $N_i \in [0, 2^n - 1]$ et (m, n) celles du pixel de niveau de gris $N_j \in [0, 2^n - 1]$ et n le nombre de bit [HSD, 73] [BWA, 14].

Le tableau suivant résume les formules précédentes (2.1), (2.2), (2.3) et (2.4). Le vecteur de déplacement définit la position de voisin 'X' selon le degré du θ_1 donnée.

	Vecteur de déplacement	Degré du θ_1
1	(0,d)	0°
2	(-d,d) ou (d,-d)	45°
3	(-d,0)	90°
4	(-d,-d) ou (d,d)	135°

Tableau 2.1: Les quatre directions de la matrice cooccurrence 2D [ASN, 12].

2.1.3.2 Matrice de cooccurrence 3D

Une matrice de cooccurrence 3D mesure la probabilité d'apparition des paires de valeurs de voxels (pixel en 3D) situés à une certaine distance dans différentes slices de l'image. Elle est basée sur le calcul de la probabilité $p(i,j,d,\theta_1,\theta_2)$ qui représente le nombre de fois où un voxel de niveau de gris i apparaît à une distance d relative d'un voxel de niveau de gris j et selon les deux orientations θ_1 et θ_2 données.

La principale différence entre le calcul de la GLCM 2D et le calcul de la GLCM 3D est le nombre des voisins. Dans l'image 2D chaque pixel a 8 voisins tandis que dans l'image 3D un voxel a 26 voisins (seulement 13 sont différents) qui sont utilisés pour calculer la matrice de cooccurrence selon la variation des deux orientations θ_1 et θ_2 [ASN, 12]. Le tableau suivant montre les vecteurs de déplacement (dx, dy, dz) correspondant à θ_1 et θ_2 . dx et dy sont comme GLCM 2D et dz représente le nombre de voxels déplacés sur l'axe z c'est à dire sur la troisième dimension de l'image.

	Vecteur de déplacement	Degré du (θ_1, θ_2)
1	$d, 0, d$	$0^\circ, 45^\circ$
2	$d, 0, 0$	$0^\circ, 90^\circ$
3	$d, 0, -d$	$0^\circ, 135^\circ$
4	d, d, d	$45^\circ, 45^\circ$
5	$0, d, 0$	$45^\circ, 90^\circ$
6	$d, d, -d$	$45^\circ, 135^\circ$
7	$0, d, d$	$90^\circ, 45^\circ$
8	$0, d, 0$	$90^\circ, 0^\circ$
9	$0, d, -d$	$90^\circ, 135^\circ$
10	$-d, d, d$	$135^\circ, 45^\circ$
11	$-d, d, 0$	$135^\circ, 90^\circ$
12	$-d, d, -d$	$135^\circ, 135^\circ$
13	$0, 0, d$	$0^\circ, 0^\circ$

Tableau 2.2: Les treize directions de la matrice cooccurrence 3D [ASN, 12].

2.1.4 Attributs d'Haralick extraits des matrices de cooccurrences [HSD, 73] [BWA, 14] [TAP, 10]

La matrice de cooccurrence contient une masse très importante d'informations qui sont difficile à manipuler. C'est pour cette raison qu'elle n'est pas utilisée directement mais à travers des mesures dites indices de texture. M. Haralick et M. al [HSD, 73] ont proposé quatorze indices. Ces indices réduisent l'information contenue dans la matrice de cooccurrence et permettent une meilleure discrimination entre les différents types de textures. Ces attributs sont les suivants :

1) **l'énergie (f1)**: elle est également connu en tant que second moment angulaire d'uniformité. Ce paramètre mesure l'uniformité de la texture. Elle atteint de fortes valeurs lorsque la distribution des niveaux de gris est constante. [HLO, 13] [HMA, 09] [BWA, 14]

$$f1 = \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} p(i,j)^2 \quad (2.5)$$

Tel que: $P(i,j)$ = probabilité d'occurrence de la paire de niveaux de gris (matrice de cooccurrence normalisée).

2) **Contraste (f2)**: Il mesure la variation d'intensité entre le pixel de référence et le prochain pixel. La valeur en est d'autant plus élevée que la texture présente un fort contraste. Ce paramètre est faiblement corrélé à l'énergie [HLO, 13] [HMA, 09] [BWA, 14].

$$f2 = \sum_{n=0}^{N_g-1} n^2 \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} p(i,j)^2 \quad (2.6)$$

3) **Corrélation (f3)**: Corrélation mesure la dépendance linéaire relativement à déplacement (d) des niveaux de gris de l'image. Cet attribut n'est corrélée ni à l'énergie, ni à l'entropie [HLO, 13] [HMA, 09] [BWA, 14].

$$f3 = \frac{1}{\sigma_x \sigma_y} \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} (i,j) \cdot p(i,j) - \mu_x \mu_y \quad (2.7)$$

Où, σ_x , σ_y , μ_y et μ_x sont l'écart type et la moyenne de p_x et p_y .

$$\mu_x = \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} i \cdot p(i,j) \quad (2.8)$$

$$\mu_y = \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} j \cdot p(i,j) \quad (2.9)$$

$$\sigma_x = \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} (i - \mu)^2 p(i, j) \quad (2.10)$$

$$\sigma_y = \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} (j - \mu)^2 p(i, j) \quad (2.11)$$

$$p_x = \sum_{i=1}^{N_g-1} p(i, j) \quad (2.12)$$

$$p_y = \sum_{j=1}^{N_g-1} p(i, j) \quad (2.13)$$

4) **Variance (f4)** : La variance mesure l'hétérogénéité de la texture. Elle augmente lorsque les niveaux de gris différent de leur moyenne. La variance est indépendante du contraste. [HLO, 13] [HMA, 09] [BWA, 14]

$$f4 = \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} (i - \mu)^2 \cdot p(i, j) \quad (2.14)$$

5) **Différence inverse Moment (f5)** : IDM (Inverse Difference Moment) mesure l'homogénéité local de l'image. Ce paramètre est corrélé à une combinaison linéaire des variables (f1) et (f2). [HLO, 13] [HMA, 09]

$$f5 = \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} \frac{1}{1+(i-j)^2} p(i, j) \quad (2.15)$$

6) **Somme moyenne (f6)** :

$$f6 = \sum_{i=0}^{2(N_g-1)} i \cdot p_{x+y}(i) \quad (2.16)$$

$$p_{x+y}(k) = \sum_{i=0}^{N_g-1} \cdot \sum_{\substack{j=0 \\ i+j=k}}^{N_g-1} p(i, j) \quad k = 2, 3 \dots, 2N_g \quad (2.17)$$

7) **Somme Variance (f7)**:

$$f7 = \sum_{i=0}^{2(N_g-1)} (i - f8)^2 p_{x+y}(i) \quad (2.18)$$

8) **Sum Entropy (f8)**:

$$f8 = - \sum_{i=0}^{N_g-1} p_{x+y}(i) \cdot \log p_{x+y}(i) \quad (2.19)$$

9) **Entropie (f9)**: Entropie donne la quantité d'informations d'une image qui sont nécessaires pour la compression d'image. Ce paramètre mesure le désordre d'une image [HMA, 09].

Lorsque l'image n'est pas uniforme texturalement, de nombreux éléments de GLCM ont des valeurs très faibles, ce qui implique que l'entropie est très grande.

$$f9 = - \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} p(i, j) \cdot \log p(i, j) \quad (2.20)$$

10) Différence Variance (f10) :

$$F10 = \text{Variance de } p_{x-y} \quad (2.21)$$

$$p_{x-y}(k) = \sum_{\substack{i=0 \\ |i-j|=k}}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} p(i, j) \quad k = 0, 1, \dots, N_g - 1 \quad (2.22)$$

11) Différence entropy (f11):

$$f11 = - \sum_{i=0}^{N_g-1} p_{x-y}(i) \cdot \log p_{x-y}(i) \quad (2.23)$$

12), 13) Information sur la corrélation (f12, f13) :

$$f12 = \frac{HXY - HXY1}{\max\{HX, HY\}} \quad (2.24)$$

Où HX et HY sont respectivement les entropies de Px et Py

$$f13 = (1 - \exp[-2.0(HXY2 - HXY)])^{1/2} \quad (2.25)$$

$$HXY = - \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} p(i, j) \cdot \log(p(i, j)) \quad (2.26)$$

$$HXY1 = - \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} p(i, j) \cdot \log\{p_x(i) \cdot p_y(j)\} \quad (2.27)$$

$$HXY2 = - \sum_{i=0}^{N_g-1} \cdot \sum_{j=0}^{N_g-1} p(i) \cdot p(j) \cdot \log\{p_x(i) \cdot p_y(j)\} \quad (2.28)$$

14) Coefficient de corrélation maximal (f14):

$$f14 = (\text{1ère plus grande valeur propre de } Q)^{1/2} \quad (2.29)$$

Tel que:

$$Q(i, j) = \sum_K \frac{p(i, k) \cdot p(j, k)}{p_x(i) \cdot p_y(k)} \quad (2.30)$$

2.2 La classification [HLO, 13] [CLA, 06]

La classification en général se réfère au classement ou groupement d'éléments de données dans des ensembles similaires. Cette information est souvent utile dans l'étape d'analyse pour n'importe quel système de traitement d'image ou de données, pour l'objectif de créer un modèle qui peut être appliqué aux données non classifiées dans le but de les classifiées.

La classification a deux significations distinctes. On peut recevoir une série d'observations avec l'objectif de grouper dans un même cluster (groupe) les objets considérés comme similaires pour construire des clusters. Ou peut savoir avec certitude qu'il y a tant de classes, et l'objectif consiste à instaurer une règle selon laquelle nous pouvons classer une nouvelle observation dans l'une des classes existantes. Le premier type est connu comme l'apprentissage non supervisé et le second comme l'apprentissage supervisé.

- **La classification non-supervisée [CLA, 06]**

L'apprentissage non-supervisé sert à créer des groupes homogènes d'exemples existant dans les données, c'est-à-dire à identifier des groupes tels que les exemples les plus similaires appartiennent au même groupe, et que les exemples les plus différents soient séparés dans différents groupes, la notion de similarité étant le plus souvent ramenée à une fonction de distance entre paires d'exemples. Autrement dit, il s'agit à ce niveau de rechercher la distribution sous-jacente des exemples dans leur espace de description.

- **La classification supervisée [CLA, 06]**

L'apprentissage supervisé ou d'analyse discriminante, se propose de construire automatiquement une telle procédure de classification en se basant sur des exemples, il s'agit alors d'utiliser les exemples fournis déjà classés pour apprendre un modèle qui permette ensuite d'associer à tout nouvel exemple rencontré sa classe la plus adaptée.

2.2.1 Les méthodes de classification

Il existe plusieurs méthodes de classification, nous allons présenter quelques unes :

2.2.1.1 K plus proches voisins (KPP) [SNB, 13] [LLA, 06]

Le principe général de la méthode des k-ppv consiste à rechercher parmi l'ensemble d'apprentissage T , contenant l'ensemble des individus et leurs classes d'affectation, un nombre k d'individus parmi les plus proches possibles de l'individu à classer. Puis, l'individu est affecté à la classe majoritaire parmi ces k individus trouvés. Le nombre k est fixé a priori par l'utilisateur.

Cette méthode peut se résumer par ce simple principe : *Dis moi qui sont tes voisins, je te dirai qui tu es !*, donc elle est basée sur le calcul de distance entre les exemples d'apprentissage et les exemples de tests, généralement la norme euclidienne est souvent employée comme mesure de distance, dans chaque étape de l'apprentissage.

Les étapes de mise en œuvre de la méthode kpp sont: [DSR, 13]

- **Etape 1:** Déterminer la valeur de k .
- **Etape 2:** Calculer la distance entre l'individu qui nous voulons le classer et les les exemples d'apprentissage (les voisins).
- **Etape 3:** Trier les distances calculées et sélectionner parmi eux les K distances minimale.
- **Etape 4:** Attribuer la classe majoritaire.
- **Etape 5:** Déterminer la classe.

2.2.1.2 L'analyse en composantes principales (PCA)

PCA est une technique célèbre utilisée pour la réduction de la dimension des données sans perte d'informations ; Si un grand nombre d'attributs d'apprentissage est disponible, l'analyse par composante principale peut être employée pour choisir les attributs ayant la plus grande puissance distinctive.

PCA est basée sur l'analyse de la matrice de variance-covariance de l'ensemble des données. Partant de l'idée, s'il existe des variables qui peuvent être exprimées en fonction d'autres, nous n'avons besoin que de "p variables " qui tiennent compte de la variabilité du système.

Cette technique est basée sur les étapes suivantes:

- **Étape 1:** préparer les données en vecteurs.
- **Étape2:** soustraire la moyenne de chaque dimension des données (pour chaque dimension, on soustrait la moyenne de toutes les données).
- **Étape 4 :** Calcul de la matrice de covariance.
- **Étape 5:** Calcul des vecteurs et valeurs propres de la matrice de covariance (Permettent d'obtenir des informations sur les modèles de l'ensemble des données).
- **Étape 6:** Choisir les composantes principales pour former le vecteur d'attributs.
- **Étape 7:** Obtenir de nouvelles données. [SNB, 13]

2.2.1.3 L'analyse discriminante

L'Analyse Linéaire Discriminante (LDA, Linear Discriminant Analysis ou Fisher Discriminant Analysis) est une méthode de classification basée sur la maximisation de la distance "inter-classes" et la minimisation de la distance "intra-classes". Elle permet de rechercher, dans l'espace des données, les axes qui permettent de discriminer au mieux les différentes classes (plutôt que les axes qui décrivent au mieux les données). En d'autres termes, si on considère un certain nombre de paramètres indépendants, la LDA permet de créer une combinaison linéaire de ces derniers qui aboutit à un maximum de distance entre les moyennes des différentes classes. Concrètement, pour tous les échantillons de toutes les classes. [LLA, 06]

2.2.1.4 Machines à Vecteurs de Support (SVM) [SNB, 13] [LBO, 14] [SID, 09]

Les machines à vecteurs de support ou séparateurs à vaste marge (en anglais Support Vector Machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de la classification binaire et de la régression. Après leur

développement en 1990 par Vapnik, Les SVM ont rapidement été adoptés pour leur capacité à travailler avec des données de grandes dimensions, le faible nombre d'hyper paramètres, leurs garanties théoriques, et leurs bons résultats en pratique.

Le classificateur SVM est un algorithme son but est maximise la marge entre les classes du problème à résoudre et réduit au minimum l'erreur de classification. L'objectif de la marge maximale est de faire séparer deux classes par un hyperplan de telle sorte la distance par rapport aux vecteurs supports soit maximale.

Le principe des approches SVM est de trouver l'hyperplan optimal parmi l'ensemble des hyperplans possibles (figure 3) permettant de classifier correctement les données (i.e. les données des classes de label +1 et -1 se trouvent de chaque côté de l'hyperplan) mais également tel que sa distance aux vecteurs (exemple d'apprentissage) les plus proches soit maximale (i.e. le plus loin possible de tous les exemples). Les vecteurs les plus proches sont alors dénommés "vecteurs supports" et la distance constitue la marge optimale.

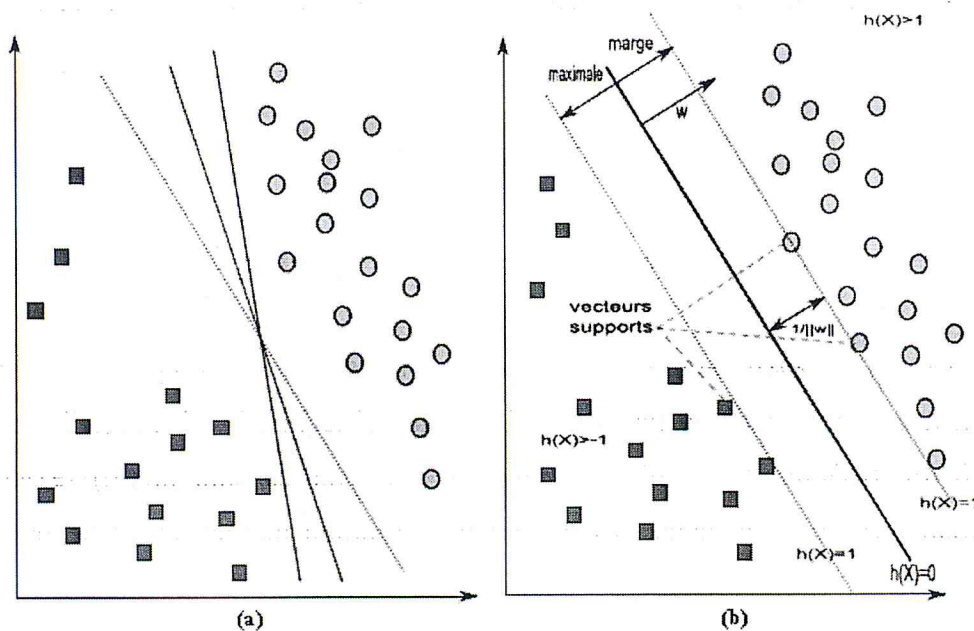


Figure 2.4: Principe des SVM : (a) Recherche de l'hyperplan optimal, (b) Hyperplan optimal, marge et vecteurs supports.

2.2.1.4.1 Fonctionnement des SVM [IEL, 11] [WIK, 15]

Les SVM sont également appelés « classifieurs à vaste marge » car leur objectif est de trouver l'hyperplan séparateur optimal qui maximise la marge entre les classes dans un espace de grande dimension. Deux idées ou astuces permettent d'atteindre cet objectif:

- La première consiste à définir l'hyperplan comme solution d'un problème d'optimisation sous contraintes dont la fonction objectif ne s'exprime qu'à l'aide de produits scalaires entre vecteurs et dans lequel le nombre de contraintes "actives" ou vecteurs supports contrôle la complexité du modèle.
- Le passage à la recherche de surfaces séparatrices non linéaires est obtenu par l'introduction d'une fonction noyau (kernel) dans le produit scalaire induisant implicitement une transformation non linéaire des données vers un espace intermédiaire (feature space) de plus grande dimension. D'où l'appellation couramment rencontrée de machine à noyau ou kernel machine. Sur le plan théorique, la fonction noyau définit un espace hilbertien, dit auto-reproduisant et isométrique par la transformation non linéaire de l'espace initial et dans lequel est résolu le problème linéaire.

2.2.1.4.2 Hyperplan optimal [MBE, 13]

Est un hyperplan qui classe correctement les données (lorsque c'est possible) et qui se trouve le plus loin possible de tous les exemples, on peut dire aussi que cet hyperplan maximise la marge.

2.2.1.4.3 Vecteurs de support [MBE, 13]

Ce sont les points les plus proches, qui seuls sont utilisés pour la détermination de l'hyperplan.

2.2.1.4.4 La marge [MBE, 13]

Est la distance entre l'hyperplan et les exemples. La marge est calculée à partir du produit scalaire entre les vecteurs situés la frontière de chaque classe et le vecteur unitaire normal de l'hyperplan séparateur.

2.2.1.4.5 Linéarité et non-linéarité [MFA, 10]

Parmi les modèles des SVM, on constate les cas linéairement séparable et les cas non linéairement séparable. Les premiers sont les plus simples de SVM car ils permettent de trouver facilement le classificateur linéaire. Dans la plupart des problèmes réels il n'y a pas de séparation linéaire possible entre les données, le classificateur de marge maximale ne peut pas être utilisé car il fonctionne seulement si les classes de données d'apprentissage sont linéairement séparables.

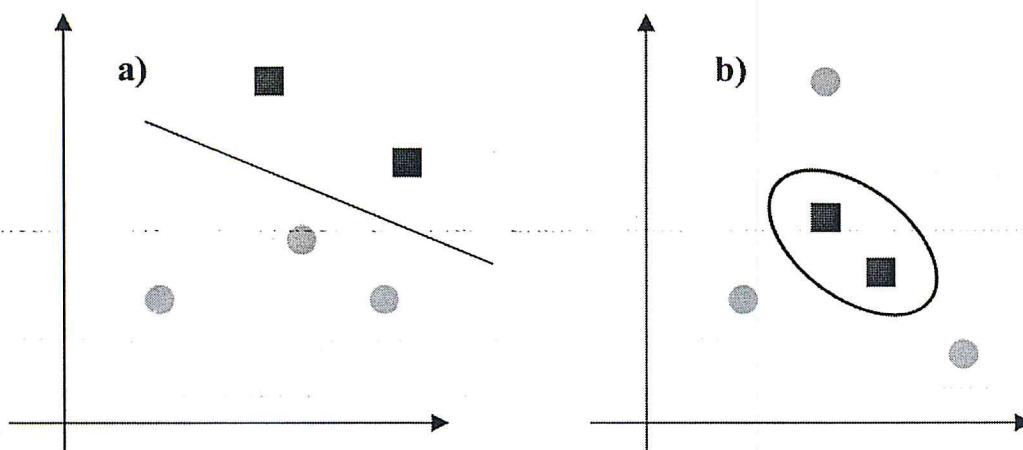


Figure 2.5 : Données linéairement et non linéairement séparables.

2.2.1.4.6 Cas non linéaire [MFA, 10]

Pour surmonter les inconvénients des cas non linéairement séparable, l'idée des SVM est de changer l'espace des données. La transformation non linéaire des données peut permettre une séparation linéaire des exemples dans un nouvel espace. On va donc avoir un changement de dimension. Cette nouvelle dimension est appelé « espace de re-description ». En effet, intuitivement, plus la dimension de l'espace de re-description est grande, plus la probabilité de pouvoir trouver un hyperplan séparateur entre les exemples est élevée. Ceci est illustré par le schéma suivant:




Figure 2.6 : Transformation non linéaire de données

On a donc une transformation d'un problème de séparation non linéaire dans l'espace de représentation en un problème de séparation linéaire dans un espace de re-description de plus grande dimension. Cette transformation non linéaire est réalisée via une fonction noyau.

En pratique, quelques familles de fonctions noyau paramétrables sont connues et il revient à l'utilisateur de SVM d'effectuer des tests pour déterminer celle qui convient le mieux pour son application. On peut citer les exemples de noyaux suivants : polynomiale, gaussien, sigmoïde et laplacien.

2.2.2 Avantage et Inconvénient des méthodes de classification:

Chaque méthode de classification a des avantages et des inconvénients, qui sont résumés dans le tableau 2.3.

Méthodes	Avantages	Inconvénients
KPPV [SAI, 13]	<ul style="list-style-type: none"> -Méthode simple et facile à comprendre -donne des résultats efficace 	<ul style="list-style-type: none"> -prédiction lente car il faut revoir tous les exemples à chaque fois -Choisir du K (alternative: choisir la taille du voisinage) -Choisir le type de la distance à appliquer
PCA [KAZ, 13]	<ul style="list-style-type: none"> -Simplicité mathématique -Simplicité des résultats 	<ul style="list-style-type: none"> -la perte d'information
ADL [MBE, 13]	<ul style="list-style-type: none"> - Maximiser la distance entre les classes. - Minimiser la variance intra-classe. 	<ul style="list-style-type: none"> -Couteuse en temps de calcul. -Couteuse en espace mémoire. -Donne mauvais résultats quand le nombre d'images d'apprentissage est grand.
SVM [MAA, 14] [AHK, 14]	<ul style="list-style-type: none"> -Ils permettent de traiter des données de très grande dimension et sont d'ailleurs très efficaces -Les SVM sont faciles d'emploi et présentent de bon comportement en prédiction -Décision rapide - offrent la possibilité d'entraîner des classificateurs généralisables ; Ils minimisent aussi le nombre d'erreurs de classement à tous ensemble possible d'échantillons 	<ul style="list-style-type: none"> -Elle ne présente pas des résultats escomptés dans une tâche de classification de très petite dimension

Tableau 2.3: Avantages et inconvénients des méthodes de classification.

Conclusion :

Dans ce chapitre nous avons présenté les différentes méthodes d'extraction d'attributs texturales qui existe dans la littérature, puis nous avons tenté de présenter les différentes méthodes de classification des images médicales. Il ressort que le domaine de classification est très riche par rapport le domaine d'extractions des attributs, en effet il est difficile de donnée une étude approfondie et de choisir une technique à utiliser plutôt qu'une autre.

Dans le chapitre suivant nous entamerons la partie pratique de ce mémoire en commençant par l'application de la méthode matrice de cooccurrence (en 2D et 3D) pour l'extraction des attributs sur les images IRM, ensuite on parlera de la classification et plus précisément la classification par la méthode SVM (machine à vecteur support).

CHAPITRE 3

***L'extraction des paramètres et la
classification des tumeurs cérébrales***

Introduction

L'extraction des attributs caractéristiques est l'une des étapes les plus importantes pour la réussite d'un système de classification des tumeurs cérébrales. Dans ce chapitre nous nous sommes intéressés à la classification de texture des images selon un certain nombre de classes prédéfinies. Nous allons donc extraire pour chaque texture donnée un vecteur qui contient les caractéristiques de cette texture, et nous utilisons ce vecteur pour la classification.

Ce chapitre est divisé en deux parties, dans la première partie nous allons présenter notre contribution dans l'extraction des paramètres texturés, la base de données utilisée, la normalisation des images ainsi que le processus d'extraction des paramètres qui sert à construire les vecteurs caractéristique des tumeurs cérébrales. Et dans la deuxième partie nous discuterons le choix de la méthode de classification ainsi que sa méthodologie.

3.1 Système d'extraction des paramètres texturés:

Dans le cadre de notre travail nous nous sommes intéressés à l'extraction des caractéristiques texturales ayant pour but la classification des tumeurs cérébrales en deux classes : Bénignes et Malignes.

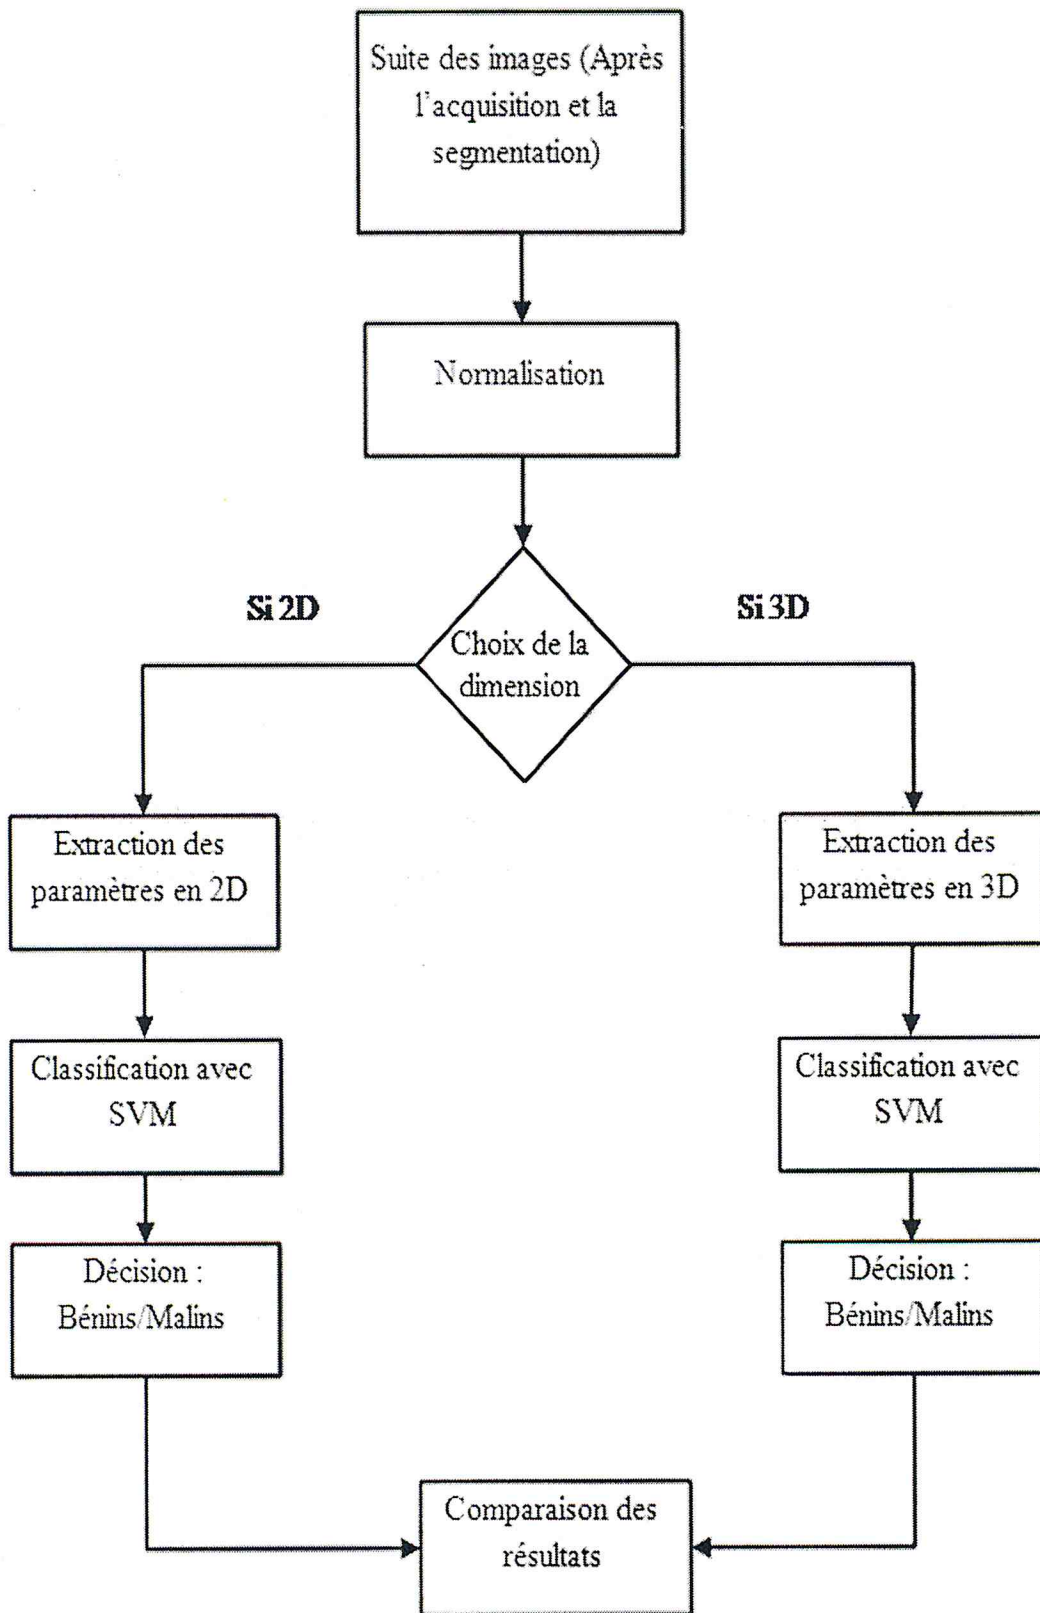


Figure 3.1 : Architecture globale de notre système.

3.2 Base de données

Nous avons utilisé une base de données internationale contenant des images BRATS 2014 qui représente des images des tumeurs cérébrales qui ont été obtenues à partir de " MICCAI 2013 Challenge" sur la segmentation Multimodale de tumeurs cérébrales téléchargée à partir du site :

[<https://www.virtualskeleton.ch/BRATS/Start2014>].

Cette base de données contient 213 images, dont 188 images de tumeurs malignes (haut grade) et 25 images de tumeurs bénignes (bas grade) avec différentes modalités pour chaque patient. Ces images sont traitées et segmentées; chaque image représente des tailles de 240×240 et contient 155 slices.

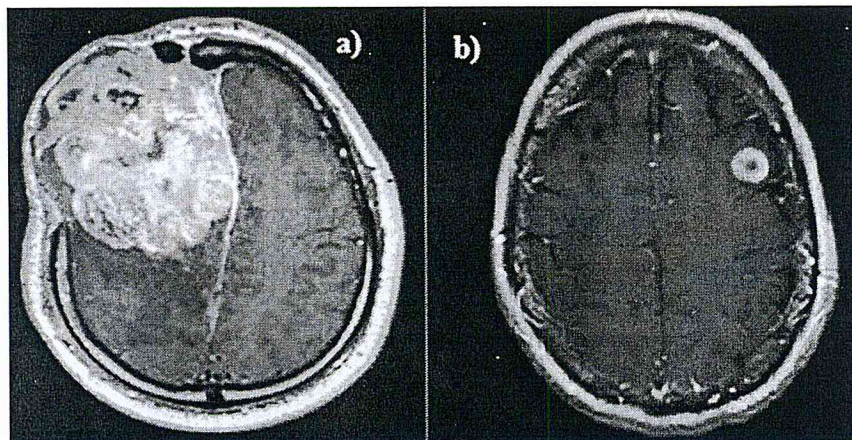


Figure 3.2 : Exemple d'image de la base de données (BRATS 2014) : a) image IRM en T2 cas maligne, b) image IRM en T2 cas bénigne.

3.3 Normalisation

Le rôle de la normalisation est d'une part d'éviter les influences des facteurs d'échelle quand les données varient dans des intervalles différents, et d'autre part La normalisation tente d'éliminer ou de réduire les effets de l'illumination de l'image. Il existe un grand nombre d'opérateurs de normalisations utilisés. Pour normaliser une donnée il est nécessaire de posséder des informations sur sa distribution. Nous appliquons une normalisation de M.Haralick sur nos images [DGH, 00]. L'algorithme suivant montre le déroulement de la normalisation :

```
Entrée :Matrice M; {la matrice M représente notre image}
Sortie: Matrice Mat;
Variables :réel : moyen, sum_deviation,segma ;
Debut
//calculer la moyen
moyen=0.0, sum_deviation=0.0;
pour i=0 allant de 1 à lignes (M) faire
pour i=0 allant de 1 à colones (M) faire
    moyen= moyen + M[i][j];
Moyen =moyen/ligne(M)*colone (M)
Fait
// calcul sum_deviation
pour i=0 allant de 1 à lignes (M) faire
pour i=0 allant de 1 à colones (M) faire
    sum_deviation= sum_deviation +(M[i][j]-moyen)*( M[i][j]-moyen);
    segma= (sum_deviation/( ligne(M)*colonne (M)-1))1/2;
fait
fait
// scaling
pour i=0 allant de 1 à lignes (M) faire
pour i=0 allant de 1 à colones (M) faire
Mat[i][j]= (M[i][j]-moyen)/segma
Fait
Fait
End
```


3.4 Extraction des paramètres

Nous avons résumé la méthodologie due processus d'extraction des paramètres par le biais de l'organigramme suivant :

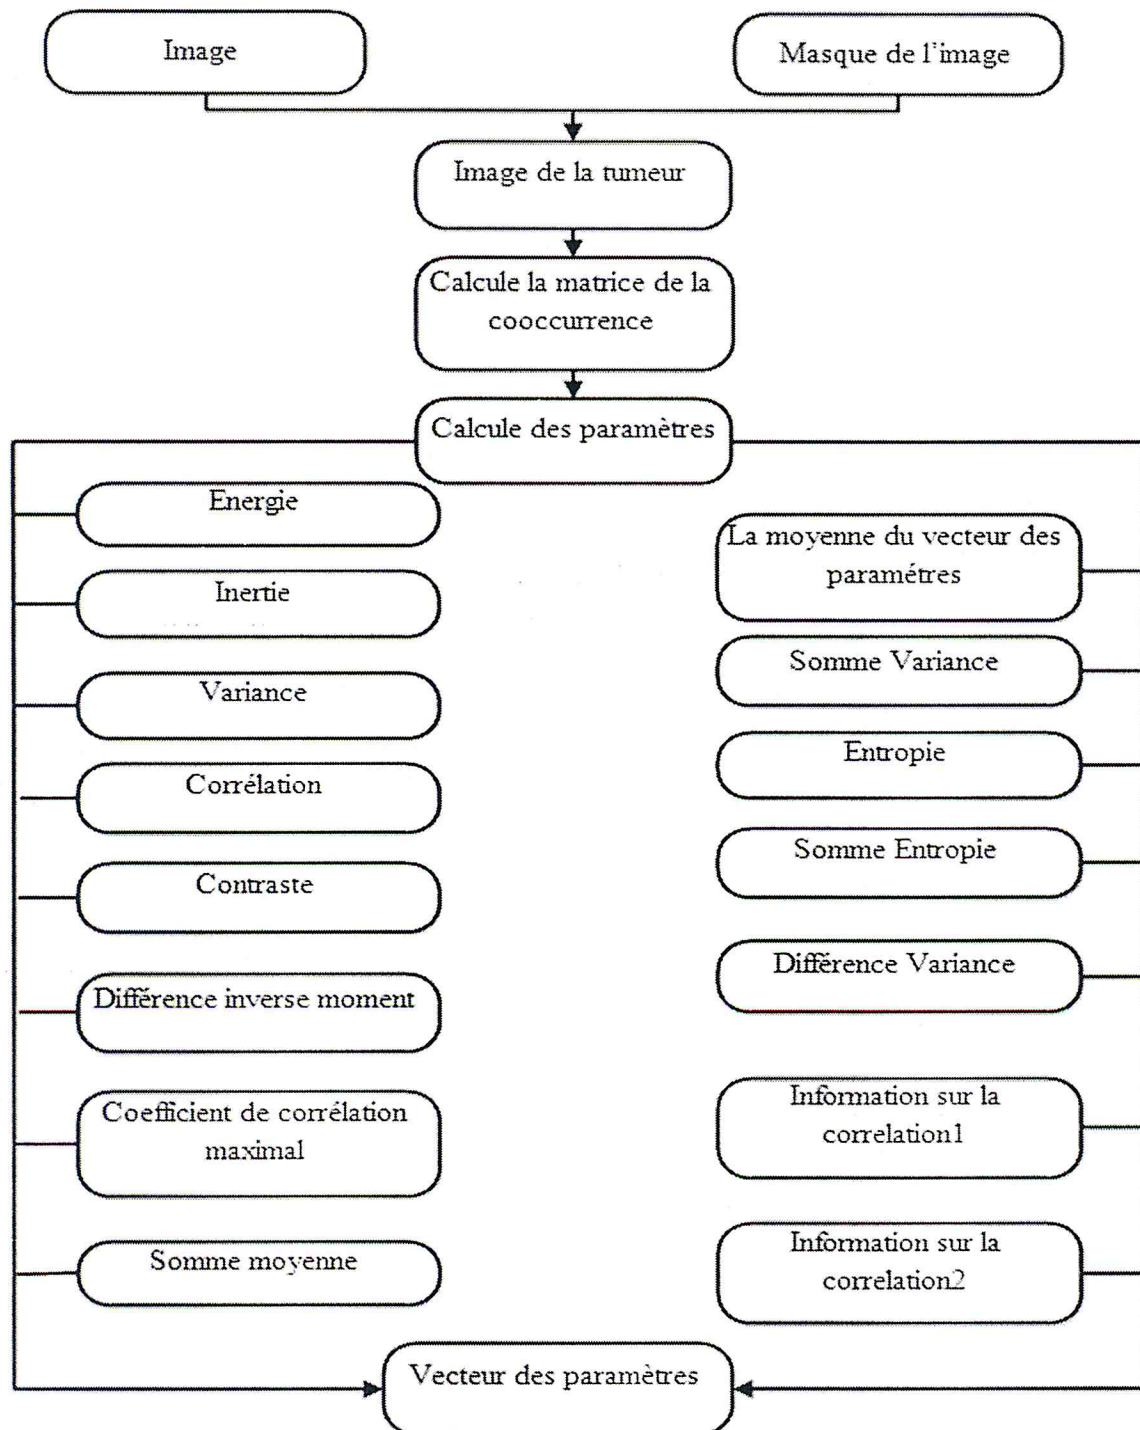


Figure 3.3 : processus de l'extraction des paramètres.

Dans cette partie nous allons appliquer plusieurs étapes afin d'obtenir les vecteurs des paramètres qui vont être utilisés ensuite dans la tâche de classification :

3.4.1 Binarisation du masque

Cette partie consiste à modifier les valeurs du pixel qui sont supérieur a 1 et leurs donner une valeur 1, afin de construire une nouvelle image qui contiendra seulement des valeurs 1 et 0.




Figure 3.4 : exemple du masque binariser.

3.4.2 Extraction de la tumeur

Nous entendons par cela : multiplication pixel par pixel du masque binariser avec l'image normalisée. Le but de cette méthode est d'éliminer la partie du cerveau qui n'était pas touché par la tumeur afin de construire une image qui contient la tumeur isolé.

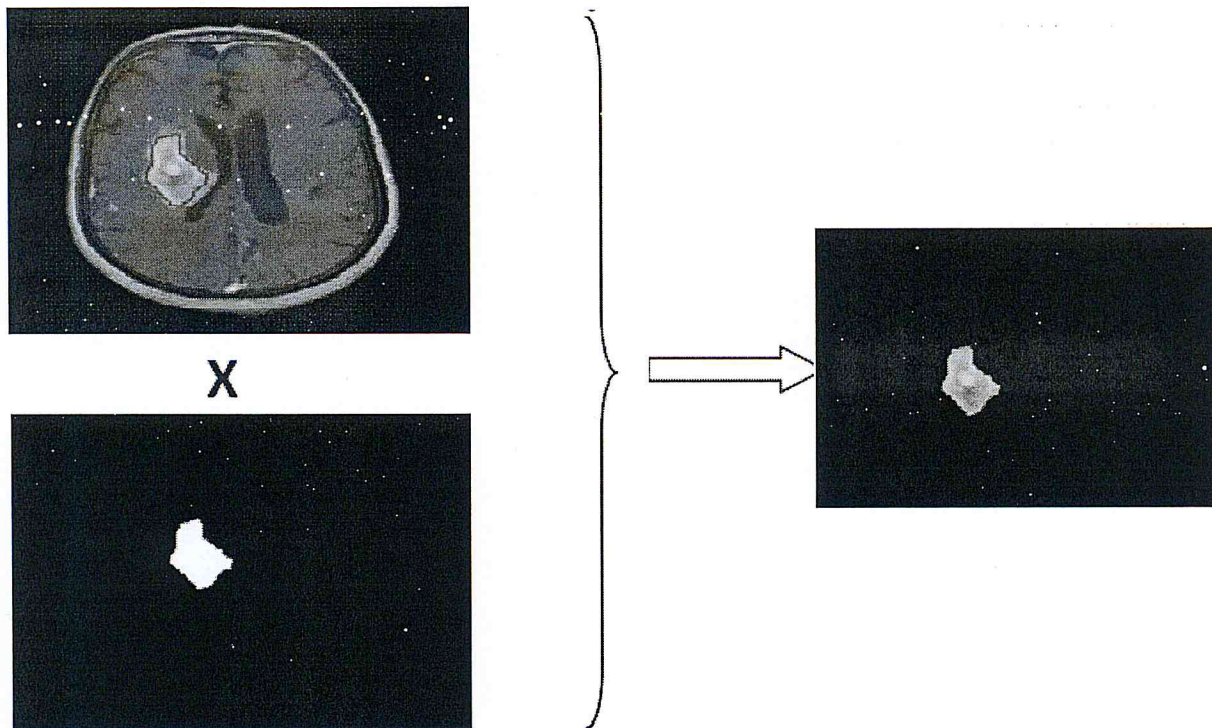


Figure 3.5 : Etape de multiplication.

3.4.3 Scaling

Les images issue par les scanner IRM sont généralement des images de niveau de gris, sachons que la taille d'une matrice de cooccurrence de niveau de gris est proportionnelle au nombre de niveaux de gris de la texture. Donc pour les 256 niveaux, il faudrait des matrices carrées de taille 256×256 . Il faut remarquer que la taille de la matrice de cooccurrence est trop grande et nécessite beaucoup de calcul. C'est pour cette raison que nous allons appliquer le scaling sur les images (c'est un type de normalisation) afin de réduire la taille de matrice de la cooccurrence de niveau de gris et d'améliorer la performance de la méthode. Cette opération consiste à réduire les valeurs de chaque pixel de manière à ce que l'image résultante garde toute ces caractéristiques texturels. L'algorithme suivant montre le scaling de l'image :

Entrées : une matrice M, entiers fmax ; {fmax taille de matrice de cooccurrence }

Sortie : une matrice Mat ;

Variable : entier :fmin,Std,Val ;

Début :

//on calculons la min et le max de l'image

Min=255 ;

Max=0 ;

Pour i=0 à lignes(M) faire

Pour j=0 à colonnes(M) faire

Si(M[i][j]< Min) alors Min =M[i][j] ;

Sinon

si (M[i][j]>= Max) alors Max=M [i][j];

finsi

finsi

fait

fait

// on remplir la matrice de sortie avec la formule suivante :

fmin=1 ;

Pour i=0 à lignes(M) faire

Pour j=0 à colonnes(M) faire

Val =M [i][j];

Std =((Val-min)/(max-min))*(fmax-fmin)+fmin;

Mat[i][j]=Std ;

fait

fait

Fin

3.4.4 Matrice de cooccurrence


Après la normalisation de l'image IRM pour extraire les paramètres, nous allons appliquer la méthode du calcul de matrice de cooccurrence pour 2 dimensions et pour obtenir un résultat amélioré nous allons appliquer la méthode de cooccurrence pour 3 dimensions.

3.4.4.1 Matrice de cooccurrence 2D

Les étapes de calcul de la matrice de cooccurrence 2D :

Pour une image contenant G niveaux de gris, la matrice de cooccurrence 2D est une matrice carrée M de taille G * G. Le calcul de la matrice se fait de cette manière :

- **Etape 1:** Nous fixons une distance D et un angle θ .
- **Etape 2:** Nous initialisons la matrice M(d, θ) a zéro.
- **Etape 3:** Pour chaque pixel P₀, on fait correspondre le pixel P₁ situé a la distance D de P₀ dans l'angle θ . Nous supposons que X₀ et X₁ sont les valeurs de niveaux de gris dans les cases P₀ et P₁. On incrémente donc la case (X₀, X₁) de la matrice M(D, θ). Dans l'exemple suivant nous avons calculé la matrice de cooccurrence avec: Distance = 1.



$$d = (0,1) \begin{pmatrix} 4 & 2 & 0 & 0 \\ 2 & 0 & 0 & 0 \\ 0 & 0 & 2 & 1 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

$$d = (1,1) \begin{pmatrix} 0 & 0 & 3 & 1 \\ 0 & 0 & 0 & 0 \\ 2 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \end{pmatrix}$$

$$d = (1,0) \begin{pmatrix} 0 & 0 & 3 & 1 \\ 0 & 0 & 1 & 1 \\ 3 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \end{pmatrix}$$

$$d = (-1,-1) \begin{pmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 2 & 0 \\ 1 & 2 & 0 & 0 \\ 1 & 0 & 0 & 0 \end{pmatrix}$$

Figure 3.6 : Exemple de calcul la matrice de cooccurrence 2D.

3.4.4.2 Matrice de cooccurrence 3D

Les étapes de calcul de la matrice de cooccurrence 3D:

Pour une image a trois dimension contenant G niveaux de gris, la matrice de cooccurrence 3D ressemble à la matrice de cooccurrence 2D, mais la différence entre elles est que la matrice de cooccurrence 3D est calculée par rapport à 2 angles et ses voisins appartient à d'autres image. Elle est calculée de cette manière

- **Etape 1:** Nous fixons une distance D et deux angles θ_1 et θ_2 .
- **Etape 2:** Nous Initialisons la matrice M (d, θ_1,θ_2) a zéro.
- **Etape 3:** Pour chaque voxel P_0 , on fait correspondre le voxel P_1 situé à la distance D de P_0 dans l'angle θ_1 et aussi pour l'angle θ_2 , donc la position du voxel P_1 dans le volume de l'image dépend du vecteur de déplacement. Nous supposons que X_0 et X_1 sont les valeurs de niveaux de gris dans les cases P_0 et P_1 .On incrémente donc la case (X_0, X_1) de la matrice M(d, θ). La **Figure 3.7** montre la méthode de calcul de la matrice de cooccurrence avec le vecteur de déplacement égale a $(0, 0, 1)$.

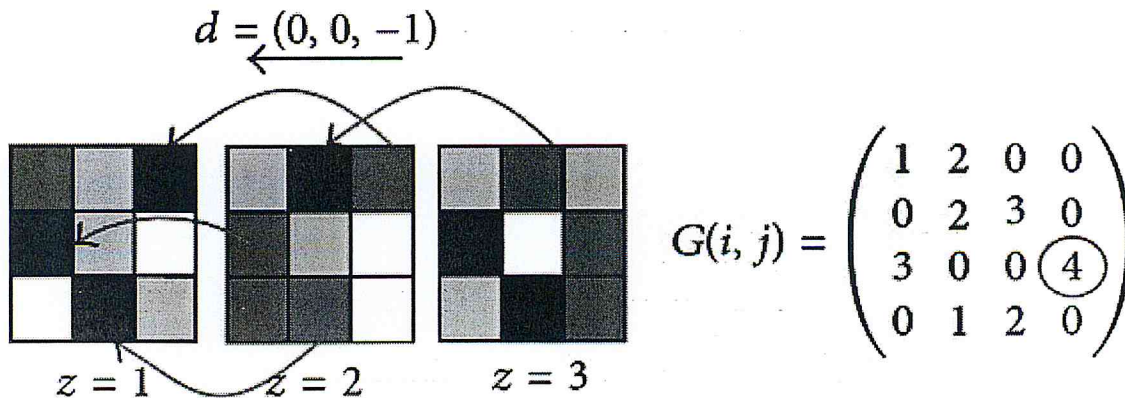


Figure 3.7 : Exemple de calcul de la matrice de cooccurrence 3D.

3.5 Extraction des paramètres

Comme nous l'avons expliqué dans le chapitre 2, nous ne pouvons pas utiliser directement la matrice de cooccurrence, mais nous pouvons l'utiliser à travers des paramètres de texture. Dans cette partie nous allons appliquer les quatorze paramètres de Haralick [RHA, 79] pour extraire les informations des matrices de cooccurrence 2D et 3D et les stockés dans un fichier afin de les utilisés pour la tache de classification.

Dans cette partie nous avons ajouté un nouveau paramètre qui est la moyenne de vecteur des paramètres. Ce dernier a été intégrer dans le vecteur des quatorze paramètres de Haralick pour bien illustré la différence entre les vecteurs des paramètres pour GLCM 2D et GLCM 3D.

3.6 Classification

La classification de textures d'image consiste à associer une classe à une texture donnée, en fonction des caractéristiques présentes. Une première étape importante est donc l'extraction des caractéristiques de textures. Ces attributs de textures sont calculés à partir des méthodes vues précédemment. Ces caractéristiques sont regroupées sous forme de vecteurs numériques et sont, par la suite, directement utilisées par un classificateur. Une deuxième étape importante du processus de classification est donc le choix du classifieur.

3.6.1 Choix de la méthode

Le SVM est une méthode d'analyse très connue dans les domaines de l'informatique et de l'ingénierie [DGH, 13]. Le succès de cette méthode est du au solides bases théoriques qui la soutiennent.

Cette méthode repose sur l'existence d'un classificateur linéaire dans un espace approprié, puisque c'est un problème de classification à deux classes, elle fait appel à un jeu de données d'apprentissage pour apprendre les paramètres du modèle. Le SVM est une méthode particulièrement bien adaptée pour traiter des données de très haute dimension comme les textes et les images. Depuis son introduction dans le domaine de la classification à base de texture plusieurs travaux ont pu montrer l'efficacité de cette technique principalement en traitement d'image [IMA, 12].

L'Analyse SVM effectue la phase de l'apprentissage et de test de manière très rapide, même lorsqu'elle est appliquée à un nombre d'échantillon relativement grand de plus elle peut être utilisée pour évaluer de nombreux paramètres à la fois. Selon [GOD, 06], le SVM a prouvé être plus précis que les autres méthodes de classification.

Dans notre projet, nous avons utilisé la méthode SVM binaire, car nous intéressons de classifier nos paramètres en façons binaire pour obtenir deux classes :

1ère classe : Tumeur maligne.

2ème classe : Tumeur bénigne.

Ces 2 classes sont les sorties du SVM.

3.7 Méthodologie du SVM

La démarche pratique que nous avons suivie pour pouvoir classifier notre base de données BRATS 2014 et les étapes de la classification sont illustrées dans l'organigramme suivant **Figure3.8**

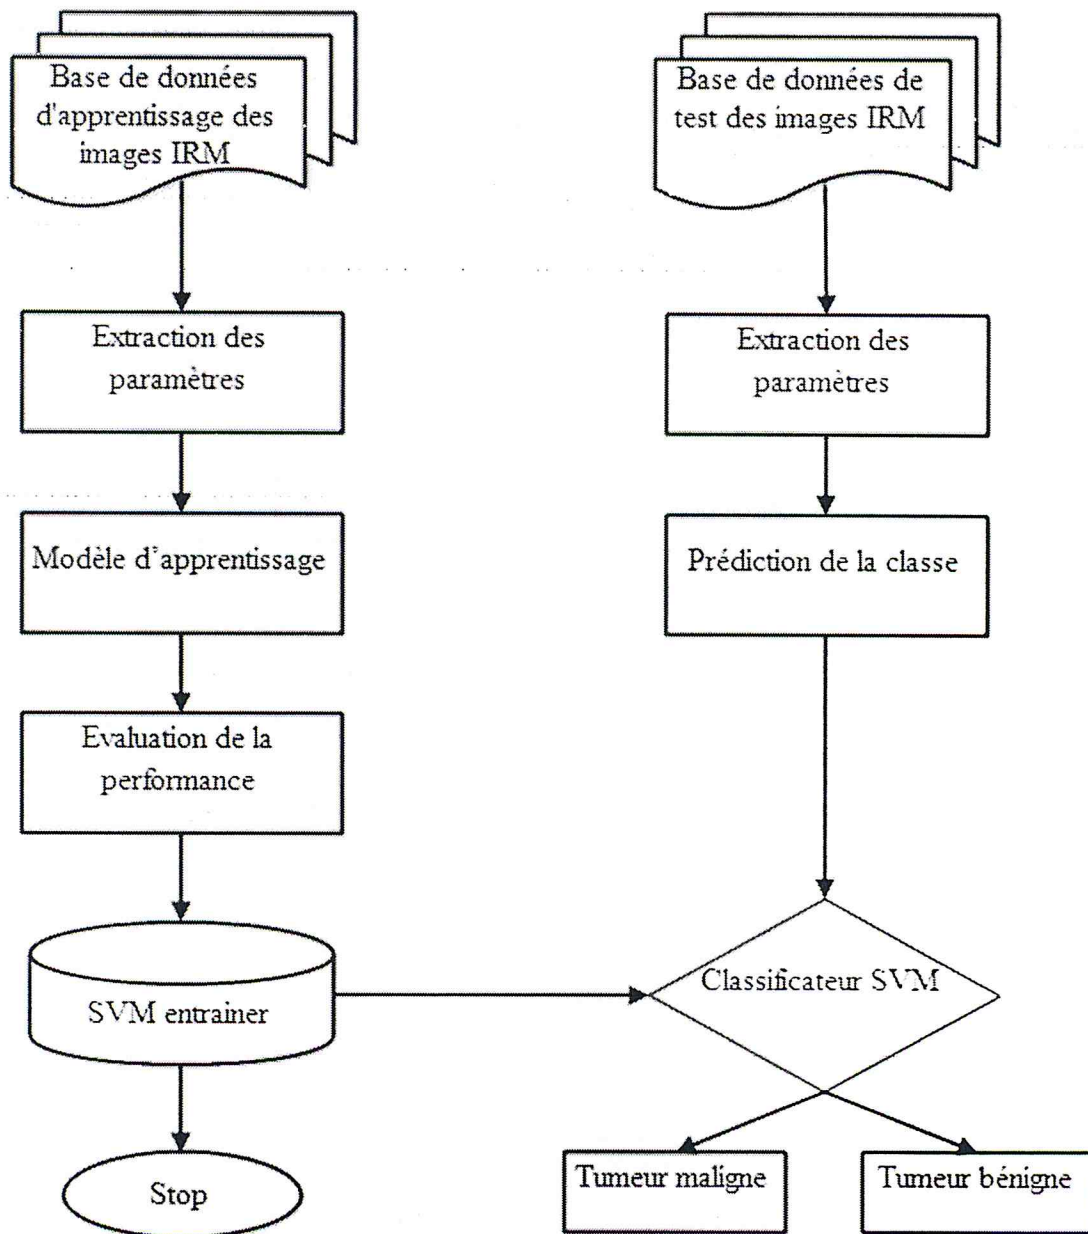


Figure3.8: Organigramme de processus de classification.

Le processus de classification par SVM se fait en deux phases : phase d'apprentissage et phase de test.

3.7.1 Phase d'apprentissage

Le SVM est une méthode d'apprentissage utilisée pour la classification. Dans ce travail, un SVM deux classes est utilisé, qui trouve un hyperplan qui sépare les données d'entrées en deux catégories. Dans notre étude les deux classes de sorties sont

1. Tumeur maligne

2. Tumeur bénigne

Pendant la phase d'apprentissage (training), le classificateur SVM est entraîné à partir d'un ensemble de données d'apprentissages appelés aussi exemples d'entraînement qui contient des vecteurs des paramètres extraits des images d'apprentissage caractérisant leurs types ou classes d'appartenance.

3.7.2 Phase de test

Cette phase a pour objectif de mesurer la qualité du classificateur SVM à comparer les images qui ne sont pas dans la base d'apprentissage avec ceux de référence de base d'apprentissage. Pendant la phase de test, si le vecteur de caractéristique d'une image inconnue est donné comme une entrée au classificateur qualifié, il classe l'image de test comme appartenant à une des deux classes. Afin d'effectuer la classification par SVM, nous utilisons deux noyaux de kernel différents ; Noyau Polynomiale et Noyau RBF, ensuite nous évaluerons et comparons leur efficacité.

3.7.3 Choix du modèle

Bien qu'il existe seulement quatre noyaux, nous devons choisir lequel essayer en premier. Notre premier choix est le noyau RBF. Il gère le cas où la relation entre les étiquettes de classe et les attributs est non linéaire. Nous avons sélectionné aussi le noyau polynomial pour pouvoir effectuer une comparaison de performance avec le noyau RBF.

3.7.4 Méthodes d'évaluation de classification

Afin d'établir un diagnostic fiable dans un système d'aide à la décision et particulièrement le domaine médical, il faut se baser sur une méthode d'évaluation.

Pour tester la performance de la classification de façon pertinente, nous jugeons la qualité de la classification obtenue par rapport à plusieurs estimateurs souvent utilisés dans la littérature : Sensibilité (SE) Spécificité (SP), Précision (taux de classification) (accuracy). Nous présentons ci-dessous les critères d'évaluation les plus communément utilisés pour un classificateur supervisé.

1. TP est le nombre de tumeurs malignes qui sont classées malignes.
2. FP est le nombre de tumeurs bénignes qui sont classées malignes.
3. TN est le nombre de tumeurs bénignes qui sont classées bénignes.
4. FN est le nombre de tumeurs bénignes qui sont classées malignes.

Le **tableau 3.1** présente chaque critère et leur formule mathématique.

Critères	Définition	Formule Mathématique
Sensibilité	Représente la probabilité que le test soit positif si la tumeur est maligne	$\frac{TP}{TP + FN}$
Spécificité	Représente la probabilité que le test soit négatif si la tumeur est bénigne	$\frac{TN}{TN + FP}$
Précision	Représente la probabilité que la tumeur soit bien classée	$\frac{TP}{TP + FP}$

Tableau 3.1: Critère d'évaluation de la classification.

La performance du système est vérifiée en démontrant les modèles corrects et incorrects. Ils sont définis par la matrice de confusion. La matrice de confusion fournit des informations sur des cas réels et des cas où la classe est prédite par le système de classification [MAT, 12].

Ils sont présentés dans le **tableau 3.2**.

Vrais classe	Classe prédite	
	Positif (1)	Négatif (0)
Positif (1)	TP True positive Vrais positif	FP false positive faux positif
Négatif (0)	FN False negative Faux négatif	TN true negative vrais négatif

Tableau 3.2 : Matrice de confusion

Conclusion :

Dans ce chapitre nous avons présenté notre contribution dans l'extraction des paramètres texturés d'images qui servent à représenter chaque texture par un vecteur de paramètres qui devient son identité et nous avons présenté aussi le concept de la méthode de classification par SVM, qui utilise le vecteur de paramètres comme entrée .

Dans le chapitre suivant, nous expliquerons la dernière étape de notre travail qui est la représentation des résultats expérimentaux obtenus accompagnés par leurs interprétations.



CHAPITRE 4

**Implémentations, expérimentation
et interprétation des résultats**

Introduction

L'objectif de ce chapitre est de présenter l'application développée, les traitements illustrés par des images IRM dans le but de l'extraction et de la classification des pathologies cérébrales issues de la base de données BRATS 2014. Ces images de type T2 ont une résolution axial de taille 240 X 240 X 155. Notre système offre une aide à la décision pour distinguer les tumeurs malignes des tumeurs bénignes de la base BRATS 2014 suivant les SVM, qui est l'un des classificateurs supervisés les plus populaires dans la classification des images IRM grâce à son rendement élevé, sa capacité à traiter des données de grande dimension, et sa flexibilité dans la modélisation de diverses sources de données telles que les tumeurs cérébrales [RSA, 14].

4.1 Environnement de travail

4.1.1 Matériel

Pour le développement de notre application, nous avons utilisé un microordinateur, menu essentiellement de :

- Intel Core i5 3632QM (2.20GHz)
- 4GB Memory
- 1600 x 900
- Windows 7 (32 bits)

4.1.2 Langage

Langage C++ est un langage de programmation de haut niveau développé en 1983 par Bjarne Stroustrup aux Laboratoires Bell. Il s'agit d'une version orientée objet de son prédécesseur C. C'est un langage très utilisé pour développer des applications graphiques (comme celles qui tournent sur les environnements Windows et Macintosh) [KHA, 11].

Insight Toolkit ou ITK est un projet américain destiné à offrir une base solide aux développements informatiques dans le cadre du traitement d'images. Les applications envisagées sont plutôt orientées vers l'imagerie médicale, mais le logiciel est suffisamment généraliste pour être utilisé dans d'autres domaines.

ITK utilise beaucoup le mécanisme de templates propre au C++. De ce fait, un algorithme écrit une fois pourra être compilé pour des images de type et de dimension arbitraire, ce qui améliore considérablement la généralité de la bibliothèque. Par contre, le développement et la manipulation de la bibliothèque sont plus ardues. Une alternative à la programmation en C++ avec ITK est de passer par un wrapper, pour appeler les fonctions d'ITK depuis un autre langage.

OpenCV (Open Source Computer Vision) est une librairie open source de traitement et analyse d'images et vidéos avec des interfaces pour les principaux langages de programmation C, C++, Java, C#, Python. Elle a l'avantage d'être optimisée pour les applications temps réelles, de fournir une API bas et haut niveau ainsi qu'une interface pour le langage de programmation parallèle IPP [AMI, 15].

La **LIBSVM** est une librairie dédiée aux Machines à Support de Vecteurs (SVM). Élaborée par Chih-Chung Chang et Chih-Jen Lin, deux chercheurs du département informatique de l'université de Taipei à Taiwan « National Taiwan University ». La librairie englobe un ensemble de fonctions implémentant des algorithmes de fouille de données, particulièrement utilisée pour mettre en œuvre des classifications et des régressions. Elle est disponible en langage C++ et en JAVA, et compatible avec diverses plateformes logicielles (Python, R, MATLAB, Perl, Ruby, Weka, Common LISP, CLISP, Haskell, LabVIEW, interfaces PHP, C# .NET, extensions CUDA) [IEL, 11].

4.2 Sélection des attributs d'extraction des paramètres texturaux

L'extraction de paramètres texturaux des images, nous permet de constituer des vecteurs des paramètres de chacune des textures étudiées, en vue d'une classification par SVM, pour une prise de décision. Les tableaux suivants représentent l'évaluation des paramètres de M.Haralick utilisés pour la caractérisation des images utilisées :

F14	F13	F12	F11	F10	F9	F8	F7	F6	F5	F4	F3	F2	F1	Mha
0.0367	0.00	0.4621	0.772	0.382	1.00	2.5737	1.107	0.783	1.279	0.39	0.205	0.545	0.008	Mha
54 0.0552	0.00	25 -0.4113	0.865	493 0.437	1.14	60 2.1504	1.062	465 0.698	1.481	142 0.50	0.248	920 0.683	0.012	005 Mha
36	0.00	0.00	177	991	814	12	089	837	819	397	728	035	935	015
0.0704	0.00	-0.5063	0.772	0.237	1.21	2.8020	1.286	0.775	1.450	0.44	0.331	0.328	0.019	Mha
59	00	00	045	102	881	79	408	980	649	260	540	790	738	020
0.2151	0.00	-0.4202	0.750	0.188	1.30	1.3098	0.965	0.394	1.516	0.25	0.541	0.281	0.086	Mha
59	0	00	801	562	430	25	509	267	102	476	760	159	628	023
0.0390	0.00	-0.6604	0.458	0.090	0.62	2.4272	0.726	0.616	0.702	0.43	0.138	0.103	0.004	Mha
23	00	00	542	012	482	63	412	876	592	720	145	642	433	030
0.0293	0.00	-0.4572	0.722	0.410	0.90	2.2993	0.903	0.722	1.145	0.34	0.163	0.564	0.005	Mha
71	000	00	228	194	297	94	334	399	762	304	480	508	476	032
0.0359	0.00	-0.5014	0.696	0.391	0.87	2.1132	0.782	0.654	1.091	0.32	0.156	0.524	0.005	Mha
09	000	00	579	104	493	41	477	594	751	184	982	421	151	039
0.0613	0.00	-0.4848	0.787	0.261	1.19	3.1103	1.454	0.874	1.447	0.48	0.300	0.391	0.017	Mha
21	000	00	414	854	438	37	403	820	295	045	472	509	434	040
0.0476	0.00	-0.5244	0.719	0.261	1.01	2.9339	1.127	0.841	1.224	0.46	0.221	0.368	0.010	Mha
19	000	00	579	088	112	41	891	348	446	183	633	707	000	045
0.0668	0.00	-0.4185	0.859	0.336	1.26	2.4556	1.231	0.747	1.586	0.37	0.308	0.546	0.019	Mha
76	000	00	120	857	062	98	975	703	003	493	568	499	010	050

Tableau 4. 1: Tableau des paramètres de masses malignes 3D

F14	F13	F12	F11	F10	F9	F8	F7	F6	F5	F4	F3	F2	F1	
0.02 95	0.00 00	-0.4478	0.792 598	0.475 681	0.992 002	2.189 725	0.966 819	0.706 424	1.283 422	0.305 880	0.18 224	0.70 087	0.007 128	Mha 012
0.04 793	0.00 00	-0.4574	0.803 431	0.331 971	1.134 978	2.835 996	1.278 636	0.832 299	1.412 867	0.432 344	0.26 362	0.48 215	0.012 796	Mha 015
0.05 010	0.00 000	-0.5043	0.713 377	0.313 024	0.947 681	2.749 270	1.037 714	0.798 277	1.168 148	0.418 770	0.19 525	0.42 256	0.007 583	Mha 020
0.03 603	0.00 000	-0.4942	0.733 779	0.302 586	1.005 647	2.448 061	0.987 116	0.721 249	1.241 425	0.390 035	0.21 623	0.41 675	0.008 530	Mha 031
0.06 272	0.00 000	-0.4851	0.783 777	0.272 519	1.175 167	2.961 169	1.370 914	0.838 440	1.425 580	0.454 652	0.30 162	0.38 150	0.016 453	Mha 040
0.03 265	0.00 00	-0.4360	0.811 522	0.441 640	1.035 336	2.092 550	0.988 519	0.708 281	1.344 187	0.298 822	0.20 476	0.66 079	0.008 698	Mha 042
0.10 152	0.00 00	-0.5871	0.731 865	0.192 229	1.225 397	3.469 355	1.497 575	0.890 705	1.389 298	0.511 449	0.36 695	0.24 765	0.026 321	Mha 045
0.13 156	0.00 000	-0.5623	0.769 042	0.231 199	1.300 817	3.792 109	1.735 988	0.960 983	1.494 056	0.527 828	0.41 761	0.29 764	0.036 787	Mha 047
0.14 049	0.00 000	-0.5889	0.742 068	0.207 229	1.277 032	3.859 788	1.792 119	0.961 589	1.446 808	0.539 504	0.42 267	0.25 985	0.039 447	Mha 049
0.13 452	0.00 000	-0.5914	0.720 501	0.173 570	1.249 694	3.682 526	1.735 596	0.941 939	1.407 794	0.519 493	0.39 772	0.22 241	0.034 080	Mha 050

Tableau 4. 1: Tableau des paramètres de masses bénignes 3D

F14	F13	F12	F11	F10	F9	F8	F7	F6	F5	F4	F3	F2	F1	Mha
0.3115 18	0.000 000	-0.5796	0.651 358	0.14 365	1.077 546	3.112 771	3.112 566	0.820 732	1.216 320	0.420 224	0.556 806	0.170 157	0.127 433	Mha 012
0.0919 54	0.000 00	-0.683	0.613 587	0.11 137	1.009 459	3.208 524	1.119 253	0.835 536	1.106 155	0.530 217	0.301 293	0.133 621	0.020 990	Mha 015
0.1029 13	0.000 00	-0.667	0.602 705	0.10 573	0.962 861	3.261 108	1.243 689	0.847 073	1.063 294	0.536 337	0.282 427	0.127 184	0.019 419	Mha 020
0.1703 12	0.000 000	-0.5556	0.694 256	0.14 235	1.148 129	3.288 549	2.154 688	0.869 403	1.288 029	0.500 356	0.414 531	0.189 063	0.051 351	Mha 030
0.3108 61	0.000 000	-0.4679	0.663 848	0.14 983	1.170 731	2.007 491	3.333 333	0.550 562	1.318 255	0.312 720	0.626 217	0.194 757	0.147 603	Mha 040
0.0331 35	0.000 000	-0.4365	0.807 089	0.39 754	1.071 285	2.469 028	1.146 559	0.768 808	1.379 174	0.370 098	0.218 734	0.606 202	0.009 669	Mha 080
0.0561 80	0.000 000	-0.4135	0.851 633	0.36 499	1.190 627	2.351 194	1.294 382	0.730 495	1.530 110	0.368 239	0.285 843	0.570 787	0.016 266	Mha 100
0.0405 41	0.000 000	-0.4554	0.797 545	0.38 563	1.067 993	2.643 427	1.110 360	0.802 749	1.344 228	0.390 171	0.219 369	0.567 568	0.009 501	Mha 160
0.0340 63	0.000 000	-0.4715	0.766 130	0.39 218	0.990 032	2.415 317	1.012 166	0.744 948	1.256 753	0.358 774	0.193 431	0.564 477	0.007 686	Mha 200
0.0389 11	0.000 000	-0.4692	0.758 234	0.39 978	0.966 847	2.238 795	0.953 307	0.702 046	1.235 355	0.344 004	0.186 641	0.569 390	0.007 161	Mha 300

Tableau 4. 3: Tableau des paramètres de masses bénignes 2D

F14	F1	F12	F11	F10	F9	F8	F7	F6	F5	F4	F3	F2	F1	Mha
0.050	0.0	-0.4776	0.756	0.287	1.059	2.663	1.186	0.76	1.313	0.425	0.241	0.409	0.01	012
077	00		455	111	720	075	006	808	114	202	347	263	102	012
0.033	0.0	-0.4379	0.810	0.470	1.025	2.128	0.972	0.70	1.329	0.294	0.192	0.711	0.00	035
398	00		167	660	410	737	405	995	435	995	289	070	807	035
0.033	0.0	-0.4077	0.865	0.501	1.099	2.320	1.173	0.77	1.451	0.309	0.218	0.789	0.01	060
091	00		322	560	541	993	598	761	304	563	865	460	008	060
0.030	0.0	-0.4287	0.825	0.472	1.046	2.401	1.124	0.78	1.366	0.335	0.201	0.719	0.00	130
746	00		264	798	660	892	643	034	237	423	889	495	856	130
0.028	0.0	-0.4236	0.833	0.470	1.070	2.411	1.139	0.78	1.396	0.335	0.207	0.729	0.00	140
848	00		712	669	769	971	688	547	516	850	658	912	915	140
0.119	0.0	-0.3168	0.915	0.350	1.682	2.941	2.028	0.88	2.102	0.436	0.560	0.607	0.05	250
862	00		264	299	902	240	483	708	354	340	172	085	848	250
0.043	0.0	-0.4351	0.829	0.470	1.065	2.517	1.138	0.80	1.375	0.340	0.211	0.706	0.00	260
147	00		662	846	233	612	379	610	355	660	372	819	927	260
0.033	0.0	-0.4222	0.832	0.481	1.047	2.339	1.143	0.58	1.197	0.379	0.286	0.200	0.01	270
174	00		898	905	426	220	270	844	747	607	845	734	720	270
0.030	0.0	-0.4295	0.825	0.500	1.031	2.396	1.119	0.79	1.351	0.324	0.190	0.770	0.00	300
541	00		337	701	165	312	287	167	618	848	612	373	817	300
0.054	0.0	-0.4503	0.808	0.336	1.130	2.966	1.345	0.86	1.414	0.441	0.255	0.504	0.01	350
142	00		064	783	688	261	137	780	182	011	695	970	293	350

Tableau 4. 4: Tableau des paramètres de masses malignes 2D

Nous remarquons que le paramètre de **Information sur la corrélation2 (f13)** nous donne un résultat nul sur la plus part des images de base des données étudier alors nous l’enlevons et nous ajoutons le paramètre qui est la moyenne de vecteur des paramètres.

Mha 025	Mha 022	Mha 020	Mha 018	Mha 015	Mha 012	Mha 009	Mha 006	Mha 003	Mha 001
10.129	7.720	8.969	9.831	9.831	8.213	9.821	7.839	9.603	10.129
la moyenne de vecteur des paramètres									

Tableau4. 5:Tableau des paramètres de masses bénignes 2D après l’amélioration.

Mha 150	Mha 120	Mha 114	Mha 100	Mha 066	Mha 044	Mha 030	Mha 015	Mha 005	Mha 001
9.565	8.948	10.659	10.50	8.035	9.153	8.926	8.483	9.134	9.800
la moyenne de vecteur des paramètres									

Tableau4. 6:Tableau des paramètres de masses malignes 2D après l’amélioration.

Mha 025	Mha 022	Mha 020	Mha 018	Mha 015	Mha 012	Mha 009	Mha 006	Mha 003	Mha 001	
7.939	9.064	4.532	6.432	7.094	8.543	4.517	3.711	10.872	10.129	la moyenne de vecteur des paramètres

Tableau4.7 : Tableau des paramètres de masses bénignes 3D après l'amélioration.

Mha 150	Mha 120	Mha 114	Mha 100	Mha 066	Mha 044	Mha 030	Mha 015	Mha 005	Mha 001	
11.561	11.396	10.434	10.239	9.950	10.745	10.320	10.177	9.099	9.172	la moyenne de vecteur des paramètres

Tableau4.8 : Tableau des paramètres de masses malignes 3D après l'amélioration.

La mesure de ces descripteurs, nous permet de réaliser des graphes statistiques, afin de voir leur influence sur les différentes masses étudiées.

Nous montrons à cet effet (figures 4.1 ; 4.2 ; 4.3 ; 4.4) à six paramètres qui sont considérés comme étant les plus utilisés et les plus pertinents [HMA, 09] tel que la variation de l'énergie, de l'entropie, de la corrélation, du contraste, de la variance et de la déférence inverse moment, suivant les masses bénignes et malignes en 2D et en 3D.

Nous remarquons que les valeurs des paramètres texturaux ne varient pas seulement selon le type de la tumeur, mais ils varient aussi selon la méthode appliquée pour calculer les vecteurs des paramètres.




Figure4. 1: Influence des caractéristiques sur des masses malignes 3D.




Figure4. 2: Influence des caractéristiques sur des masses bénignes 3D.

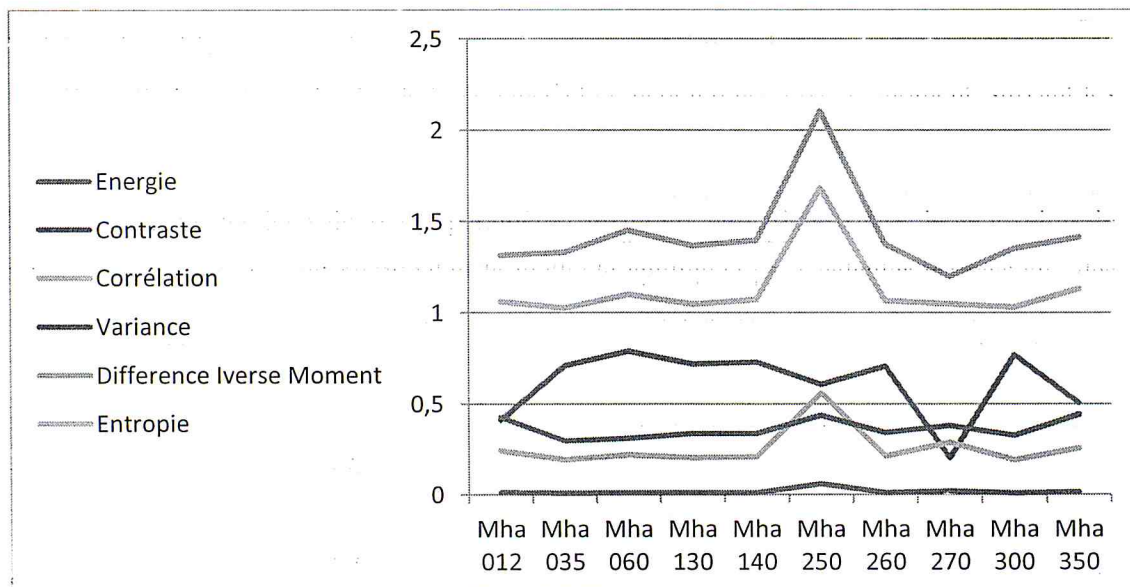


Figure4. 3: Influence des caractéristiques sur des masses malignes 2D.




Figure4. 4: Influence des caractéristiques sur des masses bénigne 2D.

4.3 Classification

L'objectif de cette partie est de faire l'analyse de l'influence des attributs de texture dans la classification automatique et leur efficacité à distinguer les tumeurs cérébrales malignes et bénignes. Des résultats comparatifs avec pourcentage de taux de classification pour les méthodes d'extraction des attributs que nous avons utilisé, a été montrer dans le tableau suivant pour GLCM et GLCM amélioré (qui été calculé à l'aide de treize paramètres de M. Haralick et le paramètre la Moyenne du vecteur de paramètres).

Méthode	Fonction de Kernal	sensibilité	spécificité	Taux de classification
GLCM 2D	Polynomial	85%	7%	84.58%
	RBF	85.7%	7.2%	84.85%
GLCM 2D amélioré	Polynomial	89%	7.5%	88.89%
	RBF	89%	7.5%	88.89%
GLCM 3D	Polynomial	89.56%	10%	89.23%
	RBF	89.56%	10.3%	89.29%
GLCM 3D amélioré	Polynomial	90.89%	11%	89.90%
	RBF	90.89%	11%	89.90%

Tableau 4.9 : Taux de classification pour chaque méthode d'extraction de caractéristiques.

Nous remarquons que le taux de classification avec le noyau RBF est presque égal aux taux de classification avec le noyau polynomial, et la meilleure performance de classification a été obtenue par la méthode de GLCM 3D à eu 89,90 % de précision tandis que l'ensemble GLCM 3D et GLCM 2D amélioré ont eu respectivement 89.29% et 88.89% de taux de classification.

L'histogramme de La précision de classification pour le noyau RBF et polynomial sont représentés respectivement dans la figure 4.5 et figure 4.6.




Figure4. 5: Histogramme de La précision de classification pour le noyau RBF.

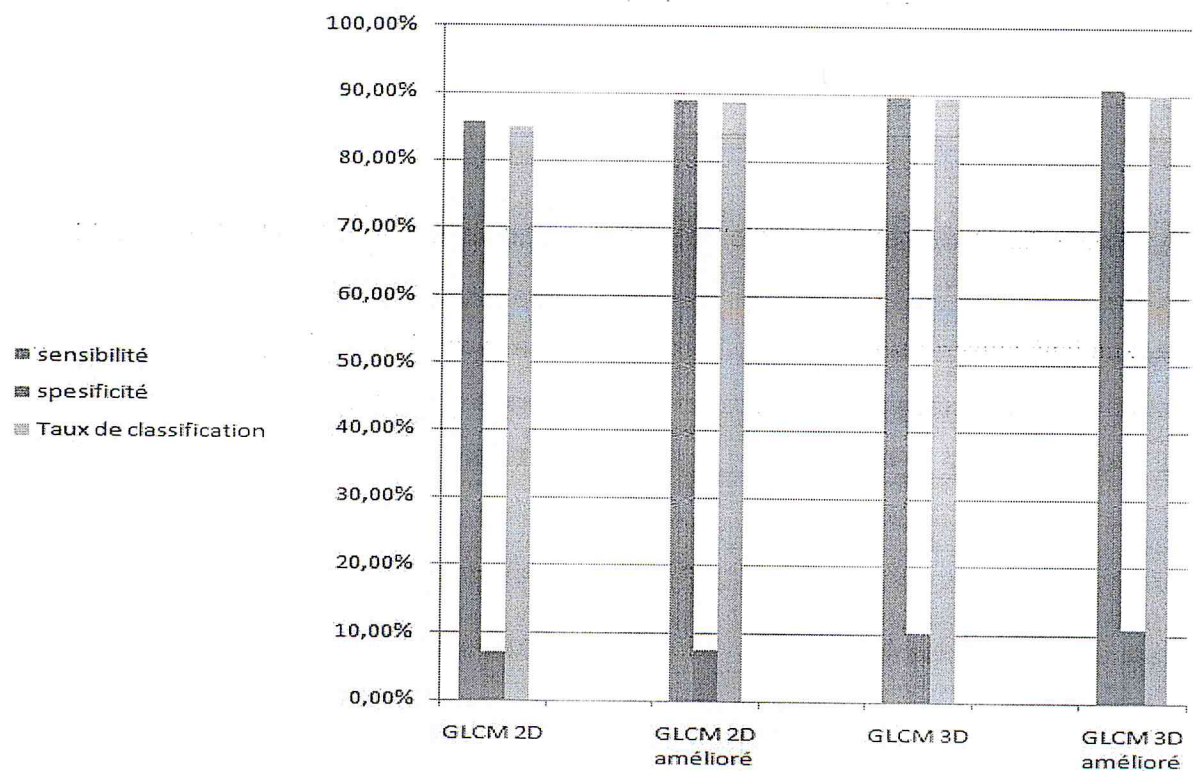


Figure4. 5: Histogramme de La précision de classification pour le noyau polynomial.

A partir des figures 4.5 et 4.6, nous remarquons que les pourcentages de la précision, spécificité et sensibilité avec le noyau RBF et le noyau polynomiale dans tous les méthodes d'extraction des paramètres ont presque des même valeurs, et la meilleure performance est réalisée par GLCM 3D amélioré avec les paramètres de performance sont égaux à 90.89% de sensibilité, 11 % pour la spécificité et la précision de la classification est donc de 89.90%. Ce qui signifie que nous avons un très bon taux de classification.

Nous remarquons aussi que les résultats du paramètre de performance de sensibilité sont très bas, et c'est à cause du déséquilibre de la base de données (BRATS 2014) que nous avons utilisé, elle contient 188 images malignes et seulement 25 images bénignes.

Conclusion

Nous avons présenté dans ce chapitre l'application des méthodes d'extraction d'attribut et le calcul de ces derniers que ce soit par la méthode GLCM 2D ou la méthode GLCM 3D. Nous avons présenté aussi les résultats obtenues par la classification de SVM. Nous avons démontré que la classification de texture basée sur la méthode GLCM 3D a eu le meilleur taux de classification. 89.13%.

Conclusion général

La recherche médicale progresse rapidement, révélant dans la foulée de nombreux nouveaux dés en matière de santé : parmi eux la capacité de diagnostiquer automatiquement une tumeur cérébrale dans ce début et pouvoir savoir si c'est une tumeur ou non afin que le patient ait une chance de survie.

La nécessité d'un système automatique de classification évaluant si une image d'entrée IRM du cerveau représente une tumeur cérébrale maligne ou bénigne augmente de plus en plus chaque jour.

L'objectif de notre travail est l'extraction à partir des images IRM, d'une certaine information pertinente de la texture par deux méthodes d'extraction existante dans la littérature : la méthode de matrice de cooccurrence 2D (GLCM 2D) et la méthode de matrice de cooccurrence 3D (GLCM 3D) qui été appliquée rarement auparavant sur les images médicales ou encore sur les images IRM.

Ces attributs texturaux permettent de caractériser les images de notre base de données et de distinguer et classifier les tumeurs malignes et bénignes.

Le travail présenté dans ce mémoire a révélé des résultats encourageants qui indiquent que le système de la classification des images cérébrales proposé a réussi à classifier la tumeur. Comme ce système détecte cette dernière après la comparaison entre GLCM 2D et GLCM 3D avec (la sensibilité >90.89% pour classification a travers GLCM 3D tandis que la sensibilité >90% pour la classification a travers GLCM 2D), il peut être alors utilisé GLCM 3D pour aider les neurologues en leur fournissant une opinion d'orientation afin qu'ils puissent poser un diagnostic avec certitude.

La première étape a été consacrée au contexte médical de notre travail qui présente la description des notions essentielles liées à l'anatomie du cerveau, et les principales régions cérébrales qui ont une importance dans l'examen et le diagnostic clinique, ainsi que nous avons présenté la technique d'imagerie par résonance magnétique nucléaire IRM.

Dans la deuxième étape, nous avons passé en revue l'état de l'art les différentes méthodes d'extractions d'attributs texturaux à partir des images IRM cérébrales tout en se focalisant sur les méthodes (GLCM 2D, GLCM 3D). Et nous avons présenté aussi les méthodes de classification qui peut être utilisé dans la tâche de classification des tumeurs.

La troisième étape constitue l'application des méthodes de la cooccurrence (2D et 3D) sur notre base de données. Au début, nous avons commencé par une présentation de la base de données BRAST 2014 puis nous avons présenté la méthodologie du travail accompli. Et comprend aussi la partie classification dont laquelle nous avons donné les aspects théoriques du classificateur à vaste marge SVM suivi par les notions de base et les fondements mathématiques de ce classificateur.

Dernière partie de notre travail nous avons implémenté ce travail qui permet une classification rapide et facile d'une image cérébrale et permet aussi de visualiser les résultats pour chaque méthode.

A l'issue de ce travail, quelques perspectives sont dégagées comme l'utilisation :

1. Equilibrer le nombre des images bénignes et malignes dans la base de données.
2. De ce travail pour une nouvelle base nationale algérienne.
3. Ajouter la forme comme approche d'extraction d'attribut.
4. Et pourquoi pas aussi une réalisation de ce classificateur sur carte FPGA au lieu d'avoir un système embarqué.

Référence:

[KML, 15] K. Hoang-Xuan, M. Peyre et L. Feuvret, <http://www.fondation-arc.org/Les-cancers-du-cerveau/le-cerveau-et-les-differents-types-de-cancers-du-cerveau.html>(2015).

[SCA, 16] Société canadienne du cancer, Anatomie et physiologie de l'encéphale et de la moelle épinière, <http://www.cancer.ca/fr-ca/cancer-information/cancer-type/brain-spinal/anatomy-and-physiology/?region=on>(2016).

[VUM ,16] Vulgaris medical, cerveau, <http://www.vulgaris-medical.com/encyclopedie-medicale/cerveau>(2016).

[CNA, 10] C.Nadine Étude anatomique de l'encéphale, <http://nadcou.cegep-rdl.qc.ca/biogen/labo/labocenceph.pdf> (2010).

[BGO, 10] B. Boutillier G. Outrequin, Anatomie, <http://www.anatomie-humaine.com/Le-Cervelet.html> (2010).

[FSC, 16] Futura Sciences, Futura Santé, cervelet, <http://www.futura-sciences.com/magazines/sante/infos/dico/d/biologie-cervelet-13719/>(2016).

[PAS, 16] Passeport Sante, une tumeur cérébrale (cancer du cerveau), http://www.passeportsante.net/fr/Maux/Problemes/Fiche.aspx?doc=tumeur-cerebrale-cancer-cerveau_pm(2016).

[HDO, 10] H. Dominique, Tumeur, <http://www.docteurcliv.com/encyclopedie/tumeur.aspx> (2010).

[INC, 16] Institut national du cancer, tumeur de cerveau, Symptomes, <http://www.e-cancer.fr/Patients-et-proches/Les-cancers/Tumeurs-du-cerveau/Symptomes>(2016).

[ART, 11] Association pour la recherche sur les tumeurs cérébrales, les tumeurs cérébrales, <http://www.artc.asso.fr/la-recherche-et-l-information-medicale/le-cerveau-et-les-tumeurs/les-tumeurs-cerebrales>(2011).

[ESV, 16] Eureka santé par vidal, symptômes et évolution des tumeurs du cerveau, <http://eukasante.vidal.fr/maladies/cancers/tumeurs-cerveau.html?pb=symptomes-evolution>(2016).

[16] Item 146, Tumeurs intracrâniennes.pdf.

[FJA, 10] F. Jauzein, Généralités sur l'IRM, http://acces.ens-lyon.fr/acces/ressources/neurosciences/methodes_etude_cerveau/irm_atomique_et_fonctionnelle/irm_generalites/generalites-sur-irm(2010).

[JME, 14] J.Meder, IRM cérébrale rachidienne & médullaire, <http://irmparis14.fr/irm-cerebral/>(2014).

[BAL, 11] B.Ali, « mise en œuvre d'une technique automatique de segmentation de sillons corticaux », Magister en Informatique, Université Abou-Bakr Belkaid-Tlemcen, 2011.

[ZHA, 08] Z. Hakima, « Clustering par fusion floue de données appliqué à la segmentation d'image IRM », Mémoire de magistère, Université M'hamed Bougara de Boumerdas, 2008.

[ZEF] Z. Fatima, « détection de lésion cérébrale en utilisant L'IRM de diffusion, mémoire de magistère », Université Mouloud Mammeri Tizi-Ouzou.

[KNZ, 15] K. Nadjat, Z. Feriel, « Extraction des paramètres caractéristiques des images IRM pour la classification des tumeurs cérébrales », mémoire de master, université de Boumerdas, 2015.

[IDC, 16] Institut national du cancer, troubles localisés, [http://www.e-cancer.fr/Patients-et-proches/Les-cancers/Tumeurs-du-cerveau/Symptomes/Troubles-localises\(2016\)](http://www.e-cancer.fr/Patients-et-proches/Les-cancers/Tumeurs-du-cerveau/Symptomes/Troubles-localises(2016)).

[BDL, 15] B. Alexandre, D. Lilian, analyse de texture par fourier, [http://www.tsi.telecom-paristech.fr/pages/enseignement/ressources/beti/textures_Fourier/texture.html\(2015\)](http://www.tsi.telecom-paristech.fr/pages/enseignement/ressources/beti/textures_Fourier/texture.html(2015)).

[HSD, 73] R. Haralick, K. Shanmugan, et I. Dinstein, textural features for image classification (1973), p.610–621.

[AFA, 13] A. Fazia, « Extraction de la composante texturée d'une image », thèse de magister, université Mouloud Mammeri tizi ouzou, 2013.

[HLO, 13] H. lotfi, « Contribution à l'analyse de textures de radiographies osseuses pour le diagnostic précoce de l'ostéoporose », thèse de doctorat, école doctorale mathématique, physique, informatique théorique et ingénierie du système, 2013.

[GAS, 13] G. Saliha. « Décomposition modale empirique: application a l'analyse de texture », thèse de magister, université mouloud mammeri tizi ouzo, 2013.

[PLU, 09] P. Ludovic, Outils et méthodes d'analyse d'images 3D texturées : Application à la segmentation des images échographiques, thèse de doctorat, université François Rabelais de tours, 2009.

[LMA] L. Malha. « Segmentation d'image textures à partir des attributs fractals », mémoire de magister, Université Mouloud Mammeri Tizi-Ouzou.

[GMI] G.Michele, "Analyse de textures", <http://webcache.googleusercontent.com/search?q=cache:http://m.i.c.h.e.l.e.free.fr/Cours+Texture.pdf>.

- [JWO, 72] J. Woods, two-dimensional discrete Markovian fields(1972), p. 232-240.
- [HMA, 09] H. Majdoulyne, « Extraction de caractéristique de texture pour la classification d'images satellitaires », thèse doctorat, université de Toulouse présenter, 2009.
- [BWA, 14] B. Wafaa, « Utilisation des attributs de texture pour la segmentation par classification pixellaire des images microscopiques », mémoire de master en informatique, université Abou Bakr Belkaid– Tlemcen, 2014.
- [ASN, 12] A.Dhara, S.Mukhopadhyay et N. Khandelwal, 3D texture analysis of solitary pulmonary nodules using co-occurrence matrix from volumetric lung CT Images, https://www.researchgate.net/publication/233114063_3D_Texture_Analysis_of_Solitary_Pulmonary_Nodules_Using_Co-occurrence_Matrix_from_Volumetric_Lung_CT_Images(2012).
- [TAP, 10] T. Pham, « Optimization of texture feature extraction algorithm», thèse master, Delft University of Technology, 2010.
- [CLA, 06] C.laurent, « contextualisation, visualisation et évaluation en apprentissage non supervisé », thèse de doctorat, université Charles de Gaulle, 2006.
- [SNB, 13] S.Nebti, « Reconnaissance de caractères manuscrits par intelligence collective », thèse de doctorat, Université Ferhat Abass-Sétif , 2013.
- [LLA, 06] L. LAOUAMER, « Approche exploratoire sur la classification appliquée aux images », thèse, Université du Québec, 2006.
- [DSR, 13] D.SELVARAJ, R.DHANASEKARAN, A Review on Tissue Segmentation and Feature Extraction of MRI Brain images (2013), p. 2229-3345.
- [AME, 09] A .Mellakh, « Reconnaissance des visages en conditions dégradées », thèse de doctorat, Institut National des Télécommunications, 2009.
- [LBO, 14] L. Houria, B. Oumessàd, « Classification Des Feuilles de Plantes à Base de Moment de Hu », thèse de master academique, Université Kasdi Marbah Ouragla, 2014.
- [SID, 09] S. Idbraim, « Méthodes d'extraction de l'information spatiale et de classification en imagerie de télédétection : Applications à la cartographie thématique de la région d'Agadir (Maroc) », thèse de doctorat, Université Med V-Agdal & Université Paul Sabatier de Toulouse, 2009.
- [IEL, 11] I. Elhassani, « SVR avec boosting pour la prévision à long terme », projet de fin d'études, école polytechnique de l'université de tours, 2011.
- [WIK, 15] WikiStar, Machines à vecteurs supports, <http://www.math.univ-toulouse.fr/~besse/Wikistat/pdf/st-m-app-svm.pdf>(2015).

[SAI, 13] S. Imandoust , al. Int, application of K-Nearest neighbor (KNN) approach for predicting economic events: theoretical background(2013), p.605-610.

[KAZ, 13] S. Karamizadeh, S. Abduliah , A.Manaf, M. Zamani et A.Hooman, An Overview of Principal Component Analysis (2013), p. 173-175.

[MAA, 14] M.Atteib, M. Adoum , « introduction aux SVM (Support Vector Machines), applications aux données médicales », thèse de master Ingénierie Mathématiques , 2014.

[AHK, 14] A. El-Dahshan, H. Mohsen, K. Revett et M. Salem , Computer-aided diagnosis of human brain tumor through MRI : A survey and a new algorithm, https://www.researchgate.net/publication/261715655_Computer-aided_diagnosis_of_human_brain_tumor_through_MRI_A_survey_and_a_new_algorithm(2014).

[MBE, 13] M. Belahcene, « Authentification et identification en biométrie », thèse de doctorat, Université Mohamed Khider Biskra, 2013.

[MFA, 10] M.Faouzi. « Les Supports Vecteurs Machines (SVM) pour la reconnaissance des caractères manuscrits arabes », thèse magister, université Mohamed Khider BISKRA, 2010.

[RHA, 79] R. Haralick, Statistical and structural approaches to texture (1979), p. 0018-9219.

[IMA, 12] N. Imane, développement d'outil logiciel d'annotation d'images médicales, utilisant les méthodes d'indexation par descripteurs invariants de contenus, thèse de Magistère, Université de Abou Bakr Belkaid, Tlemcen, 2012.

[GOD, 06] S. Godbole, Inter-class relationships in text classification, thèse de Doctorat, Indian institute of technologie, India, 2006.

[MAT, 12] R. Manavalan, K. Thangavel. evaluation of textural feature extraction from GRLM for prostat cancer TRUS medical images(2012), international journal of advances in engineering & technology, p. 401-409.

[DGH, 13] K. Deepack, K.Gokul, R .Hinduja, S. Rajkumar , An efficient approach to predict tumor in 2D brain image using classification techniques, International Conference on Information Communication and Embedded Systems (ICICES), 2013

[DGH, 00] S. Aksoy, R. Haralick, Feature Normalization and Likelihood-based Similarity Measures for Image Retrieval (2000), pp.98195-2500.

[KHA, 11] S.Khadidja. Application des codes correcteurs d'erreurs Reed Muller, Mémoire de Master en Informatique, université Abou Bakr Belkaid– Tlemcen, 2011.

[DAV, 09] L. David, logicielles pour le traitement d'images, <http://www7.inra.fr/vh/pflcepia/uploads/docs/softsImage.pdf> (2009).

[AMI, 15] S.Amin. Déploiement d'application OpenCv : de la compilation à la diffusion, 2015.

[RSA, 14] K. Redouan, F. Sidi Mohamed, S. Abderrah-mane, T. Rajaa, T.Mustapha, A Combined method of fractal and GLCM featur for MRI and CT Scan images classification, Signal & Image Processing : An International Journal (SIPIJ) Vol.5, No.4,2014.

[BDD, 14] Bade de données BRATS , www.virtualskeleton.ch/BRATS/Start2014.