

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE  
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE



ÉCOLE NATIONALE POLYTECHNIQUE  
DÉPARTEMENT ÉLECTRONIQUE

MÉMOIRE DE PROJET DE FIN D'ÉTUDES POUR L'OBTENTION DU DIPLÔME  
D'INGÉNIEUR D'ÉTAT EN ÉLECTRONIQUE

---

# Combinaison de classifieurs basée sur les transformées multi-échelles pour la classification de tumeurs cérébrales

---

**BOUREGA Khadidja Yasmine**

**MAMARELI Basma**

Sous la direction de Mme. Nesrine BOUADJENEK

Présenté le 17/09/2020

*Composition du Jury :*

Président	M. Sid-Ahmed BERRANI	Dr	ENP
Encadreur	Mme. Nesrine BOUADJENEK	Dr	ENP
Examinatrice	Mme. Nour El Houda BENALIA	Dr	ENP

ENP 2020



RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE  
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE



ÉCOLE NATIONALE POLYTECHNIQUE  
DÉPARTEMENT ÉLECTRONIQUE

MÉMOIRE DE PROJET DE FIN D'ÉTUDES POUR L'OBTENTION DU DIPLÔME  
D'INGÉNIEUR D'ÉTAT EN ÉLECTRONIQUE

---

# Combinaison de classifieurs basée sur les transformées multi-échelles pour la classification de tumeurs cérébrales

---

**BOUREGA Khadidja Yasmine**  
**MAMARELI Basma**

Sous la direction de Mme.Nesrine BOUADJENEK

Présenté le 17/09/2020

*Composition du Jury :*

Président	M. Sid-Ahmed BERRANI	Dr	ENP
Encadreur	Mme. Nesrine BOUADJENEK	Dr	ENP
Examinatrice	Mme. Nour El Houda BENALIA	Dr	ENP

ENP 2020

**ملخص** --- إن تصنيف أورام الدماغ يشكل مهمة بالغة الأهمية في تقييم الأورام واتخاذ قرار العلاج استناداً إلى أنواعها. وفي هذا العمل، نقترح نموذجاً جديداً لنظام التشخيص التلقائي للأورام الدماغية الذي يعتمد على صور التصوير بالرنين المغناطيسي. ويتألف النظام من أربع خطوات، هي: المعالجة المسبقة، واستخراج الميزات باستخدام ثلاثة تحويلات متعددة المقاييس وتصنيف الصور وفقاً لأنواع مختلفة من أورام المخ باستخدام مصنف SVM، ومجموعة المصنفات المتوازية. وكجزء من هذا العمل، سنستخدم ثلاث مجموعات بيانات متاحة للجمهور لتقييم فعالية المنهجية المقترحة. ويحقق هيكل النظام المقترح أداءً كبيراً بدقة إجمالية تبلغ ١٠١ و ٣٣.٧٩ و ٢٠.٦٩ و ٩٢.٧٩ على التوالي للدراسات الأربع.

**الكلمات الأساسية:** ورم الدماغ، التصوير بالرنين المغناطيسي، SVM، التحويلات متعددة المقاييس، التعلم الآلي، استخراج الميزات، مجموعة المصنفات.

---

**Abstract** — Classification of brain tumors is a crucial task in assessing tumors and making decisions for suitable treatments based on their types. In this work, we propose a new model of automatic system diagnosing brain tumor from MRI images. The system consists of four steps, namely preprocessing, feature extraction using three multiscale transforms, classification of images according to the different types of brain tumors using a Support Vector Machine (SVM) classifier and parallel combination of classifiers. In this work, we will use three publicly available datasets to assess the efficiency of the proposed method. The proposed system structure achieves a significant performance giving 100%, 97.33%, 96.02% and 97.29% accuracy respectively for four studies.

**Keywords :** Brain tumor, Magnetic Resonance Imaging, SVM, multi-scale transforms, machine learning, feature extraction, classifiers combination.

---

**Résumé** — La classification des tumeurs cérébrales est une tâche cruciale pour évaluer les tumeurs et prendre une décision de traitement en fonction de leurs classes. Dans ce travail, nous proposons un nouveau modèle pour le système automatique de diagnostic de tumeur cérébrale à partir d'images IRM. Le système se compose de quatre étapes, à savoir le prétraitement, l'extraction des caractéristiques en utilisant trois transformées multi-échelles, la classification des images selon les différents types de tumeurs cérébrales à l'aide d'un classifieur Machine à vecteurs de support (SVM), et la combinaison parallèle de classifieurs. Dans le cadre de ce travail, nous utiliserons trois ensembles de données accessibles au public pour évaluer l'efficacité de la méthode proposée. La structure du système proposée atteint des performances significatives avec des précisions globales de 100%, 97.33%, 96.02% et 97.29% respectivement pour quatre études.

**Mots clés :** Tumeur cérébrale, imagerie par résonance magnétique, SVM, transformées multi-échelles, extraction de caractéristiques, combinaison de classifieurs.

## *Remerciements*

*Ce travail est l'aboutissement d'un dur labeur et de beaucoup de sacrifices ; nos remerciements vont d'abord au Créateur de l'univers qui nous a doté d'intelligence, de volonté et nous a maintenu en santé durant cette pandémie, pour réaliser ce modeste travail.*

*Nous tenons à remercier infiniment notre encadreur de mémoire Mme.Nesrine BOUADJENEK pour son accompagnement durant cette période et ses constantes orientations dans notre projet. Sa patience, ses conseils, son extrême amabilité et sa méthode de travail ont fait qu'on y arrive.*

*Nos remerciements et gratitude s'adressent aussi aux messieurs le président et les membres de jury d'avoir accepté d'examiner notre travail.*

*Nous tenons aussi à adresser nos remerciements à nos famille, et plus précisément à nos parents pour l'amour et le soutien constant qu'ils nous ont témoigné tout au long de notre parcours. Ce présent travail a pu voir le jour grâce à leur encouragement.*

*Nous voudrions exprimer notre reconnaissance envers les amis et collègues qui nous ont apporté leur support moral et intellectuel tout au long de cette démarche.*

*Enfin nous remercions tous ceux qui ont contribué de près ou de loin à l'aboutissement de ce travail.*

---

## Table des matières

---

**Table des figures**

**Liste des tableaux**

**Liste des acronymes**

<b>Introduction générale</b>	<b>13</b>
<b>1 Généralités sur la classification des tumeurs cérébrales : contexte clinique et état de l'art</b>	<b>15</b>
1.1 Introduction . . . . .	15
1.2 Les Tumeurs cérébrales . . . . .	16
1.2.1 Classification en grade : Gradation des tumeurs selon l'OMS . . . . .	16
1.2.2 Classification histologique : les différents types de tumeurs cérébrales . . . . .	16
1.3 L'imagerie par résonance magnétique . . . . .	20
1.3.1 Principe général de l'IRM . . . . .	20
1.3.2 Origine physique du signal IRM . . . . .	21
1.3.3 Principe de formation de l'image IRM . . . . .	22
1.3.4 Pondération et séquences des images IRM . . . . .	23
1.4 Classification automatique des tumeurs cérébrales . . . . .	24

1.4.1	Le pré-traitement . . . . .	25
1.4.2	L'extraction de caractéristiques . . . . .	26
1.4.3	La classification . . . . .	26
1.5	Résumé de l'état de l'art de la classification automatique des tumeurs cérébrales	27
1.6	Conclusion . . . . .	29
<b>2</b>	<b>Description des transformées multi-échelles pour l'extraction de caractéristiques et combinaison de classifieurs</b>	<b>30</b>
2.1	Introduction . . . . .	30
2.2	Pré-traitement . . . . .	31
2.2.1	Redimensionnement de la taille de l'image . . . . .	31
2.2.2	Filtre Gaussien . . . . .	32
2.2.3	Filtre médian . . . . .	33
2.2.4	Rehaussement de contraste . . . . .	33
2.3	Transformées multi-échelles . . . . .	34
2.3.1	Transformée en ondelette discrète . . . . .	34
2.3.2	Transformée de Gabor . . . . .	40
2.3.3	Transformée en Shearlet . . . . .	45
2.4	Extraction des caractéristiques . . . . .	47
2.4.1	Caractéristiques statistiques . . . . .	47
2.4.2	Caractéristiques de texture . . . . .	48
2.5	Les machines à vecteur de support (SVM) . . . . .	52
2.5.1	Architecture du SVM en multi-classe . . . . .	56
2.6	Combinaison de classifieurs . . . . .	56
2.6.1	Stratégies de Combinaison . . . . .	57
2.6.2	Types de Réponses fournies par un classifieur . . . . .	58
2.6.3	Règles de combinaison . . . . .	59
2.7	Conclusion . . . . .	61
<b>3</b>	<b>Expérimentation et résultats</b>	<b>63</b>
3.1	Introduction . . . . .	63
3.2	Données expérimentales utilisées . . . . .	63

3.2.1	Base de données Kaggle . . . . .	64
3.2.2	Base de données Figshare . . . . .	64
3.2.3	Base de données Rembrandt . . . . .	65
3.3	Critères d'évaluation . . . . .	67
3.4	Résultats des transformée multi-échelle pour la classification des tumeurs cérébrales . . . . .	69
3.4.1	Résultats de classification avec la transformée en ondelette discrète . . . . .	69
3.4.2	Résultats de classification avec la transformée de Gabor . . . . .	72
3.4.3	Résultats de la transformée en Shearlet . . . . .	75
3.5	Résultats de la combinaison de classifieurs . . . . .	78
3.6	Comparaison avec les résultats de l'état de l'art . . . . .	83
3.7	Conclusion . . . . .	84
	<b>Conclusion générale</b>	<b>86</b>
	<b>Bibliographie</b>	<b>88</b>

---

## Table des figures

---

1.1	Système nerveux central avec les différents types de cellules gliales. . . . .	17
1.2	Les méninges. . . . .	19
1.3	Emplacement de l'hypophyse. . . . .	19
1.4	Appareil d'acquisition d'images IRM. . . . .	20
1.5	Représentation des moments magnétiques macroscopique, de gauche à droite : État à l'équilibre, État pendant l'excitation . . . . .	22
1.6	FID d'un système complexe et sa transformée de Fourier. . . . .	23
1.7	Coupe axiale d'un cerveau humain avec 2 pondérations différentes. De gauche à droite : pondération T1, pondération T2. . . . .	24
1.8	Architecture d'un système automatique de classification de tumeurs cérébrales. .	25
2.1	Images IRM de tailles différentes avant et après le redimensionnement . . . . .	32
2.2	IRM cérébrale avant et après l'application du filtre Gaussien . . . . .	32
2.3	IRM cérébrale avant et après l'application du filtre médian . . . . .	33
2.4	Application du rehaussement de contraste sur une image IRM . . . . .	34
2.5	Décomposition de la TOD-2D . . . . .	36
2.6	TOD d'une IRM cérébrale sans tumeur en utilisant l'ondelette de Haar à 4 ni- veaux de décomposition . . . . .	36
2.7	Exemple d'ondelette Haar $\psi(t)$ . . . . .	37
2.8	Exemples d'ondelettes Daubechies $\psi(t)$ . . . . .	38

## Table des figures

---

2.9	Exemples d'ondelettes Symlets $\psi(t)$ .	38
2.10	Exemple d'ondelette Biorthogonale $\psi(t)$ .	39
2.11	Exemples d'ondelettes coifflet $\psi(t)$ .	39
2.12	Décomposition à 1 niveau d'une image IRM (a) en une imagerie d'approximation (b) et trois imageries de détails (c), (d) et (e) avec l'ondelette de Haar. La tumeur est localisée à l'intérieur du cercle rouge.	40
2.13	Filtre de Gabor dans le domaine spatial	41
2.14	Orientation du filtre	42
2.15	Fréquence centrale du filtre	42
2.16	Phase du filtre	43
2.17	Support temporel du filtre	43
2.18	Forme de l'enveloppe Gaussienne	43
2.19	Résultats d'application d'un banc de 40 filtres de Gabor sur une image IRM	44
2.20	Décomposition en Shearlet à trois niveaux.	46
2.21	Résultat de la décomposition en Shearlet à trois niveaux d'une image IRM.	46
2.22	Exemple de calcul de la matrice de cooccurrence pour $d = 1$ et $\theta=0$	49
2.23	Schéma résumant l'étape d'extraction de caractéristiques.	51
2.24	Principe de séparation du SVM	53
2.25	Choix de l'hyperplan optimal	54
2.26	Transformation d'espace	55
2.27	Schéma de combinaison séquentielle de classifieurs	57
2.28	Schéma de combinaison parallèle de classifieurs	58
2.29	Architecture du système multi-classifieurs proposée	61
3.1	Échantillons d'images IRM provenant de la base Kaggle, (a) cas sain, (b) cas tumoral	64
3.2	Représentation des images IRM montrant différents types de tumeurs dans différents plans	65
3.3	Exemple de cinq différents types d'images cérébrales axiales de gliomes (a) astrocytomes diffus, (b) astrocytomes anaplasiques, (c) glioblastomes, (d) oligodendrogliomes grade II et (e) oligodendrogliomes grade III.)	66
3.4	Différents grades de gliome (a) grade II, (b) grade III et (c) grade IV	66

3.5	Décomposition en quatre niveaux d'une IRM avec la transformée en ondelette discrète type Haar. . . . .	69
3.6	Matrices de confusion des quatre études obtenues avec la transformée en ondelette discrète . . . . .	71
3.7	Décomposition d'une image IRM classe astrocytome anaplasique avec le filtre de Gabor . . . . .	73
3.8	Matrices de confusion des quatre études obtenues avec la transformée de Gabor .	74
3.9	Décomposition d'une IRM cérébrale avec la transformée en Shearlet . . . . .	75
3.10	Matrices de confusion des quatre études obtenues avec la transformée en Shearlet	76
3.11	Comparaison du taux de bonne classification entre les trois systèmes . . . . .	77
3.12	Combinaison de classifieurs VS meilleur système individuel . . . . .	83

---

## Liste des tableaux

---

1.1	Les différents grades des tumeurs cérébrales. . . . .	17
1.2	Résultats de l'état de l'art pour la classification des tumeurs cérébrales. . . . .	29
3.1	Distribution des données par classe pour la base de données Figshare . . . . .	65
3.2	Matrice de confusion binaire . . . . .	67
3.3	Performances de la TOD-2D . . . . .	71
3.4	Performances de la transformée de Gabor . . . . .	74
3.5	Performances de la transformée en Shearlet . . . . .	76
3.6	Résultats de la combinaison de classifieurs pour la première étude (Kaggle) . . .	78
3.7	Résultats de la combinaison de classifieurs pour la deuxième étude (Figshare) . .	78
3.8	Résultats de la combinaison de classifieurs pour la troisième étude (Rembrandt) .	80
3.9	Résultats de la combinaison des classifieurs pour la quatrième étude (Rembrandt)	80
3.10	Comparaison des performances avec les travaux de la littérature pour la classification des tumeurs cérébrales . . . . .	83

---

## Acronymes

---

**BOW** Bag of Words. 27

**CNN** Convolutional Neural Networks. 27–29

**ELM** Extreme Learning Machine. 27

**FID** Free Induction Decay. 22, 23

**FN** Prédiction négative incorrecte. 67

**FP** Prédiction négative correcte. 67

**GA** Algorithmes génétiques. 28, 29

**GLCM** Gray Level Co-occurrence Matrix. 26, 27, 47–50, 70, 72, 87

**IRM** Imagerie par Résonance Magnétique. 15, 20–23, 25, 27–29, 31–33, 36, 44, 46, 64, 65, 69, 70, 72, 75, 78, 83, 84

**KNN** K-Nearest Neighbors. 27

**ML** Machine Learning. 24

**MRN** Résonance Magnétique Nucléaire. 20–23

**OMS** Organisation Mondiale de la Santé. 16

**SVM** Support Vector Machine. 27–29, 31, 52–56, 69, 78, 82, 84, 87

**TE** Temps de'Echo. 23, 24

**TOD** Transformée en Ondelette Discrète. 27, 35, 82

**TR** Temps de répétition. 23, 24

**VN** Prédiction positive incorrecte. 67

**VP** Prédiction positive correcte. 67

---

## Introduction

---

L'ampleur et la complexité croissante des connaissances médicales, telles que les données physiopathologiques ou les moyens diagnostiques et thérapeutiques, obligent le médecin à gérer plus d'informations pour soigner un patient. Ainsi, le développement de systèmes d'aide à la décision, simulant le raisonnement médical, est de plus en plus recherché de nos jours pour assister le praticien [1].

Les tumeurs cérébrales sont une maladie très fréquente et en croissance remarquable dans le monde. Elles touchent beaucoup plus les hommes et les personnes âgées de plus de 50 ans. La croissance incontrôlée des tissus dans le cerveau humain provoque une tumeur cérébrale. Il en existe deux types ; bénigne et maligne. Les tumeurs non cancéreuses dites bénignes, ne réapparaissent pas une fois enlevées contrairement aux tumeurs cancéreuses dites malignes, qui risquent de réapparaître parce que, des cellules cancéreuses pourraient s'être déjà propagées de la tumeur à d'autres parties du corps [2]. Il est important de trouver la tumeur dès que possible, alors qu'elle est plus petite et plus facile à traiter. Être atteint d'une tumeur cérébrale peut entraîner des complications sur la santé du patient, tels que le manque d'énergie, les crises d'épilepsie, la difficulté à parler ou à comprendre les mots, les troubles de la vue et de l'équilibre, la confusion et parfois même un coma [3].

Dans ce travail, nous proposons un système de classification de tumeurs cérébrales basé sur une combinaison de classifieurs. Ces classifieurs sont entraînés en utilisant trois transformées multi-échelle différentes à savoir ; la transformée en ondelette discrète, la transformée de Gabor et la transformée en Shearlet. Un tel système aspire à aider les médecins dans leurs routines cliniques à diagnostiquer une tumeur cérébrale selon son type et son grade. Les expérimentations ont été effectuées sur des images IRM (Imagerie par Résonance Magnétique) de trois bases de données standards à savoir Kaggle, Figshare et Rembrandt. Chaque transformée multi-échelle présente des points forts et des points faibles. Le domaine médical étant très sensible aux erreurs, et nécessite beaucoup de précision et de certitude, une combinaison de classifieurs est proposée afin

de diversifier l'information et d'améliorer ainsi les performances en obtenant des réponses plus fiables qui conduiront à des décisions objectives.

Ce mémoire est principalement organisé en trois chapitres :

Chapitre 1 : Présente le contexte médical, les travaux effectués, et les étapes constituant un système de classification automatique des tumeurs cérébrales.

Chapitre 2 : Concerne les transformées multi-échelles, la génération de caractéristiques et les stratégies de combinaison de classifieurs adoptées.

Chapitre 3 : Présente, discute et compare les résultats des tests effectués.

En dernier lieu, une conclusion générale et quelques perspectives sont présentés.

---

## Généralités sur la classification des tumeurs cérébrales : contexte clinique et état de l'art

---

### 1.1 Introduction

Malgré les avancées technologiques dans le domaine médical, et en particulier en imagerie médicale, l'étude du cerveau humain est un domaine difficile et reste un sujet de recherche d'actualité. D'où l'intérêt d'un système d'aide au diagnostic qui va aider le praticien en lui fournissant un deuxième avis pour prendre sa décision quant au type et au grade de la tumeur cérébrale pour une meilleure prise en charge du patient. Ce chapitre est consacré à la description du contexte médical plus précisément les tumeurs cérébrales sur lesquelles a porté ce travail. La description proposée est faite tant du point de vue du contenu des images IRM que des différentes caractéristiques liées à la classification des tumeurs cérébrales. Comme les images à traiter sont des images IRM, nous présentons l'imagerie par résonance magnétique, ses principes ainsi que ses caractéristiques. Mais avant tout, nous évoquerons les tumeurs cérébrales et quelques notions d'anatomie cérébrales qui vont nous permettre d'introduire les différents types de tumeurs qui doivent être localisées et identifiées. À la fin, le chapitre présente un résumé de l'état de l'art de la classification automatique des tumeurs cérébrales.

## **1.2 Les Tumeurs cérébrales**

Le mot «cancer» est utilisé pour désigner de nombreuses maladies différentes ayant pour point commun la présence de cellules cancéreuses. La plupart du temps, ces cellules cancéreuses forment des tumeurs dites «malignes», qui ont tendance à s'accroître et à se disséminer. Certaines, dites «bénignes», ne sont toutefois pas cancéreuses : elles peuvent comprimer des tissus ou des organes mais elles demeurent localisées dans une partie du corps et ne mettent généralement pas la vie en danger [4]. Toutefois, dans le cas du cancer du cerveau, les tumeurs bénignes peuvent être très dangereuses. En raison du volume non extensible de la boîte crânienne, elles peuvent comprimer des zones vitales du cerveau et causer des troubles importants. Il peut également arriver qu'une tumeur bénigne s'aggrave et se transforme en cancer. Si ce processus a lieu, il est généralement lent. Les tumeurs malignes, par contre, peuvent détruire des tissus proches par leur croissance rapide et leur caractère envahissant. De plus, les cellules cancéreuses des tumeurs malignes peuvent se mettre à circuler dans le sang ou le système lymphatique et envahir des ganglions (nodules répartis dans tout l'organisme et ayant une fonction immunitaire) [5].

Les tumeurs cérébrales sont nommées et classées en fonction du type de cellules dont elles sont issues : par exemple méningiomes pour des tumeurs se développant à partir des méninges, ou gliomes pour les tumeurs d'origines gliales (cellules de soutien du cerveau) [5].

### **1.2.1 Classification en grade : Gradation des tumeurs selon l'OMS**

Des grades établis par l'OMS (Organisation Mondiale de la Santé) permettent une classification des tumeurs en fonction de leur malignité et de leurs caractéristiques [6]. Le grade d'une tumeur dépend du degré d'anormalité (anaplasie) des cellules cancéreuses et du taux de croissance et d'expansion de la tumeur. La détermination du grade est effectuée lors d'une analyse microscopique des tissus prélevés.

Il existe 4 grades de tumeurs cérébrales, plus le grade de la tumeur est élevé, plus son développement est rapide. A l'inverse, plus le grade est bas, plus l'évolution est lente et locale. Le tableau 1.1 résume les 4 grades de tumeurs cérébrales.

### **1.2.2 Classification histologique : les différents types de tumeurs cérébrales**

L'OMS distingue environ 200 types de tumeurs cérébrales, classifiées en fonction des cellules dont elles sont issues. Les tumeurs cérébrales les plus fréquentes sont : les gliomes, les méningiomes et l'hypophyse [6].

#### **a) Les gliomes**

Ces tumeurs se développent au niveau des structures de soutien du système nerveux, les

## 1.2. Les Tumeurs cérébrales

TABLE 1.1: Les différents grades des tumeurs cérébrales.

Grade	Description
Grade I (Tumeurs bénignes)	Tumeurs à croissance lente et circonscrites limites bien définies.
Grade II (Tumeurs bénignes)	Tumeurs à croissance lente, mais, contrairement aux tumeurs de grade I, leurs limites sont imprécises.
Grade III (Tumeurs malignes)	Tumeurs anaplasiques. Un ou plusieurs foyers anaplasiques se sont développés au sein d'une tumeur pré-existante de bas grade (I ou II). Leur croissance est plus rapide que celle des tumeurs de bas grade.
Grade IV (Tumeurs malignes)	Les tumeurs de grade IV présentent une anaplasie très prononcée. Leur croissance est plus rapide que celle des tumeurs de bas grade.

cellules gliales. Il existe différents types de cellules gliales à partir desquelles peuvent se développer différents types de gliomes [7]. 58% des tumeurs du cerveau sont des gliomes. La figure 1.1 illustre les cellules gliales dans le système nerveux central. Il existe deux principales types de gliomes : tumeurs astrocytaires et tumeurs oligodendrogliomes [8].

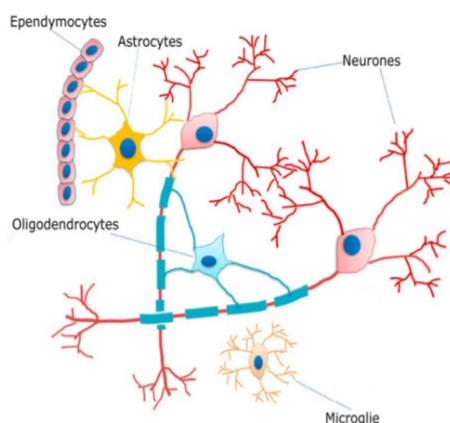


FIGURE 1.1: Système nerveux central avec les différents types de cellules gliales.

- **Les tumeurs astrocytaires** : se développent à partir de cellules gliales de forme étoilée (astrocytes). Ces tumeurs pouvant dégénérer (transformation bénigne à maligne), elles peuvent se développer dans toutes les régions du cerveau ou de la moelle épinière [8], on les rencontre le plus souvent dans les lobes cérébraux. On distingue principalement les tumeurs astrocytaires suivantes :

**i Les astrocytomes pilocytiques (grade I) :** Elles touchent surtout les enfants et les adolescents. Une transformation maligne est extrêmement rare. Ce sont des tumeurs à croissance lente et circonscrites (limites bien définies).

**ii Les astrocytomes diffus (grade II) :** Elles touchent surtout les jeunes adultes et ont une forte propension à la transformation maligne, c'est des tumeurs bénignes à croissance lente, mais, contrairement aux tumeurs de grade I, leurs limites sont imprécises.

**iii Les astrocytomes anaplasiques (grade III) :** Elles touchent surtout les personnes à partir de 50 ans et ont une forte propension à la transformation maligne en glioblastomes. Leur croissance est plus rapide que celle des tumeurs de bas grade.

**iv Les glioblastomes (astrocytomes de grade IV) :** Ces tumeurs malignes sont les plus fréquentes et les plus agressives. Elles représentent 20% de l'ensemble des tumeurs du cerveau [9]. Elles se développent rapidement et s'étendent dans plusieurs zones du cerveau en même temps.

— **Les oligodendrogliomes :** Elles sont ainsi nommées car elles se développent à partir des oligodendrocytes, les cellules gliales à l'origine de la formation de la myéline qui isole les fibres des nerfs. Il en existe deux types : les oligodendrogliomes de bas grade, qui évoluent lentement et les oligodendrogliomes, de haut grade qui sont malins et évoluent plus rapidement.

## **b) Les méningiomes**

Les méningiomes se développent aux dépens des méninges (les trois membranes conjonctives qui entourent la moelle épinière et l'encéphale), dans la boîte crânienne ou le long de la colonne vertébrale. La plupart des méningiomes sont bénins [6], mais, dans certains cas isolés, on peut observer une évolution défavorable (bénin à malin). Ces tumeurs ont une prédominance féminine et constituent la tumeur cérébrale la plus fréquente après les gliomes (représentent 20% des tumeurs cérébrales). Leur vitesse de croissance est lente et leur développement superficiel (d'où la fréquence des crises d'épilepsie) [8]. La figure 1.2 représente l'empilement des méninges, notamment, la dure-mère, l'arachnoïde et la pie-mère.

## 1.2. Les Tumeurs cérébrales

---

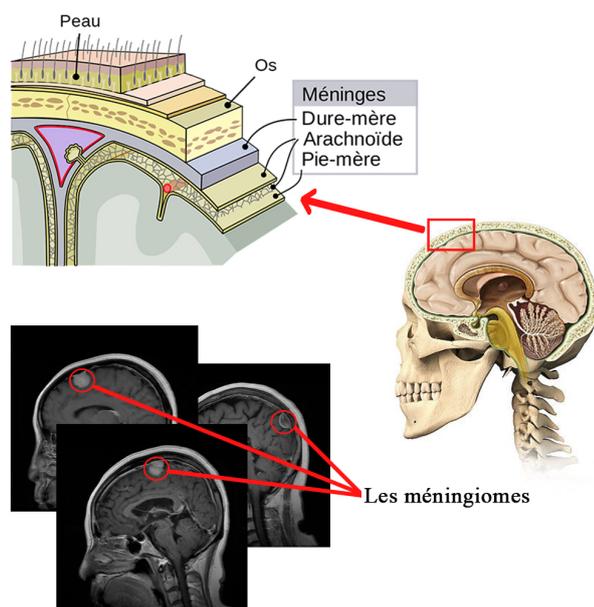


FIGURE 1.2: Les méninges.

### c) Les adénomes de l'hypophyse

Tumeurs bénignes (grade I) dans la grande majorité des cas, développées au dépens des cellules de l'hypophyse ; ces cellules sont responsables de la fabrication et la libération des hormones dans le sang. Leur présence peut se manifester par des troubles de la vision et des problèmes hormonaux tels que des troubles menstruels ou des troubles de la croissance [8]. Elles représentent 14% des tumeurs cérébrales. La figure 1.3 montre l'emplacement de l'hypophyse dans le cerveau de l'homme.

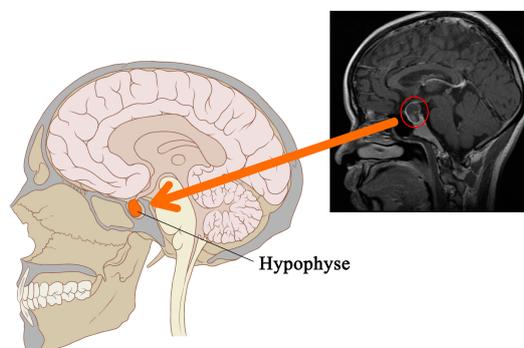


FIGURE 1.3: Emplacement de l'hypophyse.

## **1.3 L'imagerie par résonance magnétique**

Imagerie par Résonance Magnétique ou IRM, est une technique d'imagerie médicale qui permet d'analyser avec une grande précision les organes et les tissus mous, dans différents plans de l'espace. Ses champs d'application sont larges, elle est utilisée dans l'exploration des pathologies cérébrales, permettant ainsi de visualiser et de détecter des lésions infectieuses ou inflammatoires, des anomalies des vaisseaux, ainsi que des tumeurs. C'est une technique de diagnostic médical puissante, non invasive et sans effets secondaires connus. La figure 1.4 représente un appareil d'acquisition d'images IRM.



FIGURE 1.4: Appareil d'acquisition d'images IRM.

### **1.3.1 Principe général de l'IRM**

Le principe de l'IRM se base sur le phénomène physique de Résonance Magnétique Nucléaire MRN, qui repose sur les propriétés magnétiques des atomes d'hydrogènes composants les tissus de l'organisme.

En utilisant des aimants très puissants, les protons des atomes d'hydrogène du corps sont stimulés simultanément, ce qui a pour effet d'orienter tous les atomes d'hydrogène dans la même direction. Ils seront mis en résonance, suite à une perturbation ou excitation par des ondes radio durant une très courte période. A la fin de cette stimulation, le retour à l'état normal produit une variation du champs électrique, donc les atomes restituent l'énergie accumulée en produisant un signal, qui sera capté par une antenne, enregistré et traité sous forme d'image par un système informatique.

Puisque tous les tissus ne contiennent pas la même quantité d'atomes d'hydrogène, le niveau d'énergie restitué différera selon la composition tissulaire [10, 11].

### 1.3. L'imagerie par résonance magnétique

---

#### 1.3.2 Origine physique du signal IRM

Comme cité, l'IRM et la MRN reposent sur l'interaction de certains noyaux atomiques avec un champs magnétique. Mais seuls les noyaux de spin non-nul possèdent un moment magnétique et peuvent être étudiés par MRN.

Le spin nucléaire est une caractéristique quantique intrinsèque au noyau de l'atome comme sa masse et sa charge, il associe à la rotation de la charge du proton une propriété magnétique induite. En physique élémentaire, on considère que le proton de l'atome d'hydrogène tourne autour de son propre axe, cette rotation est caractérisée par une grandeur physique appelée moment angulaire intrinsèque, le spin est considéré comme une grandeur analogue à ce moment. Comme toute charge électrique en mouvement induit la formation d'un champ magnétique, le proton de l'atome d'hydrogène possède un moment magnétique qui est représenté par un vecteur  $\mu$  relié à son spin  $I$  par l'équation :

$$\mu = \gamma * I \quad (1.1)$$

$\gamma$  est la constante gyromagnétique du proton.

Le principe de la mesure de résonance magnétique nucléaire est de mettre ce moment  $\mu$  en mouvement de précession, car soumis à un champ magnétique intense appelé  $B_0$ , les spins s'orientent dans l'axe du champ produisant un moment magnétique macroscopique appelé  $M_0$ . Cependant l'axe de rotation d'un noyau tournant ne peut pas être exactement orienté parallèlement (ou anti-parallèlement) à la direction du champ externe appliqué  $B_0$ , il est alors mis en mouvement de précession, mouvement similaire à celui d'un gyroscope, autour de ce champ à un certain angle et avec une vitesse angulaire donnée par l'expression :

$$v = \gamma * B_0 \quad (1.2)$$

$v$  est la vitesse de précession appelée fréquence de Larmor.

Puis ce mouvement va être perturbé à l'aide d'un deuxième champ magnétique  $B_1$ , qui n'est pas uniforme mais alternatif de fréquence égale à la fréquence de précession des moments autour de  $B_0$ . Cela dévie la trajectoire de  $\mu$ , ainsi le moment magnétique macroscopique sera modifié, mais une fois  $B_1$  disparu, il retrouve son mouvement initial en présence de  $B_0$  seul, le phénomène décrit est illustré dans la figure 1.5. Ce retour à l'équilibre s'accompagne d'une émission d'ondes électromagnétiques que l'on peut détecter : c'est le signal mesuré en MRN [12].

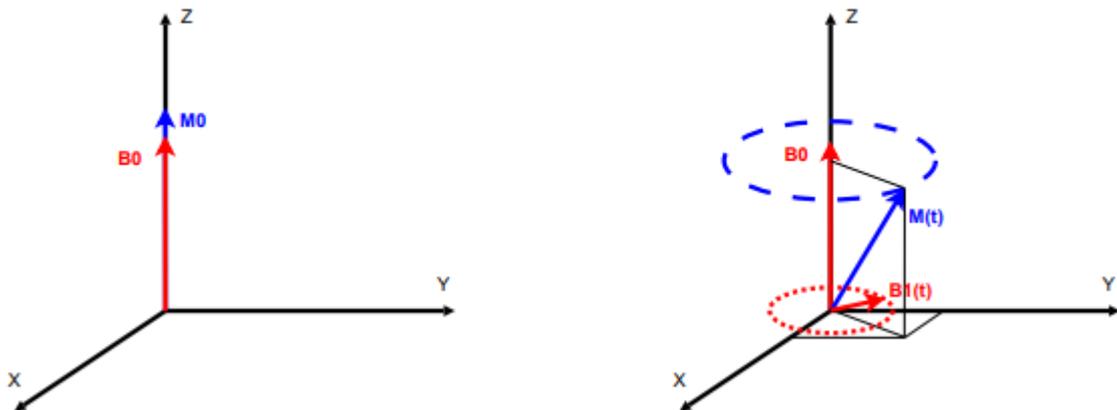


FIGURE 1.5: Représentation des moments magnétiques macroscopiques, de gauche à droite : État à l'équilibre, État pendant l'excitation

### 1.3.3 Principe de formation de l'image IRM

La mesure du signal MRN est liée au dispositif d'émission de l'impulsion, car le champ  $B_1$  est induit par la circulation d'un courant dans une bobine solénoïde et le retour du spin à l'équilibre induit un courant dans cette même bobine, elle sert donc à la fois de système d'émission et de réception. Ce courant induit est le signal effectivement mesuré.

La courbe qui donne le courant induit en fonction du temps est appelée FID pour "Free Induction Decay", son allure pour un proton isolé est une sinusoïde amortie exponentiellement, mais les choses se compliquent avec le nombre de noyaux mis en jeu, on obtiendra donc une somme de sinusoïdes amorties de caractéristiques différentes, ce qui rend le FID incompréhensible, son interprétation est triviale, il faut alors faire appel à une opération mathématique de traitement du signal, la transformée de Fourier [12].

La transformée de Fourier du FID d'un système complexe donne des informations sur les différentes contributions au signal, chaque pic est centré sur la fréquence d'une contribution et sa surface est proportionnelle à l'amplitude de la contribution. On obtient ainsi un signal fonction de la fréquence représentant le spectre MRN final. La figure ci-dessous représente la transformée de Fourier du FID d'un système complexe.

### 1.3. L'imagerie par résonance magnétique

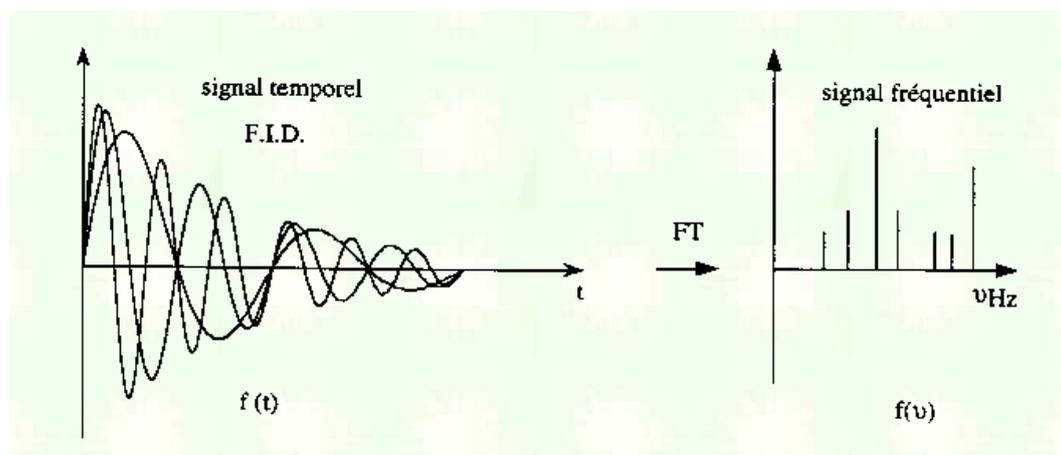


FIGURE 1.6: FID d'un système complexe et sa transformée de Fourier.

Le signal reçu par l'antenne de réception est un signal délocalisé qui ne contient pas d'information spatiale et provient de toute la partie de l'échantillon excitée. Pour l'imagerie, il est nécessaire d'ajouter une information spatiale au signal pour attribuer une position aux différents signaux, ainsi pour former une image à partir d'un signal MRN, des gradients de champ magnétiques sont appliqués pour modifier la phase et la fréquence en fonction des coordonnées spatiales. On parle alors d'encodage spatial du signal. Le codage spatial du signal est un codage cartésien au cours duquel la transformée de Fourier de l'image est acquise ligne par ligne. L'espace fréquentiel ainsi balayé est appelé l'espace K, il suffira donc d'appliquer une transformée de Fourier 2D inverse sur l'espace K pour obtenir une image de la coupe du corps humain.

#### 1.3.4 Pondération et séquences des images IRM

Une séquence IRM est un ensemble d'impulsions excitatrices qui se caractérise par deux principaux paramètres, le temps de répétition TR, l'intervalle de temps entre deux excitations, le temps d'écho TE, et l'intervalle de temps entre l'excitation et la survenue du signal IRM. Ces derniers sont ajustés pour obtenir des images ayant un contraste donné T1 ou T2. Il est alors possible, en faisant varier les temps d'écho TE et de répétition TR, d'obtenir des contrastes physiques très différents [13]. On peut voir la différence entre les deux pondérations sur les images IRM représentées sur la figure 1.7.

- **Pondération T1**

Un TR et un TE bas pondéreront les images en T1 où la graisse apparaît hyperintense (couleur claire) et l'eau hypointense. La pondération T1 est souvent utilisée pour l'anatomie, car elles permettent la mise en évidence de l'eau peu mobile, c'est à dire intracellulaire.

- **Pondération T2**

Un TR et un TE élevés pondéreront les images en T2 ou l'eau apparaît hyperintense (couleur claire) et la graisse un peu plus sombre que l'eau. Les images pondérées T2 sont utilisées comme images fonctionnelles car elles mettent en évidence l'eau mobile c'est à dire extracellulaire ou intravasculaire, permettant par exemple de mettre en évidence un débit sanguin cérébral local.

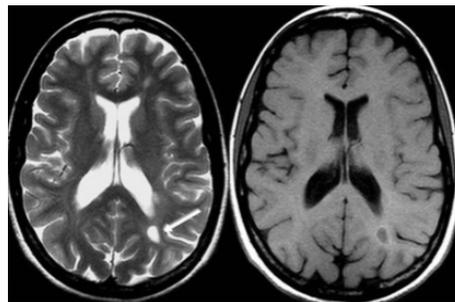


FIGURE 1.7: Coupe axiale d'un cerveau humain avec 2 pondérations différentes. De gauche à droite : pondération T1, pondération T2.

## 1.4 Classification automatique des tumeurs cérébrales

La classification des images médicales peut être une opération déroutante et fastidieuse pour les médecins ou les radiologues dans certains cas compliqués. Ces cas nécessitent des experts pour localiser la tumeur, comparer les tissus tumoraux avec les régions adjacentes afin de conclure s'il y a une tumeur et en déduit son type et son grade. Cependant, au cours des dernières années, des méthodologies de traitement d'image numérique ainsi que d'apprentissage automatique ont été introduites dans la classification d'images médicales afin de détecter précocement les tumeurs cérébrales, ce qui va fournir un deuxième avis et une assistance aux radiologues dans la compréhension des images médicales, facilitant ainsi le diagnostic, le traitement, les procédures antérieures et postopératoires. L'apprentissage automatique ou Machine Learning ML, est un champs d'étude de l'intelligence artificielle, qui se fonde sur des approches mathématiques et statistiques donnant la capacité aux ordinateurs de comprendre une structure de données sans avoir été programmés explicitement à cet effet [10, 14]. Il peut être divisé en deux catégories principales :

- **Apprentissage supervisé** : Où des exemples d'entrées étiquetés sont fournis avec les sorties souhaitées, le but de cette méthode est que l'algorithme puisse apprendre les conclusions qu'il devrait tirer.
- **Apprentissage non-supervisé** : Il comporte un entraînement fondé sur des données qui n'ont pas d'étiquettes ou une sortie précise, de sorte que l'algorithme d'apprentissage

## 1.4. Classification automatique des tumeurs cérébrales

---

trouve tout seul des points communs parmi ses données d'entrée.

Dans ce travail, un modèle d'apprentissage supervisé est proposé pour classer différents types de tumeurs cérébrales à l'aide d'images IRM, regroupées en trois ensembles de données accessibles au public. Le premier reconnaît les cas tumoraux et les non-tumoraux, le deuxième classe les tumeurs en méningiome, gliome et tumeur hypophysaire. Enfin, le dernier est utilisé pour deux études, à savoir, différenciation entre les trois grades de gliome grade II, grade III et grade IV, et une classification selon le type astrocytomes diffus, astrocytomes anaplasiques, glioblastomes, oligodendrogliomes bas grade et oligodendrogliomes haut grade. Cette méthodologie va s'appuyer sur l'analyse de la texture des tissus dépendants de la tumeur, qui sera réalisée selon une succession de quatre étapes décrites par la figure ci-dessous :

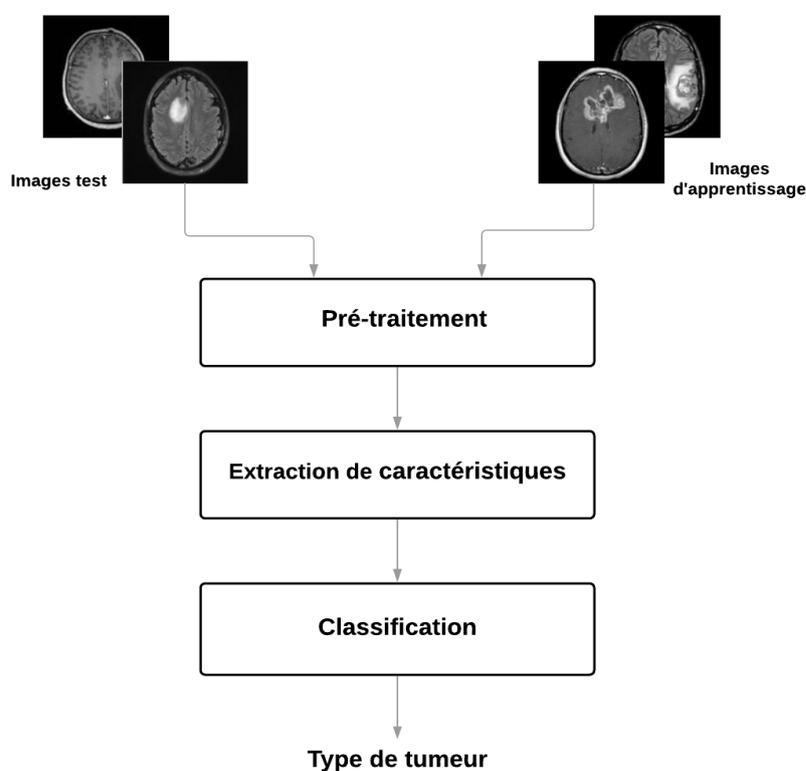


FIGURE 1.8: Architecture d'un système automatique de classification de tumeurs cérébrales.

### 1.4.1 Le pré-traitement

Ce processus regroupe des techniques qui visent à améliorer la qualité de l'image et à éliminer les bruits et les artefacts d'acquisition afin d'éviter les résultats trompeurs pouvant survenir dans l'étape d'extraction de caractéristiques et de classification. Il s'agit de quelques étapes fon-

damentales du traitement d'image numérique, qui consistent à mettre en évidence des détails qui sont obscurcis, ou simplement de mettre en évidence certaines caractéristiques intéressantes d'une image. Les méthodes de prétraitement sont très nombreuses mais dans ce travail nous avons commencé par une normalisation de la taille des images impliquées dans le traitement, en une taille standard, sans perturber le rapport d'aspect, et ceci dans le but d'assurer l'uniformité des données. Par la suite, des techniques de filtrage numériques sont appliquées aux images résultantes. Le filtrage est une des méthodes les plus courantes de réduction de bruit dans une image. Ce bruit se caractérise par de légères fluctuations autour de l'intensité moyenne d'une région de l'image. On distingue plusieurs types de filtres, parmi lesquels les filtres linéaires et les filtres non linéaires. On ne s'intéressera principalement ici qu'aux filtres linéaires. Et finalement, nous avons employé des méthodes de rehaussement de contraste pour l'amélioration de la qualité des images afin de fournir plus de détails. Plus de détails seront fournis au chapitre suivant.

### 1.4.2 L'extraction de caractéristiques

La phase d'extraction de caractéristiques constitue généralement l'une des phases les plus importantes dans l'élaboration d'un système de classification. Les caractéristiques de l'image contiennent des informations nécessaires pour analyser la tumeur et pouvoir l'identifier. Ces attributs sont utilisées comme entrées pour les classifieurs qui les affectent davantage à la classe qu'ils représentent. Il existe différents types de caractéristiques basées sur les formes, les couleurs ou les textures. Dans ce travail deux types de caractéristiques ont été utilisées pour la classification :

- **Caractéristiques statistiques** : pour obtenir des informations statistiques standard telles que la moyenne, l'entropie, l'écart-type, l'asymétrie et le kurtosis.
- **Caractéristiques de texture** : qui représentent un ensemble de propriétés statistiques locales d'intensités de pixels. Nous avons basé notre extraction des caractéristiques de texture sur la matrice de cooccurrence de niveau de gris GLCM (Gray Level Co-occurrence Matrix) qui considère la relation spatiale entre les pixels de différents niveaux de gris. Les quatre paramètres calculés à partir de la matrice de cooccurrence sont : la dissimilarité, l'homogénéité, l'énergie, et la corrélation [15, 13]. Plus de détails seront fournis au chapitre suivant.

### 1.4.3 La classification

La classification est un processus qui consiste à extraire de manière automatique des connaissances à partir d'un ensemble de données lors d'une phase d'apprentissage, puis à utiliser ces connaissances afin de regrouper les données (les mêmes que celles utilisées pour l'apprentissage ou d'autres) en classes homogènes dans le sens de propriétés communes lors d'une phase de prédiction. Le but de la classification de données est d'organiser et classer des données dans des

## 1.5. Résumé de l'état de l'art de la classification automatique des tumeurs cérébrales

---

classes distinctes constituant un modèle. Cette dernière étape est donc l'étape décisionnelle. La justesse de la prise de décision dépend des performances du classifieur choisi et de la qualité du processus d'apprentissage, mais aussi des traitements précédents. L'étude et la classification automatique des tumeurs cérébrales ont motivé plusieurs recherches. Les chercheurs ont utilisé différents classifieurs parmi ceux les K plus proches voisins (KNN) [16], les machines à vecteurs de support (SVM) [10, 14, 17], les réseaux de neurones [18], ...etc. Dans ce travail, nous avons utilisé une structure de classifieur SVM pour discriminer entre les types et les classes des tumeurs cérébrales. SVM est une méthode d'apprentissage supervisé qui permet de séparer les classes par un séparateur linéaire appelé hyperplan. Plus de détails seront fournis au chapitre suivant.

## 1.5 Résumé de l'état de l'art de la classification automatique des tumeurs cérébrales

Les travaux de recherche dans le domaine médical ont mobilisé durant ces dernières années une large communauté de chercheurs. La recherche dans ce domaine s'appuie principalement sur la prise en compte des cas réels, c'est-à-dire des cas qui représentent la situation des patients. Nous présentons un aperçu de l'état de l'art des approches utilisées dans les systèmes de classification automatique des tumeurs cérébrales. En règle générale, ces systèmes comportent des étapes de prétraitement, d'extraction des caractéristiques et de classification. Nous citons ici les travaux les plus importants :

- **Jun Cheng et al., (2015) [19]** Ont proposé une méthode pour améliorer la performance de la classification des tumeurs cérébrales en augmentant la région tumorale par dilatation d'image, puis en la divisant en sous-régions. Ils ont utilisé trois approches pour extraire les caractéristiques ; histogramme d'intensité, matrice de cooccurrence de niveau de gris (GLCM pour Gray Level Co-occurrence Matrix) et sac de mots (BOW pour Bag of Words) [20]. Machine à vecteur de support (SVM pour Support Vector Machine) a été utilisé pour la classification.
- **Mustafa R.Ismael et al., (2018) [21]** Ont présenté un algorithme pour classer trois types de tumeurs cérébrales, à savoir le méningiome, le gliome et les tumeurs hypophysaires à partir d'images IRM. Après l'identification de la région d'intérêt, c'est-à-dire le segment tumoral, le travail a été concentré sur l'extraction des caractéristiques statistiques en utilisant une combinaison des techniques 2D (TOD) et 2D Gabor filter. Pour la classification, un réseau neurones à rétropropagation a été utilisé pour tester l'impact de sélection des caractéristiques.
- **Ali Pashaei et al., (2018) [22]** L'extraction des caractéristiques a été réalisé en utilisant un réseau de neurones convolutifs (CNN pour Convolutional Neural Network). Ensuite, un noyau ELM (Extreme Learning Machine ) qui est un type de réseau de neurones avec une seule couche de noeuds cachés où les poids des entrées de connexion de noeuds cachés sont

répartis au hasard et jamais mis à jour, classe les images en fonction de ces caractéristiques extraites. L'ensemble de données utilisée pour évaluer l'efficacité de la méthode proposée, consiste en trois types de tumeurs cérébrales, y compris le méningiome, le gliome et la tumeur hypophysaire, dans des images IRM rehaussées par contraste (IRM-CE) pondérées en T1.

- **Amin K.Anaraki et al., (2018) [18]** Ont proposé un modèle basé sur un réseau de neurones convolutif associé à un algorithmes génétiques (GA-CNN) pour classer différents types de tumeurs cérébrales à l'aide de deux ensembles de données accessibles au public. Le premier classe les tumeurs en (méningiome, gliome, et la tumeur hypophysaire). L'autre distingue les trois gliomes (grade II, grade III et grade IV).
- **M.Z.Zafar et al., (2019) [23]** La méthode proposée se compose de trois parties pour déterminer la présence d'une tumeur cérébrale; la première étape est le prétraitement, elle consiste a dépouillé le cerveau du crâne en utilisant le masquage d'image . La deuxième étape est l'extraction des caractéristiques à l'aide de descripteurs géométriques. Ces descripteurs géométriques comprennent trois formes géométriques éclipse, parabole et hyperbole. Puis ces caractéristiques sont classées à l'aide d'un SVM.
- **P.M.Ameer (2019) [24]** Ont introduit un nouvel algorithme pour détecter et différencier entre trois types de tumeurs cérébrales, à savoir les gliomes, les méningiomes et les tumeurs hypophysaires, qui forment trois types importants de tumeur cérébrale. Dans cette méthode, le concept de l'apprentissage par transfert profond a été adopté en utilisant un GoogleNet préformé pour l'extraction des caractéristiques des images IRM cérébrales. Puis un SVM est intégré pour classer les caractéristiques extraites. L'expérience suit un processus de validation croisée en cinq étapes au niveau du patient, sur l'ensemble de données IRM.
- **Hossam.H.Sultan et al., (2019) [25]** Ont testé les performances d'une implémentation personnalisée du réseau de neurones convolutif CNN sur deux ensembles de données médicales pour classer différentes types et grades de tumeurs cérébrales. Une distorsion en niveaux de gris est ajoutée aux images puis le type de classe ou grade auquel appartient chaque image est déterminé.

Le tableau 1.2 résume les résultats de la classification des tumeurs cérébrales de l'état de l'art pour différentes bases de données.

## 1.6. Conclusion

---

TABLE 1.2: Résultats de l'état de l'art pour la classification des tumeurs cérébrales.

Référence	Base de données	Caractéristiques	Classifieur	Précision
[19]	Figshare	sac de mots	SVM	91,28%
[21]	Figshare	2D-TOD Gabor	NN	91,90%
[22]	Figshare	CNN	KELM	93,68%
[18]	Figshare	GA	CNN	94,20%
[24]	Figshare	deep CNN	SVM	97,10%
[25]	Figshare		CNN	96,13%
[18]	Rembrandt	GA	CNN	90,00%
[25]	Rembrandt		CNN	98,70%
[23]	Kaggle	descripteurs géométriques	SVM	97,50%

## 1.6 Conclusion

Une tumeur cérébrale est un signe de croissance anormale de cellules dans le cerveau humain qui peut entraîner un cancer, l'une des principales causes de décès dans le monde. Dans ce chapitre nous avons abordé les principaux caractères cliniques liées aux tumeurs cérébrales, nous avons présenté également les principes d'acquisition et de formation des images médicales par résonance magnétique, un état de l'art des travaux réalisés autour de la problématique étudiée a été exhibé.

La détection précoce des tumeurs et l'estimation de leur évolution sur la base d'imagerie IRM peut sauver des vies, nous allons alors présenter dans le chapitre suivant un modèle pour la détection et la classification de différentes tumeurs cérébrales et leur étude selon le type et le grade.

---

### Description des transformées multi-échelles pour l'extraction de caractéristiques et combinaison de classifieurs

---

#### 2.1 Introduction

Un système de classification automatique d'images est composé des étapes suivantes : l'étape de prétraitement permettant de "nettoyer" les images ; la phase d'extraction de caractéristiques permettant de décrire l'information pertinente contenue dans l'image à l'aide de descripteurs discriminants ; la phase d'apprentissage permettant de construire une frontière de décision pour identifier la classe d'une image présentée à l'entrée du système. Ces trois phases sont essentielles dans la construction du système de classification.

La description obtenue lors de la phase d'extraction de caractéristiques tient compte de la totalité des informations présentes dans l'image. Les techniques d'extraction de caractéristiques peuvent se scinder en caractéristiques bas-niveau utilisant par exemple l'information au niveau du pixel dans l'image et en caractéristiques de plus haut niveau avec des descripteurs utilisant notamment une représentation texturée de l'image. Comme ces caractéristiques représentent l'entrée de notre système et sont importantes pour différencier les images à analyser, il serait intéressant de profiter de la variété des informations qu'elles apportent. Une solution à ce problème consiste à utiliser plusieurs systèmes et entraîner chacun d'eux sur un ensemble de caractéristiques différentes.

La phase d'apprentissage consiste en la construction d'une règle de décision soit à partir

## 2.2. Pré-traitement

---

d'un modèle, soit en élaborant une frontière dans l'espace de caractéristiques formé à l'étape précédente. Les méthodes standards utilisent un seul classifieur pour la construction de la règle de décision. Ainsi, l'estimation de la fonction de décision se fait à partir d'une seule hypothèse. Parmi les méthodes de classification les plus utilisées pour la reconnaissance, on trouve les Machines à Vecteur de Support (SVM pour Support Vector Machine). Cependant, des approches plus flexibles que la formulation d'une unique hypothèse considèrent plutôt une combinaison de classifieurs permettant d'améliorer les performances de ces mêmes classifieurs pris individuellement.

Nous présentons dans les sections suivantes les différentes approches pour chacune des étapes composant le système de classification des tumeurs cérébrales. Dans un premier temps, nous verrons brièvement les méthodes de prétraitement utilisées en imagerie médicale. Ensuite, nous parlerons des différentes transformées multi-échelles à deux dimensions utilisées pour l'extraction de caractéristiques. Nous aborderons à la fin le SVM ainsi que la combinaison de classifieurs.

## 2.2 Pré-traitement

Pendant le processus de formation des images IRM, leur qualité peut se dégrader en raison de diverses causes telles que la mise au point, la présence de bruit, le mouvement relatif entre la caméra et la scène, etc. Les risques de bruits sur ces images seront plus élevés. De ce fait, avant le diagnostic, une image doit être prétraitée en fonction de nos besoins. Le rehaussement du contraste, la conversion en image niveaux de gris et la suppression du bruit excessif en utilisant différentes méthodes de filtrage sont les étapes de prétraitement de base utilisées dans la plupart des travaux liés à la classification automatique des tumeurs cérébrales [26]. L'objectif de l'étape de prétraitement est d'améliorer la qualité des images IRM en améliorant certains paramètres, telles que l'apparence visuelle de l'image IRM, l'élimination du bruit et des parties indésirables en arrière-plan, le lissage de la partie intérieure de la région, et la préservation de ses bords [27].

### 2.2.1 Redimensionnement de la taille de l'image

Avant d'alimenter les images dans la structure proposée, une étape de prétraitement est effectuée. Le premier processus consiste à réduire l'image originale à 128x128x1 pixels sans perturber le rapport d'aspect afin de réduire la dimensionnalité ce qui permettra de gagner en temps de calcul. La figure 2.1 représente quelques images cérébrales issus de différentes bases de données avant et après le redimensionnement.

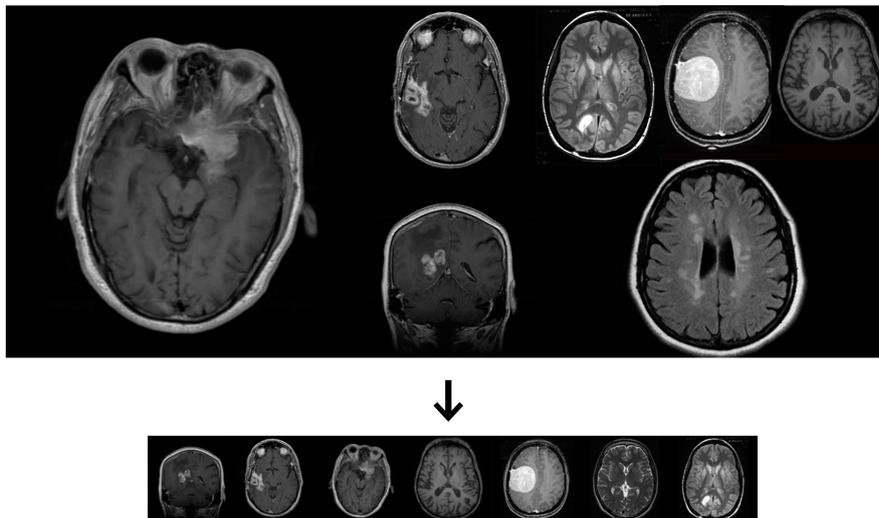


FIGURE 2.1: Images IRM de tailles différentes avant et après le redimensionnement

### 2.2.2 Filtre Gaussien

Le flou gaussien (aussi connu sous le nom de lissage gaussien) est un filtre linéaire passe-bas. Il s'agit d'un effet largement utilisé pour la réduction du bruit gaussien existant dans l'IRM cérébrale. Ce filtre possède l'inconvénient d'étaler les transitions, il accorde une grande importance aux pixels proches du pixel central, et diminue cette importance au fur et à mesure que l'on s'éloigne de lui.

Ce filtre produit une impression de flou. La figure 2.1 montre l'application de ce filtre à l'IRM.

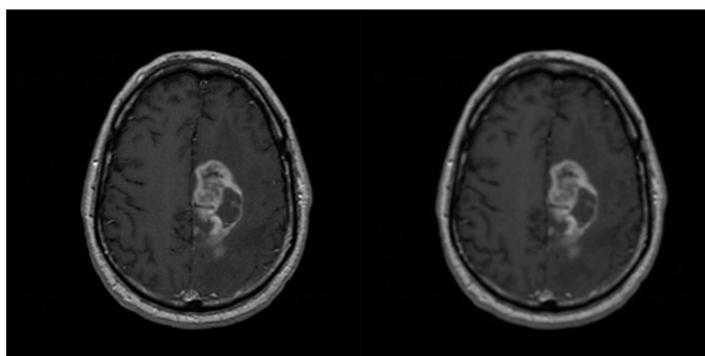


FIGURE 2.2: IRM cérébrale avant et après l'application du filtre Gaussien

## 2.2. Pré-traitement

---

### 2.2.3 Filtre médian

Cette technique est la plus utilisée pour l'élimination du bruit. C'est une technique de filtrage non linéaire. Elle est utilisée pour éliminer le bruit poivre et sel formant l'image en niveaux de gris [28]. Le filtre médian est basé sur la valeur moyenne des pixels. Ce filtre a l'avantage de ne pas introduire de nouvelles valeurs d'intensité et de réduire la variance de celles-ci. La figure suivante montre l'application du filtre médian à une image IRM.

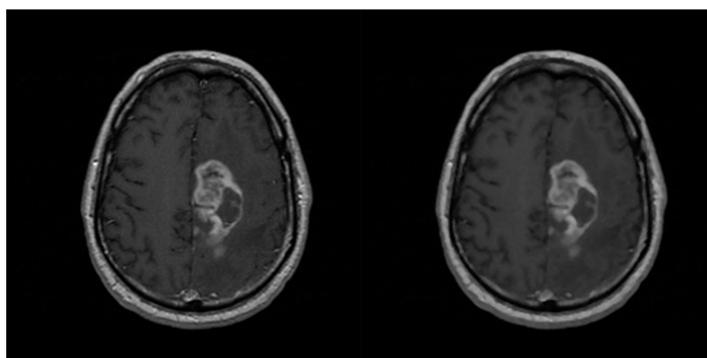


FIGURE 2.3: IRM cérébrale avant et après l'application du filtre médian

### 2.2.4 Rehaussement de contraste

Le but des filtres définis dans les paragraphes précédents est de réduire les fluctuations d'intensité à l'intérieur d'une même région, sans perturber, par élargissement, la zone de transition marquant la frontière entre régions. Il arrive cependant que la transition entre régions soit initialement floue, c'est-à-dire, qu'elle s'étale sur plusieurs pixels. Ceci se produit dans le cas de bougés (objets ou caméra mobiles) ou de défocalisation de la caméra. La cause peut également en être le processus physique de formation de l'image (phénomènes de diffraction en radiographie X ou échographie ultrasonore). Rehausser le contraste de l'image consiste à diminuer l'étendue de la zone de transition sans affecter l'intensité moyenne des régions situées de part et d'autre. On limite ainsi le risque de fusion intempestive de régions distinctes lors de la phase de segmentation. L'opérateur de rehaussement de contraste devra, si possible, réduire le bruit dans les zones stationnaires et éviter les phénomènes de dépassement. Dans ce travail, nous avons utilisé l'égalisation d'histogramme qui est un procédé par lequel on force tous les niveaux de gris de l'image à être équiprobables. La figure suivante montre l'application du rehaussement de contraste par égalisation d'histogramme à une image IRM.

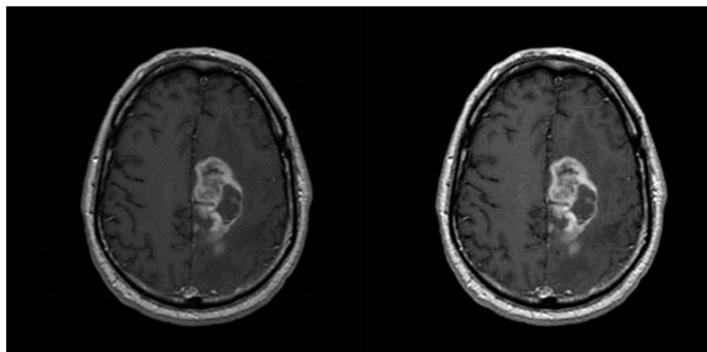


FIGURE 2.4: Application du rehaussement de contraste sur une image IRM

## 2.3 Transformées multi-échelles

Dans cette partie, on expose une sélection de méthodes multi-échelles qui peuvent s'inscrire dans notre problématique. Dans le cas le plus simple d'application de problèmes multi-échelles, deux niveaux se distinguent : le niveau global, qui définit le comportement macroscopique de la structure, et le niveau local, qui apporte une information plus riche car il expose un comportement se déroulant à une échelle inférieure, éventuellement microscopique [29].

La notion d'échelle peut être vue comme une mesure abstraite liée à la taille des différentes structures (objets, contours, régions, etc.) présentes au sein d'une image. Il existe en général plusieurs niveaux d'échelles d'étude pour une image donnée. La gamme des échelles possibles au sein d'une image est bornée, et ces bornes dépendent directement de la résolution de celle-ci. En effet, l'échelle minimale représentée ne pourra être plus petite que la taille d'un pixel.

Il existe une quantité notable de méthodes multi-échelles dans la littérature. Dans ce chapitre, nous aborderons les trois techniques présentées ci-dessous.

### 2.3.1 Transformée en ondelette discrète

La transformation en ondelettes est un outil mathématique puissant pour l'extraction de fonctionnalités d'images, introduit au début des années 1980 et est devenu un choix populaire dans de nombreux problèmes d'analyse d'images et de classification. Cette transformation est utile pour analyser le signal ou l'image à différentes échelles ou résolutions [30]. Contrairement à

### 2.3. Transformées multi-échelles

---

d'autres techniques de transformation, la transformée en ondelettes fournit la localisation temps-fréquence d'un signal [31].

#### Définition

Une ondelette est une fonction oscillante de moyenne nulle, appelée  $\psi$ , possédant un certain degré de régularité et dont le support est fini.

L'ondelette mère  $\psi$  génère une famille d'ondelettes :

$$W_\psi(s, t) = \int_{-\infty}^{+\infty} f(x) \psi_{s,t}(x) dx \quad (2.1)$$

où

$$\psi_{s,t}(x) = \frac{1}{\sqrt{s}} \psi\left(\frac{x-t}{s}\right); \quad s \in \mathfrak{R}^+, \quad t \in \mathfrak{R} \quad (2.2)$$

Avec  $s$  est le facteur de dilatation « Echelle »,  $t$  le paramètre de translation et  $\frac{1}{\sqrt{s}}$  facteur de normalisation de l'énergie afin que le signal transformé ait la même énergie à toutes les échelles. La fonction d'ondelette  $\psi_{s,t}(x)$  est construite à partir de l'ondelette mère  $\psi(\cdot)$  tradatée de  $t$  et dilatée (contractée si  $s < 1$ ) par  $s$  [32].

La variation discrète de l'équation 2.1 peut être obtenue en discrétisant les coefficients  $s$  et  $t$  de la manière suivante  $s = 2^j$  et  $t = 2^j k$  et est exprimée comme :

$$TOD_{f(n)} = \begin{cases} A_{j,k}(n) = \sum_n f(n) G_j^*(n - 2^j k) \\ D_{j,k}(n) = \sum_n f(n) H_j^*(n - 2^j k) \end{cases} \quad (2.3)$$

où  $A_{j,k}(n)$  fait référence aux coefficients de la composante approximation et  $D_{j,k}(n)$  indique les coefficients des composantes de détails. Les fonctions  $G(n)$  et  $H(n)$  représentent respectivement les coefficients des filtres passe-bas et passe-haut. Les deux paramètres  $j$  et  $k$  désignent respectivement l'échelle d'onde et les facteurs de translation [33].

La transformée en Ondelette discrète à deux dimensions (TOD - 2D) est mis en œuvre en faisant usage de 2 filtres d'analyses  $h$  (passe-bas) et  $g$  (passe-haut), suivis d'un sous-échantillonnage (décimation) de facteur 2 de chaque sortie. La figure 2.5 illustre le schéma de la TOD-2D. Pour le cas des images, la TOD est appliquée à chaque dimension séparément, c'est-à-dire d'abord ligne par ligne, puis colonne par colonne. Par conséquent, quatre images de sous-bande (LL :low-low, LH :low-high, HL :high-low, HH : high-high) sont obtenues à chaque niveau. À leur tour, trois images de sous-bande LH ( $D_j^h$ ), HL ( $D_j^v$ ), HH ( $D_j^d$ ) sont les images détaillées le long des directions horizontales, verticales et diagonales, respectivement. La sous-bande LL ( $A_j$ ) est l'image d'approximation qui est utilisée pour les calculs de la TOD-2D au niveau suivant. La figure 2.6

## Chapitre 2. Description des transformées multi-échelles pour l'extraction de caractéristiques et combinaison de classifieurs

montre une image IRM normale du cerveau avec sa décomposition en ondelettes de Haar de niveau 4.

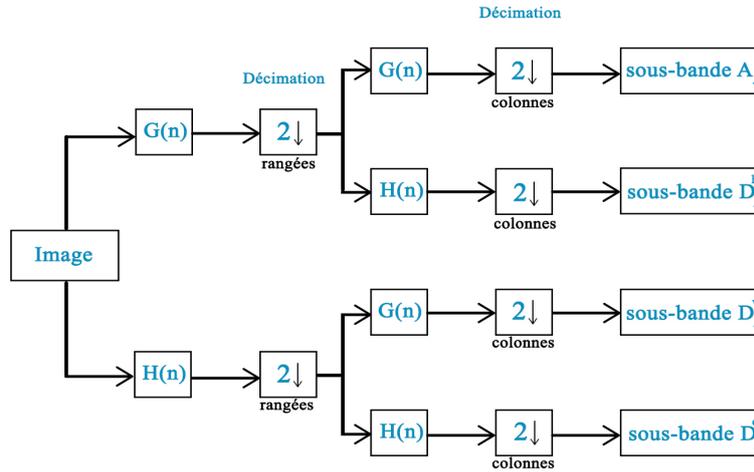


FIGURE 2.5: Décomposition de la TOD-2D

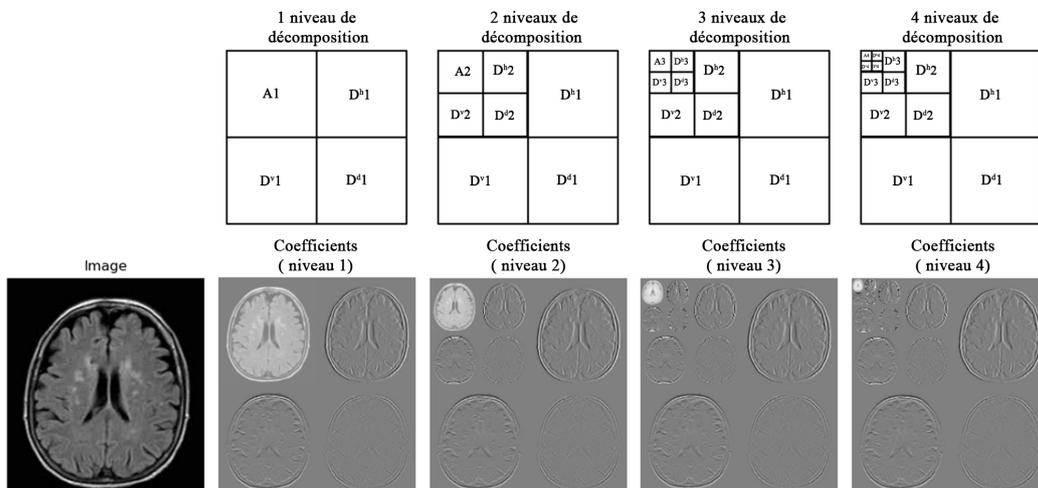


FIGURE 2.6: TOD d'une IRM cérébrale sans tumeur en utilisant l'ondelette de Haar à 4 niveaux de décomposition

Il existe différents types d'ondelettes qui ont pris la prévalence tout au long du développement de l'analyse d'ondelettes. L'une des ondelettes les plus importantes et les plus simples est l'ondelette Haar qui est fréquemment utilisée pour diverses applications [34]. Nous présentons ci-dessous les ondelettes les plus connues.

### 2.3. Transformées multi-échelles

**L'ondelette de Haar :** Un premier exemple d'ondelette orthogonale est l'ondelette de Haar. La fonction d'échelle dans ce cas est :

$$\phi(t) = \begin{cases} 1 \rightarrow 0 \leq t \leq 1 \\ 0 \rightarrow \text{sinon} \end{cases} \quad (2.4)$$

et l'ondelette correspondante :

$$\psi(t) = \begin{cases} 1 \rightarrow 0 \leq t \leq 1/2 \\ -1 \rightarrow 1/2 < t \leq 1 \\ 0 \rightarrow \text{sinon} \end{cases} \quad (2.5)$$

Un exemple de l'ondelette Haar est montré dans la figure 2.7.

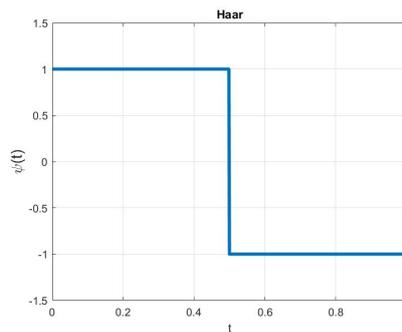


FIGURE 2.7: Exemple d'ondelette Haar  $\psi(t)$ .

**L'ondelette de Daubechies :** L'ondelette de Daubechies est la famille la plus connue des ondelettes orthonormales. Ses ondelettes sont généralement dénommées par le nombre de coefficients à  $k$  non nuls, on parle donc d'ondelettes Daubechies4, Daubechies6, etc. Les ondelettes de Daubechies sont supportées sur un intervalle de longueur  $2N - 1$ . Elles présentent l'inconvénient de ne pas être symétriques ou antisymétriques, excepté quand  $N = 1$  ce qui correspond à l'ondelette de Haar. L'ondelette de Daubechies peut être évaluée en utilisant les fonctions mère et mise à l'échelle suivantes :

$$\begin{aligned} \psi(t) &= \sqrt{2} \sum_{m=0}^{2N-1} (-1)^m h_{2N-1-m} \phi(2t - m) \\ \phi(t) &= \sqrt{2} \sum_{m=0}^{2N-1} h_m \phi(2t - m) \end{aligned} \quad (2.6)$$

Plusieurs exemples de l'ondelettes Daubechies sont montrés dans la figure 2.8.

## Chapitre 2. Description des transformées multi-échelles pour l'extraction de caractéristiques et combinaison de classifieurs

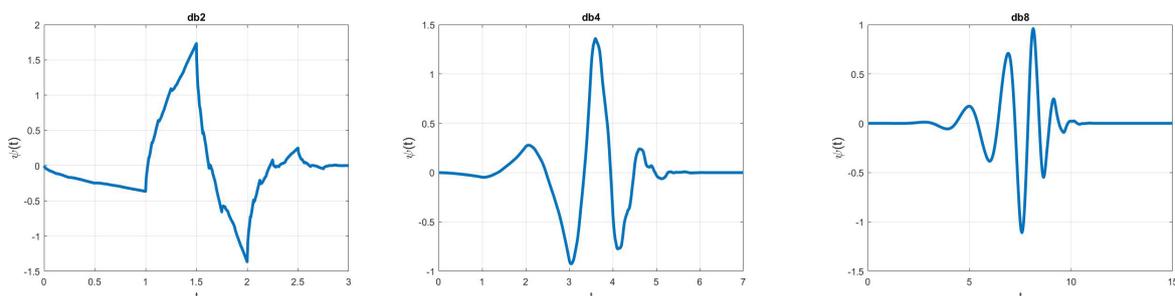


FIGURE 2.8: Exemples d'ondelettes Daubechies  $\psi(t)$ .

**L'ondelette de Symlets :** Les Symlets sont des ondelettes symétriques, orthogonales et biorthogonales proposées par Daubechies comme modifications à la famille *db*. Les ondelettes résultantes ont encore un support minimum  $[N + 1, N]$  avec des moments de disparition de  $p$ , mais elles sont plus symétriques. Plusieurs exemples de l'ondelettes Symlets sont montrés dans la figure 2.9.

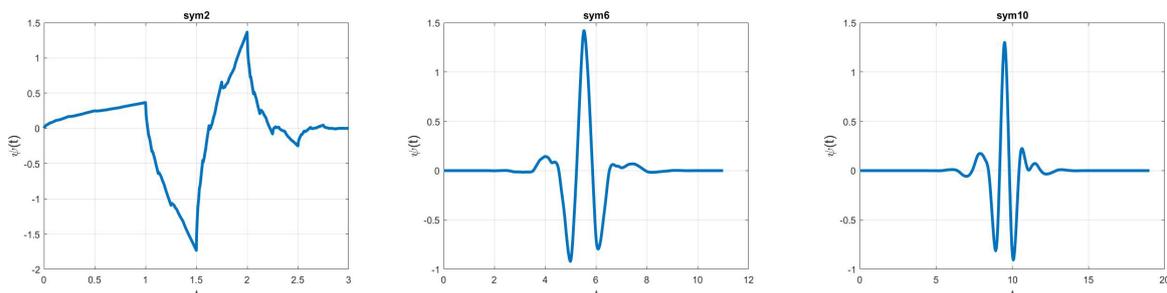


FIGURE 2.9: Exemples d'ondelettes Symlets  $\psi(t)$ .

**L'ondelette Biorthogonales :** Pour diverses raisons, tel que l'invariance par renversement du temps et la gestion des effets de bord, il est préférable d'avoir des ondelettes (anti) symétriques. Comme Il n'existe pas d'ondelettes réelles orthogonales a support compact et moments nuls (excepté Haar). La solution est de relâcher la condition d'orthogonalité, et utiliser des ondelettes biorthogonales. La fonction d'échelle et l'ondelette mère sont présentées par la relation récursive :

$$\begin{aligned} \psi(t) &= \sqrt{2} \sum_m g_m \phi(2t - k) \\ \phi(t) &= \sqrt{2} \sum_m h_m \phi(2t - m) \end{aligned} \quad (2.7)$$

Un exemple de l'ondelette Biorthogonale est montré dans la figure 2.10.

### 2.3. Transformées multi-échelles

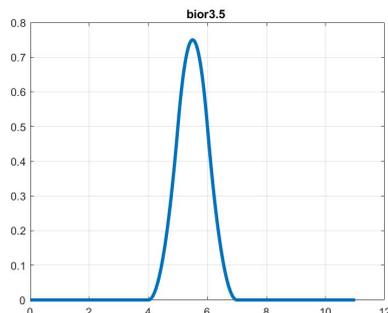


FIGURE 2.10: Exemple d'ondelette Biorthogonale  $\psi(t)$ .

**L'ondelette de coifflet :** En 1989, R. Coifmann a suggéré la conception de systèmes d'ondelettes orthonormales avec des moments de fuite pour les fonctions de mise à l'échelle et d'ondelette. Ils ont d'abord été construits par I. Daubechies et nommé Coifflets. Une famille d'ondelettes  $\phi$  a  $N$  moments nuls et un support de taille minimum, et une fonction d'échelle qui vérifie :

$$\int_{-\infty}^{+\infty} \phi(t) dt = 1 \quad \int_{-\infty}^{+\infty} t^k \phi(t) dt = 0 \quad \text{pour } 1 \leq k \leq N \quad (2.8)$$

Plusieurs exemples de l'ondelettes coifflet sont montrés dans la figure 2.11.

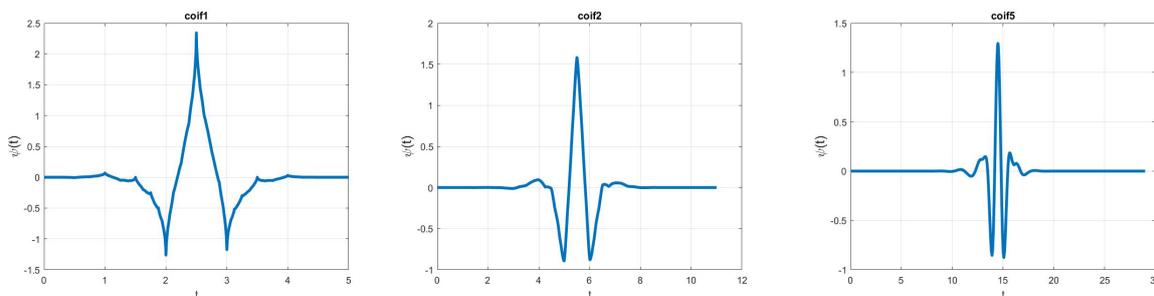


FIGURE 2.11: Exemples d'ondelettes coifflet  $\psi(t)$ .

La transformée en ondelettes présente de nombreux avantages dans le domaine du traitement du signal 1D et 2D. L'analyse par ondelettes ne se limite plus à l'image telle qu'elle nous apparaît, mais permet l'étude des objets présents dans l'image à différentes échelles. Elle permet d'extraire des informations importantes (texture, contours, etc.). C'est un outil puissant de transformation du signal qui permet de «préparer» le signal afin de faciliter le traitement envisagé.

La figure suivante montre comment apparaît une tumeur avec une décomposition en ondelette de Haar à 1 niveau.

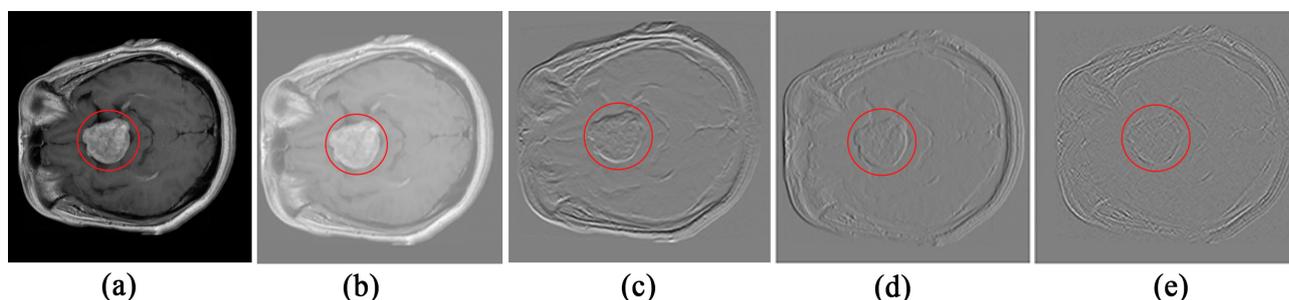


FIGURE 2.12: Décomposition à 1 niveau d'une image IRM (a) en une imagerie d'approximation (b) et trois imageries de détails (c), (d) et (e) avec l'ondelette de Haar. La tumeur est localisée à l'intérieur du cercle rouge.

### 2.3.2 Transformée de Gabor

Transformation intégrale introduite par Dennis Gabor, lauréat du prix Nobel de physique en Hongrie pour ses travaux sur l'holographie, qui a modifié la célèbre transformée de Fourier d'une fonction (ou d'un signal) en introduisant une fonction de fenêtre de localisation temporelle, également appelée fenêtre temps-fréquence [35].

En effet la transformation de Fourier d'une image permet de mettre en évidence les régularités d'un signal en examinant le domaine fréquentiel seulement. Le problème posé par cette opération, qui agit globalement sur l'image, est qu'elle ne tient pas compte de la localisation spatiale. Afin de remédier à ce problème, Dennis Gabor a suggérer de rendre locale l'analyse de Fourier, en s'aidant de fenêtres. Une fenêtre est une fonction régulière, lentement variable, et bien localisée, ce qui signifie qu'elle est nulle en dehors de son support. En multipliant la fonction étudiée par une fenêtre, on en obtient une version «locale», dont on peut déterminer le contenu fréquentiel par analyse de Fourier classique. On renouvelle alors l'opération en déplaçant la fenêtre d'analyse. L'ensemble de ces transformées de Fourier ainsi localisées forme la transformée de Gabor du signal, et fournit donc une analyse fréquentielle locale [36]. La transformée de Gabor d'un signal  $x(t)$  est définie par la formule suivante :

$$G_x(t, f) = \int_{-\infty}^{\infty} e^{-\pi(\tau-t)^2} e^{-j2\pi f\tau} x(\tau) d\tau \quad (2.9)$$

Il existe différentes fenêtres d'observation : la fenêtre triangulaire, la fenêtre Gaussienne. Le choix de la taille de la fenêtre et du pas de déplacement dépend des caractéristiques spatiales des textures à analyser.

## 2.3. Transformées multi-échelles

### Filtre de Gabor (Ondelettes de Gabor 2D)

Le filtre de Gabor est un filtre linéaire utilisé dans un très grand nombre d'applications de traitement d'image pour la détection des contours, l'analyse de texture, l'extraction d'entités,...etc. Il a été démontré que ces filtres possèdent des propriétés de localisation optimales dans le domaine spatial et fréquentiel et sont donc bien adaptés aux problèmes de segmentation de texture. Les filtres de Gabor sont des classes spéciales de filtres passe-bande, c'est-à-dire qu'ils autorisent une certaine «bande» de fréquences et rejettent les autres. Un filtre de Gabor 2D peut être considéré comme un signal sinusoïdal de fréquence et d'orientation particulières, modulé par une onde Gaussienne [37]. La figure 2.13 est une représentation d'un filtre de Gabor dans le domaine spatial.

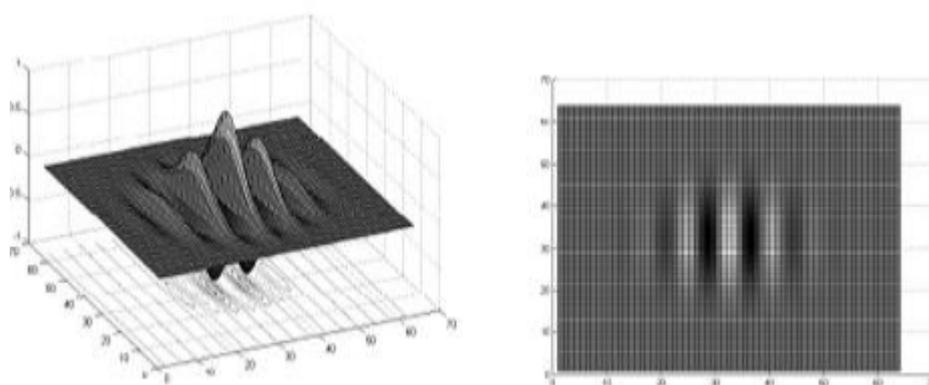


FIGURE 2.13: Filtre de Gabor dans le domaine spatial

Les filtres de Gabor sont définies comme suit :

$$g(x,y;\lambda,\theta,\phi,\sigma,\gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \phi\right)\right) \quad (2.10)$$

où

$$x' = x \cos \theta + y \sin \theta \quad (2.11)$$

et

$$y' = -x \sin \theta + y \cos \theta \quad (2.12)$$

Où  $x$  et  $y$  représentent les coordonnées d'un pixel dans le domaine spatial, tandis que  $\lambda$ ,  $\theta$ ,  $\phi$ ,  $\sigma$  et  $\gamma$  représentent les entités suivantes :

- **Orientation de l'ondelette ( $\theta$ )** : Ce paramètre fait pivoter l'ondelette autour de son centre. L'orientation de l'ondelette détermine l'angle des contours ou des lignes de l'image auxquelles l'ondelette va être sensible. Dans la plupart des cas  $\theta$  prend ses valeurs entre 0 et  $\pi$ , car les valeurs de  $\pi$  à  $2\pi$  sont redondantes vu la symétrie de l'ondelette [35]. La figure ci-dessous montre l'effet du paramètre  $\theta$  sur le filtre de Gabor.

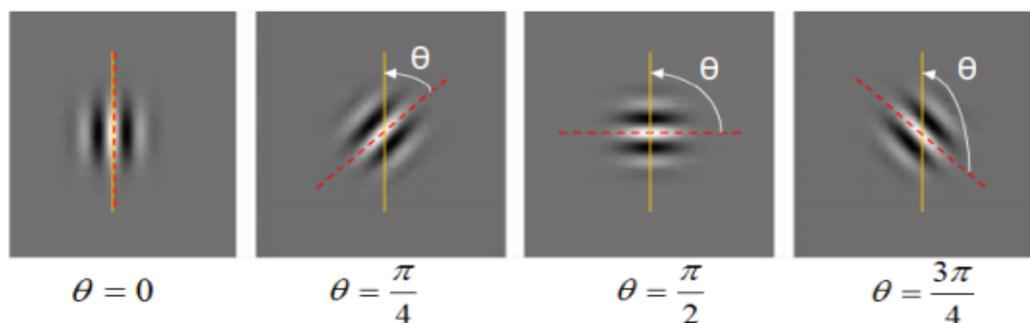


FIGURE 2.14: Orientation du filtre

- **Fréquence centrale de l'ondelette ( $\lambda$ )** : Ce paramètre spécifie la longueur d'onde du cosinus ou inversement la fréquence centrale de l'ondelette. Les ondelettes avec une grande longueur d'onde seront sensibles à des changements progressifs d'intensité dans une image. Les ondelettes avec une petite longueur d'onde seront sensibles à des contours et des lignes abruptes [35]. La figure ci-dessous montre l'effet du paramètre  $\lambda$  sur le filtre de Gabor.

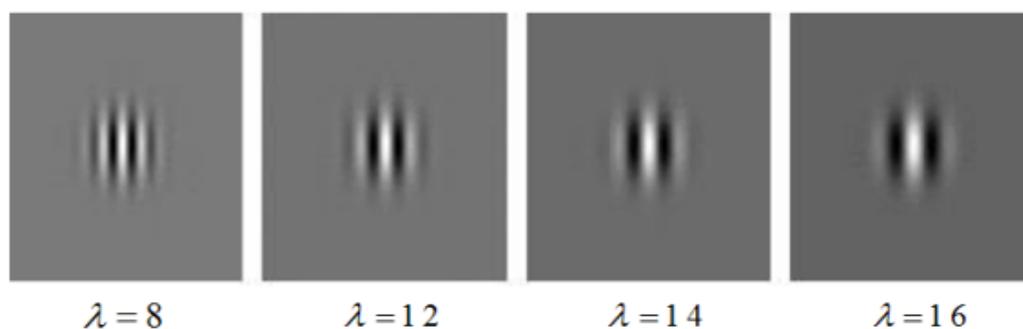


FIGURE 2.15: Fréquence centrale du filtre

- **Phase de la sinusoïde ( $\phi$ )** : On utilise à la fois la partie réelle et la partie imaginaire de l'ondelette complexe de Gabor. Ce qui nous donne deux ondelettes, une ondelette paire et une ondelette impaire. La convolution incluant alors deux phases, donne un coefficient complexe basé sur deux ondelettes qui sont déphasées de  $2\pi$  [35]. La figure ci-dessous montre l'effet du paramètre  $\phi$  sur le filtre de Gabor.

### 2.3. Transformées multi-échelles

---

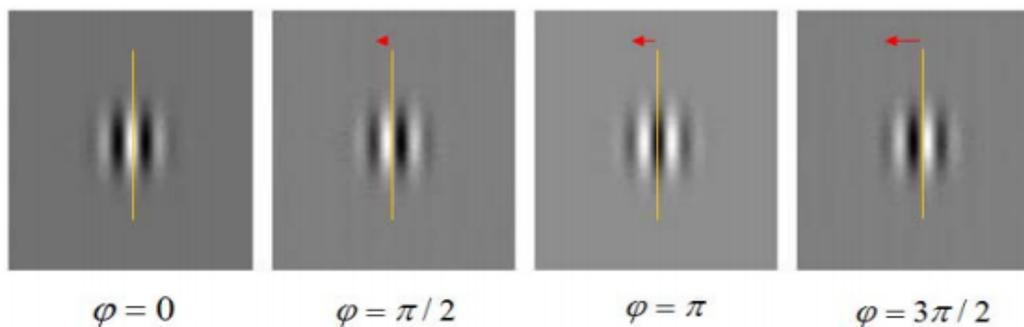


FIGURE 2.16: Phase du filtre

- **Support temporel de l'ondelette ( $\sigma$ )** : Ce paramètre spécifie le rayon de la Gaussienne. La taille de la Gaussienne détermine la quantité de pixels de l'image qui va être prise en compte dans la convolution [35]. La figure ci-dessous montre l'effet du paramètre  $\sigma$  sur le filtre de Gabor.

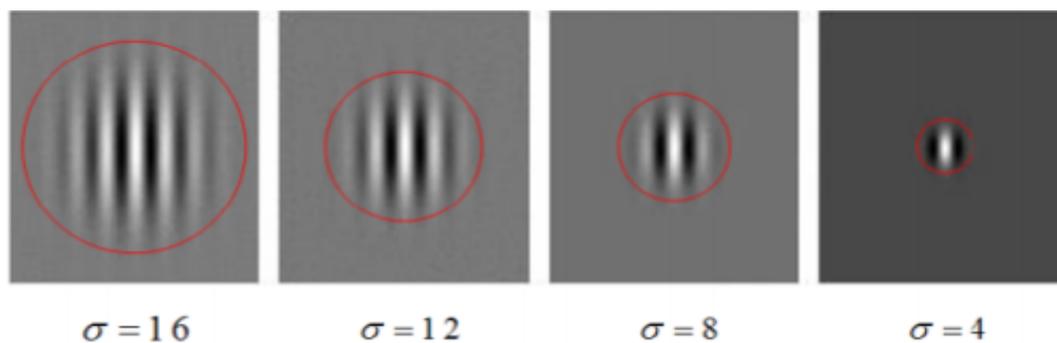


FIGURE 2.17: Support temporel du filtre

- **Enveloppe de la Gaussienne ( $\gamma$ )** : Ce paramètre agit sur la forme de l'enveloppe Gaussienne, en l'étirant spatialement [35]. La figure ci-dessous montre l'effet du paramètre  $\gamma$  sur le filtre de Gabor.

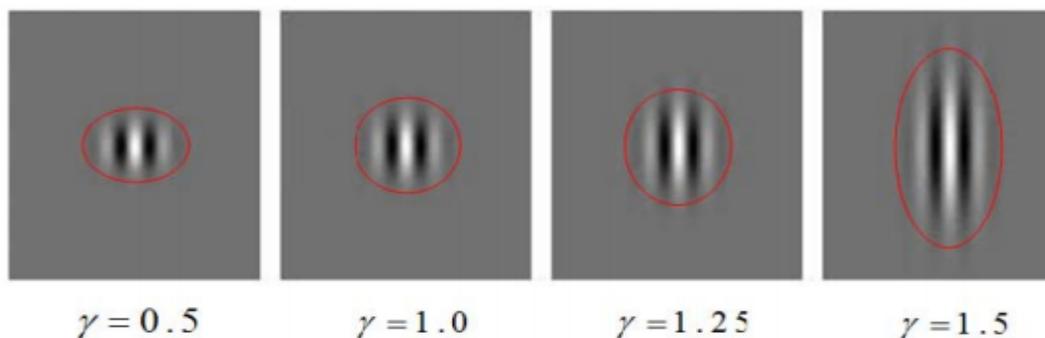


FIGURE 2.18: Forme de l'enveloppe Gaussienne

## Chapitre 2. Description des transformées multi-échelles pour l'extraction de caractéristiques et combinaison de classifieurs

Dans les applications de traitement d'images réelles, les caractéristiques sont généralement extraites à l'aide d'un banc de filtres de Gabor avec un nombre d'orientations différentes. L'association d'un ensemble de filtres de Gabor permet de couvrir plus largement l'espace fréquentiel et de détecter un plus grand nombre d'orientations, donc d'extraire tous les contours de l'image. Les fréquences  $\lambda_n$  et les orientations  $\theta_m$  des filtres de Gabor sont obtenues par les équations suivantes :

$$\lambda_n = \frac{\pi}{2} \sqrt{2}^{-(n-1)} \quad n = 1, 2, \dots, 5 \quad (2.13)$$

$$\theta_m = \frac{\pi}{8} (m-1) \quad m = 1, 2, \dots, 8 \quad (2.14)$$

La figure 2.19 représente un banc de 40 filtres de Gabor et le résultat de son application sur une image IRM cérébrale.

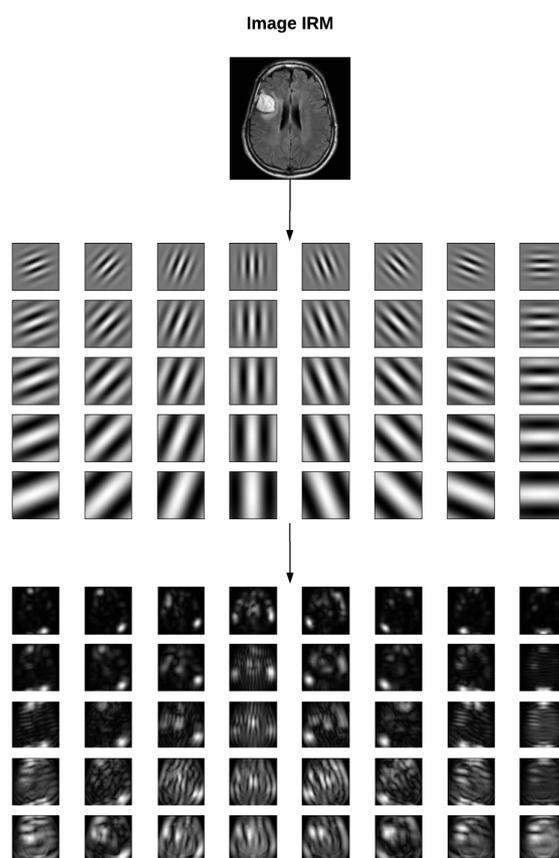


FIGURE 2.19: Résultats d'application d'un banc de 40 filtres de Gabor sur une image IRM

## 2.3. Transformées multi-échelles

### 2.3.3 Transformée en Shearlet

Les Shearlets sont similaires aux ondelettes, mais ils diffèrent par certaines caractéristiques. En raison de sa nature isotrope, la transformation en ondelettes ne peut pas fournir des informations supplémentaires sur la géométrie de l'ensemble des singularités d'une fonction. Les images naturelles vont donc être difficiles à représenter à l'aide d'une transformée en ondelettes, à la fois à cause des contours et des textures. Ces limites des ondelettes ont motivé le développement de méthodes alternatives telles que la transformée en Shearlet [38].

La transformée en Shearlet est une transformée en ondelettes multi-échelles et multidimensionnelles, qui est capable d'adresser des informations anisotropes et directionnelles à différentes échelles. Elle combine la puissance des méthodes multi-échelles avec une capacité unique de capturer la géométrie des données multidimensionnelles et est de manière optimale efficace pour représenter des images contenant des bords, qui peuvent être détectés et localisés avec précision, ce qui la rend utile dans la classification des textures. Les Shearlets sont obtenus par translation, dilatation et cisaillement d'un nombre fini de fonctions génératrices. Ainsi, les éléments d'un système Shearlet sont distribués non seulement à différentes échelles et emplacements, mais aussi à divers orientations [39]. La construction de la transformée en Shearlet est générée comme décrit ci-dessous :

$$SH_{\phi} f(a, s, t) = \langle f, \phi_{a,s,t} \rangle, a > 0, s \in \mathbb{R}, t \in \mathbb{R}^2 \quad (2.15)$$

Où le facteur d'analyse  $\phi_{a,s,t}$  est appelé coefficient de Shearlet, qui est défini comme :

$$\phi_{a,s,t}(x) = |\det M_{a,s}|^{-\frac{1}{2}} \phi(M_{a,s}^{-1}x - t) \quad (2.16)$$

Dans laquelle  $M_{a,s}$  est donné par :

$$M_{a,s} = B_s A_a = \begin{pmatrix} a & \sqrt{as} \\ 0 & \sqrt{a} \end{pmatrix} \quad (2.17)$$

avec

$$A_a = \begin{pmatrix} a & 0 \\ 0 & \sqrt{a} \end{pmatrix} \quad (2.18)$$

et

$$B_s = \begin{pmatrix} 1 & s \\ 0 & 1 \end{pmatrix} \quad (2.19)$$

Où  $A_a$  est la matrice de dilatation anisotrope et  $B_s$  est la matrice de cisaillement [40].

La transformée en Shearlet décompose l'image d'entrée en un nombre d'images de sous-bandes, l'ampleur de chaque sous-bande de Shearlet a la même amplitude que celle de l'image initiale. La figure 2.20 représente la décomposition par transformée en Shearlet avec un nombre de niveau égal à 3. Elle consiste en un banc de filtres non séparables à deux canaux consistant

## Chapitre 2. Description des transformées multi-échelles pour l'extraction de caractéristiques et combinaison de classifieurs

en la fonction source concernée avec différentes directions à de nombreuses échelles et aspects ratios [41].

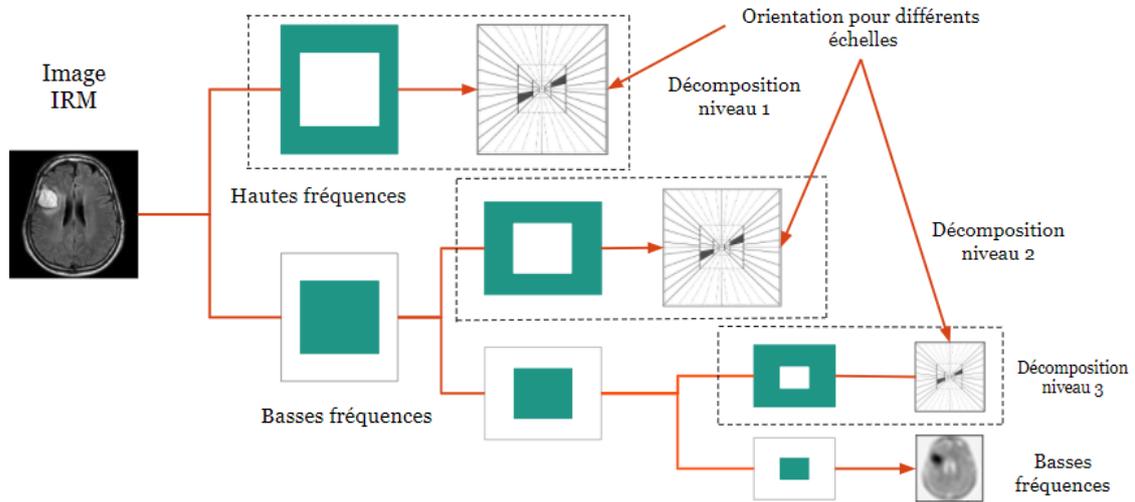


FIGURE 2.20: Décomposition en Shearlet à trois niveaux.

La figure 2.21 représente le résultat d'une décomposition d'une image IRM cérébrale par la transformée en Shearlet discrète avec un niveau égal à 3. Le paramètre  $j$  désigne l'échelle du filtre Shearlet, tandis que le paramètre de cisaillement  $s$  contrôle son orientation.

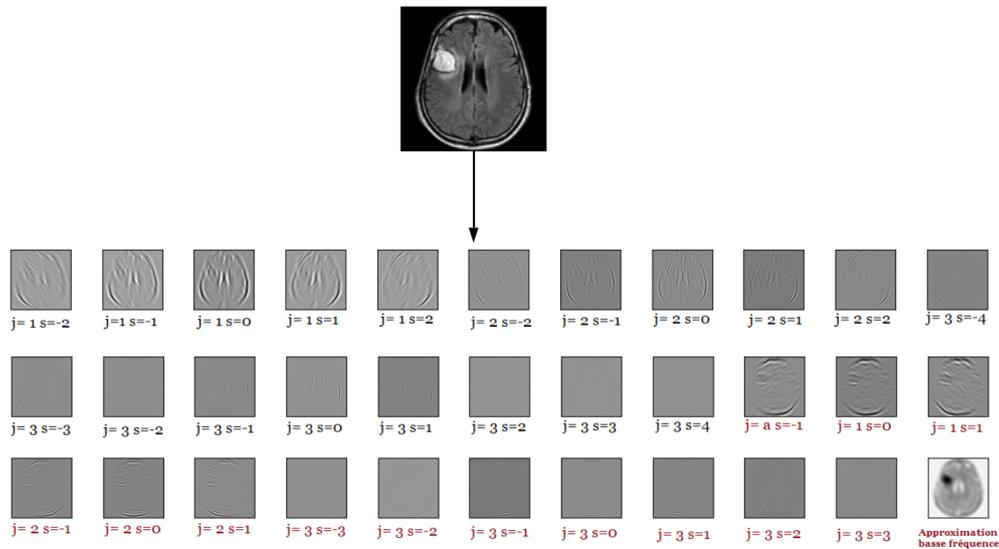


FIGURE 2.21: Résultat de la décomposition en Shearlet à trois niveaux d'une image IRM.

### 2.4 Extraction des caractéristiques

L'extraction de caractéristiques vise à réduire le nombre d'entités dans un ensemble initial de données brute en créant un nouvel ensemble de caractéristiques réduit, plus facile à gérer pour le traitement, qui sera en mesure de représenter la plupart des informations contenues dans l'ensemble de données d'origine. L'analyse de l'image médicale, la détermination du type de tissu (normal ou anormal) et la classification de la pathologie tissulaire sont effectuées en utilisant la texture, qui s'est avérée utile pour la détermination du type de la tumeur. L'analyse de texture est un paramètre important de la perception visuelle humaine et du système d'apprentissage automatique [42], elle est utilisée efficacement pour améliorer la précision du système de diagnostic. Dans notre travail, nous proposons d'utiliser deux types de caractéristiques qui décrivent les informations de structure d'intensité et de texture de l'image. Le premier type considère les caractéristiques statistiques qui sont déterminées à partir de la distribution spatiale des niveaux de gris  $x_i$  d'une image. Le deuxième type considère les caractéristiques de texture du second ordre qui ont été extraites à partir de la matrice de cooccurrence de niveau de gris (Gray Level Co-occurrence Matrix ou GLCM), implémentée non pas directement à partir des images originales, ni à partir d'images filtrées, mais par l'intermédiaire des transformées multi-échelles.

#### 2.4.1 Caractéristiques statistiques

Cinq caractéristiques statistiques ont été calculées à partir de l'image originale à savoir ; la moyenne, l'écart-type, l'asymétrie, le kurtosis et l'entropie. Ces caractéristiques sont présentées dans ce qui suit où  $M$  et  $N$  dénotent les dimensions de l'image et  $P_{(i,j)}$  désigne le niveau de gris de la  $i^{me}$  colonne et de la  $j^{me}$  ligne.

- **La moyenne**

La moyenne est calculée en ajoutant toutes les valeurs de pixels d'une image divisées par la taille de l'image [37]. Elle s'exprime par la relation suivante :

$$\mu = \frac{1}{M * N} \sum_{i=1}^M \sum_{j=1}^N P_{(i,j)} \quad (2.20)$$

- **L'écart-type**

Décrit la distribution de probabilité d'une population observée autour d'une moyenne et peut servir de mesure de l'inhomogénéité. Une valeur plus élevée indique un meilleur niveau d'intensité et un contraste élevé des bords d'une image [37]. L'écart-type s'exprime par la relation suivante :

$$\sigma = \sqrt{\frac{1}{M*N} \sum_{i=1}^M \sum_{j=1}^N (P_{(i,j)} - \mu)^2} \quad (2.21)$$

- **L'asymétrie**

Mesure le degré et la direction de la symétrie ou de l'asymétrie de la distribution des couleurs. Une distribution normale ou symétrique a une asymétrie de zéro. Cependant, dans le monde réel, les distributions normales sont difficiles à trouver. Par conséquent, l'asymétrie d'une distribution peut être positive si la queue de droite est plus longue ou grosse, et négative si la queue de gauche est plus longue ou grosse [37]. L'asymétrie est désignée par la formule suivante :

$$\eta = \frac{\sum_{i=1}^M \sum_{j=1}^N (P_{(i,j)} - \mu)^3}{M*N*\sigma^3} \quad (2.22)$$

- **Kurtosis**

Fournit des informations sur la forme de la distribution des valeurs. Plus précisément, kurtosis est une mesure de la façon dont la distribution est plate ou grande par rapport à la distribution normale [37]. Le kurtosis est définie comme :

$$\gamma = \frac{\sum_{i=1}^M \sum_{j=1}^N (P_{(i,j)} - \mu)^4}{M*N*\sigma^4} \quad (2.23)$$

- **L'entropie**

L'entropie mesure le caractère aléatoire de répartition des niveaux de gris. L'entropie sera élevée si les niveaux de gris sont répartis de façon aléatoire dans toute l'image [43, 44]. Elle est définie par la formule suivante :

$$\text{Entropie} = - \sum_{i=1}^M \sum_{j=1}^N P_{(i,j)} \log_2 P_{(i,j)} \quad (2.24)$$

## 2.4.2 Caractéristiques de texture

### La matrice de cooccurrence de niveau de gris GLCM

La matrice de cooccurrence de niveau de gris ( Gray Level Co-occurrence Matrix ou GLCM) est la méthode statistique d'examen des textures qui se base sur la relation entre les pixels voisins

## 2.4. Extraction des caractéristiques

à des distances et angles différents  $(d, \theta)$ . Elle estime des propriétés des images relatives à des statistiques de second ordre (2D). Une matrice de cooccurrence mesure la probabilité 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  $P(i, j|d, \theta)$  qui représente le nombre de fois où un pixel de niveau de gris  $i$  apparaît à une distance relative d'un pixel de niveau de gris  $j$  et selon une orientation donnée, ainsi le nombre de lignes et de colonnes dans la matrice GLCM est exactement égal au nombre de niveaux de gris dans l'image. La figure 2.22 montre une portion d'une image d'entrée se composant de 8 niveaux de gris. La relation entre les pixels est calculée horizontalement vers la droite  $\theta = 0^\circ$  une distance  $d = 1$ . Initialement, la valeur de chaque élément dans GLCM  $(i, j)$  est nulle, mais elle sera mise à jour en fonction de l'occurrence des pixels [45, 46, 47].

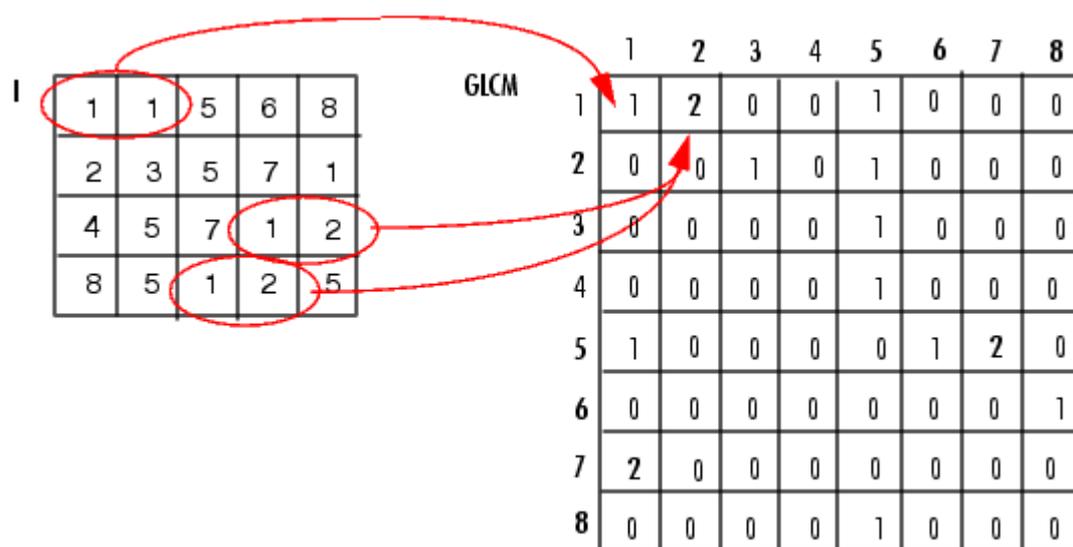


FIGURE 2.22: Exemple de calcul de la matrice de cooccurrence pour  $d = 1$  et  $\theta = 0$

Il existe deux cas de figures de la matrice de cooccurrence. Dans le premier cas, la matrice est symétrique où les paires séparées par  $d$  et  $-d$  (pour une direction  $\theta$ ) sont comptés. Dans le second cas, la matrice n'est pas symétrique et seules les paires séparées par une distance  $d$  sont dénombrées. Cela conduit à une matrice carrée qui a une dimension égale au nombre de niveaux d'intensité dans l'image, pour chaque distance  $d$  et orientation  $\theta$ . La classification des textures fines nécessite l'utilisation de petites valeurs pour  $d$  alors que la classification des textures grossières nécessite l'utilisation de grandes valeurs [47].

Les caractéristiques de texture extraites à partir de la matrice GLCM sont calculées à l'aide des équations citées ci-dessous, où  $P(i, j)$  est les probabilités calculées pour les valeurs dans GLCM et  $N$  est la taille de la matrice GLCM.

- **L'énergie**

Définit la mesure de la somme des carrés des éléments. Elle mesure l'homogénéité dans l'image. Lorsque les pixels sont très similaires, la valeur énergétique sera importante [43, 44]. Elle est définie par la formule suivante :

$$\text{Energie} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P^2(i, j) \quad (2.25)$$

- **Le contraste**

Le contraste est la quantité de variation locale présente dans une image, elle mesure l'intensité d'un pixel et de son voisin sur l'image [43, 44]. Il est définie par la formule suivante :

$$\text{Contraste} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - j)^2 P(i, j) \quad (2.26)$$

- **L'homogénéité**

Mesure de l'uniformité locale dans une image. Des valeurs d'homogénéité élevées indiquent l'absence de changements intra-régionaux et une distribution locale homogène dans les textures d'image [43, 44]. Elle est définie par la formule suivante :

$$\text{Homogénéité} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{P(i, j)}{1 + (i - j)^2} \quad (2.27)$$

- **La corrélation**

La corrélation nous donne des informations sur la corrélation d'un pixel avec ses pixels voisins. Sa valeur varie de -1 à 1, où -1 est négativement parfaitement corrélé, 0 est non corrélé et 1 est positivement parfaitement corrélé [43, 44]. Elle est définie par la formule suivante :

$$\text{Corr}(d, \theta) = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{i * j * P_d^\theta(i, j) - \mu_x * \mu_y}{\sigma_x * \sigma_y} \quad (2.28)$$

où  $\mu_x$  et  $\mu_y$  représente la moyenne GLCM basée respectivement sur le pixel de référence et le pixel voisin, tandis que  $\sigma_x$  et  $\sigma_y$  représente l'écart type le long des deux moyennes, étant donné que :

## 2.4. Extraction des caractéristiques

$$\mu_x = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} i * P_d^\theta(i, j) \quad (2.29)$$

$$\mu_y = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} j * P_d^\theta(i, j) \quad (2.30)$$

$$\sigma_x = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \sqrt{(i - \mu_x)^2 P_d^\theta(i, j)} \quad (2.31)$$

$$\sigma_y = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \sqrt{(j - \mu_y)^2 P_d^\theta(i, j)} \quad (2.32)$$

La figure 2.23 représente un schéma résumant l'opération d'extraction de caractéristiques statistiques et de texture avec les transformées multi-échelles.

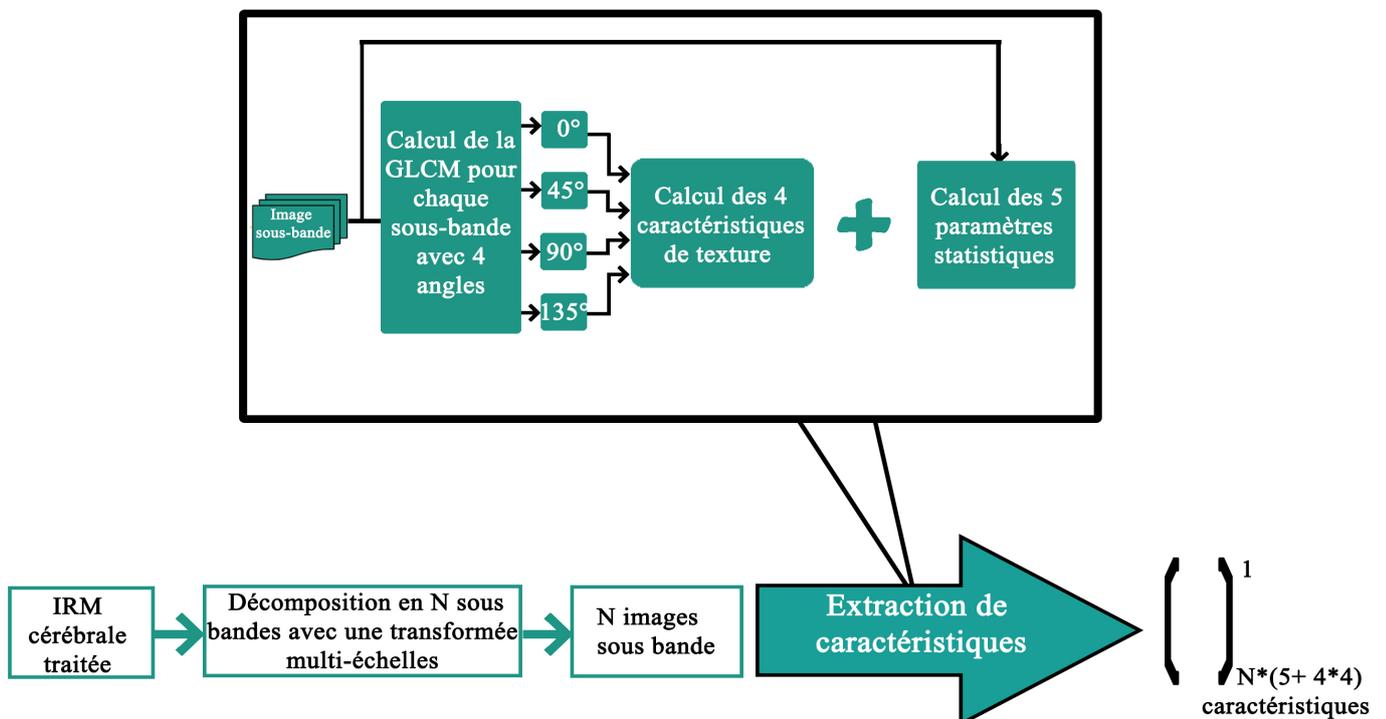


FIGURE 2.23: Schéma résumant l'étape d'extraction de caractéristiques.

## 2.5 Les machines à vecteur de support (SVM)

Les machines à vecteurs de support, ou Séparateur à Vaste Marge (SVM) sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de classification binaire et de régression. Les SVMs sont une généralisation des classifieurs linéaires. Ils ont été développés dans les années 1990 par Vladimir Vapnik. Aujourd'hui, elles sont utilisées par de nombreux chercheurs et dans différents domaines tels que l'aide au diagnostic médical qui fait l'objet de notre étude. SVM permet de résoudre des problèmes linéairement et non linéairement séparables, en reposant sur deux notions clés : celle de la maximisation de la marge et celle de la fonction noyau. L'avantage principal du classifieur SVM est sa facilité d'emploi. Ce classifieur est couramment utilisé jusqu'à aujourd'hui pour des problèmes de reconnaissance de formes [48, 49]. Il est réputé pour :

- Son optimalité garantie : En raison de la nature de l'optimisation convexe, la solution sera toujours un minimum global, pas un minimum local.
- Son astuce du noyau qui représente sa vraie force. Avec une fonction de noyau appropriée, presque n'importe quel problème complexe peut être résolu.
- Son bon fonctionnement sur des ensembles de données petits.
- Sa haute dimensionnalité car il fonctionne efficacement dans les espaces de grandes dimensions ( $\geq 10^{16}$ ).
- Sa bonne généralisation dans la pratique, le risque de sur-apprentissage est moindre si les paramètres sont judicieusement choisis.

Le but de l'approche SVM est de trouver une bonne séparation entre deux classes. Le classifieur linéaire qui effectue une séparation de données entre les classes est appelé hyperplan.

Il existe une multitude d'hyperplans valides, c'est-à-dire qui assurent une séparation entre les deux classes. La principale particularité des SVMs est que l'hyperplan choisi doit être optimal. Nous allons donc en plus chercher parmi les hyperplans valides, celui qui passe au milieu des deux classes. Intuitivement, cela revient à chercher l'hyperplan le plus sûr, c'est-à-dire celui qui passe au milieu des deux classes et qui offre le maximum de précision pour une bonne classification. Formellement, cela revient à chercher un hyperplan dont la distance minimale aux exemples d'apprentissage est maximale. On appelle cette distance « marge » entre l'hyperplan et les vecteurs de support [50]. L'hyperplan séparateur optimal est celui qui maximise la marge d'où le nom des séparateurs à vaste marge (Voir figure 2.23).

## 2.5. Les machines à vecteur de support (SVM)

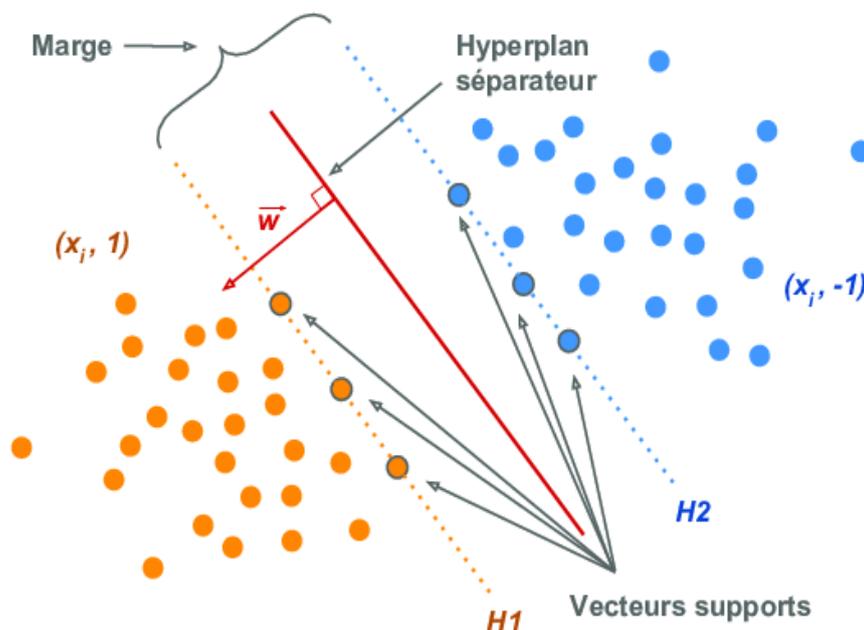


FIGURE 2.24: Principe de séparation du SVM

L'équation caractéristique d'un hyperplan séparateur est  $h(x) = w^\top \cdot x + b = 0$  où  $w$  est le vecteur normale à l'hyperplan de séparation et  $b$  est le déplacement par rapport à l'origine. Pour décider à quelle classe un vecteur  $x_i$  appartient, il suffit de prendre le signe de la fonction de décision  $\text{sign}(h(x))$  [51]. La règle de décision correspond à observer de quel côté de l'hyperplan se trouve l'exemple  $x_k$ , si  $h(x_k)$  est positif ou nul, alors  $x_k$  est d'un côté de l'hyperplan et appartient à la première classe, sinon  $x_k$  est de l'autre côté de l'hyperplan et donc appartient à la seconde classe.

$$\begin{cases} h(x) \geq 0 \implies x \in \text{Classe 1} \\ h(x) < 0 \implies x \in \text{Classe 2} \end{cases} \quad (2.33)$$

Ainsi on assigne à tout point  $x_k$  un label  $l_k$  qui vaut 1 si  $x_k$  appartient à la première classe, et -1 si  $x_k$  appartient à la seconde classe. Il existe plusieurs couples  $(w, b)$  qui décrivent ce même hyperplan, donc afin de faciliter l'optimisation on ne considère que les couples  $(w, b)$  tel que les vecteurs support  $x_k$  vérifient :

$$\forall k, l_k \left( w^\top \cdot x_k + b \right) \geq 1 \quad (2.34)$$

La marge est la distance minimale entre les échantillons d'apprentissage et l'hyperplan séparateur qui satisfait la condition de l'équation 2.34, elle est égale à  $\frac{2}{\|w\|}$  [52, 53], puisque l'on

## Chapitre 2. Description des transformées multi-échelles pour l'extraction de caractéristiques et combinaison de classifieurs

---

cherche un hyperplan optimal qui maximise la marge on aura à minimiser l'expression inverse  $\frac{\|\tilde{w}\|^2}{2}$ . La formulation dite primale des SVMs s'exprime alors sous la forme suivante :

$$\begin{cases} \text{minimiser } \frac{\|\tilde{w}\|^2}{2} \\ \text{sous la contrainte } \forall k, l_k (w^T \cdot x_k + b) \geq 1 \end{cases} \quad (2.35)$$

Pour obtenir la formulation duale, on introduit les multiplicateurs  $\alpha_k$  de Lagrange, on obtient ainsi une fonction de décision permettant de classer une nouvelle observation  $x$ , elle est donnée par :

$$h(x) = \sum_{k=1}^n \alpha_k^* y_k x_k^T x + b^* \quad (2.36)$$

Où :

$b$  : Le biais.

$x$  : Les données à classer.

$x_k$  : Les vecteurs de support.

$\alpha_k$  : Les multiplicateurs de Lagrange.

$l_k$  : Les labels de classe des données d'entraînement.

Dans la figure 2.24, la partie gauche nous montre qu'avec un hyperplan optimal, un nouvel exemple reste bien classé, par contre dans la partie droite où il y a une marge plus petite, le nouvel exemple se voit mal classé [52, 53].

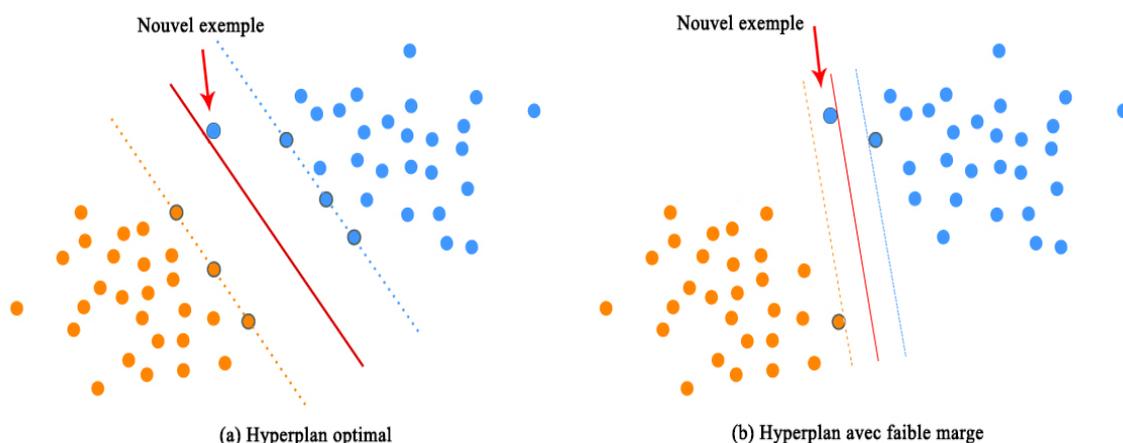


FIGURE 2.25: Choix de l'hyperplan optimal

## 2.5. Les machines à vecteur de support (SVM)

### Séparation linéaire et non linéaire

Il existe deux cas de séparation, les cas linéairement séparables et les cas non linéairement séparables. Le premier cas est le plus simple à réaliser mais dans la majorité des cas pratiques, très peu de problèmes peuvent être séparés d'une manière linéaire. Pour surmonter les inconvénients du deuxième cas, l'idée des SVMs est de changer l'espace des données (figure 2.25). La transformation non-linéaire des données peut permettre une séparation linéaire des exemples dans un nouvel espace. On va donc procéder à un changement de dimension. Cette nouvelle dimension est appelée «espace de redescription». En effet, plus la dimension de l'espace de redescription est grande, plus la probabilité de pouvoir trouver un hyperplan séparateur entre les exemples est élevée [48, 53].

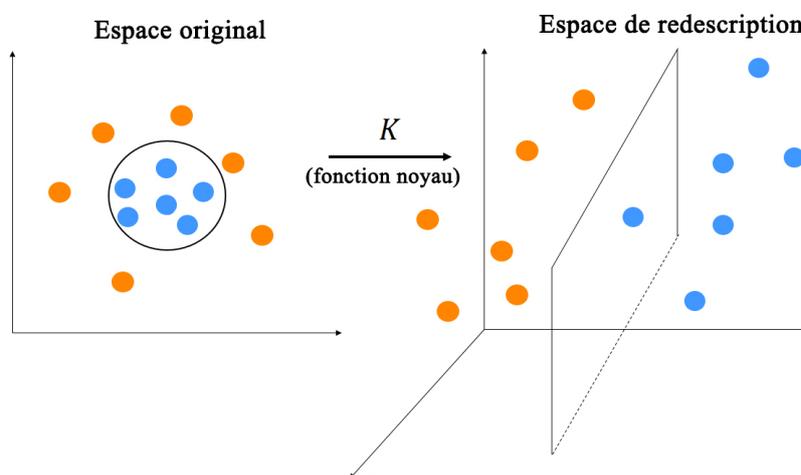


FIGURE 2.26: Transformation d'espace

Nous avons donc transformé un problème non linéairement séparable dans l'espace de représentation à deux dimensions à un cas linéairement séparable dans un espace de plus grande dimension qui est l'espace de redescription (Features space). Cette transformation est réalisée via une fonction noyau (Kernel). En pratique, plusieurs fonctions de noyaux existent connues et il revient à l'utilisateur d'effectuer des tests pour déterminer celle qui convient le mieux à son application. Néanmoins, le noyau le plus pratique et le plus efficace dans la plupart des tâches de reconnaissance de formes est la fonction de base radiale (ou RBF pour Radial Basis Function). Sa flexibilité et ses caractéristiques générales en font le choix optimal dans les problèmes de classification complexes, tels que la classification des tumeurs cérébrales. Le noyau RBF s'exprime par l'équation suivante :

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (2.37)$$

### 2.5.1 Architecture du SVM en multi-classe

Initialement, SVM permet de séparer les données étiquetées en deux classes seulement. Mais quand un problème a  $M$  se présente, des architectures heuristiques existent afin de transformer le problème multi-classes en un ensemble de problèmes bi-classes. Nous présentons les approches les plus connues, notamment, l'architecture **un-contre-tous** et l'architecture **un-contre-un** [50]. Ces deux architectures ne sont pas équivalentes, elles peuvent donner des résultats différents pour une même entrée, et avec les mêmes données d'entraînement.

- **Un-contre-tous** (One-vs-all) : implique de diviser l'ensemble de données multi-classes en plusieurs problèmes de classification binaire. Elle consiste à construire  $M$  classifieurs binaires en attribuant le label 1 aux échantillons de l'une des classes et le label -1 à toutes les autres. En phase de test, le classifieur donnant la valeur de la fonction de décision la plus élevée remporte le vote. Cette approche nécessite donc la création d'un modèle pour chaque classe [50].
- **Un-contre-un** (One-vs-One) : consiste à construire  $M * (M - 1) / 2$  classifieurs binaires en confrontant chacune des  $M$  classes. En phase de test, l'échantillon à classer est analysé par chaque classifieur et un vote majoritaire permet de déterminer sa classe. Chaque modèle de classification binaire peut prédire une étiquette de classe et le modèle avec le plus de prédictions ou de votes est sélectionné [50].

Il peut sembler logique que le temps total d'entraînement avec la stratégie «un-contre-un» est plus large qu'avec la stratégie «un-contre-tous», car il faut entraîner davantage de classifieurs binaires, mais ce n'est pas forcément vrai pour des classifieurs SVM. En effet, le temps d'apprentissage d'un SVM augmente considérablement avec le nombre d'échantillons d'entraînement. Ainsi, pour des problèmes impliquant un petit nombre d'échantillons d'apprentissage, il est généralement plus rapide de former les  $M * (M - 1) / 2$  classifieurs SVM de la stratégie «un-contre-un» que les  $M$  SVM du «un-contre-tous». Pareil pour la complexité du processus décisionnel, il peut sembler logique que la prise de décision avec la stratégie «un-contre-un» est plus complexe qu'avec la «un-contre-tous», car il faut évaluer plus de fonctions de décision, mais, comme précédemment, c'est pas nécessairement vrai avec les SVM. En effet, la complexité de la prise de décision d'un SVM est directement liée aux nombres de vecteurs de support, et bien que la prise de décision soit plus compliquée dans le cas de multi-classes, il est raisonnable de considérer que la complexité est proportionnel au nombre total de vecteurs de support [54].

## 2.6 Combinaison de classifieurs

La combinaison de classifieurs cherche à combiner des informations obtenues de différents systèmes dont les principes de fonctionnement peuvent être très divers et ainsi tirer profit au mieux de la complémentarité des systèmes de décision individuels mis en cause. L'idée principale

## 2.6. Combinaison de classifieurs

derrière la combinaison de classifieurs est l'augmentation de la qualité de la reconnaissance du système par rapport à chacun des classifieurs isolés, c'est-à-dire de collecter de l'information de plusieurs sources et de décider à travers des règles de combinaison de l'appartenance d'une donnée à une classe. Il existe différentes topologies de combinaison de classifieurs à savoir ; la combinaison série , la combinaison parallèle et la combinaison hybride.

### 2.6.1 Stratégies de Combinaison

#### — Combinaison série

La combinaison série, appelée également combinaison séquentielle, est organisée en niveaux successifs de décision permettant de réduire progressivement le nombre de classes possibles. Dans chaque niveau, il existe un seul classifieur qui prend en compte la réponse fournie par le classifieur placé en amont afin de traiter les rejets ou confirmer la décision obtenue sur la forme qui lui est présentée (figure 2.27). Une telle approche permet généralement de diminuer le taux d'erreur globale de la chaîne de reconnaissance. Néanmoins, une combinaison de ce type demeure particulièrement sensible à l'ordre dans lequel sont placés les classifieurs.

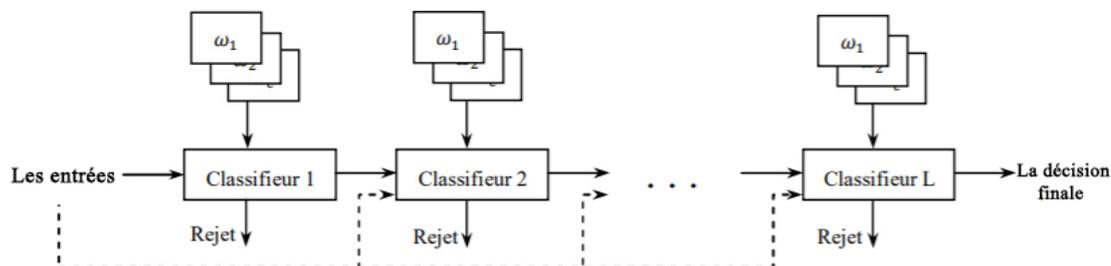


FIGURE 2.27: Schéma de combinaison séquentielle de classifieurs

#### — Combinaison parallèle

L'architecture de combinaison que nous avons adoptées pour notre système est la combinaison parallèle. A la différence de l'approche séquentielle, l'approche parallèle conduit dans un premier temps différents classifieurs à fonctionner indépendamment les uns des autres, puis fusionne leurs réponses respectives. Cette fusion est faite soit de manière démocratique, dans le sens où elle ne favorise aucun classifieur par rapport à un autre, soit au contraire dirigée et, dans ce cas, on attribue à la réponse de chaque classifieur un poids en fonction de ses performances. L'ordre d'exécution des classifieurs n'intervient pas dans cette approche. La figure 2.28 fournit une représentation de la combinaison parallèle de classifieurs.

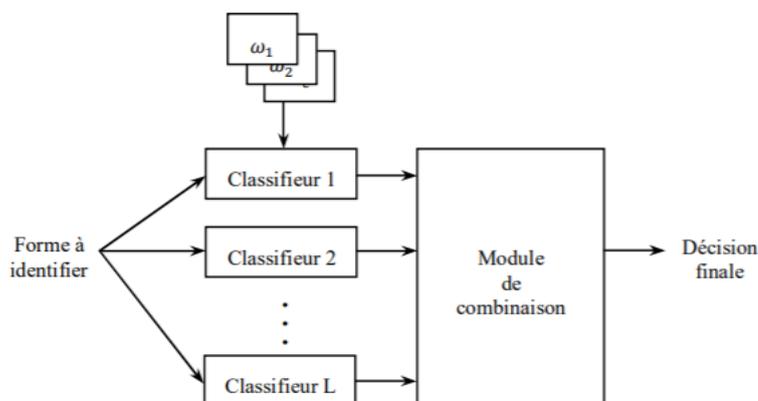


FIGURE 2.28: Schéma de combinaison parallèle de classifieurs

— **Combinaison hybride**

L'approche hybride combine les deux architectures parallèles et séquentielles afin de profiter pleinement de chaque classifieur utilisé.

### 2.6.2 Types de Réponses fournies par un classifieur

Les réponses fournies par un classifieur peuvent être divisées en trois catégories suivant le niveau d'information apporté par le classifieur :

— **Sortie de type classe**

Les sorties de type classe sont les moins riches en information et les plus simples à utiliser. Son principal avantage est qu'elle peut être utilisée pour tout type de sortie de classifieur, quelle que soit sa structure. Le classifieur ne donne que la proposition de la classe de l'entrée à reconnaître sans aucune autre information ; autrement dit, nous aurons

$$e_j(x) = C_i, i \in \{1, \dots, M\} \quad (2.38)$$

où  $C_i$  est la classe attribuée par le classifieur  $e_j$  à l'entrée  $x$ .  $M$  étant le nombre de classes.

— **Sortie de type rang**

Ce type de sortie reflète l'ordre de préférence des propositions fournies par le classifieur, cela se traduit par l'attribution d'un rang pour chaque classe ; Les rangs attribués par chaque classifieur peuvent être considérés comme étant des votes pour toutes les classes. Ayant un nombre  $M$  de classes, chaque classifieur attribue un poids  $N$  à la classe placée au début de la liste, un poids  $M - 1$  à la seconde classe et ainsi de suite. La classe placée à la

## 2.6. Combinaison de classifieurs

---

fin de la liste reçoit un seul vote.

$$e_j(x) = (r_{1,j}, r_{2,j}, \dots, r_{M,j}) \quad (2.39)$$

où  $r_{i,j}$  est le rang attribué à la classe  $C_i$  par le classifieur  $e_j$

### — Sortie de type mesure

Cette sortie est la plus riche en informations puisque le classifieur dans ce cas associe à chaque classe une mesure de confiance. La sortie du classifieur est donc un vecteur de mesures de taille  $M$  [55].

$$e_j(x) = (m_{1,j}, m_{2,j}, \dots, m_{M,j}) \quad (2.40)$$

où  $m_{i,j}$  est la mesure attribuée à la classe  $i$  par le classifieur  $e_j$

## 2.6.3 Règles de combinaison

### Combinaison de classifieurs parallèle de type « classe » : Vote majoritaire

Tous les classifieurs de type classe proposent uniquement la classe d'appartenance de la forme à reconnaître [56, 57]. Dans ce cas, les seules méthodes à appliquer pour combiner ces résultats sont basées sur le principe du vote.

Le vote majoritaire consiste à faire voter de manière indépendante plusieurs classifieurs et à retenir la réponse majoritaire, correspondant normalement à la meilleure solution. L'inconvénient de cette méthode est dans le cas où plus de la moitié des classifieurs de base obtiennent de faux résultats.

Les résultats de la combinaison est la classe la plus proposée parmi  $N$  classifieurs. Néanmoins, il y a rejet si toutes les classes ont le même nombre de votes. Dans ce cas, les risques de conflits sont particulièrement importants.

### Combinaison de classifieurs parallèle de type « mesure »

Il existe de nombreuses méthodes de combinaison de classifieurs parallèle de type mesure, et selon [58] la combinaison par règles basées sur la mesure sont de loin les plus couramment utilisées dans la pratique. En effet, bien qu'un combineur puisse être spécifiquement choisi pour optimiser la performance dans une application particulière, ces règles de combinaison montrent toujours un bon comportement à travers de nombreux problèmes, et sont assez simples à appliquer [58].

Le principe de base derrière ces méthodes est le suivant : les classifieurs sont indépendants et

## Chapitre 2. Description des transformées multi-échelles pour l'extraction de caractéristiques et combinaison de classifieurs

---

estiment des probabilités a posteriori des classes. Ainsi, pour reconnaître une forme  $x$ , on utilise une règle de décision  $E(x)$  qui revient à choisir la classe  $C_i$  pour laquelle la probabilité a posteriori  $P_i$  est la plus élevée :

$$E(x) = \begin{cases} C_i & \text{si } \max_{i=1}^M P_i = \max_{m=1}^M P_m \\ \text{rejet} & \text{sinon} \end{cases} \quad (2.41)$$

Où  $M$  désigne le nombre de classes et  $L$  désigne le nombre de classifieurs. La probabilité a posteriori  $P_m$  peut être calculée selon les règles suivantes :

- **La moyenne**

$$P_m = \frac{1}{L} \sum_{j=1}^L m_{i,j} \quad (2.42)$$

- **La somme**

$$P_m = \sum_{j=1}^L m_{i,j} \quad (2.43)$$

- **Le produit**

$$P_m = \prod_{j=1}^L m_{i,j} \quad (2.44)$$

- **Le maximum**

$$P_m = \max_{j=1}^L m_{i,j} \quad (2.45)$$

- **Le minimum**

$$P_m = \min_{j=1}^L m_{i,j} \quad (2.46)$$

- **La moyenne pondérée**

$$P_m = \frac{1}{L} \sum_{j=1}^L w_j m_{i,j} \quad (2.47)$$

- **La somme pondérée**

$$P_m = \sum_{j=1}^L w_j m_{i,j} \quad (2.48)$$

Où  $m_{i,j}$  désigne la mesure de confiance de la classe  $C_i$  par le classifieur  $e_j$ .

La règle du maximum consiste à choisir la classe pour laquelle la probabilité  $m_{i,j}$  est la plus élevée. Si le classifieur qui propose cette confiance a une mauvaise performance alors la règle maximum n'est pas fiable.

## 2.7. Conclusion

La règle minimum consiste à choisir le classifieur qui propose la probabilité la plus faible. Comme la règle maximum, il est difficile de prédire les situations dans lesquelles cette règle est la plus efficace.

Les deux dernières méthodes consistent tout simplement à appliquer des pondérations aux sorties des classifieurs. Où  $w_j$  est le coefficient qui détermine l'importance attribuée au  $j^{\text{ème}}$  classifieur dans la combinaison ( $j = 1, \dots, L$ ).

La structure de la combinaison de classifieurs proposée dans ce travail est montrée par la figure 2.29.

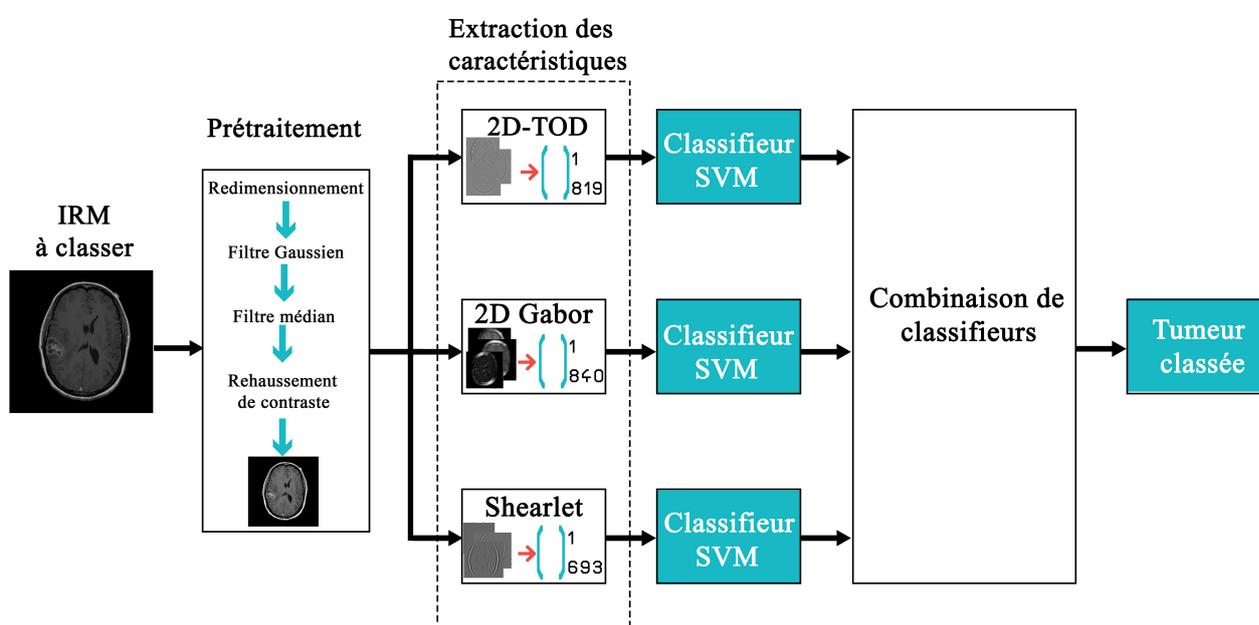


FIGURE 2.29: Architecture du système multi-classifieurs proposée

## 2.7 Conclusion

Dans ce chapitre, nous avons illustré les outils utilisés dans notre travail. Après une phase de prétraitement, nous avons dressé un panorama des méthodes d'analyse de la texture, en commençant par l'exposition des transformées en ondelettes, transformées de Gabor et transformées en Shearlet. Par la suite, des caractéristiques d'intensité et de texture ont été adoptées pour une meilleure représentation de l'information contenue dans les images d'entrée, en se basant sur l'histogramme d'une image et la matrice de cooccurrence de niveau de gris (GLCM). Les vecteurs caractéristiques obtenus seront utilisés comme données d'entrée pour l'architecture basée sur la combinaison de classifieurs. La combinaison est un outil efficace pour réaliser de grandes performances sans augmenter la complexité des techniques de classification existantes.

## **Chapitre 2. Description des transformées multi-échelles pour l'extraction de caractéristiques et combinaison de classifieurs**

---

L'évaluation de la performance est essentielle pour confirmer l'avantage et l'efficacité de l'architecture proposée, ainsi le chapitre suivant sera consacré à la présentation des résultats obtenus.

### 3.1 Introduction

Afin de pouvoir détecter et distinguer entre les différents types/grades des tumeurs cérébrales, les différentes méthodologies et techniques de combinaison discutées dans le chapitre précédent sont appliquées à trois bases de données standards, à savoir, Kaggle, Rembrandt et Figshare constituées d'images cérébrales IRM. Quatre études indépendantes ont été menées ; une classification binaire afin d'identifier des cas tumoraux des non tumoraux, une classification selon le type méningiome, gliome et hypophyse, une classification plus poussée des gliomes soit en différents grades Grade II, Grade III et Grade IV, soit selon le type et le grade astrocytomes pilocytiques, astrocytomes diffus, astrocytomes anaplasiques, glioblastomes et oligodendrogliome. Ce chapitre est dédié à la présentation et la discussion des différents tests effectués et résultats expérimentaux obtenus.

### 3.2 Données expérimentales utilisées

Pour estimer les performances de notre système, nous avons choisi trois bases de données publiques, à savoir Kaggle <sup>1</sup>, Figshare <sup>2</sup> et Rembrandt <sup>3</sup>.

- 
1. <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection>
  2. [https://figshare.com/articles/brain\\_tumor\\_dataset/1512427/5](https://figshare.com/articles/brain_tumor_dataset/1512427/5)
  3. <https://wiki.cancerimagingarchive.net/display/Public/REMBRANDT>

### 3.2.1 Base de données Kaggle

La base Kaggle est constituée de 247 images IRM cérébrales pondérées en T1 dont 155 sont anormales et 92 normales, avec différentes résolutions. Les données ont été collectées à partir de Google Images en 2019. 122 et 125 images sont utilisées, respectivement pour l'apprentissage du système et le test, et sont distribuées comme suit : 61 données apprentissage pour les deux classes, 31 données test sans tumeurs et 94 données test avec tumeurs. La figure 3.1 illustre des IRM d'un cas sans tumeur et un autre avec tumeur.

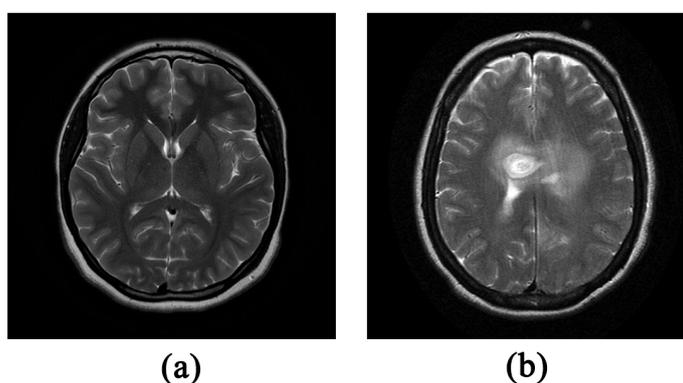


FIGURE 3.1: Échantillons d'images IRM provenant de la base Kaggle, (a) cas sain, (b) cas tumoral

### 3.2.2 Base de données Figshare

La base de donnée Figshare a été acquise à l'hôpital Nanfang et à l'hôpital général de l'université médicale de Tianjing, en Chine, de 2005 à 2010 [19], puis publié en ligne avec diverses versions depuis 2015 jusqu'à sa dernière version en 2017. Elle est fournie sous la forme d'un ensemble de coupes, qui contient 3064 images pondérées en T1 de taille 512 x 512 pixels, disponibles en format .MAT (extension fourni par MATLAB pour enregistrer et charger des données de l'espace de travail). Ces images cérébrales sont répartis en trois classes : méningiome (708 images), gliome (1426 images) et la tumeur de l'hypophyse (930 images). Les images ont été acquises à partir de 233 patients dans trois plans différents : sagittale (1025 images), axiale (994 images) et coronale (1045 images). 1416 images sont dédiées à l'apprentissage du système, tandis que les 1648 images restantes sont dédiées à la phase de test. Le tableau 3.1 résume la distribution des données par classe. Les exemples de différents types de tumeurs, ainsi que les différents plans, sont présentés dans la figure 3.2.

### 3.2. Données expérimentales utilisées

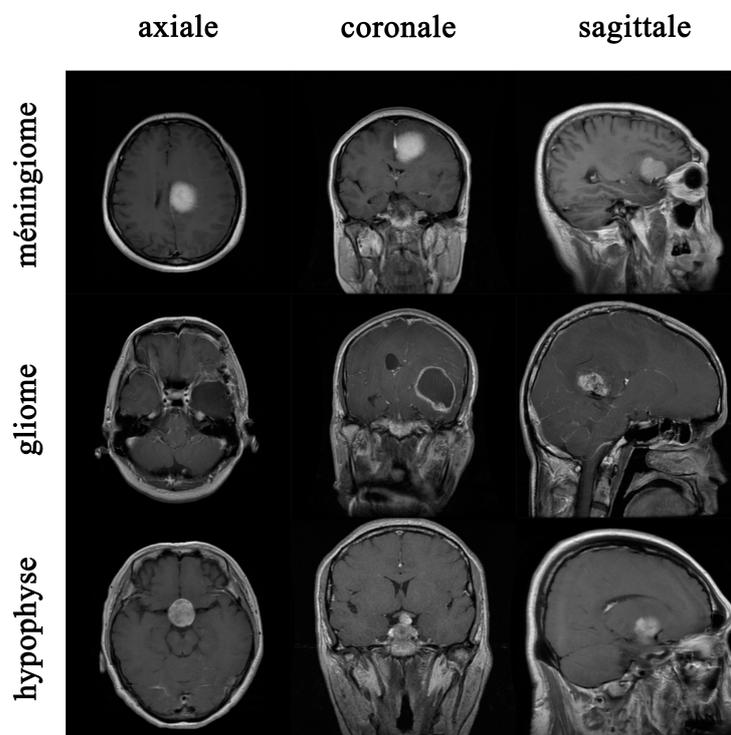


FIGURE 3.2: Représentation des images IRM montrant différents types de tumeurs dans différents plans

TABLE 3.1: Distribution des données par classe pour la base de données Figshare

Méningiome		Gliome		Hypophyse	
Apprentissage	Test	Apprentissage	Test	Apprentissage	Test
472	236	472	954	472	458

#### 3.2.3 Base de données Rembrandt

Le troisième ensemble de données provient de l'archive d'imagerie du cancer (The Cancer Imaging Archive, TCIA) [59]. Rembrandt (Repository of Molecular Brain Neoplasia Data) a été acquise à l'hôpital Henry Ford et à l'hôpital universitaire Thomas Jefferson aux Etats-Unis, puis publié en ligne en 2014. Cette base contient des images IRM multi-séries de 130 patients atteints de tumeurs gliales diverses, notamment par la taille et la complication, avec un total de 110020 images [60]. Nous avons sélectionné 981 images de 73 patients pondérée en T1 et avec rehaussement de contraste (injection d'un agent de contraste appelé gadolinium, pour mieux identifier la frontière de la tumeur) qui comprennent différents grades et types de gliome. Les images à

traiter sont sous la forme de coupes axiales, sagittales et coronales de taille 256 x 256 pixels, et sont au format DICOM (Digital Imaging and Communications in Medicine). Les figures 3.3 et 3.4 montrent des échantillons de chaque type et grade de gliome.

Cette base de données est utilisée pour deux expériences, la première distingue les tumeurs gliales par leurs types et la deuxième les distingue selon leurs grades. Il est à noter que pour la première expérience, le jeu de données est composé de trois classes : Les gliomes de grade II, les gliomes de grade III et les gliomes de grade IV, avec 327 images pour chaque grade (218 données apprentissage et 109 données test). D'un autre côté pour la deuxième expérience, les données sont réparties en 5 classes, à savoir : les astrocytomes diffus, les astrocytomes anaplasiques, les glioblastomes, les oligodendrogliomes de grade II et les oligodendrogliomes de grade III. Chaque classe contient 111 images (74 données apprentissage et 37 données test).

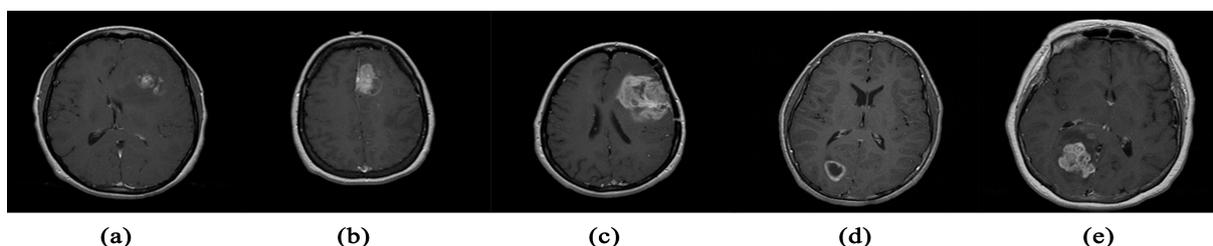


FIGURE 3.3: Exemple de cinq différents types d'images cérébrales axiales de gliomes (a) astrocytomes diffus, (b) astrocytomes anaplasiques, (c) glioblastomes, (d) oligodendrogliomes grade II et (e) oligodendrogliomes grade III.)

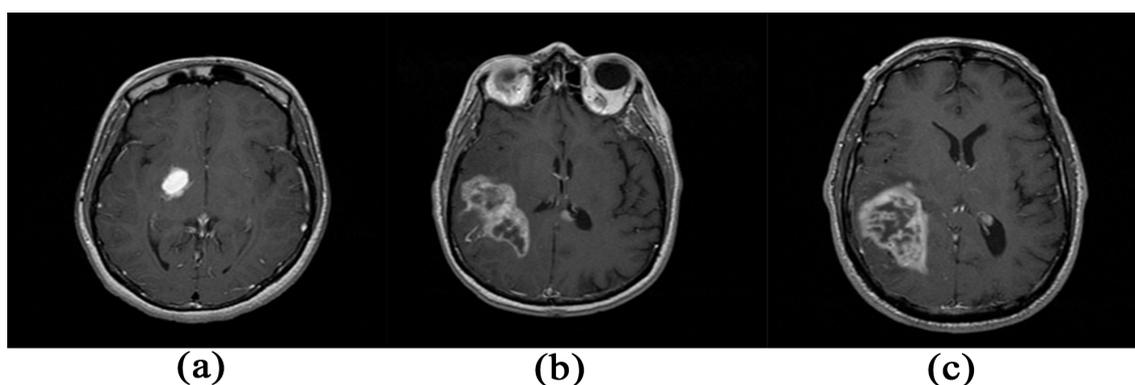


FIGURE 3.4: Différents grades de gliome (a) grade II, (b) grade III et (c) grade IV

Dans ce qui suit, nous allons présenter les résultats obtenus avec les 3 systèmes (TOD-2D + SVM), (GABOR-2D + SVM) et (Shearlet-2D + SVM) pour quatre différentes études.

- La première étude distingue les images avec tumeurs de celles sans tumeurs, cette étude est faite avec la base Kaggle.

### 3.3. Critères d'évaluation

---

- La deuxième étude faite sur l'ensemble de donnée Figshare, elle consiste à différencier entre trois types de tumeurs cérébrales, à savoir les gliomes, les méningiomes et les tumeurs hypophysaires.
- La troisième étude distingue les trois grades de gliomes, grade II, grade III et grade IV, l'ensemble de données utilisé est Rembrandt.
- La dernière étude, effectuée aussi sur la base Rembrandt, qui consiste en cinq type de gliomes, y compris les astrocytomes diffus, les astrocytomes anaplasiques, les glioblastomes, les oligodendrogliomes de grade II et les oligodendrogliomes de grade III.

### 3.3 Critères d'évaluation

Dans ce travail, la performance est déterminée en se basant sur la matrice de confusion qui mesure la qualité d'un système de classification, où chaque colonne représente le nombre d'occurrences d'une classe prédite, alors que chaque ligne représente le nombre d'occurrences d'une classe réelle. Elle est généralement utilisée pour des problèmes de classification binaire, mais peut aussi être utilisée pour des problèmes de multi-classes. Une illustration d'une matrice de confusion pour la classification binaire est représentée dans le tableau ci-dessous :

TABLE 3.2: Matrice de confusion binaire

Classe réelle	Classe prédite	
	A <sub>1</sub>	A <sub>2</sub>
A <sub>1</sub>	VP	FN
A <sub>2</sub>	FP	VN

- **VP** : vrai positif, correctement classé ou détecté.
- **FP** : faux positif, mal classé ou détecté.
- **FN** : faux négatif, rejeté incorrectement.
- **VN** : vrai négatif, correctement classé.

Plusieurs mesures importantes, telles que le taux de bonne classification (accuracy), la précision, le rappel et le F1-score peuvent être calculées à l'aide de la matrice de confusion.

- **Taux de bonne classification (TBC)**

C'est le rapport des exemples correctement prédits par le nombre total d'exemples. Il est calculé par la formule suivante :

$$\text{TBC} = \frac{\text{VP} + \text{VN}}{\text{VP} + \text{VN} + \text{FP} + \text{FN}} \quad (3.1)$$

- **Précision**

C'est-à-dire la proportion de prédictions correctes parmi les données que l'on a prédit positifs. Elle est calculée par la formule suivante :

$$\text{Précision} = \frac{VP}{VP + FP} \quad (3.2)$$

- **Rappel**

C'est le taux de vrais positifs, c'est à dire la proportion de positifs que l'on a correctement identifiés. Il est calculée par la formule suivante :

$$\text{Rappel} = \frac{VP}{VP + FN} \quad (3.3)$$

- **F1-Score**

C'est la moyenne harmonique de précision et de rappel qui est une mesure de la performance de la capacité de classification du modèle. Il est calculé par la formule suivante :

$$\text{F1-score} = 2 * \frac{\text{Précision} * \text{Rappel}}{\text{Précision} + \text{Rappel}} \quad (3.4)$$

### Remarque

- Le taux de bonne classification est utilisée lorsque les vrais positifs et les vrais négatifs sont plus importants, tandis que le F1-score est utilisé lorsque les faux négatifs et les faux positifs sont cruciaux.
- Le taux de bonne classification peut être utilisée lorsque la distribution des classes est similaire tandis que le F1-score est une meilleure métrique lorsqu'il y a des classes déséquilibrées.

Tous les tests et expériences ont été réalisés sous langage de programmation Python associé à différentes bibliothèques. Nos PC personnels ont été utilisés à cet effet, à savoir un Asus Intel Core i7-7500U CPU à @2.90 GHZ avec 8 Go de RAM et environnement windows 10.

### 3.4. Résultats des transformée multi-échelle pour la classification des tumeurs cérébrales

## 3.4 Résultats des transformée multi-échelle pour la classification des tumeurs cérébrales

Pour évaluer les performances des transformées multi-échelles pour la classification des tumeurs cérébrales, le classifieur SVM doit être formé en essayant trois fonctions noyau (linéaires, polynomiales et RBF) et en faisant varier ses paramètres qui sont : le paramètre de régularisation  $C$  et le paramètre de mise à l'échelle  $\gamma$ , puis le couple et le noyau donnant la meilleure précision d'entraînement sont sélectionnés. Nous avons utilisé la recherche par grille pour sélectionner les valeurs optimales de " $C$ ", et " $\gamma$ " parmi une grille de valeurs  $\{C = [1, 10, 50, 100, \dots, 100000]; \gamma = [10^{-1}, 10^{-2}, 5 \cdot 10^{-2}, \dots, 10^{-4}]\}$ . Ainsi, la grille de recherche a construit des dizaines de modèles SVM avec différents paramètres.

Les sections suivantes présentent les résultats de la classification en termes de sensibilité, de F1-score, de précision et de taux de bonne classification pour les données Kaggle, Figshare et Rembrandt. Plusieurs noyaux ont été testé mais les résultats suivants concernent le noyau RBF car il a donné les meilleures performances, la performance du noyau RBF est attendu car il a prouvé son efficacité sur les noyaux linéaires dans de nombreuses applications de classification.

### 3.4.1 Résultats de classification avec la transformée en ondelette discrète

Dans cet algorithme, la transformée en ondelette 2D est implémentée avec quatre niveaux de décomposition en utilisant différents filtres. Par conséquent, on retrouve quatre images de sous-bande (LL, LH, HH et HL) à chaque échelle. La sous-bande LL est utilisée pour la prochaine décomposition en ondelette et peut être considérée comme la composante d'approximation de l'image, tandis que les sous-bandes LH, HL et HH peuvent être considérées comme les composantes détaillées de l'image. Au fur et à mesure que le niveau de décomposition augmente, on accède à un composant d'approximation plus compact, mais plus grossier. Ainsi, les ondelettes donnent une base hiérarchique simple pour souligner les informations pertinentes contenues dans l'image. Un échantillon d'une image IRM cérébrale pathologique avec sa décomposition en ondelettes à quatre niveaux est présenté dans la figure ci-dessous :

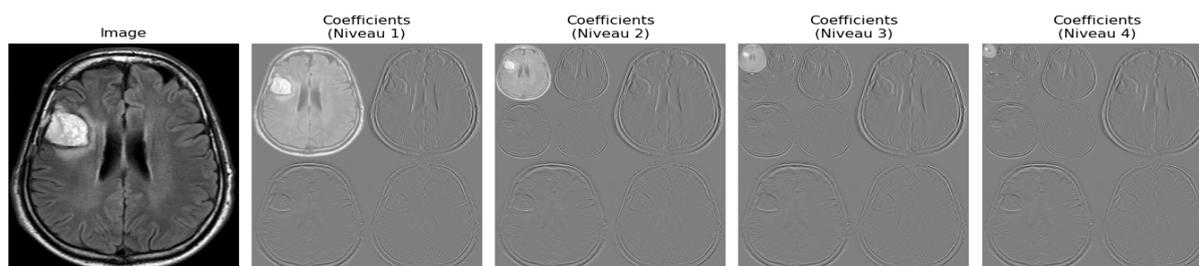


FIGURE 3.5: Décomposition en quatre niveaux d'une IRM avec la transformée en ondelette discrète type Haar.

Dans ce travail, la méthode proposée est mise en œuvre en utilisant des caractéristiques obtenues à partir de toutes les sous-bandes d'ondelettes. L'intensité et la texture de l'image sont contenues dans la sous-bande LL tandis que les sous-bandes LH et HL capturent les bords ou les composantes haute fréquence de l'image. La combinaison des caractéristiques extraites de chacune de ces sous-bandes améliore les performances du classifieur par rapport aux autres.

Une décomposition à quatre niveaux de l'image d'entrée donne 13 sous-bandes. Rappelons que pour chaque sous bande, nous avons calculé cinq statistiques (moyenne, écart-type, asymétrie, kurtosis et entropie) et quatre statistiques de second ordre (contraste, corrélation, énergie, homogénéité) calculées à partir de la matrice de cooccurrence des niveaux de gris (GLCM) en considérant quatre angles  $\theta$  différents ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ) à une distance fixe  $d = 1$ . En conséquence, 21 caractéristiques ( $5+4*4$ ) ont été obtenues à partir de chaque image de sous-bande, le nombre total de caractéristiques extraites avec la transformée en ondelette discrète est de 273 ( $21*13$ ) caractéristiques par image.

Il existe différentes familles d'ondelettes ; Haar, les Daubechies, les Symlets, les Coifflets et les ondelettes Biorthogonales. Nous avons testé chaque famille sur les trois bases de données, certaines donnent des résultats prometteurs par rapport à d'autres. Ainsi en comparant certains critères d'évaluation à partir des matrices de confusion, telle que la précision apportée et le taux d'erreur qui correspond au taux de mal classification, que les types d'ondelettes ont été choisis. Afin d'améliorer les performances de notre système, un choix de concaténation des caractéristiques des meilleures ondelettes a été adopté. Nous avons choisi de concaténer les caractéristiques extraites de plusieurs familles d'ondelette en se basant sur leurs performances, pour les 4 études tels que :

- **Pour l'étude 1 (tumeur/non tumeur) :** concaténation de vecteur caractéristiques des ondelettes Haar et Biorthogonales.
- **Pour l'étude 2 (différencier entre les trois types de tumeurs) :** concaténation de vecteur caractéristiques des ondelettes Haar, Daubechie et Symlet.
- **Pour l'étude 3 (classer les gliomes selon le grade) :** concaténation de vecteur caractéristiques des ondelettes Haar , Daubechies et Biorthogonales.
- **Pour l'étude 4 (classer les gliomes selon le type) :** une concaténation de vecteur caractéristiques des ondelettes Haar, Coifflets et Daubechies.

La figure 3.6 présente les matrices de confusion, tandis que le tableau 3.3 fournit les différentes performances pour les 4 études. Dans les matrices de confusion, le nombre d'images correctement classées est indiqué en diagonale.

### 3.4. Résultats des transformée multi-échelle pour la classification des tumeurs cérébrales

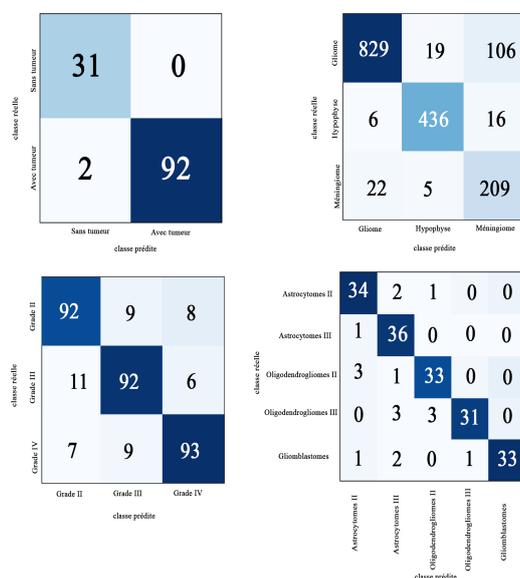


FIGURE 3.6: Matrices de confusion des quatre études obtenues avec la transformée en ondelette discrète

TABLE 3.3: Performances de la TOD-2D

	Classe	TP	FP	TN	FN	Précision	Rappel	F1-Score	TBC
Étude 1	Normal	31	2	92	0	0.94	1.00	0.97	96.85 %
	Anormal	92	0	31	2	1.00	0.98	0.99	
Étude 2	Gliome	829	28	666	125	0.97	0.87	0.92	89.44%
	Hypophyse	436	24	1166	22	0.95	0.95	0.95	
	Méningiome	209	122	1290	27	0.63	0.89	0.74	
Étude 3	Grade II	92	18	200	17	0.84	0.84	0.84	84.71 %
	Grade III	92	18	200	17	0.84	0.84	0.84	
	Grade IV	93	14	204	16	0.87	0.85	0.86	
Étude 4	Gliome 1	34	5	143	3	0.87	0.92	0.89	90.27%
	Gliome 2	36	8	140	1	0.82	0.97	0.89	
	Gliome 3	33	0	148	4	1.00	0.89	0.94	
	Gliome 4	33	4	144	4	0.89	0.89	0.89	
	Gliome 5	31	1	147	6	0.97	0.84	0.90	

où Gliome 1 = Astrocytomes diffus, Gliome 2 = Astrocytomes anaplasiques, Gliome 3 = Oligodendrogliomes bas grade, Gliome 4 = Oligodendrogliomes haut grade et Gliome 5 = Glioblastomes.

### Discussion

La transformée en ondelette discrète est un outil puissant pour l'extraction de caractéristiques, son application aux images IRM associée à la matrice GLCM a donné de bons résultats. Comme le montre le tableau 3.3, la méthode proposée, détecte dans presque tous les cas les tumeurs, leurs types et leurs grades avec une bonne précision. Pour la première étude, les IRMs normales ont été classées avec un taux de bonne classification de 96.85%. Par ailleurs pour la deuxième étude, les précisions des gliomes, tumeurs hypophysaires et méningiomes étaient respectivement de 97, 95 et 63%. Les méningiomes présente la précision la plus basse, en d'autre terme, parmi toutes les tumeurs classées méningiomes, seulement 63% d'entre elles le sont réellement. D'un autre côté, les méningiomes présente un rappel de 89%, c'est à dire que dans l'ensemble des tumeurs méningiomes, 89% ont été classées correctement. Globalement, 89.44% des prévisions du système sont correctes. La troisième étude qui porte sur les tumeurs gliales, a apporté un taux de bonne classification de 84.71% . En outre, environ 84% des tumeurs de grade II et III, et 87% des tumeurs de grade IV ont été correctement classées. Au final, pour la quatrième étude qui consiste à classer les gliomes selon leur type et grade en astrocytomes grade II, astrocytomes grade III, glioblastome, oligodendrogliome grade II et oligodendrogliome grade III, la méthode proposée arrive à classer efficacement ces derniers avec des précisions respectives de 87, 82, 100, 89 et 97%, le taux de bonne classification global est de 90.27%. En examinant les résultats des classifications obtenus, on constate que la capacité de la méthode proposée à classer différentes images IRM efficacement est confirmée.

### 3.4.2 Résultats de classification avec la transformée de Gabor

Comme pour la transformée d'ondelette, les caractéristiques statistiques et de texture extraites des images IRM du cerveau après l'application des filtres Gabor forment le vecteur caractéristique de taille 840  $((5+4*4)*5*8)$  caractéristiques. La transformée de Gabor a été appliquée à une fréquence de 1.4 en considérant 5 échelles et 8 orientations. Les résultats obtenues après la convolution des images avec le noyau de Gabor pour différentes échelles et orientations sont présentés dans la figure 3.7.

### 3.4. Résultats des transformée multi-échelle pour la classification des tumeurs cérébrales

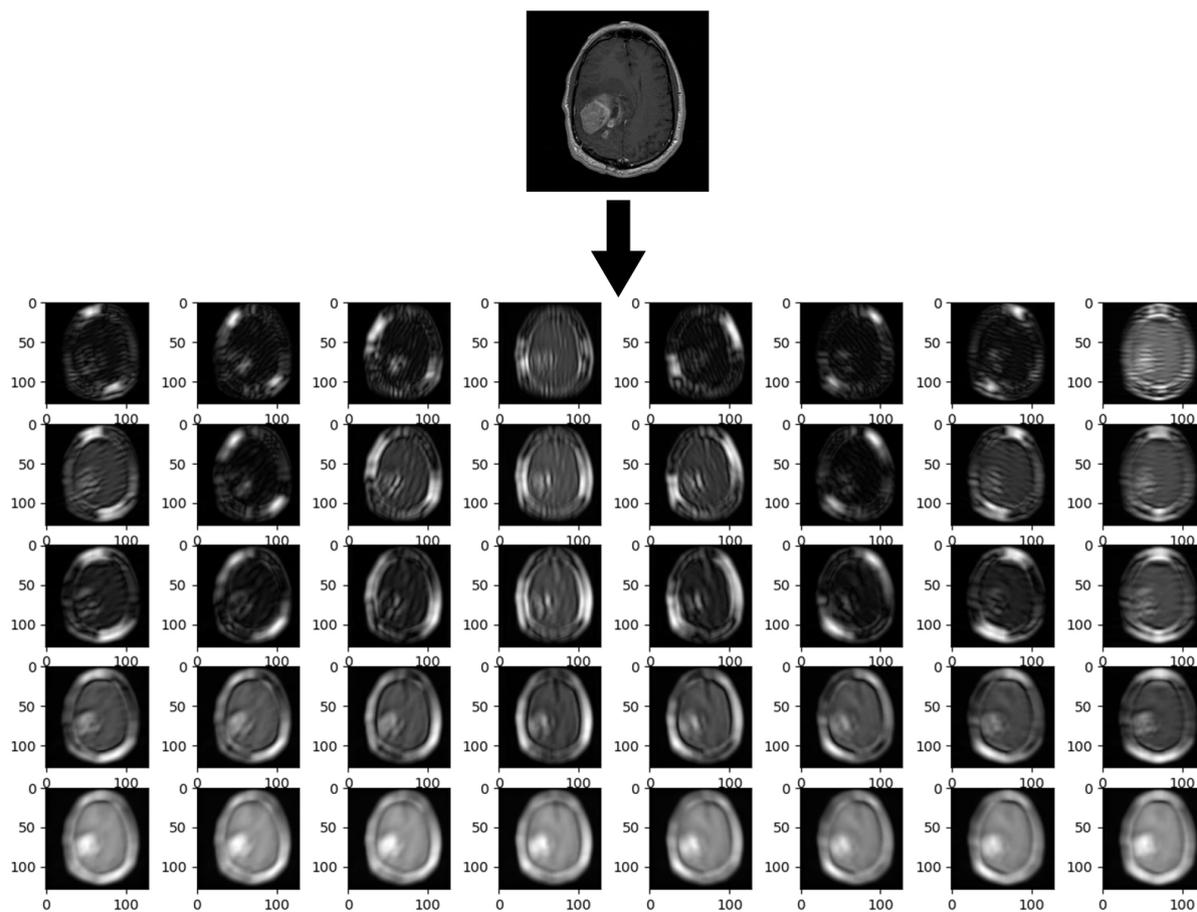


FIGURE 3.7: Décomposition d'une image IRM classe astrocytome anaplasique avec le filtre de Gabor

Les métriques calculés à partir des matrices de confusion (figure 3.8) sont résumées et comparées dans le tableau 3.4.

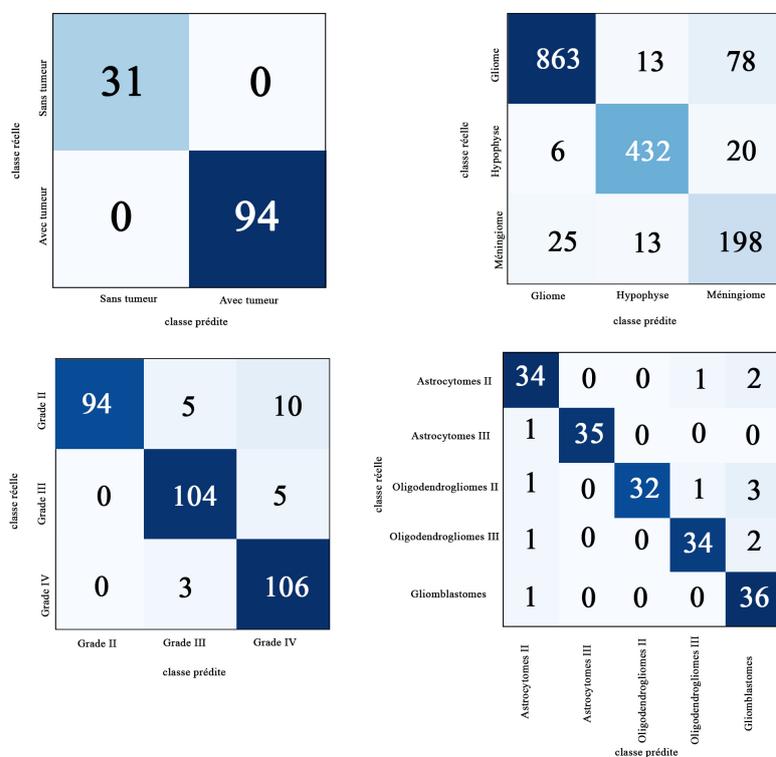


FIGURE 3.8: Matrices de confusion des quatre études obtenues avec la transformée de Gabor

TABLE 3.4: Performances de la transformée de Gabor

	Classe	TP	FP	TN	FN	Précision	Rappel	F1-Score	TBC
Étude 1	Normal	31	0	94	0	1.00	1.00	1.00	100.0 %
	Anormal	94	0	31	0	1.00	1.00	1.00	
Étude 2	Gliome	863	13	663	91	0.97	0.90	0.93	90.59%
	Hypophyse	432	26	1164	26	0.94	0.94	0.94	
	Méningiome	198	98	1314	38	0.67	0.84	0.74	
Étude 3	Grade II	94	0	218	15	1.00	0.86	0.93	92.97 %
	Grade III	104	8	210	5	0.93	0.95	0.94	
	Grade IV	106	15	203	3	0.88	0.97	0.92	
Étude 4	Gliome 1	34	4	144	3	0.89	0.92	0.91	92.43 %
	Gliome 2	35	0	148	2	1.00	0.95	0.97	
	Gliome 3	32	0	148	5	0.84	0.97	0.90	
	Gliome 4	34	3	145	3	1.00	0.86	0.93	
	Gliome 5	36	7	141	1	0.92	0.92	0.92	

### 3.4. Résultats des transformée multi-échelle pour la classification des tumeurs cérébrales

où Gliome 1 = Astrocytomes diffus , Gliome 2 =Astrocytomes anaplasiques , Gliome 3 = Oligodendrogliomes bas grade , Gliome 4= Oligodendrogliomes haut grade et Gliome 5 = Glioblastomes

#### Discussion

D'après le tableau 3.4, la transformée de Gabor offre des résultats satisfaisants. Effectivement, la transformée de Gabor a permis un gain qui varie approximativement entre 2% et 8% par rapport a la transformée en ondelette. En effet, la transformée de Gabor fournit une détection optimale pour le premier cas d'étude qui classe l'IRM en saine ou tumorale avec un taux de 100%. Pour la deuxième étude, le taux de bonne classification est passé à 90.59%, avec une légère amélioration de la précision des méningiomes de 4%, mais toute fois, dans l'ensemble des tumeurs méningiomes, seulement 84% ont été classées correctement contre 89% pour la transformée en ondelette. Le gain le plus attrayant est sans doute obtenu pour la troisième étude, ou le TBC est passé de 84.71% à 92.97%, permettant une précision optimale pour les gliomes de grade II. Quant à la dernière étude, une amélioration de 2% du TBC est observée, cependant, la précision des gliomes oligodendrogliomes bas grade a chuté de 16% par rapport à la TOD, mais les précisions des gliomes Oligodendrogliomes haut grade et glioblastomes se voient atteindre la précision optimale de 100%. D'après l'analyse de ces résultats on peut dire que la transformée de Gabor est plus performante que la transformée en ondelette, mais leux deux transformée sont complémentaires.

#### 3.4.3 Résultats de la transformée en Shearlet

La dernière transformée décompose l'image IRM à 3 niveaux donnant ainsi 33 sous bandes tel qu'il a été expliqué dans le chapitre 2. Le vecteur caractéristique aura alors une taille de  $693 \cdot 33 \cdot (5+4 \cdot 4)$  caractéristiques. La figure 3.9 montre les coefficients de la transformée de Shearlet d'une IRM cérébrale après trois niveaux de décomposition. Les résultats de la classification des quatre études après la décomposition en shearlet sont présentés dans le tableau 3.5 et visualisés à l'aide des matrices de confusion, comme le montrent la figure 3.10.

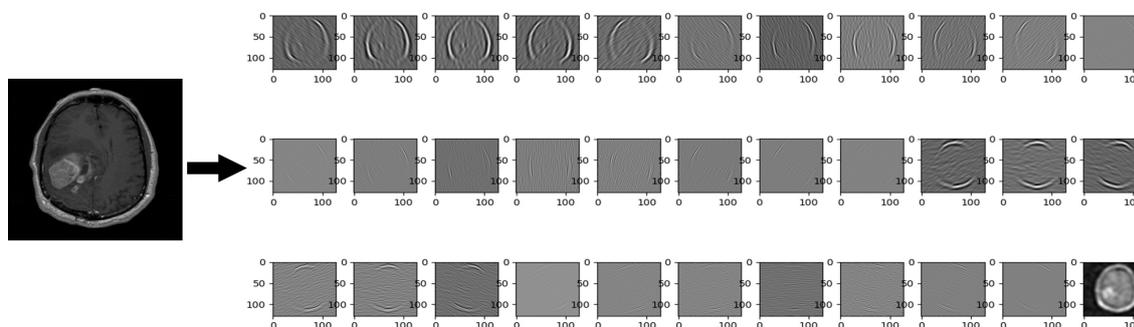


FIGURE 3.9: Décomposition d'une IRM cérébrale avec la transformée en Shearlet

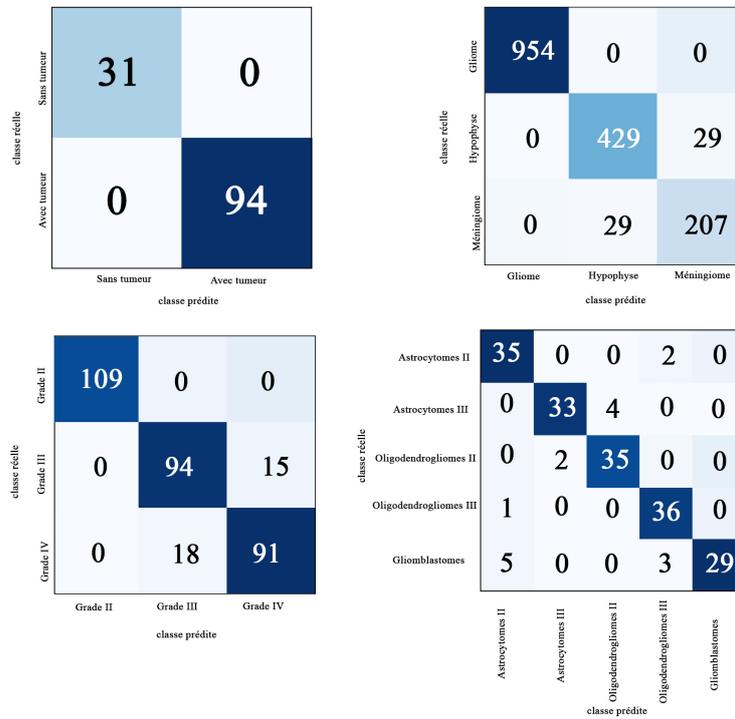


FIGURE 3.10: Matrices de confusion des quatre études obtenues avec la transformée en Shearlet

TABLE 3.5: Performances de la transformée en Shearlet

	Classe	TP	FP	TN	FN	Précision	Rappel	F1-Score	TBC
Étude 1	Normal	31	0	94	0	1.00	1.00	1.00	100.0 %
	Anormal	94	0	31	0	1.00	1.00	1.00	
Étude 2	Gliome	954	0	694	0	1.00	1.00	1.00	96.48 %
	Hypophyse	429	29	1161	29	0.94	0.94	0.94	
	Méningiome	207	29	1383	29	0.88	0.88	0.88	
Étude 3	Grade II	109	0	218	0	1.00	1.00	1.00	89.91 %
	Grade III	94	18	200	15	0.84	0.86	0.85	
	Grade IV	91	15	203	18	0.86	0.83	0.85	
Étude 4	Gliome 1	35	6	142	2	0.85	0.95	0.90	90.81 %
	Gliome 2	33	2	146	4	0.94	0.89	0.92	
	Gliome 3	35	4	144	2	0.90	0.95	0.92	
	Gliome 4	36	5	143	1	0.88	0.97	0.92	
	Gliome 5	29	0	148	8	1.00	0.78	0.88	

### 3.4. Résultats des transformée multi-échelle pour la classification des tumeurs cérébrales

#### Discussion

D'après le tableau 3.5, l'application de la transformée en Shearlet a amélioré quelques résultats. Effectivement, comme pour la transformée de Gabor, la méthode proposée permet d'obtenir un taux de classification optimal pour la première étude qui classe les IRMs cérébrales en cas sain ou cas tumoral. Aussi, pour la deuxième étude, le taux de bonne classification obtenu qui est 96.48% est nettement supérieur à ceux obtenus par les deux autres transformée permettant un gain de presque 6% par rapport à la transformée de Gabor. En effet, la précision des tumeurs gliomes passe de 97% à 100%. De plus, la précision des méningiomes qui était la plus basse avec les deux autres transformée, est passée à 88% (contre 67% avec la transformée de Gabor), cependant le rappel reste pratiquement identique à celui obtenu avec la transformée en ondelette. Quant à la troisième étude, une chute du TBC d'environ 3% est observée avec la transformée en Shearlet, le rappel des gliomes de grade IV a diminué de 14% par rapport à celui obtenu par la transformée de Gabor, mais il est passé à 100% pour les gliomes de grade II. D'autre part, pour le dernier ensemble de données, nous avons retenu un taux de bonne classification avoisinant les 91%, avec une amélioration remarquable du rappel qui passe de 86% avec la transformée de Gabor à 97% pour les les oligodendrogliomes de grade III accompagnée d'une précision optimale de 100% pour les glioblastomes. Nous pouvons conclure que la transformée en Shearlet associée aux caractéristiques statistiques et de texture peut donner de bons résultats pour la détection et la classification des tumeurs cérébrales.

Pour résumer, la figure 3.11 montre une comparaison des résultats obtenus avec les 3 systèmes pour chaque étude. Nous remarquons que le système basé sur la transformée de Gabor a amélioré les performances pour 3 études, tandis que pour la deuxième étude, la meilleure performance est obtenue avec le système basé sur la transformée en Shearlet. Pour tirer profit de chacun des trois systèmes présentés ci-dessus, nous proposons dans la section suivante une architecture de combinaison qui se base sur les performances individuelles de chaque système.

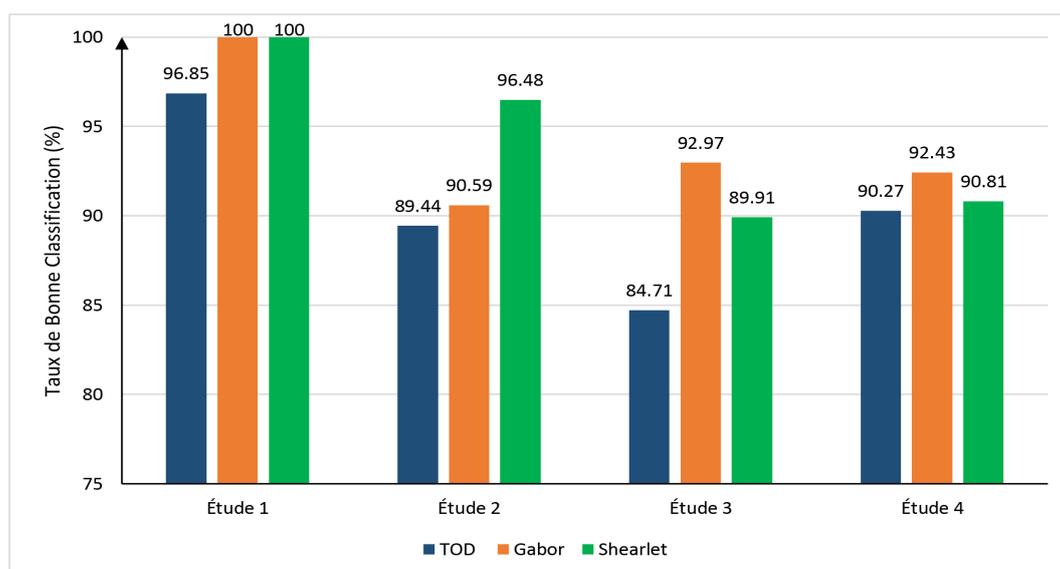


FIGURE 3.11: Comparaison du taux de bonne classification entre les trois systèmes

### 3.5 Résultats de la combinaison de classifieurs

L'objectif principal de notre travail est de proposer une architecture performante de combinaison de classifieurs pour la classification des différents types et grades des tumeurs cérébrales. L'idée est d'utiliser trois classifieurs SVM associés à différentes caractéristiques, chacun étant responsable d'apprendre les IRM cérébrales représentées par un ensemble de caractéristiques statistiques et de texture calculées à partir de transformées multi-échelle. La combinaison consiste à prendre la décision finale en appliquant une certaine règle de combinaison sur les sorties fournies par les trois classifieurs. Au total, huit règles de combinaison ont été testées à fin d'améliorer les performances des classifieurs individuelles. Les tableaux 3.6, 3.7, 3.8 et 3.9 relatent les résultats obtenus pour les quatre études soit les trois bases de données ; Kaggle, Figshare et Rembrandt.

TABLE 3.6: Résultats de la combinaison de classifieurs pour la première étude (Kaggle)

Règle de combinaison	Classe	Rappel	F1-score	Précision	TBC (%)
Le vote majoritaire	Normal	1.0	1.0	1.0	100
	Anormal	1.0	1.0	1.0	
La moyenne	Normal	1.0	1.0	1.0	100
	Anormal	1.0	1.0	1.0	
La somme	Normal	1.0	1.0	1.0	100
	Anormal	1.0	1.0	1.0	
Le produit	Normal	0.77	0.61	0.5	75.20
	Anormal	0.74	0.82	0.91	
Le maximum	Normal	0.77	0.87	1.0	94.40
	Anormal	1.0	0.96	0.93	
Le minimum	Normal	1.0	0.72	0.56	80.80
	Anormal	0.74	0.85	1.0	
La moyenne pondérée	Normal	1.0	1.0	1.0	100
	Anormal	1.0	1.0	1.0	
La somme pondérée	Normal	1.0	1.0	1.0	100
	Anormal	1.0	1.0	1.0	

### 3.5. Résultats de la combinaison de classifieurs

TABLE 3.7: Résultats de la combinaison de classifieurs pour la deuxième étude (Figshare)

Règle de combinaison	Classe	Rappel	F1-score	Précision	TBC (%)
Le vote majoritaire	Gliome	0.94	0.96	0.98	94.11
	Méningiome	0.90	0.84	0.78	
	Hypophyse	0.95	0.96	0.96	
La moyenne	Gliome	0.95	0.97	1.00	95.08
	Méningiome	0.93	0.91	0.88	
	Hypophyse	0.96	0.93	0.90	
La somme	Gliome	0.97	0.98	1.0	96.84
	Méningiome	0.96	0.92	0.88	
	Hypophyse	0.97	0.97	0.96	
Le produit	Gliome	0.95	0.97	1.00	95.08
	Méningiome	0.93	0.91	0.88	
	Hypophyse	0.96	0.93	0.90	
Le maximum	Gliome	0.86	0.91	0.97	89.19
	Méningiome	0.89	0.72	0.60	
	Hypophyse	0.96	0.96	0.96	
Le minimum	Gliome	0.96	0.98	1.00	95.81
	Méningiome	0.95	0.92	0.89	
	Hypophyse	0.95	0.94	0.92	
La moyenne pondérée	Gliome	0.98	0.99	1.0	97.33
	Méningiome	0.96	0.93	0.90	
	Hypophyse	0.97	0.97	0.96	
La somme pondérée	Gliome	0.98	0.99	1.0	97.33
	Méningiome	0.96	0.93	0.90	
	Hypophyse	0.97	0.97	0.96	

TABLE 3.8: Résultats de la combinaison de classifieurs pour la troisième étude (Rembrandt)

Règle de combinaison	Classe	Rappel	F1-score	Précision	TBC (%)
Le vote majoritaire	Grade II	0.98	0.96	0.93	94.19
	Grade III	0.90	0.93	0.96	
	Grade IV	0.94	0.94	0.94	
La moyenne	Grade II	0.95	0.98	1.00	96.02
	Grade III	0.96	0.95	0.95	
	Grade IV	0.96	0.95	0.94	
La somme	Grade II	0.95	0.98	1.0	96.02
	Grade III	0.96	0.95	0.95	
	Grade IV	0.96	0.95	0.94	
Le produit	Grade II	0.90	0.95	1.00	92.04
	Grade III	0.94	0.91	0.88	
	Grade IV	0.93	0.91	0.89	
Le maximum	Grade II	1.00	1.00	1.00	91.13
	Grade III	0.90	0.87	0.84	
	Grade IV	0.83	0.86	0.89	
Le minimum	Grade II	0.91	0.95	1.00	92.35
	Grade III	0.93	0.92	0.92	
	Grade IV	0.94	0.90	0.86	
La moyenne pondérée	Grade II	0.95	0.98	1.0	95.41
	Grade III	0.97	0.95	0.94	
	Grade IV	0.94	0.93	0.93	
La somme pondérée	Grade II	0.97	0.99	1.0	96.02
	Grade III	0.95	0.95	0.95	
	Grade IV	0.95	0.95	0.94	

TABLE 3.9: Résultats de la combinaison des classifieurs pour la quatrième étude (Rembrandt)

### 3.5. Résultats de la combinaison de classifieurs

Règle de combinaison	Classe	Rappel	F1-score	Précision	TBC (%)
Le vote majoritaire	Gliome 1	0.95	0.93	0.92	93.51
	Gliome 2	0.95	0.90	0.85	
	Gliome 3	0.95	0.95	0.95	
	Gliome 4	0.92	0.96	1.00	
	Gliome 5	0.92	0.94	0.97	
La moyenne	Gliome 1	0.95	0.97	1.00	97.29
	Gliome 2	1.00	0.99	0.97	
	Gliome 3	0.97	0.99	1.00	
	Gliome 4	0.97	0.95	0.92	
	Gliome 5	0.97	0.97	0.97	
La somme	Gliome 1	0.95	0.97	1.00	97.29
	Gliome 2	1.00	0.99	0.97	
	Gliome 3	0.97	0.99	1.00	
	Gliome 4	0.97	0.95	0.92	
	Gliome 5	0.97	0.97	0.97	
Le produit	Gliome 1	0.95	0.97	1.00	96.21
	Gliome 2	0.95	0.97	1.00	
	Gliome 3	0.95	0.96	0.97	
	Gliome 4	1.00	0.96	0.93	
	Gliome 5	0.97	0.95	0.92	
Le maximum	Gliome 1	0.97	0.99	1.00	85.94
	Gliome 2	0.73	0.81	0.90	
	Gliome 3	0.89	0.86	0.82	
	Gliome 4	0.92	0.86	0.81	
	Gliome 5	0.78	0.78	0.78	
Le minimum	Gliome 1	0.89	0.94	1.00	93.51
	Gliome 2	0.89	0.93	0.97	
	Gliome 3	0.95	0.97	1.00	
	Gliome 4	1.00	0.91	0.84	
	Gliome 5	0.95	0.92	0.90	
La moyenne pondérée	Gliome 1	0.97	0.99	1.0	96.21
	Gliome 2	0.95	0.96	0.97	
	Gliome 3	0.95	0.97	1.00	
	Gliome 4	0.97	0.96	0.95	
	Gliome 5	0.97	0.94	0.90	
La somme pondérée	Gliome 1	0.97	0.99	1.0	96.21
	Gliome 2	0.95	0.96	0.97	
	Gliome 3	0.95	0.97	1.00	
	Gliome 4	0.97	0.96	0.95	
	Gliome 5	0.97	0.94	0.90	

### Discussion

La première étude a pour objectif de distinguer entre la présence et l'absence des tumeurs cérébrales. Nous remarquons que pour la majorité des règles de combinaison, le taux de bonne classification est le même que celui obtenu par la transformée de Gabor et la transformée en Shearlet, à l'exception du produit, du maximum et du minimum, où nous constatons une chute d'environ 15 % du taux de bonne classification par le produit, 6% pour la maximum et 10% pour le minimum. Selon les résultats obtenus dans le tableau 3.7, les précisions globales de la deuxième étude pour classer les tumeurs en gliome, méningiome et hypophysaire, étaient respectivement de 100 %, 90 % et 96 %. Dans ce cas d'étude, les règles de combinaison basées sur la moyenne pondérée et la somme pondérée, ont montrées les meilleurs résultats avec un TBC de 97.33 %, permettant un gain de presque 1% ce qui correspond à 2% de méningiomes et 9% en plus des tumeurs hypophysaire correctement classées par rapport au meilleur résultat obtenu par le système individuel ( transformée en Shearlet). Le troisième ensemble de données, a pour objectif de distinguer entre les trois grades des gliomes. Nous remarquons que pour la majorité des règles de combinaison, le TBC a été amélioré. Cependant, le meilleur taux de bonne classification a été obtenu par les règles moyenne, somme et somme pondérée avec un TBC de 96.02 %, permettant une amélioration de 3% par rapport au meilleur système individuel (transformée de Gabor). Concernant la quatrième étude, nous remarquons que la combinaison a apporté une amélioration qui varie entre 1.08 % et 4.86 % par la majorité des règles de combinaison. Le meilleur taux de bonne classification qui est de 97.29 % est obtenu avec les règles moyenne et somme, tandis que pour la règle du maximum, le taux de bonne classification a diminué de 6.94 %. Ce que nous pouvons relever, est que le classifieur utilisant la transformée de Gabor fournit un taux plus ou moins supérieur à celui dégagé par les deux autres dans la plupart des cas ; Une fois la combinaison parallèle appliquée, nous avons retenu des taux de bonne classification de 97.33 %, 96.02 % et 97.29 % pour les études 2, 3 et 4 respectivement. Nous pouvons dire que ces résultats sont assez intéressants par rapport à ceux de chaque classifieur pris individuellement, et ceci vient renforcer la devise concernant les multi-classifieurs : « la performance d'un comité de classifieurs surpasse celle de n'importe quel classifieur (membre du comité) pris séparément» [61].

Pour récapituler, la figure 3.12 résume les performances obtenues par combinaison de classifieurs par rapport au meilleur système individuel.

L'ensemble des résultats obtenus par les différents classifieurs (TOD+SVM, Gabor+SVM, Shearlet+SVM) ainsi les règles de combinaison ont été convaincants. Pour l'expérimentation mono classifieur, nous constatons que le classifieur avec transformée de Gabor est meilleur, il a effectué une bonne classification des données de la première , la troisième et la quatrième étude avec un taux qui atteint 100%, 92.97% et 92.43 %, respectivement. Pour les différentes règles de combinaison nous trouvons que les méthodes de la moyenne, la somme et la somme pondérée, donnent de meilleures performances que les autres règles de combinaison dans la plupart des ex-

### 3.6. Comparaison avec les résultats de l'état de l'art

périences. Nous notons des taux de bonne classification de 100 %, 97.33 %, 96.02 % et 97.29 % pour les données de Kaggle, Figshare , Rembrandt 1 et 2 ,respectivement. Nous remarquons que les règles de combinaison basées sur la mesure offrent de meilleurs taux que le vote majoritaire. Nous concluons donc, que les règles de combinaison basées sur la mesure sont plus adaptées dans notre cas à une architecture de combinaison parallèle, car elles représentent des méthodes probabilistes qui reposent sur des fondements mathématiques solides. Elles permettent de combiner les sorties réelles des fonctions de décision contrairement au vote majoritaire qui traite des étiquettes. Finalement la combinaison par règles basées sur la mesure a amélioré significativement les résultats et elle nous a donné un système robuste et fiable, qui permet classification de la tumeur, mais il n y a pas une "meilleure règle", il semblerait que cela dépend de l'ensemble de données utilisé.

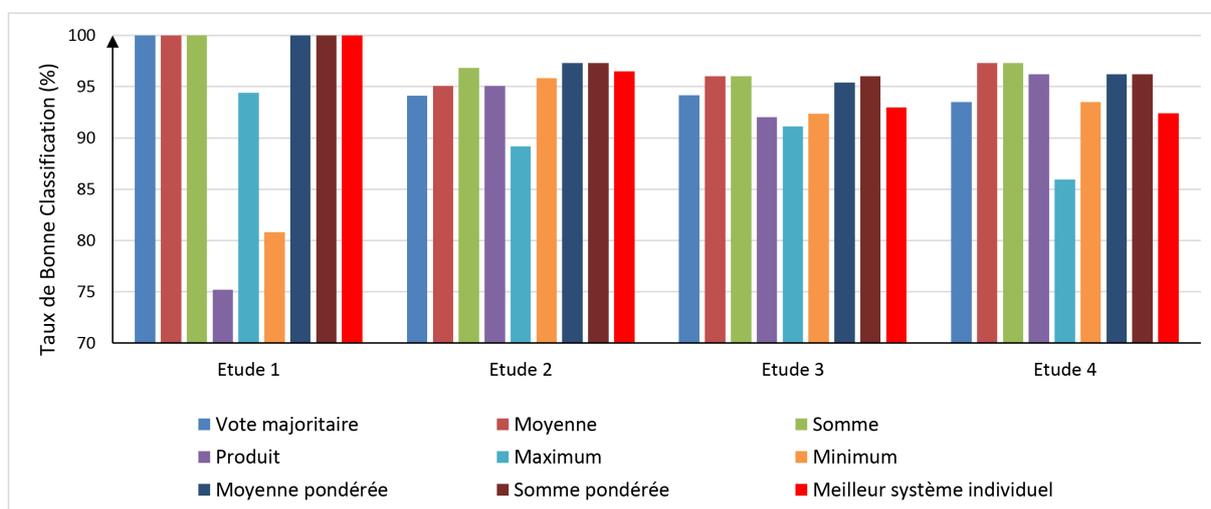


FIGURE 3.12: Combinaison de classifieurs VS meilleur système individuel

### 3.6 Comparaison avec les résultats de l'état de l'art

Pour une comparaison équitable des performances du système de combinaison proposé avec l'état de l'art, il est nécessaire de faire une comparaison avec les méthodes qui ont utilisé les mêmes ensembles de données. De nombreuses recherches ont présenté diverses techniques de classification de la tumeur cérébrale à partir des images IRM, cependant le nombres de données utilisées ainsi que leurs répartitions en données apprentissage et tests sont différentes pour chaque méthode. Une comparaison entre les résultats expérimentaux du système proposé et les résultats des méthodes précédentes dans la littérature est répertoriée dans le tableau ci-dessous :

TABLE 3.10: Comparaison des performances avec les travaux de la littérature pour la classification des tumeurs cérébrales

Base	Approche	Méthode	Type de classification	TBC (%)
Kaggle	[23]	SVM	Binaire	97.50
	<b>Méthode proposée</b>			<b>100.00</b>
Figshare	[19]	BoW-SVM	Multi	91.28
	[21]	DWT-Gabor-NN		91.90
	[22]	CNN-KELM		93.68
	[18]	GA-CNN		94.20
	[24]	Deep CNN-SVM		97.10
	[25]	CNN		96.13
	<b>Méthode proposée</b>			<b>97.33</b>
Rembrandt	[18]	GA-CNN	Multi	90.00
	[25]	CNN		<b>98.70</b>
	<b>Méthode proposée</b>			96.02
Rembrandt	<b>Méthode proposée</b>		Multi	<b>97.29</b>

D'après le tableau 3.10, la classification binaire proposée par Zafar et al., [23], a atteint un taux de 97,50% pour classer les tissus tumoraux et non tumoraux. La méthode proposée la dépasse en donnant une précision parfaite de 100%. Pour la deuxième base de données, la plupart des méthodes rapportées ont atteint des performances élevées, supérieures à 90%, où la méthode donnant la meilleure performance qui est de 97.10% est celle énoncée par Ameer et Deepak [24], qui ont utilisé un modèle d'apprentissage profond, tendance actuelle très répandue, mais qui toutefois demande beaucoup de ressources matérielles. Encore une fois, la méthode proposée est supérieure en offrant une performance de 97.33%. Cependant, pour la classification des grades de gliomes, la méthode proposée présente une performance inférieure avec une différence de 2.68%, par rapport au travail proposé par Sultan et al., [25] basé lui aussi sur un réseau de neurones convolutif. Enfin, à notre connaissance, la quatrième étude qui se base sur la classification des gliomes selon le type n'a jamais été menée. Cette comparaison montre que le schéma de combinaison proposé est simple, performant et fiable, le praticien pourrait reposer sur ce système comme deuxième avis afin d'assurer une meilleure prise en charge du patient.

### 3.7 Conclusion

L'objectif principal de la combinaison de classifieurs est d'améliorer leur capacité de généralisation et la performance de classification. Le choix correct des classifieurs à combiner est fondamental pour assurer une bonne performance globale d'un ensemble. Dans ce dernier chapitre nous avons présenté les différents résultats de classification des images IRM cérébrales en appliquant les transformées multi-échelles, et un schéma de combinaison qui combine leurs décisions selon certaines règles. L'approche proposée a été testée, comparée à la littérature et validée avec succès en considérant différentes bases de données standards. Les résultats ont permis de démontrer l'efficacité de notre méthode par rapport à l'état de l'art. Aussi, en analysant les

### **3.7. Conclusion**

---

travaux antérieurs, ces derniers proposent souvent des méthodes d'apprentissage profond et en particulier les réseaux de neurones convolutif qui sont connus pour être coûteux en ressources matérielles, en temps de calcul et en nombre de données nécessaires.

---

## Conclusion générale

---

Pour diagnostiquer certaines maladies liées à des lésions cérébrales internes, le médecin doit analyser des images médicales. Pour étudier l'évolution d'une tumeur, il est nécessaire de connaître avec exactitude les changements survenus sur ces images. L'interprétation visuelle des IRM cérébrales, n'est pas toujours sûre. C'est pour cela que le besoin d'une interprétation automatique qui permet d'assister les médecins dans leur prise de décision s'est fait ressentir. L'objectif de notre travail est de concevoir un système automatisé pour la détection et la classification de différentes tumeurs cérébrales selon le type et le grade, en utilisant un système d'apprentissage automatique.

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

La première partie est dédiée au cadre d'application de ce mémoire. Mener à bien ce travail a nécessité tout d'abord la maîtrise de certaines connaissances concernant l'anatomie cérébrale et la technique d'imagerie par résonance magnétique. Une étude bibliographique a été faite sur les méthodes de classification de tumeurs cérébrales, ce qui nous a permis d'appréhender la diversité des méthodes utilisées à cet effet. Un état concernant les étapes d'une chaîne de diagnostic assisté par ordinateur a été réalisé afin de réussir la description et la classification des différentes tumeurs.

La deuxième partie représente le cœur de notre travail, elle se focalise sur différentes étapes de la chaîne du diagnostic assisté par ordinateur afin de donner une description détaillée de différentes tumeurs, le prétraitement des images avec différentes techniques, ensuite l'extraction des caractéristiques se basant sur la texture, qui est une caractéristique importante de la surface et de la structure interne d'un objet. Son analyse est essentielle dans l'interprétation automatique d'une scène. Elle repose principalement sur la détermination de mesures ou d'attributs de texture suffisamment pertinents et discriminants, pouvant permettre de la caractériser efficacement et de

## Conclusion générale

---

la différencier aisément entre plusieurs autres. L'analyse de la texture joue un grand rôle en traitement et analyse d'images. Dans ce travail l'extraction de caractéristiques est réalisée à travers des transformées multi-échelles en l'occurrence des matrices de cooccurrence de niveaux de gris GLCM. Les sorties obtenus seront utilisés comme données d'entrée pour l'étape de classification qui se base sur des classifieurs SVM.

La dernière partie est consacré à l'implémentation des outils présentés précédemment afin de concevoir le système automatisé pour la détection et la classification de différentes tumeurs cérébrales selon le type et le grade. Trois systèmes individuels basés respectivement sur trois transformée multi-échelles différentes à savoir, la transformée en ondelette, la transformée de Gabor et la transformée en Shearlet ont présentés des performance satisfaisantes, mais qui peuvent être améliorées grâce à une architecture de combinaison parallèle basée sur des règles simples. Cette combinaison a permis d'atteindre des performances de classification très intéressantes, encore meilleurs que la majorité des méthodes proposées dans la littérature. A partir des résultats de combinaison obtenus, nous pouvons conclure, qu'il n'y a pas une règle meilleure que les autres, et que cela dépend de l'ensemble de données utilisées. Par contre, nous pouvons dire que les règles de combinaison basées sur la mesure sont plus performantes que celles basées sur la classe.

Les résultats obtenus sont encourageants, on peut voir que la méthode proposée a apporté des résultats significatifs supérieures par rapport à la majorité des méthodes de la littérature ce qui démontre la fiabilité du système proposé et montre que le radiologue peut l'utiliser pour le dépistage informatisé en prenant les meilleures décisions sur la base des résultats obtenus. Pour conclure, ce mémoire a permis de dégager les perspectives suivantes :

- Investiguer d'autres transformées multi-échelles et mener une étude sur leurs complémentarité à fin de combiner les caractéristiques les plus complémentaires.
- Tester les méthodes d'apprentissage profond pour réaliser une étude comparative avec la méthode proposée.
- Acquérir des données algériennes afin de déployer la solution proposée dans des hôpitaux Algériens.

---

## Bibliographie

---

- [1] Le Duff Franck Cléret Mireille, Le Beux Pierre. Les systèmes d'aide à la décision médicale. *Les Cahiers du numérique*, vol 2(no 2) :pp 125–154, 2001.
- [2] T. Hossain, F. S. Shishir, M. Ashraf, M. A. Al Nasim, and F. Muhammad Shah. Brain tumor detection using convolutional neural network. In *2019 1st International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT)*, pages 1–6, 2019.
- [3] société canadienne du cancer/ symptômes de la tumeur au cerveau ou à la moelle épinière. <https://www.cancer.ca/fr-ca/cancer-information/cancer-type/brain-spinal/signs-and-symptoms/?region=on>, [consulté le 10 Juin 2020].
- [4] V. Priya and Shoba Rani. An efficient segmentation approach for brain tumor detection in mri. *Indian Journal of Science and Technology*, vol 9, 05 2016.
- [5] société canadienne du cancer/ types de tumeurs. <https://www.cancer.ca/fr-ca/cancer-information/cancer-101/what-is-cancer/types-of-tumours/?region=qc>, [consulté le 11 Juin 2020].
- [6] David N et al Louis. The 2016 world health organization classification of tumors of the central nervous system : a summary. *Acta neuropathologica*, vol 131(no 6) :pp 803–820, 2016.
- [7] McKinsey L Goodenberger and Robert B Jenkins. Genetics of adult glioma. *Cancer genetics*, vol 205(no 12) :pp 613–621, 2012.
- [8] Lisa M. DeAngelis. Brain tumors. *New England Journal of Medicine*, vol 344(no 2) :pp 114–123, 2001.

## Bibliographie

---

- [9] Laura Guarnaccia Chiara Pesenti, Stefania Elena Navone. The genetic landscape of human glioblastoma and matched primary cancer stem cells reveals intratumour similarity and intertumour heterogeneity. *Stem Cells International*, vol 2019 :12 pages, 2019.
- [10] Mohammed Al-Tamimi and Ghazali Sulong. Tumor brain detection through mr images : A review of literature. *Journal of Theoretical and Applied Information Technology*, vol 62, 04 2014.
- [11] Nicolas Passat François Rousseau. L'analyse et le traitement d'images irm cérébrales. *Techniques de l'Ingenieur*, page MED900.
- [12] Abdellah Adiba Mohammed Khalila, Habib Ayada. Performance evaluation of feature extraction techniques mri-brain image classification system. *Procedia Computer Science*, vol 127 :pp 218 – 225, 2018.
- [13] Marc Dhenain. Imagerie cérébrale : outils, principes et utilisations de la clinique aux sciences cognitives comparatives. *Bulletin de l'Académie Vétérinaire de France*, page 164, 01 2015.
- [14] A. Jayachandran, R. Dhanasekaran, and Syed Ammal. Brain tumor detection and classification of mr images using texture features and fuzzy svm classifier. *Research Journal of Applied Sciences, Engineering and Technology*, vol 6 :pp 2264–2269, 2013.
- [15] S.ANITHA and Dr.V.RADHA. Comparison of image preprocessing techniques for textile texture images. *International Journal of Engineering Science and Technology*, vol 2, 12 2010.
- [16] P.M. Patil Nikita V. Chavan, B.D. Jadhav. Detection and classification of brain tumors. 112 :1–6, 2015.
- [17] Manikandan Jay and Bala Venkataramani. Study and evaluation of a multi-class svm classifier using diminishing learning technique. *Neurocomputing*, vol 73 :pp 1676–1685, 06 2010.
- [18] Foad Kazemi Amin Kabir Anarakia, Moosa Ayatib. Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. *Biocybernetics and Biomedical Engineering*, vol 39(no 1) :pp 63–74, 2019.
- [19] Jun Cheng, Wei Huang, Shuangliang Cao, Ru Yang, Wei Yang, Zhaoqiang Yun, Zhijian Wang, and Qianjin Feng. Enhanced performance of brain tumor classification via tumor region augmentation and partition. *PLOS ONE*, vol 10(no 10) :pp 1–13, 10 2015.
- [20] N. M. Ali, S. W. Jun, M. S. Karis, M. M. Ghazaly, and M. S. M. Aras. Object classification and recognition using bag-of-words (bow) model. In *2016 IEEE 12th International Colloquium on Signal Processing Its Applications (CSPA)*, pages pp 216–220, 2016.

- [21] M. R. Ismael and I. Abdel-Qader. Brain tumor classification via statistical features and back-propagation neural network. In *2018 IEEE International Conference on Electro/Information Technology (EIT)*, pages pp 0252–0257, 2018.
- [22] A. Pashaei, H. Sajedi, and N. Jazayeri. Brain tumor classification via convolutional neural network and extreme learning machines. In *2018 8th International Conference on Computer and Knowledge Engineering (ICCKE)*, pages pp 314–319, 2018.
- [23] W.Ahmad J.Ikram J.Rashid M.Z.Zafar, S.M.Adnan. Brain tumor detection and classification using geometrical shapes as texture descriptors. vol 24 :pp 83–89, 05 2019.
- [24] P.M. Ameer S. Deepak. Brain tumor classification using deep cnn features via transfer learning. *Computers in Biology and Medicine*, 111 :103345, 2019.
- [25] Hossam H. Sultan ; Nancy M. Salem ; Walid Al-Atabany. Multi-classification of brain tumor images using deep neural network. *IEEE Access*, vol 7 :pp 69215–69225, 2019.
- [26] M. S. Atkins and B. T. Mackiewich. Fully automatic segmentation of the brain in mri. *IEEE Transactions on Medical Imaging*, 17(1) :98–107, 1998.
- [27] A. Demirhan, M. Törü, and İ. Güler. Segmentation of tumor and edema along with healthy tissues of brain using wavelets and neural networks. *IEEE Journal of Biomedical and Health Informatics*, 19(4) :1451–1458, 2015.
- [28] A.S. Bhalchandra Rajesh C. patil. Brain tumour extraction from mri images using matlab. *International Journal of Electronics, Communication Soft Computing Science and Engineering*, 2, issue1. :1–4.
- [29] Josselyn Touzeau. *Approches numérique multi-échelle/multi-modèle de la dégradation des matériaux composites*. Theses, Ecole Centrale Paris, October 2012.
- [30] M. Vetterli ; C. Herle. Wavelets and filter banks : theory and design. *IEEE Transactions on Signal Processing*, vol 40(no 9) :pp 2207–2232, 1992.
- [31] E. El-Dahshan, Tamer Hosny, and A. Salem. Hybrid intelligent techniques for mri brain images classification. *Digit. Signal Process.*, vol 20 :pp 433–441, 2010.
- [32] S. Mallat. *A Wavelet Tour of Signal Processing-3rd Edition*, AcademicPress. 1999.
- [33] L.Wu S.Wang Y.Zhang, Z.Dong. A hybrid method for mri brain image classification. *Expert Systems with Applications*, vol 38(no 8) :pp 10049–10053, 2011.
- [34] E. El-Dahshan, Tamer Hosny, and A. Salem. Hybrid intelligent techniques for mri brain images classification. *Digit. Signal Process.*, 20 :433–441, 2010.

## Bibliographie

---

- [35] GUILLAUME CEDILLE ARNAUD CALMETTES. Vision par ordinateur – filtres de gabor.
- [36] Wei-Lun Chao. Gabor wavelet transform and its application. 2010.
- [37] M. R. Ismael and I. Abdel-Qader. Brain tumor classification via statistical features and back-propagation neural network. In *2018 IEEE International Conference on Electro/Information Technology (EIT)*, pages 0252–0257, 2018.
- [38] K. Meshkini and H. Ghassemian. Texture classification using shearlet transform and glcm. In *2017 Iranian Conference on Electrical Engineering (ICEE)*, pages 1845–1850, 2017.
- [39] Lesley-Ann Duflot, Rafael Reisenhofer, Brahim Tamadazte, Nicolas Andreff, and Alexandre Krupa. Wavelet and shearlet-based image representations for visual servoing. *The International Journal of Robotics Research*, 38(4) :422–450, 2019.
- [40] Fang Yuan, Lam-Man Po, Mengyang Liu, Xuyuan Xu, Weihua Jian, Kaman Wong, and Keith Cheung. Shearlet based video fingerprint for content-based copy detection. *Journal of Signal and Information Processing*, 07 :84–97, 01 2016.
- [41] K. G. Krishnan, Vanathi P.T., and R. Abinaya. Performance analysis of texture classification techniques using shearlet transform. In *2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*, pages 1408–1412, 2016.
- [42] V.P.Gladis Rathi. Brain tumor mri image classification with feature selection and extraction using linear discriminant analysis. *International Journal of Information Sciences and Techniques*, 2 :131–146, 07 2012.
- [43] G. Preethi and V. Sornagopal. Mri image classification using glcm texture features. pages 1–6, 03 2014.
- [44] Har Pal Thethi Nilesh Bhaskarrao Bahadure, Arun Kumar Ray. Image analysis for mri based brain tumor detection and feature extraction using biologically inspired bwt and svm. *International Journal of Biomedical Imaging*, 2017.
- [45] Nitish Zulpe and V Pawar. Glcm textural features for brain tumor classification. *IJ CSI*, 9 :354–359, 05 2012.
- [46] Shruti Singh, Divya Srivastava, and Agarwal S. Glcm and its application in pattern recognition. pages 20–25, 08 2017.
- [47] Shijin P.S and Dharun Vs. Extraction of texture features using glcm and shape features using connected regions. *International Journal of Engineering and Technology*, 8 :2926–2930, 12 2016.

- [48] Chen Junli and Jiao Licheng. Classification mechanism of support vector machines. In *WCC 2000 - ICSP 2000. 2000 5th International Conference on Signal Processing Proceedings. 16th World Computer Congress 2000*, volume 3, pages 1556–1559 vol.3, 2000.
- [49] Praveena Pedapati and Rama Vaishnavi Tannedi. Brain tumour detection using hog by svm. Master's thesis, , Blekinge Institute of Technology, 2018.
- [50] Kwang In Kim, Keechul Jung, Se Hyun Park, and Hang Joon Kim. Support vector machines for texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(11) :1542–1550, 2002.
- [51] M. A. Hearst, S. T. Dumais, E. Osuna, J. Platt, and B. Scholkopf. Support vector machines. *IEEE Intelligent Systems and their Applications*, 13(4) :18–28, 1998.
- [52] V. Jakkula. Tutorial on support vector machine ( svm ). 2011.
- [53] Dominik Francoeur. Tmachines à vecteurs de support, une introduction. pages 1–19, 2010.
- [54] Jonathan Milgram, Mohamed Cheriet, and Robert Sabourin. “one against one” or “one against all” : Which one is better for handwriting recognition with svms? pages 1–6, 10 2006.
- [55] A. S. Atukorale and P. N. Suganthan. Combining classifiers based on confidence values. In *Proceedings of the Fifth International Conference on Document Analysis and Recognition. ICDAR '99 (Cat. No.PR00318)*, pages 37–40, 1999.
- [56] L. Xu, A. Krzyzak, and C. Y. Suen. Methods of combining multiple classifiers and their applications to handwriting recognition. *IEEE Transactions on Systems, Man, and Cybernetics*, 22(3) :418–435, 1992.
- [57] Y. S. Huang and C. Y. Suen. A method of combining multiple experts for the recognition of unconstrained handwritten numerals. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17(1) :90–94, 1995.
- [58] Aizhong Mi and Zhanqiang Huo. Experimental comparison of six fixed classifier fusion rules. *Procedia Engineering*, 23 :429 – 433, 2011. PEEA 2011.
- [59] Smith K Freymann J Kirby J Koppel P Moore S Phillips S Maffitt D Pringle M Tarbox L Prior F Clark K, Vendt B. The cancer imaging archive (tcia) : Maintaining and operating a public information repository. *Journal of digital imaging*, vol 26(no 6) :pp 1045–1057, 2013.
- [60] Rembrandt brain tumor dataset. <https://wiki.cancerimagingarchive.net/display/Public/REMBRANDT>, 2014.
- [61] Josef Kittler Fabio Roli. *Multiple Classifier Systems*, volume 1857.