

: N° d'ordre
: N° de série

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



UNIVERSITE ECHAHID HAMMA LAKHDAR - EL OUED
FACULTÉ DES SCIENCES EXACTES
Département D'Informatique



Mémoire de Fin D'étude
Présenté pour l'obtention du Diplôme de

MASTER ACADEMIQUE

Domaine : **Mathématique et Informatique**
Filière : **Informatique**
Spécialité : **Systèmes Distribués et Intelligence Artificielle**

Présenté par :

- **AMIMOUR Oussama**
- **CHIHANI HOUSSAM Eddine**

Thème

**Artificial intelligence
paradigms for the automated
diagnosis of brain cancer**

Soutenu le xx-xx- 2022 Devant le jury:

M.	MCA	Président
M.	MAA	Rapporteur
M.	Hamoud Mariem	MAA	Encadreur

Année Universitaire: 2021/2022

Dédicace

Nous tenons remercier avant tout DIEU qui nous a donné la force, la volonté, le courage, et la patience de pouvoir réaliser ce modeste travail. On tient aussi remercier Dr **"Hamoud Mariem"**, notre encadreur qui a su orienter notre travail, aussi pour sa disponibilité nous prodiguer des conseils, pour sa confiance et pour sa précieuse aide, on le remercie du fond du cœur. Nous remercions aussi notre encadreur aux ses efforts et ses aides, en lui espérant une meilleure vie pleine de joie, de bonheur et de succès en différents domaines nous lui dedions ce modeste travail. Nos sincères remerciements sont adressés à tous les membres du jury qui ont accepté de juger notre modeste travail, et tous ceux qui, sans avoir été impliqués directement dans ce travail, ont toujours été d'un grand support : nos enseignants, nos familles, nos amis, nos collègues chacun son nom.

Abstract

Neuroscience has typically been tasked with processing MRI data in order to detect malignancies.

The procedure, on the other hand, grapples with a significant obstacle and necessitates a substantial level of domain competence gained through rigorous formal skill training. Indeed, brain tumor is one of the most harmful cancers that cause death of both children and adults but early screening strengthens enormously the chances of the patient's survival.

Although MRI has several advantages over other imaging modalities, such as being safer and delivering richer information, it is difficult to detect minute changes in MRI images, particularly in the early stages of abnormalities. Furthermore, slice-by-slice annotation of a brain tumor from MRI scan is a time-consuming and laborious task. Through CAD systems implementation, this manual burden can be substituted by automatic segmentation based computer vision techniques where Artificial intelligence, machine learning and deep learning are the buzzwords.

To identify glioma, meningioma and pituitary tumor ; a single framework based on U-net model and SVM algorithm with textural tumors characterization based power laws models: Zipf and inverse Zipf and Gabor filters is used to handle both tumor segmentation and classification tasks simultaneously.

Not only has the suggested approach successfully identified the presence of cancer cells in the brain, but it has also correctly identified the type of cancer present in the segmented region of interest, whether it is glioma, pituitary tumor or meningioma.

Key words: Brain cancer, tumor, MRI, Artificial Intelligence, Preprocessing, CAD systems, Segmentation, Deep learning, U-net, Classification, Machine learning, SVM, Texture characterization, Power law: Zipf and inverse Zipf, Gabor filters.

Résumé

Les neurosciences ont typiquement été chargées de traiter les données IRM afin de détecter les tumeurs malignes. La procédure, d'autre part, se heurte à un obstacle important et nécessite un niveau substantiel de compétence dans le domaine acquis grâce à une formation formelle rigoureuse. En effet, la tumeur cérébrale est l'un des cancers les plus nocifs pouvant causer la mort, aussi bien, dans le sujet enfants qu'adulte. Ceci dit, un dépistage précoce renforce énormément les chances de survie du patient.

Bien que l'IRM présente plusieurs avantages par rapport aux autres modalités d'imagerie, comme étant plus sûre et fournissant des informations plus riches, il est difficile de détecter des changements infimes dans les images IRM, en particulier au cours des premiers stades relatifs aux anomalies. De plus, l'annotation tranche par tranche d'une tumeur cérébrale à partir d'une IRM est une tâche longue et laborieuse. Grâce à l'implémentation de systèmes CAD, cette charge manuelle peut être remplacée par des techniques de vision par ordinateur basées sur la segmentation automatique où l'intelligence artificielle, l'apprentissage automatique et l'apprentissage en profondeur sont les tendances actuelles.

Pour identifier le gliome, la tumeur hypophysaire et le méningiome ; une approche basée sur le modèle U-net et l'algorithme SVM avec des lois de puissance : Zipf et Zipf inverse et les filtres de Gabor pour la caractérisation texturales des tumeurs a été suggérée avec l'ultime but de gérer simultanément les tâches de segmentation et de classification des tumeurs.

Non seulement l'approche suggérée a identifié avec succès la présence de cellules cancéreuses dans le cerveau, mais elle a également identifié correctement le type de cancer présent dans la région d'intérêt segmentée, qu'il s'agisse d'un gliome, d'une tumeur hypophysaire ou d'un méningiome.

Mots clés : Cancer du cerveau, tumeur, IRM, Intelligence Artificielle, Prétraitement, Systèmes CAD, Segmentation, Apprentissage profond, U-net, Classification, Apprentissage automatique, SVM, Caractérisation de texture, Loi de puissance : Zipf et Zipf inverse, Filtres de Gabor.

الملخص

عادة ما يتم تكليف علم الأعصاب بمعالجة بيانات التصوير بالرنين المغناطيسي من أجل الكشف عن الأورام الخبيثة.

الإجراء ، من ناحية أخرى ، يصارع مع عقبة كبيرة ويتطلب مستوى كبير من الكفاءة في المجال المكتسبة من خلال التدريب الرسمي الصارم على المهارات. في الواقع ، يعتبر ورم المخ من أكثر أنواع السرطانات ضرراً التي تسبب وفاة كل من الأطفال والبالغين ، لكن الفحص المبكر يعزز بشكل كبير من فرص بقاء المريض على قيد الحياة.

على الرغم من أن التصوير بالرنين المغناطيسي له العديد من المزايا مقارنة بطرق التصوير الأخرى ، مثل كونه أكثر أماناً وتقديم معلومات أكثر ثراءً ، إلا أنه من الصعب اكتشاف التغييرات الدقيقة في صور التصوير بالرنين المغناطيسي ، خاصة في المراحل المبكرة من التشوهات. علاوة على ذلك ، يعد التعليق التوضيحي على شكل شريحة لورم في المخ من فحص التصوير بالرنين المغناطيسي مهمة شاقة وتستغرق وقتاً طويلاً. من خلال تنفيذ أنظمة **CAD** ، يمكن استبدال هذا العبء اليدوي بتقنيات رؤية الكمبيوتر القائمة على التقسيم التلقائي حيث الذكاء الاصطناعي والتعلم الآلي والتعلم العميق هي الكلمات الطنانة.

لتحديد الورم الدبقي والورم السحائي وورم الغدة النخامية. إطار واحد يعتمد على نموذج **U-net** وخوارزمية **SVM** مع نماذج قوانين الطاقة القائمة على توصيف الأورام التركيبية: يتم استخدام مرشحات **Zipf** و **Inverse Zipf** و **Gabor** للتعامل مع مهام تجزئة الورم والتصنيف في وقت واحد.

لم يقتصر الأمر على تحديد النهج المقترح بنجاح لوجود الخلايا السرطانية في الدماغ ، ولكنه أيضاً حدد بشكل صحيح نوع السرطان الموجود في المنطقة المجزأة موضع الاهتمام ، سواء كان الورم الدبقي أو ورم الغدة النخامية أو الورم السحائي.

الكلمات الأساسية: سرطان الدماغ ، الورم ، التصوير بالرنين المغناطيسي ، الذكاء الاصطناعي ، المعالجة المسبقة ، أنظمة **CAD** ، التقسيم ، التعلم العميق ، **U-net** ، التصنيف ، التعلم الآلي ، **SVM** ، توصيف الملمس ، قانون القوة: **Zipf** و معكوس **Zipf** ، مرشحات **Gabor** .

Table des matières

Table des matières.....	I
Liste Des Figures.....	III
Liste Des Tableaux	V
Glossaire.....	VI
Introduction générale	VII
Chapitre I : L'analyse d'image, la vision par ordinateur, les paradigmes de l'intelligence artificielle état de l'art et enjeux majeurs	
I.1 Introduction.....	2
I.2 La vision par ordinateur	3
I.3 L'analyse d'image	3
I.3.1 Analyse de bas niveau d'image.....	4
I.3.2 Analyse de haut niveau d'image	4
I.4 Analyse de la texture d'image.....	4
I.4.1 Définition de la texture.....	5
I.4.2 Quantification de la texture d'une image.....	5
I.5 L'apprentissage automatique et l'apprentissage profond en action.....	6
I.5.1 L'apprentissage automatique	6
I.5.2 L'apprentissage profond	9
I.6 Evocation de quelques modèles des réseaux de neurone convolutifs.....	13
I.6.1 U-net.....	13
I.6.2 AlexNet, ResNet et VggNet.....	14
I.6.3 Mask-RCNN.....	15
I.7 Conclusion	17
Chapitre II : Initiation au pronostic automatique du cancer du cerveau	
II.1 Introduction	19
II.2 Le cancer du cerveau	20
II.3 Les différents types des tumeurs cérébrales	21
II.4 L'imagerie par résonance magnétique (IRM) pour le dépistage du cancer du cerveau.....	23
II.5 Les facteurs rendant l'IRM restreinte pour le diagnostic du cancer du cerveau.	24
II.6 Diagnostic automatique (CAD) du cancer du cerveau.....	25

II.6.1 Détection des tumeurs assistée par ordinateur (CADE).....	27
II.6.2 Diagnostic des tumeurs assisté par ordinateur (CADx)	28
II.7 L'aide au diagnostic médical du cancer du cerveau basé apprentissage automatique.....	29
II.8 L'aide au diagnostic médical du cancer du cerveau basé apprentissage profound.....	33
II.9 Conclusion	38
Chapitre III : Extraction de la problématique et définition de l'approche proposée	
III.1 Introduction.....	39
III.2 Problématique et plan d'action	40
III.3 Segmentation des tumeurs cérébrales dans les IRM basée Deep Learning.....	42
III.3.1 Base de données utilisée	42
III.3.2 Pipeline suivi pour la segmentation des tumeurs cérébrales basé U-Net.....	44
III.4 Classification des tumeurs cérébrales basée SVM	49
III.4.1 Régions d'intérêt segmentées	49
III.4.2 Pipeline basé SVM pour la classification des tumeurs cérébrales.....	49
III.5 Schématisation de l'approche proposée	59
III.6 Conclusion	61
Chapitre IV : Evaluation des performances	
IV.1 Introduction.....	63
IV.2 Environnement De Développement Et Outils Utilisés.....	64
IV.2.1 Langage Python.....	64
IV.2.1.1 Pourquoi Python.....	64
IV.2.2 Kaggle.....	64
IV.2.3 Matériel de configuration.....	64
IV.3 Mesures de performance utilisées.....	64
IV.3.1 Matrice de Confusion.....	63
IV.3.1.1 Matrice de Confusion Termes.....	65
IV.3.2 Métriques d'évaluation du Classificateur.....	66
IV.3.2.1 Accuracy.....	66
IV.3.2.2 Précision et Rappel.....	66
IV.4 Explication du code.....	67
IV.5 L'interface système.....	69

IV.6 Résultats et Discussion.....	70
IV.6.1 Segmentation.....	70
IV.6.2 Diviser l'ensemble d'origine en données d'apprentissage, de validation et de test.....	71
IV.7 Évaluation d'un classificateur	71
IV.8 Conclusion	72

Liste Des Figures

<i>Chapitre I : L'analyse d'image, la vision par ordinateur, les paradigmes de l'intelligence artificielle : état de l'art et enjeux majeurs</i>	
Figure I.1 Hyper plan optimal à deux dimensions.....	8
Figure I.2 Exemple d'un réseau de neurones.....	8
Figure I.3 Architecture Générale d'un CNN.....	10
Figure I.4 Application de la convolution sur un image.....	11
Figure I.5 Deux exemples l'un relatif au max pooling et l'autre à average pooling.....	12
Figure I.6 Architecture de U-net.....	14
Figure I.7 Diverses architectures, à savoir de AlexNet, VggNet et ResNet.....	15
Figure I.8 Architecture de Mask -RCNN.	16
<i>Chapitre II : Initiation au pronostic automatique du cancer du cerveau</i>	
Figure II.1 Structure tissulaire du cerveau humain.	21
Figure II.2 Exemple d'un Gliome en (a), un Méningiomes en (b) et une tumeur hypophysaire en (c).....	22
Figure II.3 Exemples de différentes modalités d'IRM appliquées au gliome HG. Les exemples ont été extraits de la base de données BRATS 2013. De gauche à droite : Image IRM T1, Image IRM T1-Gd, image IRM T2 et image IRM FLAIR.....	24
Figure II.4 Organigramme d'un système générique de diagnostic assisté par ordinateur (CAD) pour le diagnostic des tumeurs cérébrales. Cet organigramme	27

montre toutes les étapes d'un système CAD complet ; il est nécessaire d'avoir toutes les étapes combinées dans un seul système.....	
Chapitre III : Extraction de la problématique et définition de l'approche proposée	
Figure III.1 présentation des IRM cérébrales de la base de données utilisée.....	43
Figure III.2	45
Figure III.3 Architecture de U-Net pour la segmentation des tumeurs cérébrales...	47
Figure III.4 Pipeline suivi pour la classification des tumeurs cérébrales.....	49
Figure III.5 Courbes de Zipf et de Zipf d'une tumeur gliome	51
Figure III.6 Courbe de Zipf et Zipf inverse d'une tumeur méningiome.....	52
Figure III.7 Courbe de Zipf et Zipf inverse d'une tumeur hypophysaire	53
Figure III.8 Filtres de Gabor appliqués dans le domaine fréquentiel.....	56
Figure III.9 Parties réelles des filtres de Gabor utilisés.....	57
Figure III.10 Parties réelles des régions d'intérêt filtrées.....	57
Figure III.11 Magnitude de la réponse du filtre de Gabor suite à la convolution de la tumeur maligne avec une banque de filtres de Gabor.....	58
Figure III.12 Schémas résumant le pipeline de pronostic automatique des tumeurs cérébrales.....	60
Chapitre IV : Evaluation des performances .	
Figure IV.1 Matrice de Confusion.....	65
Figure IV.2 Formule de Accuracy.....	66
Figure IV.3 Formule de Précision.....	66
Figure IV.4 Formule de Rappel.....	66
Figure IV.5 Fonctionnalités du processus CSV.	68
Figure IV.6 Fonctionnalités extraites (CSV file)	68
Figure IV.7 La fenêtre principale pour entrer l'image.....	69
Figure IV.8 La fenêtre d'affichage.....	69
Figure IV.9 Model Accuracy.....	70
Figure IV.10 Model loss.....	70
Figure IV.11 Diviser le train en train et validation.....	71

Liste Des Tableaux

Tableau II.1 Approches CAD basées apprentissage automatique (Machine Learning) de diagnostic du cancer du cerveau	30
Tableau II.2 Approches CAD basées apprentissage profond (Deep Learning) de diagnostic du cancer du cerveau.....	31

Glossaire

CAD : Computer Aided Diagnostic

AI: Artificial Intelligence.

ML: Machine Learning.

DL: Deep Learning.

CNN: Convolutional Neural Network.

GLCM: Gray Level Co-Occurrence Matrix.

LR: Logistic Regression.

NN: Neural Network.

MRI: Magnetic Resonance Imaging.

CT: Computerized Tomography.

CV: Computer Vision.

NN: Neural Network.

SVM: support vector machine.

KNN: K-Nearest Neighbor.

CSV: Comma-separated values

A decorative border resembling a scroll, with a vertical strip on the left side and a horizontal strip at the top, both ending in small circular loops.

Introduction générale

Introduction générale

Introduction générale

Les neuro-oncologues signalent la tendance de la hausse des tumeurs cérébrales, le taux de survie relative à cinq ans après le diagnostic d'une tumeur maligne du cerveau et d'autres tumeurs du système nerveux central était de 35,8 %, et le taux de survie relative à cinq ans après le diagnostic d'une tumeur cérébrale non maligne était de 91,5 % [1]. En effet, les tumeurs cérébrales désignent la 10^{ème} forme des tumeurs surgissant chez les enfants ainsi que les adultes.

Les tumeurs cérébrales sont constituées de tissus causés par une prolifération cellulaire incontrôlée, qui n'ont aucune fonction physiologique dans le cerveau. Le glioblastome est le gliome le plus meurtrier, représentant 70 à 75 % de tous les diagnostics de gliome diffus, avec une durée médiane de survie globale de 14 à 17 mois [2].

L'IRM est un type de technique d'imagerie non ionisante qui n'utilise pas de rayonnement du tout et est considérée comme plus sûre que les rayons X et la tomodensitométrie qui utilisent des radiations [3]. Ceci dit, quelques facteurs perturbant le diagnostic comme la mauvaise résolution spatiale, le faible contraste, l'inhomogénéité ainsi que l'instabilité des formes des objets, surgissent. Dans ce sens, la segmentation manuelle nécessite beaucoup d'expertise et de compétences, mais elle peut parfois être erronée. La segmentation automatique des tumeurs dans les images IRM aide à mieux analyser les conditions pathologiques en mesurant la taille, l'emplacement, la structure et le grade de la tumeur [4]. En outre, la segmentation des tumeurs cérébrales a de nombreuses applications en neurologie telles que la planification des chirurgies.

Les techniques d'apprentissage automatique et d'apprentissage profond ont été appliquées pour la classification des tumeurs, et une précision de 100 % a été atteinte par les deux catégories d'apprentissage [5]. En effet, le développement des systèmes CAD d'aide au diagnostic médical assisté par ordinateur a eu lieu pour donner un deuxième avis au spécialiste durant l'élaboration de son diagnostic. Par la suite, ces systèmes ont été largement adoptés dans les routines sanitaires à travers le monde.

La recherche sur les tumeurs cérébrales a été menée dans diverses sociétés privées multinationales telles que Siemens, Becton Dickinson, Medtronic, Accenture, GE Medical Systems, Atlantic Biomedical P. Ltd et autres [6].

Dans ce mémoire, nous contribuons une approche basée multi-cascade d'algorithmes de segmentation et de classification de tumeurs au sein des IRM cérébrales où des algorithmes

Introduction générale

d'apprentissage en profondeur seront combinés avec des algorithmes d'apprentissage automatique.

Durant le processus de segmentation, nous avons appliqué le modèle U-net comprenant des couches de convolution et de sous-échantillonnage pour classifier les pixels du cerveau pendant le processus de segmentation. Les couches convolutives utilisent différents filtres de différentes tailles pour extraire les caractéristiques profondes de l'image de la tumeur cérébrale. Les tailles des cartes d'entités sont encore réduites à l'aide des couches de sous-échantillonnage. Cela minimisera également la résolution des caractéristiques spatiales de l'image cérébrale.

Par la suite, le modèle d'apprentissage automatique basé sur les machines à vecteurs de supports (SVM) utilisera ces sorties importantes de régions tumorales pour la classification, ce qui améliore la précision de la prédiction.

La classification des tumeurs cérébrales est un domaine de vaste recherche à l'intersection de la vision par ordinateur (CV), de l'apprentissage automatique et de l'imagerie biomédicale. Divers chercheurs ont proposé de nouvelles approches visant à lutter dans ce problème de recherche où nous proposerons la présente contribution [7].

La structuration de ce mémoire est la suivante :

Chapitre I : L'analyse d'image, la vision par ordinateur, les paradigmes de l'intelligence artificielle : état de l'art et enjeux majeurs

Tout au long du chapitre I, les concepts de base de l'analyse d'image et de la vision par ordinateur seront discutés. En outre, le boom de l'apprentissage automatique et l'apprentissage profond sera évoqué.

Chapitre II : Initiation au pronostic automatique du cancer du cerveau

Le chapitre II sera consacré à l'évocation du cancer du cerveau et son impact sur la vie quotidienne où les paradigmes de l'intelligence artificielle ont fait l'objet d'une importante contribution pour le pronostic automatique du cancer du cerveau.

Chapitre III : Extraction de la problématique et définition de l'approche proposée

Quant au chapitre III, la problématique de ce mémoire sera extraite désignant le diagnostic automatique du cancer du cerveau et éventuellement l'approche proposée dans ce sens.

Chapitre IV : Evaluation des performances

Le chapitre IV est dédié à l'évaluation des résultats aboutis par l'approche proposée. Ce mémoire s'achève par une conclusion générale et les perspectives.

Chapitre I

L'analyse d'image, la vision par ordinateur,
les paradigmes de l'intelligence artificielle:
état de l'art et enjeux majeurs

I.1 Introduction

Dans le domaine du diagnostic des images médicales, de nombreux problèmes ont été découverts par les scientifiques du fait que les images médicales présentent généralement un faible contraste, des frontières floues entre les différents tissus ou entre les tissus et les lésions. Dans ce sens, pour assurer le bon diagnostic, les images doivent être traitées pour améliorer leur qualité et extraire des caractéristiques discriminantes visant à améliorer le diagnostic à travers l'incorporation des différents paradigmes de l'intelligence artificielle.

Nous évoquons dans ce chapitre, les diverses techniques proposées pour l'analyse des images et l'extraction de caractéristiques en vue de la classification des tissus pathologiques.

I.2 La vision par ordinateur

La vision par ordinateur consiste en le domaine de l'informatique se concentrant sur la reproduction de parties désignant la complexité du système de vision humaine. En effet, ceci permettra aux ordinateurs l'identification et le traitement des objets dans les images autant que les humains.

Suite aux progrès de l'intelligence artificielle ainsi qu'aux innovations en apprentissage profond, le domaine a fait d'énormes bonds ces dernières années en surpassant les humains dans certaines tâches.

Il est utile de mentionner que l'un des facteurs essentiels de la croissance de la vision par ordinateur désigne la quantité de données gérées de nos jours. En effet, ces flux de données feront l'objet de l'amélioration de la vision par ordinateur spécialement dans le domaine médical dont nous nous intéressons.

Diverses applications de vision par ordinateur consistent à reconnaître des éléments sur des images, citons :

- La classification d'objets.
- L'identification d'objet.
- La vérification d'objet.
- La détection d'objets.
- La segmentation d'objet.
- La reconnaissance d'objets.

I.3 L'analyse d'image

La notion analyse des images indique l'analyse informatique des images numérisées en vue de l'extraction de mesures au sein de ces images [8]. Il est utile de mentionner que l'analyse des images englobe divers outils : le traitement du signal, l'intelligence artificielle ainsi que la stéréologie.

Dans le domaine de la vision par ordinateur, les images furent capturées par une caméra. Par la suite, nous effectuons une numérisation sur un ordinateur suite à l'utilisation d'une carte de capture. En effet, le processus d'analyse des images basé vision par ordinateur comporte un pipeline de traitement de données consistant en un ensemble d'algorithmes. Dippert et al. ont identifié les principaux axes dans [9], comme suit :

1. Acquisition et optimisation des images.
2. Conversion des pixels en objets.
3. Analyse et reconnaissance de ces objets.

Quant aux niveaux d'analyse des images, nous distinguons deux :

I.3.1 Analyse de bas niveau d'image

L'analyse ou le traitement de bas niveau, aussi considéré comme analyse de pixels vu qu'il vise à améliorer la qualité de l'image en convertissant l'image d'entrée en une nouvelle image prête et bien adaptée à de niveaux ultérieures de traitement.

Les algorithmes concernés par ce niveau boostent la qualité de l'image et consistent en le filtrage du bruit et l'amélioration du contraste, la mise à l'échelle avec le but de l'adaptation à la taille de l'image et en fin, nous distinguons un processus important celui de l'élimination des informations infructueuses comme l'arrière-plan.

I.3.2 Analyse de haut niveau d'image

Ce niveau d'analyse concerne la reconnaissance d'objets par le processus de la classification en associant chaque objet à une classe spécifique. Par exemple, nous associons une tumeur détectée à une classe pathologique. En effet, ce niveau s'appuie sur diverses connaissances tirées à partir du contenu de l'image.

Les paradigmes d'intelligence artificielle sont appelés à être utilisés dans l'analyse et l'interprétation des images. Voir plus, le stade avancé de la vision par ordinateur simule la cognition humaine en s'appuyant sur les informations contenues au sein de l'image.

I.4 Analyse de la texture d'image

L'analyse de la texture désigne une problématique majeure de la vision par ordinateur, spécialement dans l'analyse de l'imagerie médicale où la texture désigne un descripteur puissant des tissus pathologiques dont la quantification est difficile par un radiologue.

I.4.1 Définition de la texture

C'est ardu de donner une définition précise d'une texture. En effet, initialement nous pouvons considérer la texture comme une région d'une image ayant une organisation spatiale étant homogène des niveaux de luminance [10] ou bien considérer une texture étant un phénomène à deux dimensions comme suit [11] :

- La première dimension désigne la description des primitives qui forment la texture.
- La deuxième dimension décrit les relations spatiales existantes entre ces primitives.

Haralick [12], un des piliers des chercheurs qui ont travaillé sur ce la texture, l'a défini comme suit : analyser la texture d'une image revient à la distinction du nombre et du types de ses primitives tonales tout en considérant leurs orientations spatiales. Une texture est une zone de l'image où nous définissons une fenêtre de dimensions minimales, pour laquelle une observation à partir de celle-ci se traduit par une perception visuelle identique vis à vis l'intégralité des translations possibles à appliquer à partir de cette fenêtre au-dedans de la région en considération [12].

I.4.2 Quantification de la texture d'une image

Nous distinguons 3 approches d'analyse de la texture d'une image [13] :

- **Les approches statistiques** : comme la fonction d'autocorrélation ou les matrices de cooccurrences.
- **Les approches Spatio-fréquentielles** : comme la transformée de Fourier, les bancs de filtres ou la transformée en ondelettes
- **Les approches structurelles** : comme les composantes connexes.

Nous allons définir ces approches comme suit [14] [15] :

a) Les méthodes statistiques

- **Les statistiques de premier ordre se basant sur l'histogramme**

Ces statistiques du premier ordre se calculent selon l'histogramme des intensités. En effet, elles n'exploitent que l'information relative au niveau de gris.

- **La matrice de cooccurrence considérant les couples de pixels**

Elle désigne une méthode statistique du second ordre qui fut appelée aussi méthode de dépendance spatiale des niveaux de gris. En effet, une matrice de cooccurrence mesure la probabilité d'apparition $P(i, j, \delta, \theta)$ calculant la fréquence qu'un pixel portant un niveau

d'intensité i apparaît à une distance relative δ d'un autre pixel portant un niveau d'intensité j , par la considération d'une orientation θ donnée [16][17]. Les paramètres suivants : 0, 45, 90 et 135 degrés sont prédominants par rapport à les directions angulaires θ . Il est important de mentionner que les caractéristiques extraites à partir de ces matrices, caractérisent l'homogénéité, les dépendances linéaires existantes entre les niveaux de gris, le contraste et la complexité observée dans l'image [13].

b) Les méthodes fréquentielle ou Spatio fréquentielles

Ces approches transforment l'image originale de façon que la nouvelle image soit obtenue en considérant les propriétés des fréquences spatiales relatives à l'intensité des pixels. En effet, la Transformée de Fourier Discrète (TFD) bidimensionnelle ou les filtres de Gabor sont les approches les plus répondues dans ce sens. Le résultat de ces méthodes est l'extraction des composantes de fréquence spatiale des images [18].

c) Les méthodes structurelles

Elles considèrent les textures composées des motifs ou primitives se répétant fréquemment ainsi que régulièrement dans l'image. L'ultime but est de tracer les règles régissant l'organisation spatiale relative à ces motifs [19].

I.5 L'apprentissage automatique et l'apprentissage profond en action

Le flux de travail des techniques de l'apprentissage automatique (Machine learning) et de l'apprentissage en profondeur (Deep learning) consiste à extraire des caractéristiques puis à les utiliser durant le processus de classification d'image [3]. La toute première étape de d'apprentissage automatique est l'extraction de caractéristiques qui dépend de différentes propriétés telles que la taille, l'origine, la forme et les données de pixel.

Dans certains cas, les méthodes d'extraction de caractéristiques sont fusionnées ensemble pour obtenir un meilleur résultat. Dans la deuxième phase, une méthode de classification est utilisée pour classifier les caractéristiques extraites dans la première phase.

I.5.1 L'apprentissage automatique

En appliquant l'apprentissage automatique, en extrayant ou en apprenant des descripteurs informatifs qui décrivent bien les régularités ou les modèles inhérents aux données jouent un rôle central dans diverses tâches d'analyse des images, spécialement les images médicales. En

effet, les approches d'extraction de caractéristiques sont devenues une technique dominante pendant longtemps. La conception et l'extraction de ces caractéristiques a toujours été le principal souci de développement d'un tel système [20].

Pour étudier la précision et le temps de traitement requis que l'apprentissage automatique peut consommer dans le diagnostic de tumeur, un concours de diagnostic de tumeur cérébrale a été mené sur 225 cas pour déterminer les exactitudes de diagnostic manuel et du diagnostic par machine, ceci à l'aide de : the Artificial Intelligence Research Centre for Neurological Disorders et une équipe d'un centre de recherche de : Capital Medical University.

D'une part, il a été constaté que le diagnostic de la machine (système Biomind) fournissait 195 réponses correctes avec un ratio de 87% en 15 min. D'autre part, le diagnostic manuel a fourni 148 cas correctement diagnostiqués avec un ratio de 66% en 30 min par une équipe de 15 radiologues [5]. Ces résultats démontrent la supériorité du diagnostic par apprentissage automatique sur le diagnostic manuel dans les termes de précision, de temps de traitement et d'efforts des radiologues.

L'apprentissage automatique regorge différents algorithmes. Nous évoquons quelques algorithmes dans ce qui suit [2] :

- **Machines à Vecteurs de Support SVM**

Les machines à vecteurs de support, ou support vector machine (SVM), sont des modèles d'apprentissage automatique supervisés centrés sur la résolution de problèmes de discrimination et de régression mathématiques. Elles ont été conceptualisées dans les années 1990 à partir d'une théorie d'apprentissage statistique. Ce modèle a été rapidement adopté en raison de sa capacité à travailler avec des données de grandes dimensions, ses garanties théoriques et les bons résultats réalisés en pratique. En effet, le fait qu'ils requièrent un faible nombre de paramètres, les SVM sont connus et appréciés pour leur simplicité d'usage.

Le principe des SVM consiste à ramener un problème de classification ou de discrimination à un hyperplan dans lequel les données sont séparées en plusieurs classes dont la frontière est la plus éloignée possible des points de données. En effet, de ce principe un nom a été attribué aux SVM : les séparateurs à vaste marge. Le concept de frontière implique que les données soient linéairement séparables. Dans ce sens, les machines à vecteurs de support font appel à des noyaux, consistant en des fonctions mathématiques permettant de projeter et séparer les données dans l'espace vectoriel, les vecteurs de support étant les données les plus proches de la frontière [3]. Nous présentons sur la figure I.1, un hyper plan optimal à deux dimensions.




Figure I.1 Hyper plan optimal à deux dimensions.

• Les réseaux de neurones

Les réseaux de neurones artificiels sont des réseaux de neurones qui utilisent un algorithme d'apprentissage et déduisent des règles d'apprentissage. Pour ce faire, un ensemble d'exemples de données de d'apprentissage est nécessaire, le concept est dérivé du concept de neurone biologique. Un neurone artificiel reçoit des entrées d'autres neurones, intègre les entrées avec des poids et active (ou "se déclenche" dans le langage de la biologie) lorsqu'une condition prédéfinie est satisfaite [21]. Nous exposons sur la figure I.2, un réseau de neurones.




Figure I.2 Exemple d'un réseau de neurones.

- **K-NN (K Nearest Neighbours)**

L'algorithme des K plus proches voisins est un algorithme d'apprentissage supervisé qui est basé sur la comparaison directe entre le vecteur de descripteurs de l'instance à classifier et le vecteur de l'instance de la banque d'apprentissage. En effet, ceci est effectué par le calcul d'une distance (généralement la distance Euclidienne) entre ces instances. Par la suite, la classification consiste à attribuer la classe majoritaire parmi les classes des K instances les plus proches de cette instance [4].

- **Les arbres de décision**

Les arbres de décision sont des algorithmes utilisant un modèle de graphe sous forme d'un arbre pour aboutir à la décision finale. Comme tout algorithme de l'apprentissage automatique, le but est la conception d'un modèle qui prédit la valeur de la variable cible en fonction de la valeur de plusieurs variables d'entrée.

Notons que les arbres de décision partent à partir d'un nœud, depuis duquel divers résultats possibles sont générés. Chacun de ces résultats donne l'accès à d'autres nœuds, depuis lesquels davantage de possibilités furent émises.

I.5.2 L'apprentissage profond

L'apprentissage profond ou Deep Learning (DL) est un sous-domaine de l'apprentissage automatique qui utilise des réseaux de neurones artificiels (ANN) pour développer des algorithmes de prise de décision [21]. En effet, le réseau neuronal est combiné pour former le réseau neuronal profond. Ces techniques ont permis des progrès significatifs dans les domaines du traitement de l'image, notamment la reconnaissance faciale, la vision par ordinateur, la reconnaissance vocale, le traitement automatisé du langage ainsi que la classification du texte où ceci consiste par exemple en la reconnaissance de spam.

Nous distinguons divers types d'architectures relatifs aux réseaux de neurones, citons :

- Les perceptrons multicouches désignant ceux les plus anciens simples.
- Les réseaux de neurones convolutifs (Convolutional Neural Networks ou CNN), particulièrement adaptés au traitement des images.
- Les réseaux de neurones récurrents dédiés aux données séquentielles comme le texte.

Nous nous intéressons aux réseaux de neurones convolutifs. En effet, nous allons les détailler dans ce qui suit :

Les réseaux de neurones convolutifs (connus sous CNN) est une classe de réseau neuronal profond qui s'inspire du cortex de nos yeux où un petit groupe de cellules est réceptif à un type spécifique des paramètres du champ visuel tels que les caractéristiques verticales et horizontales [22].

Le processus de construction d'un CNN comprend six étapes principales [23]: la convolution, la couche de correction où nous distinguons la fonction d'activation (ReLU), le pooling, les couches entièrement connectées et la fonction Softmax. À l'étape initiale, un certain nombre de filtres de convolution sont appliqués à l'image d'entrée pour activer certaines caractéristiques des images. Afin d'augmenter la vitesse d'apprentissage, les valeurs négatives sont mappées sur zéro et les valeurs positives restent inchangées dans l'étape ReLU. Le but de l'étape de pooling est de simplifier la sortie en effectuant un sous-échantillonnage non linéaire, et donc de réduire le nombre de paramètres que le réseau doit connaître. Ces trois opérations sont répétées sur des dizaines ou des centaines de couches, chaque couche apprenant à détecter différentes caractéristiques. Dans l'étape d'aplatissement, tous les tableaux bidimensionnels sont transformés en un seul vecteur linéaire. Un tel processus est nécessaire pour que des couches entièrement connectées soient utilisées après des couches convolutives. Les couches entièrement connectées sont capables de combiner toutes les caractéristiques locales des couches convolutives précédentes. La procédure est terminée avec l'application de la fonction softmax pour fournir la sortie de la classification finale. Nous présentons sur la figure I. 3, l'architecture générale d'un CNN [21].




Figure I.3 Architecture Générale d'un CNN. Source [21]

A présent, nous allons détailler chaque couche comme indiqué dans [22] :

1- La couche convolutive

Elle est responsable de l'extraction des caractéristiques tels que les bords, les lignes, etc. de l'image donnée. Elle extrait les caractéristiques utilisant une opération de convolution avec une matrice de fenêtre glissante appelé filtre ou noyau. Plus précisément, le filtre effectue une opération de multiplication avec un sous-ensemble de pixels d'image d'entrée et la sommation des résultats de multiplication pixel par pixel est effectuée comme mentionné sur la figure I.4.

Ensuite, le filtre glisse le long de l'image entière pour effectuer la même opération. Maintenant, le résultat de chaque opération de convolution est concaténé dans une matrice appelée carte de caractéristiques dans la terminologie CNN.

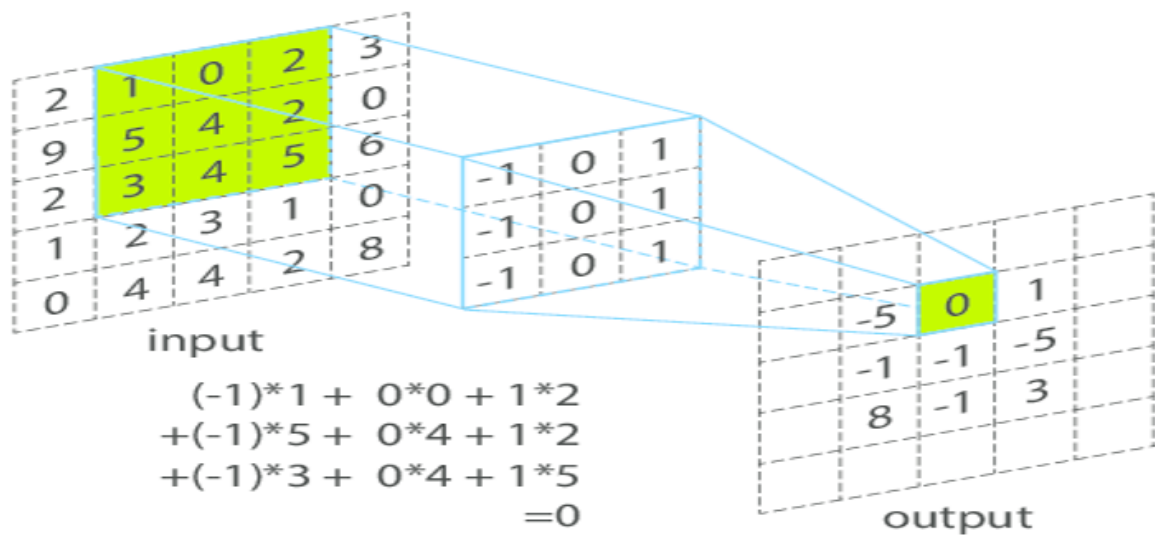


Figure 1.4 Application de la convolution sur un image

Il y aura plusieurs couches convolutives en fonction de la nature complexe de l'application. Il semble que les couches initiales capturent les informations de base comme les bords et les dégradés, etc. et les couches vers la fin capturent les caractéristiques détaillées de l'image à partir des résultats des couches initiales.

2- La couche de pooling

Elle est utilisée pour réduire la dimension de la carte d'entités. La carte des caractéristiques qui a l'allure d'une image est divisée en plusieurs sous-ensembles qui ne se chevauchent pas et à partir de chaque sous-ensemble, le paramètre pertinent est obtenu.

Il existe deux types de pooling en fonction du paramètre sélectionné à savoir le pooling maximal et le pooling moyen. Dans le pooling maximal, la valeur maximale du sous-ensemble est sélectionnée tandis que dans le pooling moyen, la valeur moyenne du sous-ensemble est sélectionnée. Nous exposons sur la figure I.5, deux exemples l'un relatif au max pooling et l'autre à average pooling.

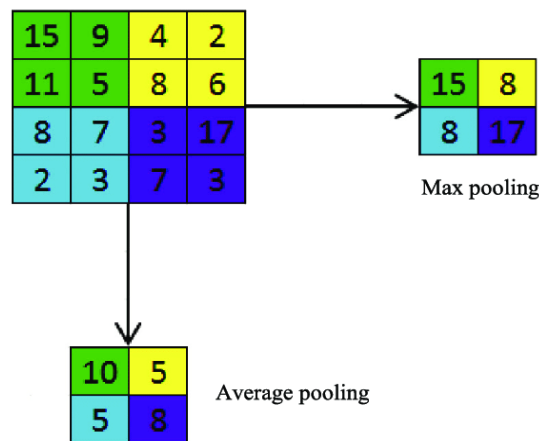


Figure I.5 Deux exemples l'un relatif au max pooling et l'autre à average pooling.

Le principal but de la couche de pooling est de réduire le temps de calcul global.

3- La couche de correction ReLu

Cette couche rajoute la non-linéarité à l'architecture qui est nécessaire dans tout réseau de neurones.

Sans l'ajout de non-linéarité, le système sera linéaire dans la nature qui conduira à l'échec de l'analyse de complexe applications. Il existe plusieurs fonctions d'activation comme Sigmoid, tanh, ReLu ...etc. En général, la fonction ReLu est utilisée pour les CNN car elle évite le problème de « vanishing gradient » pendant l'apprentissage.

4- La couche entièrement connectée

Elle présente un réseau de neurones artificiels de base où tous les nœuds des précédentes couches sont connectés à la couche suivante. La matrice de sortie des caractéristiques de la couche de convolution finale est aplatie pour former un vecteur unique qui est ensuite donné aux couches entièrement connectées. Cette couche apprend une fonction non linéaire à partir des caractéristiques et génère les résultats de la classification.

I.6 Evocation de quelques modèles des réseaux de neurone convolutifs

I.6.1 U-net

Ces derniers temps, un FCN de bout en bout (entièrement Convolutional Network) nommé U-Net a été introduit pour la segmentation des images [28]. L'architecture se compose d'un encodeur et d'un décodeur. Le codeur est utilisé pour extraire les caractéristiques spatiales de l'image tandis que le décodeur est utilisé pour construire une carte de segmentation à partir de caractéristiques encodées. L'encodeur implique la série de processus de convolution double 3×3 qui est ensuite suivi par la fonction max-pooling.

La figure I.6 montre l'illustration de l'architecture U-Net. Il s'agit d'un réseau puissant et donc le processus d'apprentissage est très rapide et envoie une segmentation précise. Moins d'informations sont nécessaires pour obtenir de meilleurs résultats, tout en conservant la possibilité de faire un apprentissage sur des échantillons de grande taille.

Outre la profondeur accrue du réseau à 19 couches, U-Net bénéficie d'une conception supérieure des skips connections entre les différentes étapes du réseau [24]. Il emploie quelques modifications pour surmonter le compromis entre la localisation et l'utilisation du contexte. Ce compromis augmente car les patchs de grande taille nécessitent plus de couches de pooling et par conséquent réduira la précision de la localisation.

En revanche, les patchs de petite taille ne peuvent observer qu'un petit contexte d'entrée. La structure proposée consiste de deux voies d'analyse et de synthèse. Le parcours d'analyse suit la structure de CNN. Le chemin de synthèse, communément appelé phase d'expansion, se compose d'une couche de suréchantillonnage suivie d'une couche de déconvolution.




Figure I.6 Architecture de U-net. Source [25]

I.6.2 AlexNet, ResNet et VggNet

AlexNet développé par Krizhevsky, Sutskever et Hinton a remporté le ImageNet Large Scale Visual Recognition Challenge (ILSVRC) en 2012. L'exemple d'architecture AlexNet est illustré à la Figure I.7. VggNet a obtenu la deuxième place dans le défi ILSVRC-2014 pour la tâche de classification avec un taux d'erreur de 7,3 % et a obtenu la première place pour le projet de localisation. AlexNet formé à l'aide de la base de données ImageNet a permis d'améliorer la précision de la classification par rapport à AlexNet. L'architecture typique de VggNet est donnée sur la figure I.7. Le réseau de neurones résiduels (ResNet) a obtenu la première place pour la tâche de classification dans le défi ILSVRC 2015 avec un taux d'erreur de 3,57 %. L'architecture ResNet a été capable de former un réseau de neurones avec 152 couches et a donné de meilleures performances de classification que d'autres architectures bien connues telles qu'AlexNet et VggNet. L'empilement de nombreux blocs résiduels forme l'architecture ResNet. En effet, sa principale contribution réside dans la modélisation de la représentation résiduelle dans la structure du réseau CNN, ce qui résout la difficulté de former une structure de réseau très profonde. La représentation schématique du ResNet-34 typique est illustrée à la figure I.7 [26] [27].

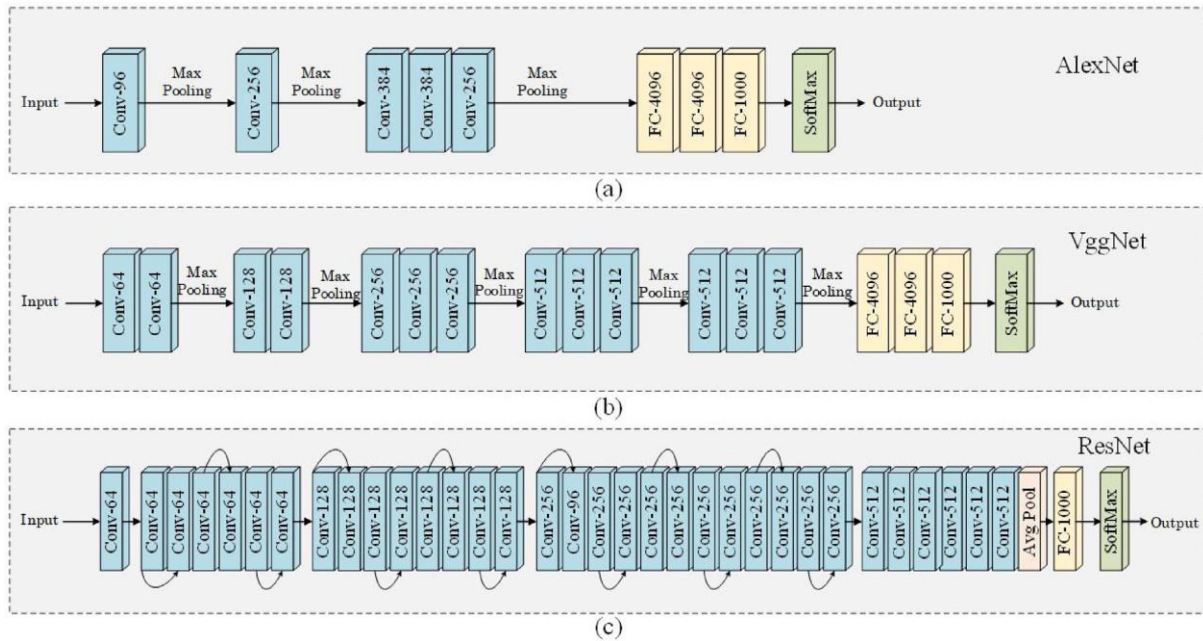


Figure I.7 Diverses architectures, à savoir de AlexNet, VggNet et ResNet. Source [26]

I.6.3 Mask-RCNN

En ML (Machine Learning), pour résoudre les problèmes liés à la segmentation DNN (Deep Neural Network) nommée Mask-RCNN (Murali et Meena 2019) [28] est introduit. Mask-RCNN est un cadre de segmentation d'instance introduit pour la détection d'instances de manière appropriée. La représentation de Mask-RCNN est illustrée à la Figure I.8.

La technique est utilisée pour séparer des objets dissemblables dans une image ou bien une vidéo. Si une image est donnée à Mask-RCNN, cela représente l'image en termes de boîtes englobantes d'objets, de classes et masques. Comparé à U-Net, Mask-RCNN produit une segmentation moins précise. Mask-RCNN utilise deux étapes RPN (Region Proposal Network) et Fast-RCNN. Dans la deuxième étape, les caractéristiques sont extraites au moyen de RoIPool de chaque boîte de candidat pour exécuter le processus de classification. FPN (Feature Pyramid Network) est utilisé par masque R-CNN pour faire progresser la pyramide d'extraction de caractéristiques standard qui utilise un niveau élevé de caractéristiques pour les passer aux couches inférieures. La reconnaissance d'objets se fait à l'aide de RPN (Region Proposal Network) qui est utilisé pour diviser l'image en ancres et détecte également les zones entourant l'objet de l'intérêt. Les boîtes englobantes sont le résultat du RPN, puis les ROI (région d'intérêts) sont catégorisées. Enfin, les masques sont générés par Mask R-CNN.

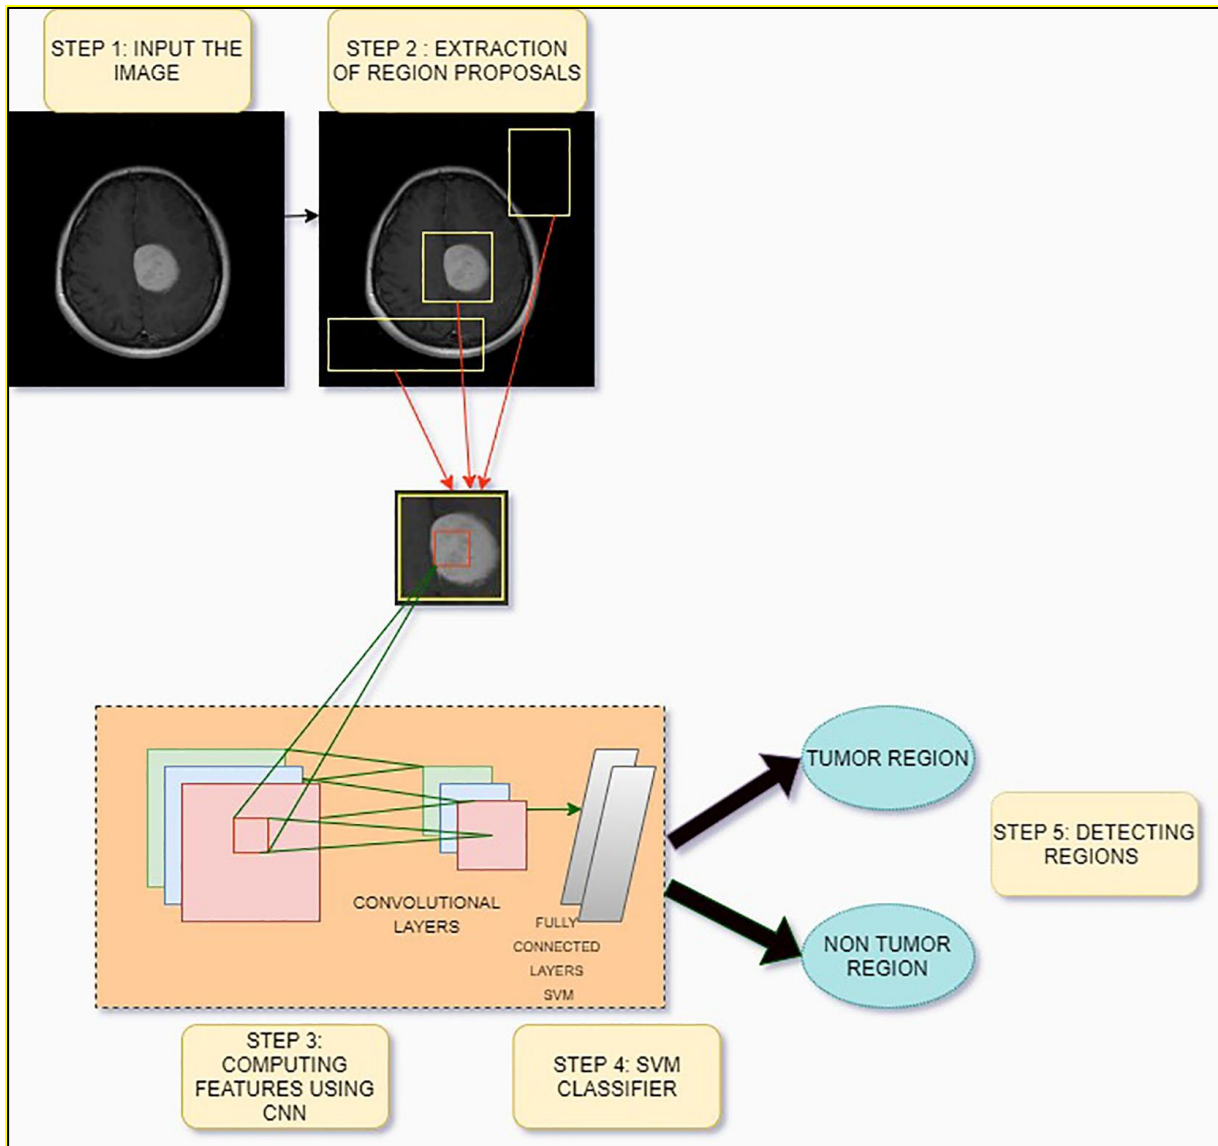


Figure I.8 Architecture de Mask -RCNN. Source [22]

I.7 Conclusion

Tout au long de ce chapitre, nous avons défini les plus importants concepts en relation à l'apprentissage automatique et l'apprentissage profond. Vu que nous nous intéressons aux réseaux de neurones convolutifs, ils ont fait l'objet de nos sections et sous-sections.

Quant au chapitre suivant, il sera consacré à un état de l'art concernant le pronostic automatique du cancer du cerveau où nous nous concentrons sur la formulation d'une contribution avec les paradigmes de l'intelligence artificielle évoqués dans ce chapitre.

A decorative border resembling a scroll, with a black outline and rounded corners. The top and bottom edges are slightly curved, and the left side features two scroll-like flourishes at the top and bottom corners.

Chapitre II

**Initiation au pronostic automatique
du cancer du cerveau**

II.1 Introduction

Le cancer du cerveau est très dangereux et répartis dans le monde entier. En effet, la tumeur cérébrale peut avoir une nature bénigne ou maligne où celle bénigne présente une structure uniforme sans les cellules actives ou cancéreuses, d'autre part, celle maligne présente une structure non uniforme avec des cellules actives.

Le gliome est un type de tumeur cérébrale qui se développe sur la région des tissus gliaux et de la moelle épinière, le méningiome est un type de tumeur qui se développe sur la zone de la membrane (la zone qui protège le cerveau et la moelle épinière), tandis que la tumeur hypophysaire se développe sur la zone de la glande pituitaire. En effet, le méningiome et les tumeurs hypophysaires sont faciles à détecter en raison de leur lieu d'apparition, cependant les gliomes sont difficiles à analyser. Ainsi, une tumeur cérébrale maligne primaire a un pronostic sombre et réduit considérablement la fonction cognitive et la qualité de vie.

Dans ce sens, les radiologues subissent une submergence de flux de donnée d'imagerie IRM cérébrales où des approches d'apprentissage automatique ou d'apprentissage en profondeur sont sollicitées dans le but d'offrir un deuxième avis pour l'élaboration du diagnostic final. En effet, le développement de systèmes CAD d'aide au diagnostic médical assisté par ordinateur était une nécessité. Tout au long de ce chapitre, nous évoquerons l'état de l'art sur le pronostic automatique des tumeurs cérébrales.

II.2 Le cancer du cerveau

Selon les rapports de l'organisation mondiale de la santé (World Health Organization (WHO)) [23], nous estimons que 9,6 millions de personnes dans le monde sont décédées du cancer en 2018. 30 à 50 % d'entre eux étaient évitables grâce à un diagnostic précoce. Parmi les types de cancer, la tumeur au cerveau est l'une des plus meurtrières. Selon les statistiques, nous estimons que 17 760 adultes sont morts de tumeurs cérébrales en 2019.

Le cancer du cerveau se classe au dixième rang des principales causes de mortalité en étant considéré comme le 3^{ème} cancer le plus répandu chez les adolescents et adultes [29]. Le taux de survie à cinq ans des hommes et les patientes femmes atteintes d'un cancer du cerveau est de 34 % et 36 % respectivement. En effet, les tumeurs cérébrales sont constituées de tissus provoqués par une prolifération cellulaire incontrôlée, qui n'ont aucune fonction physiologique dans le cerveau [2].

Les causes d'une tumeur au cerveau peuvent être attribuées aux aspects de l'environnement tels que l'utilisation excessive de produits chimiques artificiels ou bien aux facteurs génétiques. Les options de traitement comprennent la radiothérapie, la chimiothérapie et l'intervention chirurgicale.

Il existe deux types de tumeur cérébrale [3] : tumeur cérébrale primaire et tumeur cérébrale secondaire. Dans les tumeurs cérébrales primaires, les cellules cancéreuses proviennent du cerveau, tandis que dans les tumeurs secondaires du cerveau, les cellules cancéreuses sont transportées vers le cerveau à partir d'une tumeur située dans une autre partie du corps. La tumeur cérébrale secondaire est également connue sous le nom de cancer métastatique. Le cancer du cerveau est un type courant de tumeur qui se localise toujours dans le cerveau ou système nerveux central. Trente pour cent des tumeurs cérébrales sont des tumeurs cérébrales primaires, alors que 20 à 30 % des personnes sont touchées due à un cancer métastatique.

Selon la structure tissulaire, le cerveau humain se constitue de trois parties importantes : la matière grise, la matière blanche ainsi que le liquide céphalo-rachidien (CSF) comme nous pouvons le constater sur la figure II.1.




Figure II.1 Structure tissulaire du cerveau humain.

II.3 Les différents types des tumeurs cérébrales

La tumeur du cerveau est l'une des tumeurs malignes les plus courantes et les plus agressives, entraînant une espérance de vie très courte si elle fut diagnostiquée à un grade supérieur. Un tel type des tumeurs expose le tissu cérébral à une déclinaison de taille ce qui entraîne des dommages massifs au réseau neuronal du cerveau, perturbant par conséquent son travail. Nous nous intéressons aux types suivants des tumeurs [30] :

- **Gliomes**

Le gliome est l'une des tumeurs cérébrales les plus primitives qui provient des cellules gliales. L'organisation mondiale de la santé (WHO) rapporte que le gliome peut être classé en quatre niveaux différents basés sur des images microscopiques et des comportements tumoraux. Les grades I et II sont des gliomes de bas grade (LGG) qui sont de nature plutôt bénigne avec un rythme de croissance lent. Les grades III et IV sont des gliomes de haut grade (HGG) qui sont cancéreux et agressif [31]. Le gliome est le type de tumeur cérébrale la plus répandue chez les adultes. En effet, il représente près de 80% des cas malins. Nous constatons que les patients atteints de gliomes de bas grade (LGG) ont un taux de survie global à dix ans d'environ 57 % [2]. Les gliomes de haut grade sont considérés comme plus destructeurs et pénétrants, et sont associés avec une espérance de vie d'environ 2 ans après diagnostic [3]. Le glioblastome est le

gliome le plus meurtrier, représentant 70 à 75 % de tous les diagnostics de gliome diffus, avec une durée médiane de survie globale de 14 à 17 mois [2].

- **Méningiome**

Le méningiome est généralement une tumeur bénigne qui se développe lentement dans la nature et se trouve dans les méninges (la membrane qui sépare le cerveau de la moelle épinière corde) [22]. Les méningiomes peuvent perturber la barrière hémato-encéphalique et former un oedème dans le tissu péri tumoral.

- **Tumeurs hypophysaires**

La glande située à la partie de base du cerveau est connue sous le nom de glande hypophysaire et la tumeur associée à cette glande s'appelle la tumeur de l'hypophyse [22]. La majorité de ces tumeurs sont bénignes, cependant elles peuvent subir un développement et devenir malignes. Ces tumeurs peuvent interférer avec le niveau d'hormone normale, affectant ainsi tout le corps. Certains types courants de tumeurs hypophysaires sont les craniopharyngiomes, les adénomes et les kystes de la fente de Rathke. Nous présentons sur la figure II, les trois types de tumeurs mentionnés précédemment.




Figure II.2 Exemple d'un Gliome en (a), un Méningiomes en (b) et une tumeur hypophysaire en (c).

II.4 L'imagerie par résonance magnétique (IRM) pour le dépistage du cancer du cerveau

Plusieurs technologies sont utilisées pour le diagnostic non invasif et pour surveiller et analyser les tumeurs telles que l'imagerie par résonance magnétique (IRM), la tomographie par émission de positrons (PET) et la tomodensitométrie (CT). Cependant, l'IRM est une technique de diagnostic efficace pour détecter les tumeurs des tissus mous et donc populaire pour l'imagerie cérébrale [32].

À l'heure actuelle, l'IRM, qui a été inventée en 1970, est la modalité d'imagerie la plus importante pour l'imagerie cérébrale en cours d'utilisation [5]. En effet, L'imagerie par résonance magnétique (IRM) est meilleure que les autres modalités d'imagerie pour le diagnostic et le traitement des tumeurs cérébrales en raison de sa propriété non invasive sans exposition aux rayonnements ionisants et du contraste d'image supérieur dans les tissus mous [33].

L'IRM offre un aspect délicat du cerveau, de l'anatomie vasculaire et la moelle épinière peut également visualiser la structure du cerveau dans tous les plans (axial, sagittal et coronal. L'IRM est connue comme une approche standard en raison de son contraste des tissus mous et de sa grande disponibilité.

Ce test est principalement fait pour vérifier les problèmes liés à la neurochirurgie et à la neurologie. L'IRM utilise les signaux de radiofréquence au moyen d'un puissant champ magnétique.

Les avantages de l'IRM par rapport aux autres méthodes sont [28] :

- 1- L'IRM est fréquemment utilisée pour l'inspection visuelle des nerfs crâniens, des anomalies du fosse postérieure et moelle épinière, car elle est moins sensible aux artefacts dans l'image par rapport au CT [21].
- 2- Contraste élevé.
- 3- Faible rayonnement.
- 4- Capacité à diagnostiquer le flux sanguin et les dysfonctionnements vasculaires.
- 5- Détecter facilement la maladie nerveuse.
- 6- Absence d'artefacts durcissant le faisceau.

Bien qu'une disponibilité d'experts expérimentés, l'évaluation qualitative physique est constamment sauté par le système de la vision humaine. Le système d'IRM peut créer des images autour de 65 535 Gy niveaux avec une résolution et une profondeur de bits supérieures à la vision humaine.

Chaque modalité d'IRM joue un rôle différent dans le diagnostic. Les régions œdémateuses sont délimitées dans les images T2 produisant une région d'image lumineuse. Les tissus sains peuvent être distingués dans les images T1. Les scans T1-Gd utilisent un agent de contraste qui donne un signal lumineux au bord de la tumeur en raison de son accumulation. Les scans FLAIR utilisent le signal de suppression des molécules d'eau qui distingue le liquide céphalo-rachidien (LCR) de la région de l'œdème [21].

Donc, en résumé quatre modalités d'IRM standard sont appliquées pour le diagnostic : FLAIR, T2-weighted MRI (T2), T1-weighted MRI (T1), et T1-weighted MRI avec amélioration du contraste (T1-Gd) comme le montre la Figure II.3.




Figure II.3 Exemples de différentes modalités d'IRM appliquées au gliome HG. Les exemples ont été extraits de la base de données BRATS 2013. De gauche à droite : Image IRM T1, Image IRM T1-Gd, image IRM T2 et image IRM FLAIR. Source [5]

II.5 Les facteurs rendant l'IRM restreinte pour le diagnostic du cancer du cerveau

Même si l'imagerie par résonance magnétique est la méthode la plus répandue en raison de sa modalité d'imagerie non intrusive qui fournit le contraste tissulaire distinctif ainsi que le fait qu'elle soit confortable en termes de normalisation du contraste tissulaire fournissant le moindre détail d'intérêt. Cependant, les limites suivantes sont rencontrées :

- La taille, la forme et la localité incertaines, aléatoires et irrégulières des tumeurs cérébrales dans les IRM [29]. De même, le partitionnement non autonome des tumeurs coûte beaucoup de temps et exige beaucoup de travail désignant une tâche lourde et largement subjective compte tenu de la quantité de données à traiter, réduisant ainsi la précision.
- Difficile de percevoir les changements infimes dans les images IRM, en particulier dans les premiers stades des anomalies [26].
- Dans l'IRM, il est difficile d'obtenir une détection précise des contours vu que l'IRM elle-même contient du bruit ricien, qui provoque des irrégularités dans l'estimation des contours pouvant conduire à un diagnostic erroné [34].
- Les IRM pourraient accumuler des anomalies ou, comme distorsions d'inhomogénéité et hétérogénéité du mouvement, dues aux mouvements produits par le sujet lors de l'acquisition ou les limites de l'appareil IRM. Ces artefacts déclenchent l'induction de faux taux d'intensité qui conduisent à de faux points positifs dans l'image [29].

Dans l'analyse des images médicales, l'une des tâches difficiles est la reconnaissance des tumeurs via des images de résonance médicale (IRM) [28]. Le processus de diagnostic est encore fastidieux en raison de sa complexité et à sa grande variété dans les tissus de perception tumorale. Par conséquent, les nécessités des techniques d'identification automatique des tumeurs augmentent de nos jours pour la médecine.

II.6 Diagnostic automatique (CAD) du cancer du cerveau

Avec l'ultime but d'éviter l'effet désagréable de la biopsie, il a été nécessaire de concevoir un outil efficace aidant au diagnostic précis du cancer du cerveau. Dans ce sens, l'apparition des technologies robustes d'apprentissage automatique ainsi que profond a ouvert une frontière prometteuse dans l'imagerie médicale et le diagnostic automatique.

Le diagnostic assisté par ordinateur en imagerie médicale trouve ses origines dans les années 1980 au laboratoire Kurt Rossmann de Recherche en Image Radiologique du Département de Radiologie de l'université de Chicago [21]. Les premiers travaux portaient sur la détection du cancer du sein. Il y a eu beaucoup de recherche et de développement de systèmes CAD

utilisant différentes modalités des images médicales. Le CAD ne se substitue pas au spécialiste mais peut aider ou être adjoint au spécialiste de l'interprétation des images. En d'autres termes, les systèmes CAD peuvent fournir un "deuxième avis objectif" et rendre la décision de la maladie finale à partir d'informations basées sur l'image et la discrimination des lésions, en complément d'une évaluation du radiologue.

Le développement CAD prend en compte les principes de la radiomique. Le terme radiomique est défini comme l'extraction et l'analyse de caractéristiques quantitatives des images médicales, c'est-à-dire la conversion des images médicales en données exploitables avec une haute-fidélité et un haut débit pour l'aide à la décision. Les images médicales utilisées en radiomique sont obtenues principalement par TDM, PET ou IRM.

L'identification précise de l'anomalie à partir de l'imagerie cérébrale dépend quelque peu de la capacité d'un médecin spécialiste. La limitation des techniques existantes et traditionnelles utilisées pour la détection et l'identification des maladies du cerveau a poussé le développement du diagnostic assisté par ordinateur (CAD) [3].

Le diagnostic assisté par ordinateur (CAD) est entièrement automatisé et beaucoup moins coûteux et nécessite moins de temps pour l'identification des maladies du cerveau. Le CAD augmente également les capacités des médecins spécialistes. Actuellement diverses techniques de machine learning et deep learning sont utilisées pour détecter et classifier les anomalies dans le cerveau de manière automatisée. La performance d'identification est améliorée grâce à l'apprentissage automatique et techniques d'apprentissage utilisant les scanners médicaux et les données médicales pour la détection des anomalies cérébrales. L'imagerie médicale et diverses techniques d'apprentissage automatique et d'apprentissage en profondeur sont intégrés ensemble afin d'aboutir aux résultats précis.

Le cadre général d'un système de diagnostic assisté par ordinateur (CAD) pour le diagnostic de tumeur cérébrale à l'aide des images IRM, comme résumé dans la Figure II.4, consiste en la collecte de données, le prétraitement, la segmentation, l'extraction de caractéristiques, la sélection de descripteurs, la réduction de descripteurs, la classification, l'évaluation des performances et le diagnostic [5].

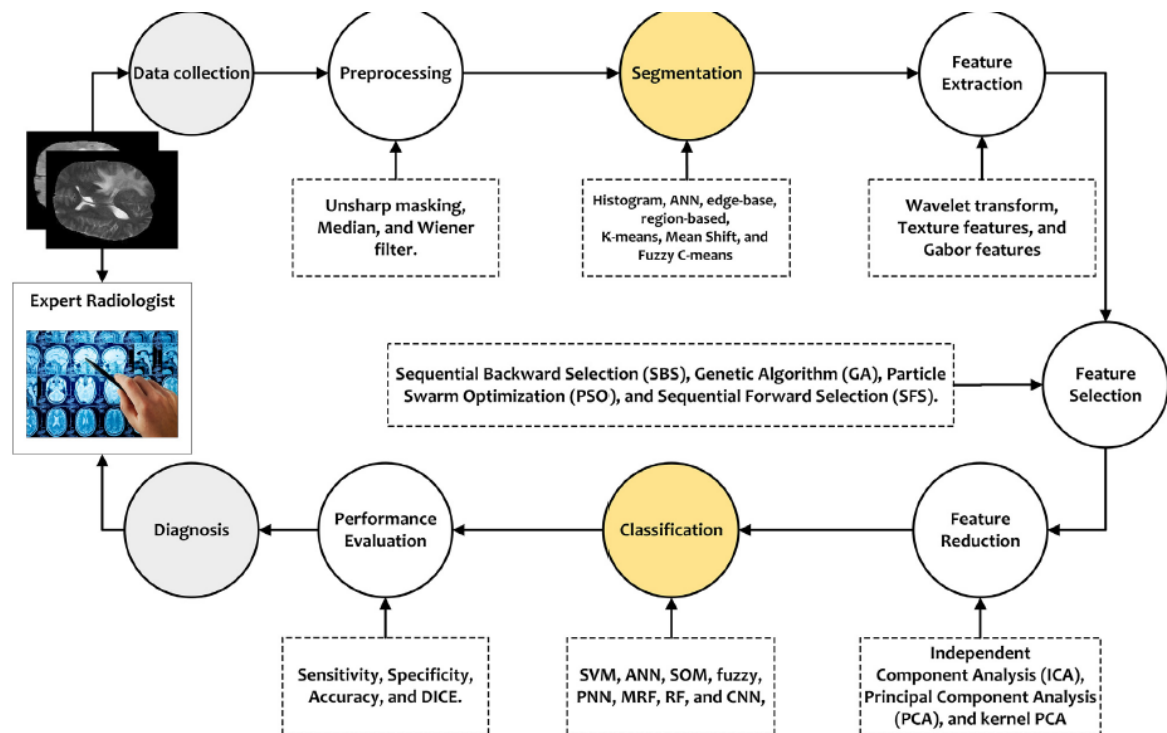


Figure II.4 Organigramme d'un système générique de diagnostic assisté par ordinateur (CAD) pour le diagnostic des tumeurs cérébrales. Cet organigramme montre toutes les étapes d'un système CAD complet ; il est nécessaire d'avoir toutes les étapes combinées dans un seul système. Source [5]

Un système CAD se compose des deux parties suivantes :

II.6.1 Détection des tumeurs assistée par ordinateur (CADE)

L'annotation tranche par tranche d'une tumeur cérébrale à partir d'examens IRM est une tâche laborieuse et chronophage [33]. Cette charge manuelle peut être remplacée par une segmentation automatique à l'aide d'algorithmes de vision par ordinateur. En effet, le but de CADE est de trouver ou de localiser des régions anormales ou suspectes dans des images structurales [35] et donc d'alerter les cliniciens.

Durant le processus de segmentation, une image est divisée en plusieurs segments. Cette partition s'effectue entre divers tissus tumoraux (nécrose, œdème et tumeur solide) et tissus cérébraux, nommés liquide céphalorachidien, matière grise et blanche [28]. Pour l'application thérapeutique, l'approche de segmentation de l'IRM est classée comme : manuelle, semi-

automatique, entièrement automatique et hybride. En méthode manuelle de la segmentation, l'étiquetage de l'image et la segmentation des limites sont réalisés par des experts humains en utilisant les mains.

Fondamentalement, les méthodes de segmentation basées sur l'atlas sont appliquées pour la segmentation manuelle. Pour réduire les certaines complexités de la méthode manuelle de segmentation, des processus bénéfiques de méthodes semi-automatiques et automatiques sont activés. Dans une segmentation automatique, la segmentation de limites sont attribuées automatiquement à l'aide d'un ordinateur.

La méthode de segmentation entièrement automatique est meilleure que la méthode semi-automatique en raison de ses effets suprêmes optimaux.

Il convient de mentionner, entre autres, qu'il existe actuellement deux catégories de tâches de segmentation d'image [25] : la segmentation sémantique et la segmentation d'instance. La segmentation sémantique d'image est une classification au niveau du pixel en attribuant une catégorie correspondante à chaque pixel d'une image. En effet, nous visons à réaliser une classification des pixels d'une image. Pour cet objectif, les chercheurs ont proposé la structure codeur-décodeur qui est l'une des architectures de bout en bout les plus populaires, comme le réseau entièrement convolutif (FCN, U-Net, Deeplab... etc). Dans ces structures, un encodeur est souvent utilisé pour extraire les caractéristiques de l'image alors qu'un décodeur est souvent utilisé pour restaurer les caractéristiques extraites à la taille de l'image d'origine et produire les résultats finaux de la segmentation.

II.6.2 Diagnostic des tumeurs assisté par ordinateur (CADx)

CADx fournit un deuxième avis objectif concernant l'évaluation d'une maladie à partir des images [35]. Les principales applications de CADx impliquent la discrimination des lésions malignes à partir des lésions bénignes et l'identification de certaines maladies à partir d'une ou plusieurs images. Classiquement, la plupart des systèmes CADx ont été développés pour utiliser des descripteurs conçus par l'homme et conçues par des experts du domaine. En effet, un algorithme ML ou DL est souvent un classifieur d'objets (par exemple des lésions dans les images médicales). La sélection des caractéristiques est une étape fondamentale dans le traitement de l'image médicale et plus spécialement, cela nous permet de rechercher quels

descripteurs sont pertinentes pour le problème de classification, et cela aide également à obtenir des taux de précision plus élevés [21].

La tâche d'extraction de caractéristiques est complexe en raison de la tâche de la détermination d'un algorithme capable d'extraire une représentation distinctive et complète des caractéristiques, et pour cette raison principale, il est très difficile de généraliser et implique qu'il faut concevoir une méthode de caractérisation pour chaque nouvelle application.

La classification est liée aux caractéristiques extraites qui sont saisies en entrée d'un modèle ML, tandis qu'un modèle d'algorithme DL utilise les valeurs de pixel dans les images directement comme entrée au lieu de caractéristiques calculées à partir d'objets segmentés.

Dans le cas du traitement des accidents vasculaires cérébraux avec des CNN, la caractérisation des images est une application clé et dépend du rapport signal sur bruit dans l'image, qui peut être amélioré par l'identification de la cible via la segmentation pour sélectionner les régions d'intérêt.

Plusieurs classifieurs sont utilisés dans les étapes de classification des tumeurs dans un système CADx [5], tels que les machines à vecteurs de support (SVM), kernel SVM (KSVM), réseau de neurones probabiliste (PNN), réseau de neurone artificiel (ANN), k-plus proche voisins (KNN), hybridation des algorithmes génétiques et machine à vecteurs de support (GA-SVM), FCM et réseau neuronal convolutif (CNN).

II.7 L'aide au diagnostic médical du cancer du cerveau basé apprentissage automatique

Nous présentons sur le tableau II.1 multiples approches CAD basées apprentissage automatique, de détection de cancer du cerveau tout en soulignant les classifieurs et techniques d'extraction de descripteurs, entre autres, les mesures de performance seront mentionnées.

Tableau II.1 Approches CAD basées apprentissage automatique (Machine Learning) de diagnostic du cancer du cerveau

Réf	Base de données utilisée	Contribution	Evaluation des performances
[36]	AMDI, in Bertam, Pulau Pinang, Malaysia	Une approche de classification des tumeurs cérébrales par l'extraction des descripteurs de la transformée en Ondelettes et une classification basée SVM.	Acc = 65%
[37]	Randomly selected	Une approche de classification des tumeurs cérébrales par l'extraction des descripteurs de la texture et une classification basée SVM.	Acc = 84%
[38]	Figshare by Cheng (Seulement 170 pour chaque classe)	Une approche de classification des tumeurs cérébrales en trois classes en extrayant les descripteurs de la transformée en Ondelette et en les donnant comme entré aux SVM durant le processus de classification.	Acc = 98.5%
[39]	Une base de données privée et publique (1000 Images utilisées au total)	Une approche de classification des tumeurs cérébrales par l'extraction des descripteurs de la transformée en Ondelettes et une classification basée réseau de neurone récurrent (RNN).	Acc = 96%
[40]	PSG IMS	Une approche de classification des tumeurs cérébrales par l'extraction des descripteurs de la texture et une classification basée BPN et RBFN.	Acc = 85.71%
[41]	Figshare Dataset (3064 images)	Une approche de classification des tumeurs cérébrales selon 3 types en extrayant les descripteurs par le modèle pré entraîné Googlenet via une classification basée SVM.	Acc = 97%
[42]	Département de radiologie Tata Memorial	Une approche d'extraction de descripteurs texturaux en basée sur la matrice de cooccurrence (GLCM) tout en appliquant une classification Neuro-fuzzy.	Acc = 89%
[43]	MICCAI 2013	Une approche de classification nommée (LIPC : Local Independent Projection Based classification) utilisant des descripteurs texturaux et statistiques.	Acc = 89%
[44]	Centres médicaux différents	Une approche de classification des tumeurs cérébrales par l'extraction des descripteurs de gray-level run-length matrix (GLRLM) Et une classification basée SVM et FCM.	Acc = 91.66%
[45]	BRATS 2013	Une approche d'extraction de descripteurs	Acc = 93.3%.

		texturaux en 3 dimensions dépendant sur la matrice de cooccurrence (GLCM) tout en appliquant différents algorithmes d'apprentissage automatique pour déterminer le grade de malignité de gliome.	
[46]	BRATS 2017 et BRATS 2015	Une approche d'extraction de descripteurs de forme, texture, intensité utilisant les formules de Beta et Gamma. De plus, L'homogénéité, l'énergie et l'entropie ont été calculé pour une classification des tumeurs, basée les SVM.	Acc = 98%
[47]	Non mentionnée	Une approche extrayant des descripteurs texturaux par les filtres de Gabor et une classification basée SVM.	Acc = 87%
[48]	BRATS 2015	Une approche extrayant 25 descripteurs texturaux et 7 descripteurs de forme pour la classification des tumeurs cérébrales via les SVM.	Acc = 94.33%
[49]	PGIMER	Une approche extrayant des descripteurs texturaux et une classification basée ANN.	Acc = 91.7%
[50]	DICOM et Brain Web dataset	Une approche extrayant des descripteurs texturaux ainsi que des descripteurs statistiques dans un processus de classification des tumeur cérébrales basé les SVM.	Acc = 96.51 %

II.8 L'aide au diagnostic médical du cancer du cerveau basé apprentissage profond

Nous exposons sur le tableau II.2 diverses approches CAD basées apprentissage profond de diagnostic de cancer du cerveau.

Tableau II.2 Approches CAD basées apprentissage profond (Deep Learning) de diagnostic du cancer du cerveau

Réf	Base de données utilisée	Contribution	Evaluation des performances
[51-a]	BDD 1: PGIMER(Postgraduate Institute of Medical Education & Research) BDD 2: SPL	Une approche de classification de divers types de tumeurs cérébrales au long de deux bases de données : BDD1 1: Astrocytoma (AS), childhood tumor Medulloblastoma (MED), Glioblastoma Multiforme (GBM), Meningioma (MEN). BDD 2: AS, Meningioma (MEN) et Low Grade Glioma (LGL) où une classification basée GA-ANN a été réalisée.	Acc = 94% (BDD 1) Acc = 94.1% (BDD 2)
[51-b]	Base de données du site de Kaggle	Une approche proposant un modèle amélioré de ResNet50 pour une classification binaire en tumeur ou non tumeur où 8 couches ont été ajoutées à l'architecture originale de ResNet 50.	Acc = 97%
[52]	Base de données du site de Kaggle	Un modèle de réseau de neurone convolutif a été proposé selon 3 étapes : la première consiste en Convolution Block Attention Module (CBAM) permettant le réseau de reconnaître l'information spatiale. La deuxième étape permet au réseau d'apprendre des fonctionnalités plus importantes et la dernière consiste en hyper Column technique implémentée avant la couche entièrement connectée.	Acc = 96.05%
[53]	Figshare (3064 images)	Une approche basée sur l'augmentation des images IRM de la base de données utilisée, a été proposée pour les fournir comme entrées au modèle ResNet50 d'apprentissage profond pour le processus de classification des IRM cérébrales.	Acc = 98%
[54]	BDD 1 : IXI dataset BDD 2: REMBRANDT dataset	Une approche de classification de divers types de tumeurs cérébrales au long de deux bases de données : BDD 1: Meningioma, Pituitary, Glioma BDD 2: Normal, différents grades de glioma (Grade I, II, III, IV) avec une classification basée CNN-GA.	Acc=90.9% (BDD 1) Acc =94.2% (BDD 2)

[55]	Figshare (3064 images)	Une approche basée le modèle d'apprentissage profond (GANs : Generative Adversarial Networks). L'idée principale était l'utilisation de CNN comme un discriminateur de GAN pour le pré-entraîner. La dernière couche du CNN discriminateur dans le GAN a été remplacé par SoftMax pour la classification.	Acc = 88%
[56]	(TCGAGBM : Cancer Genome atlas glioblastoma multiform) et une base de données (TCIA : cancer imaging archive)	Une approche hybride SR-FCM-CNN a été proposé. Premièrement un pré-traitement est effectué basé SR CNN. Les images à basse résolution sont converties à haute résolution en utilisant cette approche ensuite une segmentation basée FCM est effectuée où Squeeze-net a été appliqué pour l'extraction des descripteurs basé ELM.	Acc = 98%
[57]	BDD 1: Radiopaedia dataset BDD 2: Brain tumor dataset	Une approche de classification de divers types de tumeurs cérébrales : Meningioma, Pituitarytumor, Glioma à travers une classification basée CNN-DA	BDD 1 : Acc = 90.67%, (Après l'augmentation) Acc = 87.38% (avant l'augmentation) BDD 2 : Acc = 94.58%
[58]	Figshare (3064 images)	Une approche basée R-CNN pour la détection et classification des tumeurs cérébrales en 3 types a été proposé. Region proposal network a été utilisé pour le marquage précis de la région de la tumeur.	Acc = 77.60%
[59]	Base de données du site de Kaggle	Une approche basée le modèle CNN qui prend comme entrée une IRM pour la segmenter et extraire les descripteurs par le CNN. Les sorties sont classifiées comme tumeur ou non tumeur.	Acc = 90-99%
[60]	BRATS 2016	Une approche utilisant (PG-GANS : Progressively Growing Generative Adversarial Networks) a été proposé pour augmenter la base de données de BRATS-2016 pour la détection précise des tumeurs basée RESNET-50.	Acc = 91%

II.9 Conclusion

L'explosion des techniques d'intelligence artificielle, d'apprentissage automatique et en profondeur a engendré le développement d'approches prometteuses pour le diagnostic assisté par ordinateur des tumeurs cérébrales, améliorant dans ce sens le diagnostic tardif et réduisant l'intervention humaine.

Nous allons exposer dans le chapitre prochain la problématique tirée dans ce domaine d'actualité ainsi que le cadre méthodologique suivi pour l'implémentation de l'approche proposée de diagnostic du cancer du cerveau assisté par ordinateur.

A decorative border resembling a scroll, with a horizontal bar at the top and two curved ends on the left side.

Chapitre III

**Extraction de la problématique et
définition de l'approche proposée**

III.1 Introduction

Durant ce chapitre, nous évoquerons la problématique soulignée consistant en l'implémentation de modèles réalisant la prédiction du cancer du cerveau, bâti sur les paradigmes de l'apprentissage automatique ainsi que l'apprentissage profond.

III.2 Problématique et plan d'action

Les tumeurs cérébrales augmentent non seulement la taille et la pression dans le cerveau, mais génèrent également un gonflement provoquant tous symptômes neurologiques anormaux. En effet, selon « the National Brain Tumor Foundation (NBTF) », le nombre de personnes dans les pays développés qui meurent des suites de tumeurs cérébrales a augmenté de 300 % [5].

L'IRM fournit de riches informations sur l'anatomie des tissus humains, et en raison de sa grande disponibilité et le contraste des tissus mous, elle est considérée comme une technique standard. En effet, l'IRM utilise des signaux de radiofréquence avec un champ magnétique puissant pour produire les images du tissus humains.

En clinique, l'interprétation des images médicales a été effectuée principalement par des experts humains tels que les radiologues et les médecins. Cependant, étant donné les grandes variations de pathologie et la fatigue potentielle des experts humains, un besoin crucial de méthodes assistées par ordinateur avec une meilleure précision pour le diagnostic précoce de la tumeur était en ordre. D'autre part, les contours relatifs aux tumeurs sont flous et les tumeurs ont tendance à se propager dans la région voisine du cerveau rendant la tâche de la différenciation du tissu affecté des tissus sains environnants difficile. Dans ce sens, l'identification manuelle des tumeurs au sein des IRM est sujette aux erreurs. En effet, le diagnostic assisté par ordinateur des tumeurs cérébrales à partir des images IRM consiste en des processus de détection, de segmentation et de classification des tumeurs [5].

D'après la littérature récente, il est évident que bien que les modèles d'apprentissage en profondeur aient atteint une précision inégalée dans la classification et la segmentation des images, leur principale limite est l'interprétabilité, c'est-à-dire l'identification des caractéristiques responsables dans la prise de décision. C'est l'élément le plus important dans la compréhension du modèle et a limité l'acceptation des méthodes DL, en particulier dans le domaine médical. Les radiologues, utilisant des modèles d'IA pour les aider à diagnostiquer diverses conditions dans un système de soutien de la santé, doivent réaffirmer les décisions qu'ils prennent utilisant ces modèles. Cela nécessite que le modèle les aide à interpréter ou à visualiser les caractéristiques qui ont permis la décision du modèle.

Une fois avoir souligné les points problématiques, nous allons indiquer le plan d'action lui faisant recours, comme suit :

- 1- Pour réduire la charge de travail des pathologistes et améliorer l'objectivité de l'analyse des images, nous allons suggérer le diagnostic assisté par ordinateur ou les systèmes (CAD) comprenant le traitement d'image et les techniques modernes d'apprentissage automatique et d'apprentissage profond.
- 2- Un prétraitement des IRM par un filtre médian sera réalisé vu qu'il est le plus souvent utilisé pour préserver les contours [5]. De plus il a été démontré que les filtres médians sont supposés minimiser l'erreur quadratique moyenne entre les images d'origine et de sortie [61].
- 3- Actuellement les algorithmes d'intelligence artificielle surtout ceux qui utilisent une technique hybride de CNN et de classifieurs d'apprentissage automatique produisent une transformation marquée dans la caractérisation et la segmentation en traitement des images médicales [21]. En effet, les CNN ont une grande utilité dans des tâches telles que l'identification des caractéristiques de la hiérarchie de composition et caractéristiques de bas niveau (par exemple, bords). A cet effet, nous allons réaliser une segmentation des tumeurs basée U-net et une classification basée les machines à vecteur de support (SVM). Le choix de U-net était par rapport au fait que Contrairement à la segmentation d'image courante, les images médicales contiennent généralement du bruit et affichent des frontières floues. Par conséquent, il est très difficile de détecter ou de reconnaître des objets dans des images médicales uniquement en fonction des caractéristiques de bas niveau de l'image. En outre, il est également impossible d'obtenir des limites précises en fonction uniquement des caractéristiques sémantiques de l'image en raison du manque d'informations détaillées sur l'image. Tandis que U-Net fusionne efficacement les caractéristiques d'image de bas niveau et de haut niveau en combinant des cartes de caractéristiques basse résolution et haute résolution via des skip connexion, ce qui est une solution parfaite pour les tâches de segmentation des images médicales [25]. Actuellement, U-Net est devenu la référence pour la plupart des tâches de segmentation des images médicales.

- 4- Utilisation de la variance intra-patch, qui représente les informations de texture locales, était crucialement informative, qui est également corrélée avec des résultats radiologiques.
- 5- L'incorporation de caractéristiques robustes pour la classification basée SVM où l'analyse texturale fera l'objet de la distinction entre les tumeurs cérébrales (les tumeurs considérées sont : Meningioma, Glioma et Tumeur hypophysaire). Ceci, par l'application des lois puissance Zipf et Zipf inverse surgissant dans le domaine spatial pour l'analyse de la texture en modélisant la vision humaine. D'autre part, les filtres de Gabor seront hybridés avec ces lois puissance vu qu'ils se localisent au sein des deux domaines spatial et fréquentiel. En effet, cette hybridation permettra une analyse judicieuse de la texture des tumeurs. Il est utile de mentionner que nous avons réalisé une extraction des descripteurs via l'apprentissage automatique vu que c'était une technique dominante pendant une longue période et du moment que nous pourrions justifier les techniques d'extraction de descripteurs au lieu de la boîte noire de l'apprentissage profond [24]. En outre, il a été démontré que lorsqu'il s'agit de tâches complexes, les réseaux d'apprentissage profond simples ou complexes sont incapables de générer des résultats par eux-mêmes. Ils sont généralement combinés avec d'autres méthodes statistiques classiques comme les paradigmes d'apprentissage automatique [62] pour aboutir aux meilleurs résultats. D'autre part, il est à noter que l'interprétabilité a été un problème central pour l'application de l'IA dans les soins de santé surtout en ce qui concerne l'obscurité de la boîte noire de l'apprentissage profond, néanmoins, les approches d'extraction de la texture utilisée se basant sur les courbes de Zipf et Zipf inverse et les filtres de Gabor peuvent justifier l'explicabilité de la classification (le diagnostic).
- 6- Evaluation des performances pour les processus de segmentation et de classification (loss, accuracy, ...).

III.3 Segmentation des tumeurs cérébrales dans les IRM basée Deep Learning

III.3.1 Base de données utilisée

La base de données T1-weighted CE-IRM du cerveau a été acquise à l'hôpital de Nanfang, Guangzhou, en Chine, et à l'hôpital général de l'Université médicale de Tianjin, en Chine, de 2005 à 2010. 3064 IRM ont été collectées à partir de 233 patients, contenant 708 méningiomes, 1426 gliomes et 930 tumeurs hypophysaires. Les images ont une résolution

dans le plan de 512*512 avec une taille de pixel de 0,49*0,49 mm². L'épaisseur de la tranche est de 6 mm et l'écart entre les tranches est de 1 mm. La frontière tumorale a été délimitée manuellement par trois radiologues expérimentés. Nous exposons sur la figure III.1 quelques IRM cérébrales de la base de données utilisée.

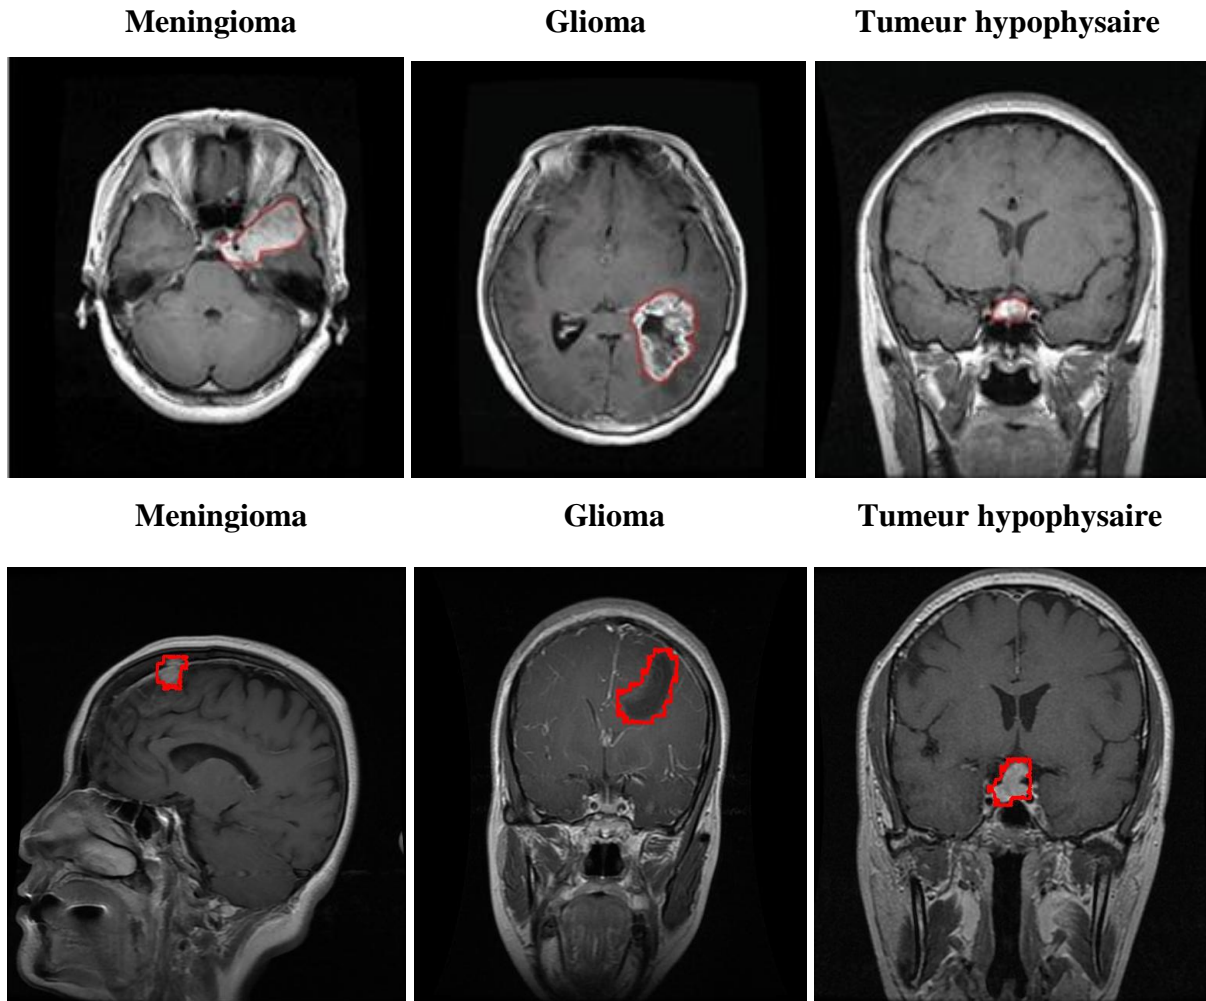


Figure III.1 présentation des IRM cérébrales de la base de données utilisée.

III.3.2 Pipeline suivi pour la segmentation des tumeurs cérébrales basé U-Net

- **Prétraitement**

Majoritairement, les images médicales souffrent d'un faible contraste et d'une luminosité inhomogène. En effet, la frontière ambiguë avec un contraste limité entre le ciblage des organes et des tissus avoisinants est un défi inhérent à l'imagerie. Ceci est généralement causé par les coefficients d'atténuation en CT et temps de relaxation en IRM.

Le prétraitement des images joue un rôle essentiel dans la détection de maladies du cerveau car le prétraitement des images implique l'amélioration de la qualité de l'image, la suppression du bruit de l'image et la normalisation. Le prétraitement des IRM est l'élément le plus critique de l'analyse des images en raison du fait que les informations incorrectes avec des statistiques indésirables peuvent conduire à la mauvaise performance d'un classifieur nettement extensif [63]. En effet, le prétraitement des données peut améliorer la qualité des données pour aider le réseau de neurones à mieux apprendre les caractéristiques.

Dans l'étape de prétraitement, des étapes de redimensionnement et d'amélioration du contraste des images IRM s'effectuent [4]. Les bases de données des images cérébrales contiennent des IRM de différentes tailles tandis que les modèles d'apprentissage doivent avoir une certaine taille standard des images.

Nous allons appliquer un prétraitement pour améliorer la résolution et le contraste et pour réduire le bruit dans les images IRM de la base de données. Plusieurs approches de prétraitement peuvent être utilisés, tels que le masquage flou, les filtres médians et les filtres de Wiener.

Les filtres médians sont les plus couramment utilisés dans l'étape de prétraitement pour préserver les contours de l'image [5]. En effet, nous avons appliqué le filtre médian sur toutes les IRM de la base de données comme indiqué sur la figure III.2.




Figure III.2 Prétraitement par le filtre médian : à gauche les IRM originales et à droite après l'application du prétraitement.

- **Segmentation des tumeurs cérébrales par le modèle U-Net**

Le défi le plus vital pour un radiologue est de localiser les tumeurs cérébrales à un stade précoce. Comme la tumeur cérébrale se développe rapidement, doublant sa taille réelle en environ vingt-cinq jours [64]. Dans le cas où cette tumeur ne se traite pas correctement, le taux de survie de la personne affectée ne dépasse pas généralement six mois. Pour cette raison, un système automatique est souhaitable pour localiser la tumeur du cerveau au stade précoce.

La segmentation des images médicales est une tâche difficile en raison de l'aspect hétérogène de l'organe cible désignant l'un des grands enjeux de la segmentation des images médicales [20]. En effet, l'organe cible ou la lésion peuvent varier énormément en taille, forme et localisation d'un patient à l'autre. Dans ce sens, l'algorithme risque de segmenter des régions

indésirables dans l'IRM cérébrale, comme la cavité orbitaire et les ventricules latéraux [34]. Augmenter la profondeur du réseau neuronal est signalée comme une solution efficace.

Dans la méthode de seuillage, le processus du contrôle de l'intensité pour la catégorisation des zones non tumorales et tumorales est plus exigeant. Dans les approches de croissance de région, l'efficacité du système dépend des classifieurs déterminant les zones d'image inhabituelles. Dans les approches à base de clusters, le calcul est nécessaire pour chaque phase de clustering ultérieure qui maximise la durée totale. Une approche de réseau de neurones est complexe pour visualiser la tumeur conformément avec localisation spatiale et décomposition structurelle. Néanmoins, une approche CNN qui est inspirée par la vision biologique, bénéficie de caractéristiques alambiquées pour que l'apprentissage profond des tissus du cerveau ainsi que de la tumeur soit bien accompli. En effet, la capacité de généralisation des modèles profonds est améliorée avec le processus de régularisation. Ceci est qualifié de moyen efficace car il permet au modèle de réseau de former des modèles plus complexes.

Pour le suivi de la thérapie oncologique, la quantification précise et morphologique des tumeurs est une tâche critique. Cependant, des travaux à grande échelle ont été réalisés dans ce domaine ; mais les cliniciens dépendent de la détermination manuelle de la tumeur, en raison du manque de lien entre les chercheurs et les cliniciens [6].

Les approches DL récentes, en particulier CNN, offrent une bonne précision et sont largement utilisées dans l'analyse des images médicales.

La structure de CNN s'énonce comme suit [24] : la couche de début est une couche d'entrée, qui est directement connectée à une image d'entrée avec le nombre de neurones égal au nombre de pixels dans l'image d'entrée. Le prochain ensemble de couches sont des couches convolutives qui présentent les résultats de la convolution d'un certain nombre de filtre avec les données d'entrée et fonctionne comme un extracteur de caractéristiques citons les contours et les lignes.

Les filtres, communément appelés noyaux, sont de taille arbitraire, définies par les concepteurs. Chaque neurone ne répond qu'à une zone spécifique de la couche précédente, appelée champ récepteur. La sortie de chaque couche de convolution est considérée comme une carte d'activation, qui met en évidence l'effet de l'application d'un filtre spécifique sur l'entrée.

Les couches convolutives sont généralement suivies de couches d'activation pour appliquer la non-linéarité aux cartes d'activation. La couche suivante peut être une couche de pooling en fonction de la conception aidant à réduire la dimensionnalité de la convolution de sortie.

Dernièrement, les abstractions de haut niveau sont extraites par des couches entièrement connectées.

Les poids des connexions neuronales et des noyaux sont continuellement optimisés dans la phase d'apprentissage.

Dans les architectures U-Net [65], SegNet et d'autres architectures similaires, certaines informations utiles sont perdues lors des opérations de max-pooling. L'architecture U-Net est enrichie des skips connexions qui sont utilisées pour transmettre des informations importantes contextuelles et spatiales de l'encodeur à l'étage du décodeur et permettant ainsi au réseau de propager les informations spatiales perdues. En effet, le point le plus remarquable à propos de U-Net est que la partie décodeur peut recevoir les informations spatiales perdues par les opérations de pooling à l'aide de ces skip connexion, facilitant ainsi le processus d'apprentissage.




Figure III.3 Architecture de U-Net pour la segmentation des tumeurs cérébrales.

Nous distinguons les parties suivantes :

1- Contracting path (Downsampling)

Il consiste en l'application répétée de :

- Deux 3x3 convolutions (unpadded convolutions).
- Suivi d'une ReLU et d'une normalisation par lots.
- Une opération de 2x2 max pooling.

2- Expansive path (Upsampling)

Consistant en séquence de convolutions ascendantes et de concaténation :

- 2 x 2 convolution (convolution ascendante) qui réduit de moitié le nombre de canaux de caractéristiques.
- Une concaténation avec la carte des caractéristiques rognée en conséquence à partir du chemin contractuel.
- Deux convolutions 3x3
- Suivi d'un ReLU avec normalisation des lots.

3- Final Bottleneck Layer

Au niveau de la couche finale, une convolution 1x1 est utilisée pour mapper chaque vecteur d'entités à 64 composants au nombre de classes souhaité.

Un autre défi à surmonter est la fonction de perte (loss function) en imagerie médicale, en effet, l'anatomie d'intérêt n'occupe qu'une très petite région de l'analyse, ce qui fait que le processus d'apprentissage est piégé dans des minima locaux de la loss function produisant un réseau dont les prédictions sont fortement biaisées vers l'arrière-plan.

En conséquence, la région de premier plan est souvent manquante ou seulement partiellement détectée.

L'utilisation d'une fonction de perte, qui évalue dans quelle mesure le CNN modélise les données d'entraînement, est nécessaire pour optimiser les poids du CNN.

La fonction de perte utilisée par notre modèle U-Net est : **Dice loss** du fait qu'elle prend en compte les informations de perte à la fois localement et globalement, ce qui est essentiel pour une grande précision. En effet, sa formule est la suivante :

$$D = \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2}$$

Où p et q représentent des paires de valeurs de pixels correspondantes de prédiction et de ground truth, respectivement. Sa quantité varie entre 0 et 1 que nous visons à maximiser.

III.4 Classification des tumeurs cérébrales basée SVM

III.4.1 Régions d'intérêt segmentées

Nous allons considérer les tumeurs détectées par le modèle U-Net effectuant une segmentation sémantique où chaque pixel du cerveau sera classifié en région tumorale ou background.

III.4.2 Pipeline basé SVM pour la classification des tumeurs cérébrales

Nous exposons sur la figure III.4 le pipeline suivi pour la classification des tumeurs cérébrales où le prétraitement a été déjà établi durant le processus de segmentation.

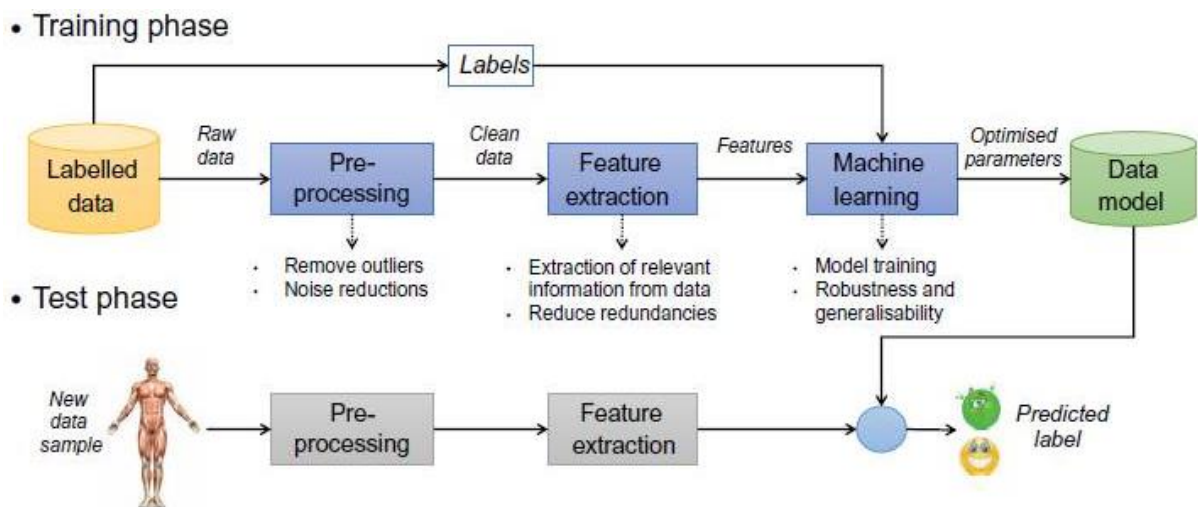


Figure III.4 Pipeline suivi pour la classification des tumeurs cérébrales. Source [66].

- **Extraction des descripteurs**

Chaque image de tumeur appartenant à une classe donnée, diffère significativement d'autres images tumorales de même classe en termes de texture et intensité [61].

Les lois de Zipf et de Zipf inverse désignent des approches perceptuelles analysant le contenu structurel des images en vue de la quantification de la texture. De l'autre côté, les filtres de Gabor se sont basés durant leur conception pour qu'ils simulent les performances des cellules corticales visuelles du mammifère. Effectivement, ils extraient divers traits selon différentes orientations ainsi qu'échelles [67] et évidemment fonctionnent de la même manière que celle des neurones relatifs au cortex visuel humain.

Notre ultime but est la fusion de ces deux techniques de caractérisation de la texture qui modélisent la vision humaine pour la distinction entre les tumeurs cérébrales segmentées à partir des IRM.

1- Analyse et caractérisation de la texture des tumeurs cérébrales par les lois de Zipf et de Zipf inverse

Les lois de Zipf et de Zipf inverse analysent statistiquement la complexité structurelle de la texture d'une image en caractérisant la structure sous-jacente des lésions cérébrales. En effet, les régions d'intérêt segmentées seront encodées par le codage des rangs généraux vu qu'il fut le plus adéquat en vue de l'étude de la texturation fine de l'image.

Nous traçons les courbes de Zipf et de Zipf inverse comme mentionné sur les figures III.5, III.6 et III.7 respectivement où les courbes de Zipf et de Zipf inverse obtenues à partir de trois tumeurs cérébrales : gliome, méningiome et tumeur hypophysaire.

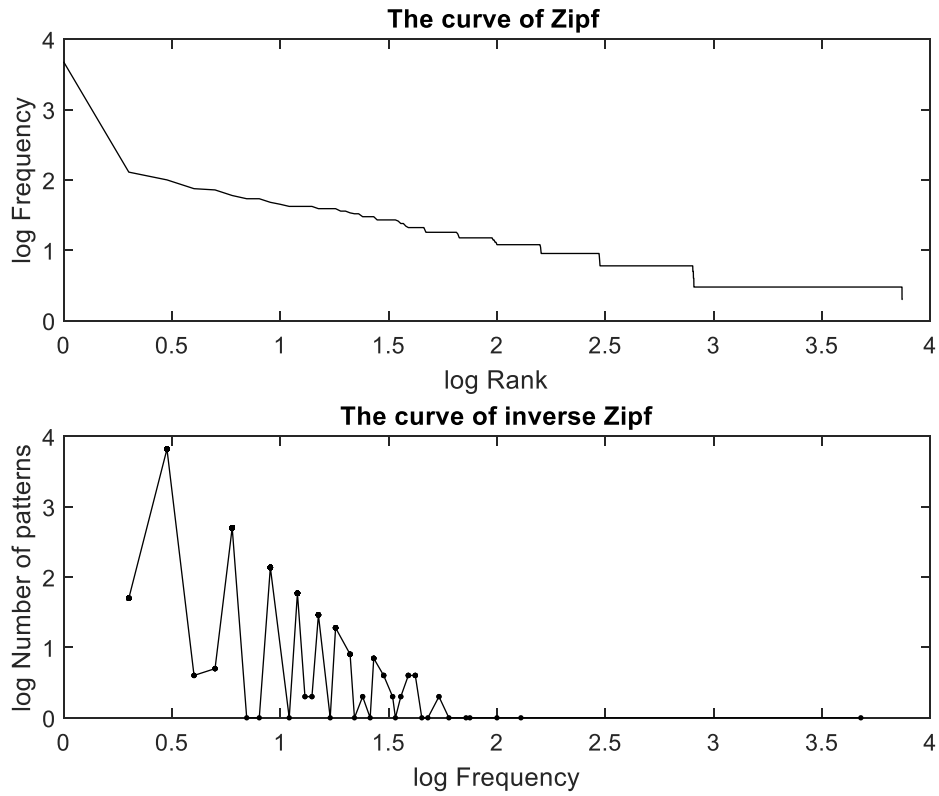



Figure III.5 Courbes de Zipf et de Zipf d'une tumeur gliome





Figure III.6 Courbe de Zipf et Zipf inverse d'une tumeur méningiome

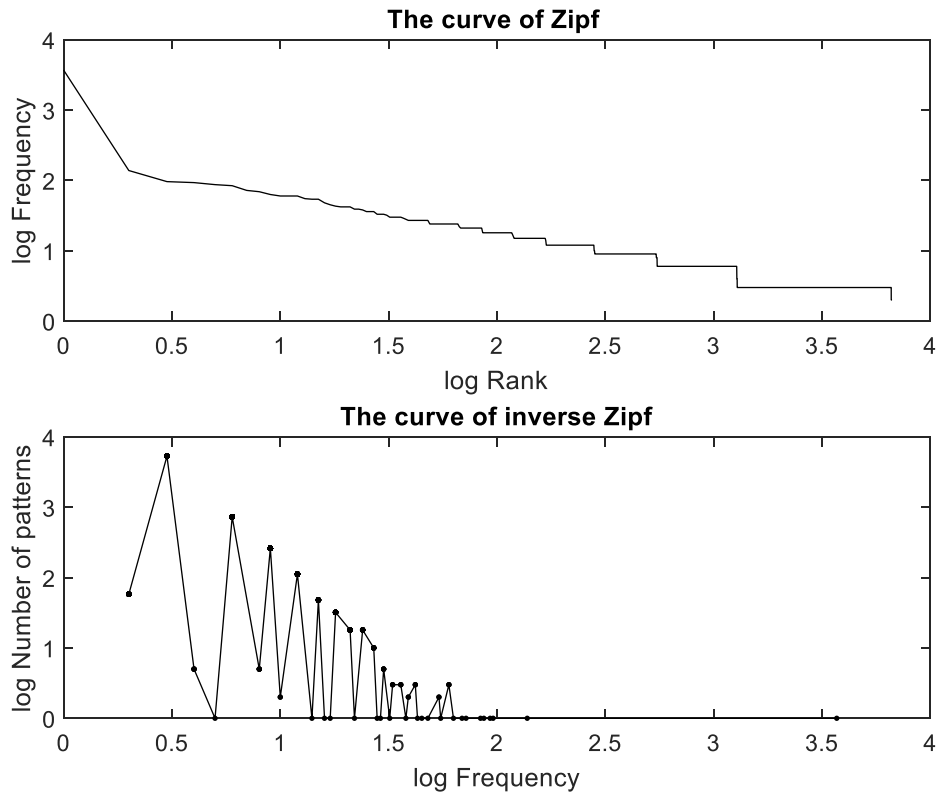



Figure III.7 Courbe de Zipf et Zipf inverse d'une tumeur hypophysaire

Les descripteurs dérivés des courbes de Zipf et de Zipf inverses sont les suivants [19] :

- **Les pentes des courbes de Zipf et de Zipf inverse**

La pente moyenne d'une courbe est le coefficient directeur de la droite des moindres carrés.

Elle est donnée par la formule III.1 :

$$p = \frac{n \sum_{i=1}^n y_i x_i - \sum_{i=1}^n y_i \sum_{i=1}^n x_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \quad (III.1)$$

- **L'aire délimitée par la courbe de Zipf**

Nous calculons l'aire délimitée par la courbe de Zipf à partir des courbes de Zipf obtenues suite au codage de l'image par le codage des rangs généraux. Soit n le nombre de motifs de la courbe, f_i la fréquence et r_i le rang du motif i , l'aire de la courbe est donnée par la formule III.2 :

$$A = \sum_{i=1}^{n-1} \frac{(f_i + f_{i+1})(r_{i+1} - r_i)}{2} \quad (\text{III.2})$$

- **Entropie1 de la courbe de Zipf**

L'entropie relative aux motifs des images mammographies est définie par la formule III.3 :

$$H_w = - \sum_{r=1}^R \frac{f(r)}{T} \log_R \frac{f(r)}{T} \quad (\text{III.3})$$

Dans cette formule, $f(r)$ représente la fréquence du motif pour la ligne r , T représente le nombre total de motifs différents, et nous utilisons un logarithme avec la base R .

- **Entropie2 de la courbe de Zipf**

L'entropie relative à la fréquence d'apparition des motifs est définie par la formule suivante :

$$H_f = - \sum_{f=1}^F \frac{I(f)}{R} \log_F \frac{I(f)}{R} \quad (\text{III.4})$$

Dans cette formule, $I(f)$ représente le nombre de motifs distincts ayant une fréquence d'apparition égale à f et F représente le nombre entier d'occurrences des motifs dans l'image.

- **Les ordonnées à l'origine des courbes de Zipf et Zipf inverse**
- **La constante alpha de la courbe de Zipf**

La loi de Zipf est fortement exprimée de la façon suivante : Quel que soit un motif appartenant à une image, la fréquence d'apparition de ce motif * son rang dans une liste ordonnée décroissante des fréquences d'apparition des motifs = constante.

2- Analyse et quantification de la texture des tumeurs cérébrales basée filtres de Gabor

Mentionnons que les filtres de Gabor se localisent au sein des deux domaines spatial et fréquentiel. En effet, ils effectuent une décomposition multi-résolution.

Dans le cas des images 2D, le filtre de Gabor est généré suite à une gaussienne bidimensionnelle modulée par une fonction sinusoïdale complexe [68]. La formule du filtre de Gabor 2D est donnée par [68] :

$$h(x, y) = \frac{1}{\sigma_x \sigma_y 2\pi} \exp\left(-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}\right) \exp(j2\pi u_0(x \cos\theta + y \sin\theta)) \tag{III.5}$$

L'enveloppe Gaussienne :

$$g(x, y) = \frac{1}{\sigma_x \sigma_y 2\pi} \exp\left(-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}\right) \tag{III.6}$$

Avec : $X = x \cos \theta + y \sin \theta$

$Y = -x \sin \theta + y \cos \theta$

Où σ_x et σ_y sont les écarts-types respectivement le long des axes x et y (ou les constants spatiales du filtre), elles déterminent la largeur du filtre.

U_0 : la fréquence centrale.

θ : l'angle de rotation de $[x, y]$ par rapport à (x, y) , il donne l'orientation de l'enveloppe Gaussienne $g(x, y)$.

La puissance des filtres de Gabor pour la caractérisation de la texture revient au fait qu'ils isolent dans une image ; des constituantes très variées allant d'objets nettement définis jusqu'à de fins détails d'orientation particulière. Ceci, suite au changement de deux paramètres : la fréquence ainsi que l'orientation.

Les filtres de Gabor sont un type de filtrage passe-bande et conservent l'information prise sur le spectre d'une image via la bande de fréquence sélectionnée. En effet, ces filtres analysent des propriétés locales au sein d'une région d'intérêt extraite à partir de l'image. Par conséquent, la configuration fréquemment utilisée d'extraction de données spatio-fréquentielles à partir des textures est générée suite à la convolution de la région d'intérêt avec

une banque de filtres [68] où chacun se retrouvera centré sur une fréquence et une orientation avec l'ultime but de couvrir parfaitement l'intégralité du domaine fréquentiel. En effet, tout pixel de l'image génèrera une réponse pour chaque filtre.

En ce qui concerne le processus de la classification, nous cherchons la relation existante entre les réponses données par les filtres de Gabor relatives à chacune des régions d'intérêt.

Nous exposons sur la figure l'application des filtres de Gabor sur une tumeur où les sorties seront utilisées pour l'extraction des descripteurs.

Les paramètres pertinents du filtre de Gabor sont la fréquence radiale ainsi que l'orientation. Ils définissent la localisation du canal dans le plan fréquentiel. En effet, chaque image de taille $N*N$ aura des fréquences significatives dans l'intervalle $[0..N/4]$ et à la puissance 2.

Nous avons appliqué une banque des filtres de Gabor avec une taille de 39 x 39 selon 5 fréquences et 8 orientations comme mentionné sur la figure III.8 :




Figure III.8 Filtres de Gabor appliqués dans le domaine fréquentiel.

Suite à l'utilisation d'un ensemble riche en variation de filtres de Gabor, ceci permettra une couverture plus étendue de l'espace fréquentiel en détectant davantage d'orientations, et aboutir donc à l'extraction de tous les contours des régions d'intérêt.

La figure III.9, démontre la partie réelle de ces filtres.




Figure III.9 Parties réelles des filtres de Gabor utilisés.

Nous allons démontrer sur la figure III.10, la partie réelle des régions d'intérêt filtrées :




Figure III.10 Parties réelles des régions d'intérêt filtrées

A ce stade, nous allons exposer sur la figure III.11, la magnitude de la réponse des régions d'intérêt filtrées.




Figure III.11 Magnitude de la réponse du filtre de Gabor suite à la convolution de la tumeur maligne avec une banque de filtres de Gabor.

Pour toutes les sorties du filtre, un calcul de statistiques locales est effectué et le vecteur de descripteurs texturaux est obtenu par combinaison de ces statistiques comme mentionné dans [69].

- **Processus d'apprentissage automatique basé SVM**

Malgré la popularité des techniques d'apprentissage en profondeur dans la classification des tumeurs cérébrales, cependant il existe de nombreuses limitations associées aux méthodes d'apprentissage en profondeur. En raison de leur architecture complexe et la nécessité d'une grande mémoire et beaucoup de temps de traitement [3].

Les classifieurs traditionnels ont un avantage sur les algorithmes d'apprentissage en profondeur car ils nécessitent de petits ensembles de données pour l'apprentissage et ont une faible complexité en temps de calcul, un faible coût pour les utilisateurs et peuvent être facilement adoptés par des personnes moins qualifiées [30]. En effet, les SVM mappent des vecteurs de descripteurs linéairement inséparables dans des dimensions élevées, de sorte que les vecteurs de caractéristiques soient linéairement séparables dans des espaces de grande

dimension. Une bonne capacité de généralisation pourrait assurer une plus grande précision de classification lorsqu'il y a moins d'échantillons d'apprentissage [70]. La généralisation a un rôle crucial celui de faire recours à l'overfitting : lorsque les paramètres q produisent une fonction f qui est très précise pour les données d'apprentissage mais qui ne se généralise pas bien aux données de test.

Le processus de classification consiste en 2 phases : l'apprentissage et le test. Dans la phase d'apprentissage, un modèle est construit qui mappe les caractéristiques extraites des données pointes vers des étiquettes ou des classes. Le modèle est ensuite utilisé pour déterminer la classe des données non étiquetées dans la phase de test [70].

III.5 Schématisation de l'approche proposée

Nous allons nous concentrer sur la classification multi classe (3 classes) pour la différenciation entre gliome, méningiome et les tumeurs hypophysaires, qui forment trois principaux types de tumeurs du cerveau.

Nous présentons sur la figure III.12 un schéma du pipeline de pronostic automatique des tumeurs cérébrales.

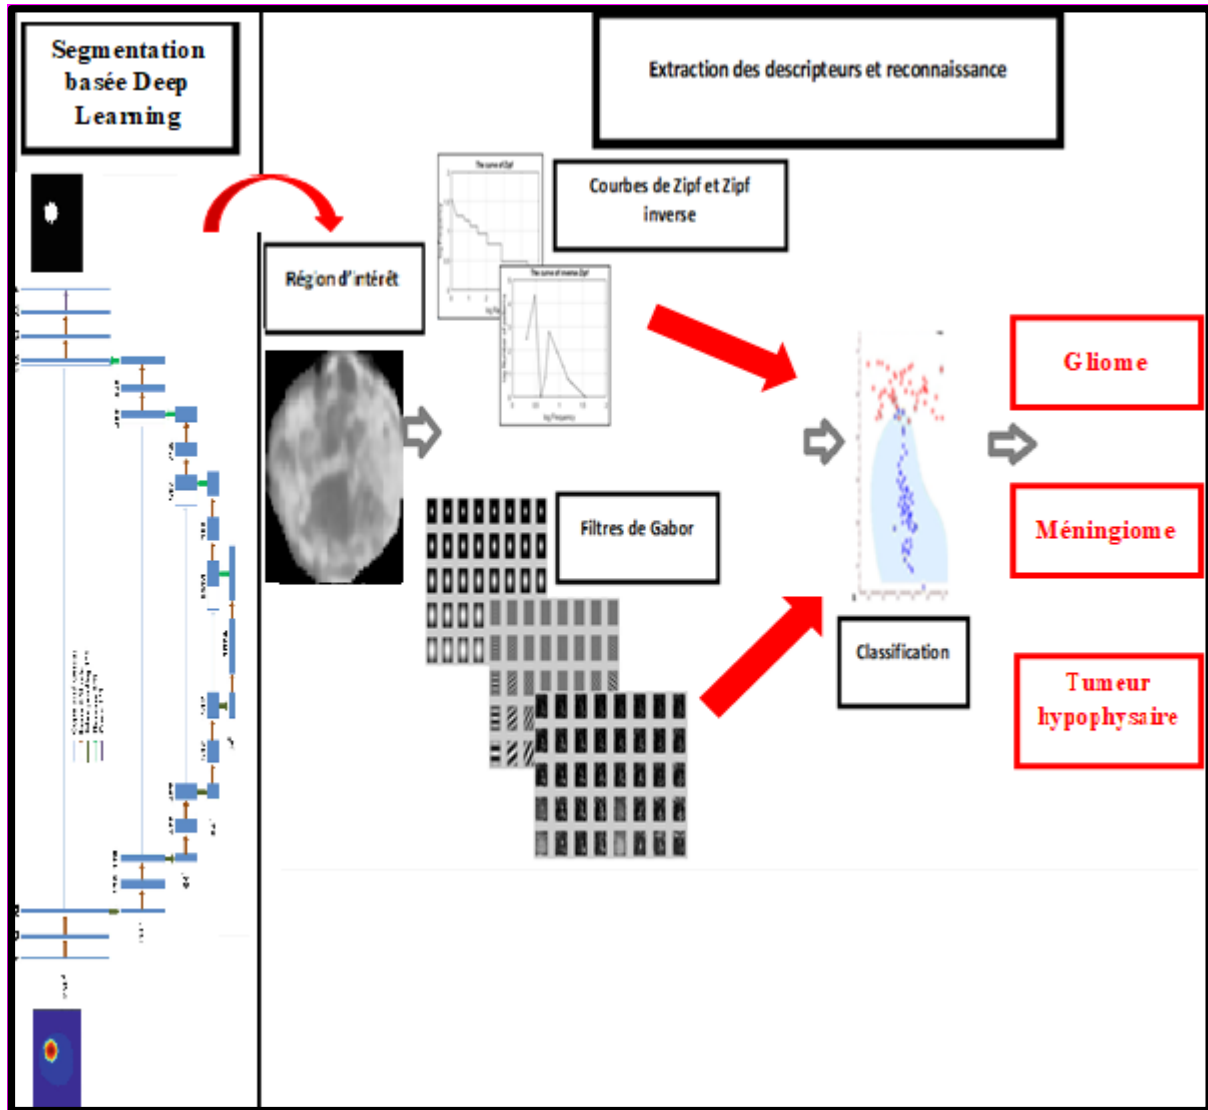


Figure III.12 Schémas résumant le pipeline de pronostic automatique des tumeurs cérébrales.

III.6 Conclusion

Une étude détaillée de l'approche proposée portant sur le diagnostic automatique des tumeurs cérébrales a été présentée au long de ce chapitre. Nous avons enrichi cette étude par les pipelines de segmentation ainsi que de classification.

Quant au chapitre suivant, une évaluation des performances de notre approche aura lieu, voire plus, une comparaison avec l'état de l'art sera effectuée également.

A decorative border resembling a scroll, with a thick top bar and rounded corners. The top-left and bottom-left corners feature scroll-like flourishes.

Chapitre IV

Evaluation des performances

IV.1 Introduction

Dans ce chapitre, nous allons expliquer le dernier, expliquer les outils utilisés et le code de programmation pour chaque étape. Enfin, nous discuterons des résultats obtenus.

IV.2 Environnement De Développement Et Outils Utilisés**IV.2.1 Langage Python**

Python est un langage de programmation de haut niveau interprété pour la programmation à usage général. Créé par Guido van Rossum, et publié pour la première fois en 1991.

IV.2.1.1 Pourquoi Python

Il est facile de travailler avec et d'avoir accès à des bibliothèques de haute qualité. Il est le plus utilisé dans le domaine de l'intelligence artificielle et de l'apprentissage automatique

IV.2.2 Kaggle

Une filiale de Google LLC, est une communauté en ligne de data scientistes et de praticiens de l'apprentissage automatique. permet aux utilisateurs de rechercher et de publier des ensembles de donnée .

IV.2.3 Matériel de configuration

- **GPU: 1xTesla P100 , ayant 3584 CUDA cores, 16GB GDDR6 VRAM (Kaggle GPU)**
- **CPU : AMD Ryzen 5 PRO 4650G with Radeon Graphics 3.70 GHz (mon pc).**

IV.3 Mesures de performance utilisées

Après avoir mis en œuvre le modèle et obtenu des résultats en classe ou probabilité, l'étape suivante consiste à détecter l'efficacité du modèle sur la base de diverses métriques à l'aide d'ensembles de données de test. Certaines mesures de performance sont utilisées pour spécifier divers algorithmes d'apprentissage automatique. Le choix de la bonne métrique est très important car il influe sur les performances de l'algorithme d'apprentissage automatique.

IV.3.1 Matrice de Confusion

En apprentissage automatique, la **matrice de confusion** est une matrice qui mesure la qualité d'un système de classification. Chaque ligne correspond à une classe réelle, chaque colonne correspond à une classe estimée.

Confusion matrix		Reality	
		Negative : 0	Positive : 1
Prediction	Negative : 0	True Negative : TN	False Negative : FN
	Positive : 1	False Positive : FP	True Positive : TP

Figure IV.1 Matrice de Confusion

IV.3.1.1 Matrice de Confusion Termes

- **Vrais Positifs (TP)** : Il s'agit de cas dans lesquels nous avons prédit que oui (ils ont la maladie), et ils ont effectivement la maladie.
- **Vrais négatifs (TN)** : Nous avons prédit que non, et ils n'ont pas la maladie.
- **Faux positifs (FP)** : Nous avons prédit que oui, mais ils n'ont pas vraiment la maladie. (Aussi connu comme une "erreur de type I").
- **Faux négatifs (FN)** : Nous avons prédit que non, mais ils ont effectivement la maladie. (Aussi connu comme une "erreur de type II").

IV.3.2 Métriques d'évaluation du Classificateur

IV.3.2.1 Accuracy

Accuracy est une mesure permettant d'évaluer les modèles de classification. la précision est la fraction des prédictions que notre modèle a eu raison. Formellement, la précision a la définition suivante :

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

Figure IV.2 Formule de Accuracy

IV.3.2.2 Précision et Rappel

La précision (precision en anglais) et le rappel (recall en anglais) sont deux métriques pour évaluer la performance des modèles de classification à 2 classes ou plus. Ces métriques sont basées sur la matrice de confusion.

$$\text{precision} = \frac{tp}{tp + fp}$$

Figure IV.3 Formule de Précision

$$\text{Recall} = \frac{\text{Vrai positif}}{\text{Vrai positif} + \text{faux négatif}}$$

Figure IV.4 Formule de Rappel

IV.4 Explication du code

Tout d'abord, nous avons commencé par la partie d'amélioration d'image :

- Débruitage d'une image en niveaux de gris avec filtre médian.
- Améliore la netteté et le contraste des images.

```

1 import cv2
2 import numpy as np
3 import os
4
5 kernel1 = np.ones((3, 3), np.float32) / 9
6
7 for image in os.listdir("images"):
8     try:
9         result = cv2.filter2D(src=cv2.imread("images/"+image), ddepth=-1
10            #cv2.imwrite("new_moyenneur/"+image, result)
11            result = cv2.medianBlur(src=cv2.imread("images/"+image), ksize=3
12            cv2.imwrite("new_median/"+image, result)
13     except:
14         pass
15

```

```

if load_model:
    print("load model from", load_model)
    # net.load_state_dict(torch.load(load_model))
    checkpoint = torch.load(load_model)
    net.load_state_dict(checkpoint['model_state_dict'])
    # optimizer.load_state_dict(checkpoint['optimizer_state_dict'])
    start_epoch = checkpoint['epoch']
    loss = checkpoint['loss']

history = {'train':{'epoch':[], 'loss' : [], 'acc':[]},
          'val' :{'epoch':[], 'loss' : [], 'acc':[]}}

best_acc = 0.92
best_loss = 10000000000
start = time.time()
for epoch in range(epochs):
    if load_model:
        epoch += start_epoch
        epochs += start_epoch
    print("-" * 30)
    print(f"Epoch {epoch + 1}/{epochs}")
    # print(f"Epoch {epoch + 1}/{epochs} learning_rate : {scheduler.get_lr()[0]}")

since = time.time()

```

Deuxièmement, le code de notre modèle U-net pour la segmentation :

Après avoir segmenté l'image, nous passons à l'étape suivante "cropping images"



Après cela, nous passons à l'étape suivante "Features extraction "

L'étape suivante consiste à enregistrer toutes les fonctionnalités sous forme de fichier csv.




Figure IV.5 Fonctionnalités du processus CSV.

La resultat de « features extraction »

1	index	img	target	0	1	2	3	4	5	6	7	8	9	10	11	12	
2	0	2497_glioma	2	-1.0372936	7.7341537	0.7783526	0.90893745	3.2940252	9939	0.60206	-0.7023668	-0.69385344	-0.13181134	1.3030232	-0.71467614	2.2514946	-0.44
3	1	2507_glioma	2	-1.2069337	8.328397	0.75695354	0.9205227	3.4831593	9407.5	0	-0.6174353	-0.6931664	0.4573434	-0.5268408	-0.69316643	-0.16558968	-0.5
4	2	2508_glioma	2	-1.2723577	8.618918	0.7775549	0.91258097	3.467312	9456	0	-0.555669	-0.6524071	0.651144	-0.6322147	-0.6572049	0.76735497	-0.6
5	3	2505_glioma	2	-0.8001054	7.0366325	0.85318094	0.9338658	3.0748165	10323	0.69897	-0.4285782	-0.6127945	3.4416733	0.03279544	0.05883848	-0.52791117	-0.20
6	4	2506_glioma	2	-1.1705394	8.338991	0.8234819	0.92351705	3.2837534	9965	0	-0.6026397	-0.75581896	1.0446264	0.42149892	-0.75538564	0.18464242	-0.4
7	5	2500_glioma	2	-0.9135363	7.199012	0.7338024	0.9038278	3.4224257	9599	0	-0.60879576	-0.4289488	3.806018	-0.32146722	-0.42897394	0.27953944	-0.34
8	6	2502_glioma	2	-0.93321115	7.185759	0.69817156	0.8897141	3.4278107	9584.5	0.30103	-0.6270073	-1.007816	2.178525	-0.38328943	-1.0113165	1.5766628	-0.15
9	7	2501_glioma	2	-0.8559066	6.8299575	0.6607168	0.87918967	3.512284	9285.5	0	-0.6894237	-0.7956672	-0.38071352	0.12488847	-0.81564635	0.5368547	-0.4
10	8	2504_glioma	2	-0.998299	7.68113	0.81361115	0.9231636	3.232488	10075.5	0.47712126	-0.47352743	-0.7114532	3.0046387	0.7001146	-0.7108482	0.8579427	-0.6
11	9	2503_glioma	2	-1.0032194	7.4862113	0.72359675	0.8956488	3.36135	9773.5	0.30103	-0.72629285	-0.5661657	1.2351106	3.3637617	-0.56606185	-0.15661858	-0.16
12	10	2514_glioma	2	-0.9123255	7.091342	0.6946819	0.87929845	3.456366	9487.5	0	-0.681696	-0.43325537	3.8077507	-0.20077895	-0.43363607	-0.27089828	-0.3
13	11	2511_glioma	2	-0.9963443	7.539549	0.7657798	0.89741915	3.352954	9796.5	0.30103	-0.71534896	-0.4653326	-0.46439362	3.5844872	0.41425028	-0.26411104	-0.39
14	12	2512_glioma	2	-1.030749	7.5603514	0.7002835	0.90816206	3.5154765	9280	0	-0.62033844	0.90225273	1.8739065	-0.6450593	-0.6451317	2.8635795	-0.5
15	13	2509_glioma	2	-1.2718865	8.749742	0.83918506	0.9376609	3.27738	9972.5	0.30103	-0.5524388	-0.7112142	1.1601917	2.3899636	-0.7217106	0.02909228	-0.6
16	14	2510_glioma	2	-0.8948002	7.013804	0.68646044	0.8912823	3.4374335	9546	0.30103	-0.59674394	-0.7821748	-0.29209653	-0.61127937	-0.7009714	0.11720128	-0.25
17	15	2515_glioma	2	-0.9146433	7.17301	0.7270924	0.89197004	3.3923452	9687.5	0	-0.63010114	-0.54970723	3.1787677	-0.561316	-0.60489786	-0.5109423	-0.3
18	16	2513_glioma	2	-0.95105535	7.4195375	0.77230597	0.90425956	3.3159704	9895.5	0.60206	-0.6309777	-0.45717394	-0.48503962	-0.06194806	-0.5640198	-0.36068326	-0.4
19	17	2516_glioma	2	-0.98704654	7.5921273	0.7919305	0.9206057	3.2741578	9983	0.30103	-0.5790057	-0.74457276	-0.04378541	1.5352451	-0.74628896	0.7059953	-0.61
20	18	2521_glioma	2	-1.0329728	7.868157	0.84318185	0.93063945	3.136086	10236.5	0.30103	-0.5680315	-0.733889	2.7648723	1.8467402	-0.7313882	-0.11408871	-0.59
21	19	2523_glioma	2	-0.9300851	7.3452272	0.7766873	0.9130674	3.3253105	9861	0	-0.52626914	-0.4519178	-0.36132076	3.714632	-0.40560186	-0.39877328	-0.32
22	20	2517_glioma	2	-1.090971	8.078572	0.8438897	0.92413855	3.180126	10167.5	0	-0.5992482	-0.6176535	-0.49075764	2.7145267	-0.61664855	-0.40829527	-0.4
23	21	2518_glioma	2	-1.0084641	7.5675635	0.747517	0.90085644	3.3884563	9702	0	-0.68011475	-0.5848085	3.3523448	1.4795177	-0.5848084	-0.35794365	-0.43

Figure IV.6 Fonctionnalités extraites (CSV file)

IV.5 L'interface système



Figure IV.7 La fenêtre principale pour entrer l'image




Figure IV.8 La fenêtre d'affichage

IV.6 Résultats et Discussion

IV.6.1 Segmentation

Nous avons mis en place la segmentation par Yonat, et nous avons obtenu de très bons résultats ,

Pour que nous ayons atteint un taux de Accuracy = 99%.

La figure représente la fonction de l'Accuracy d'entraînement sur l'époque :




Figure IV.9 Model Accuracy

La figure représente la fonction de perte d'entraînement sur l'époque :




Figure IV.10 Model loss

IV.6.2 Diviser l'ensemble d'origine en données d'apprentissage, de validation et de test

Tout d'abord, nous avons divisé l'ensemble de données d'origine en deux parties. La première partie pour entraîner le modèle et la deuxième partie pour tester sa précision afin de prédire de nouveaux échantillons (90 % des échantillons pour la formation et 10 % pour les tests).



Figure IV.11 Diviser le train en train et validation

IV.7 Évaluation d'un classificateur

De nombreuses métriques peuvent être utilisées pour mesurer les performances d'un classificateur ou d'un prédicteur ; différents champs ont des préférences différentes pour des métriques spécifiques en raison d'objectifs différents. Par exemple, en médecine, la sensibilité et la spécificité sont souvent utilisées, tandis qu'en informatique, la précision et le rappel sont préférés. Une distinction importante est entre les métriques qui sont indépendantes de la prévalence et les métriques qui dépendent de la prévalence - les deux types sont utiles, mais ils ont des propriétés très différentes.

Nous avons essayé à partir des valeurs $C = [0.1, 1, 10, 100, 1000]$ et de tous les kernel de SVM (linear, poly, rbf, sigmoid), avec deux classes " glioma " et "meningioma".

Nous avons obtenu une précision de classification de 90% avec les valeurs suivantes {'C': 1000, 'kernel': 'linear'}, ce qui est le meilleur.

Et en plus, nous avons obtenu une précision de classification de 72% avec les valeurs suivantes {'C':1000, 'kernel': 'linear'}, avec deux classes " glioma " et "meningioma".

IV.8 Conclusion

Dans ce chapitre, nous avons expliqué le langage de programmation et ses outils qui ont été très utiles pour notre modèle. De plus, la mise en œuvre de chaque étape a été bien expliquée. De plus, nous essayons tous les noyaux SVM qui nous donnent un résultat différent et le meilleur choix était le noyau linéaire (90%). Enfin, nous avons discuté des résultats obtenus.

A decorative border resembling a scroll, with a vertical strip on the left side and rounded corners at the top and bottom. The text is centered within this border.

Conclusion générale

Conclusion générale

Conclusion générale

Les troubles cérébraux peuvent entraîner la perte de certaines fonctions essentielles telles que la pensée, la parole et le mouvement. Ainsi, la détection précoce des maladies du cerveau peut aider à obtenir le meilleur traitement en temps opportun [26].

Le processus d'interprétation d'un volume massif des IRM des patients est laborieux long et sujet aux erreurs en raison de la haute résolution des images et l'évaluation subjective des pathologistes. Dans ce sens, les progrès de l'apprentissage automatique et de l'apprentissage profond dans l'enregistrement des images médicales, l'anatomie et la détection de structure cellulaire, la segmentation tissulaire ; assistées par ordinateur ont connu un remarquable succès [25].

En effet les systèmes CAD de pronostic automatique du cancer du cerveau comprennent le traitement d'image et les techniques modernes d'apprentissage automatique et profond [62].

Afin d'aider les cliniciens à établir des diagnostics précis, il est nécessaire de segmenter des organes, des tissus ou des lésions au sein des images médicales et extraire des caractéristiques à partir d'objets segmentés pour le processus décisif de la classification. En effet, ces dernières années, il y a eu un intérêt croissant dans le développement d'analyses anatomiques computationnelles plus complètes des modèles avec le développement de techniques de deep learning qui a facilité le développement de l'analyse multi-organes. En effet, les réseaux de neurones convolutifs sont moins exposés aux problèmes de l'overfitting et beaucoup plus facile à former. En outre, à l'aide des noyaux de convolution, les informations de voisinage sont également prises en compte pour conserver les propriétés de l'information source [61].

Malgré le succès des paradigmes de l'intelligence artificielle pour le pronostic automatique du cancer du cerveau, des lacunes ou perspectives comme :

- Le fait que seule l'amélioration de la précision ne peut rendre compte de la performance des algorithmes, notamment dans le domaine d'analyse des images médicales, où les problèmes de déséquilibre de classe, de problème d'inférence de bruit doivent être traités.
- L'acceptation clinique des méthodes de diagnostic a dépendu du degré de supervision des utilisateurs et la simplicité de calcul. Cependant, les applications cliniques sont encore limitées, et bien qu'une vaste quantité de travail a été effectuée, les cliniciens dépendent encore de la projection manuelle de la tumeur, probablement en raison de l'absence d'un lien entre cliniciens et chercheurs [5].

Conclusion générale

Donc, il est important d'avoir des groupes multidisciplinaires impliquant des représentants des milieux clinique, universitaire et les communautés industrielles afin de créer des processus efficaces qui peuvent valider les algorithmes et donc approuver ou réfuter les recommandations faites par les logiciels...



Bibliothèque

- [1] Y.L. Wang , Z.J. Zhao , S.Y. Hu , F.L. Chang. CLCU-Net: Cross-level connecte d U-shape d network with selective feature aggregation attention module for brain tumor segmentation. *Computer Methods and Programs in Biomedicine* 207 (2021).
- [2] J. Wang, Jun Gao, J. Ren, Zhenye Luan, Zishu Yu , Yanhua Zhao, Yuefeng Zhao. DFP-ResUNet:Convolutional Neural Network with a Dilated Convolutional Feature Pyramid for Multimodal Brain Tumor Segmentation. *Computer Methods and Programs in Biomedicine* 208 (2021).
- [3] E.Ul Haq & J.Huang & Li Kang & Hafeez Ul Haq & Tijiang Zhan. Image-based state-of-the-art techniques for the identification and classification of brain diseases: a review. *Medical & Biological Engineering & Computing* (2020).
- [4] P. Harish and S. Baskar, MRI based detection and classification of brain tumor using enhanced faster R-CNN and Alex Net model, *Materials Today: Proceedings*, <https://doi.org/10.1016/j.matpr.2020.11.495>.
- [5] M. Khaled Abd-Ellah, Ali Ismail Awad, Ashraf A.M. Khalaf, Hesham F.A. Hamed. A review on brain tumor diagnosis from MRI images: Practical implications, key achievements, and lessons learned. *Magnetic Resonance Imaging* 61 (2019).
- [6] Ginni Garg, Ritu Garg. Brain Tumor Detection and Classification based on Hybrid Ensemble Classifier. arXiv:2101.00213 (2021)
- [7] Y.Brima, Member, IEEE, Mossadek Hossain Kamal Tushar, Member, IEEE, Upama Kabir, Member, IEEE and Tariqul Islam. Deep Transfer Learning for Brain Magnetic Resonance Image Multi-class Classification. proarXiv:2106.07333v2. (2021).
- [8] 16 Boucher, A. (2013). Recalage Et Analyse D'un Couple Des images: Application Aux Mammographies. Hèse De Doctorat. Université Paris Descartes.
- [9] Dipert, B. Shoham, A.(2012). Eye, robot: Embedded vision, the next big thing in digital signal processing. *IEEE Solid-State Circuits Magazine*, pp. 26–29.
- [10] Sevcan Aytac Korkmaz Mehmet Fatih Korkmaz, *Journal: A New Method Based Cancer Detection in Mammogram Textures by finding Feature Weights and using Kullback-Leibler Measure with Kernel Estimation*, 2015.
- [11] A.Boucher, Recalage et analyse d'un couple des images : application aux mammographies, thèse doctorat Université Paris Descartesm, 9 janvier 2013.

- [12] I. Claude, Analyse de textures en traitement des images journal GB06
- [13] H. Majdoulayne, Extraction de caractéristiques de texture pour la classification des images satellites, thèse de doctorat de l'université de toulouse, 02 / 11 / 2009.
- [14] A. Lefebvre, Contribution de la texture pour l'analyse des images à très haute résolution spatiale : application à la détection de changement en milieu périurbain, thèse doctorat Université Rennes 27 May 2011.
- [15] P. Kennel, Analyse de texture pour la classification et segmentation des images, Séminaire "Imagerie pour les Plantes et les Paysages" (I2P) de l'AMAP, 24 Juin 2013.
- [16] R. Pereira Ramos , Journal : Texture extraction : An evaluation of ridgelet, wavelet and co-occurrence based methods applied to mammograms, 2012.
- [17] G.Litjens, T.Kooi, Babak Ehteshami, Joinal : A survey on deep learning in medical image analysis, 26 July2017.
- [18] R. Pereira Ramos, Marcelo Zanchetta do Nascimento, Danilo Cesar Pereira , Texture extraction: An evaluation of ridgelet, wavelet and co-occurrence based methods applied to mammograms, journal homepage: www.elsevier.com/locate/eswa
- [19] M. HAMOUD, Indexation et segmentation des images basées loi de Zipf et Zipf inverse, mémoire de doctorat UNIVERSITY BADJI MOKHTAR-ANNABA 2015.
- [20] M. Hesam Hesamian, Wenjing Jia, Xiangjian He, Paul Kennedy. Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. Journal of Digital Imaging (2019) 32:582–596.
- [21] D. Castillo, Vasudevan Lakshminarayanan, Maria J. Rodriguez-Alvarez. MRI Images, Brain Lesions and Deep Learning. arXiv:2101.05091 (2021).
- [22] N. Kesav and M.G. Jibukumar, Efficient and low complex architecture for detection and classification of Brain Tumor using RCNN with Two Channel CNN, Journal of King Saud University – Computer and Information Sciences, <https://doi.org/10.1016/j.jksuci.2021.05.008>.
- [23] V.V.S. Sasank, S. Venkateswarlu. An automatic tumour growth prediction based segmentation using full resolution convolutional network for brain tumour. Biomedical Signal Processing and Control 71 (2022).

- [24] M. Hesam Hesamian, Wenjing Jia, Xiangjian He, Paul Kennedy. Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. *Journal of Digital Imaging* (2019)
- [25] T. Lei, Senior Member, IEEE, Risheng Wang, Yong Wan, Bingtao Zhang, Hongying Meng, Senior Member, IEEE and Asoke K. Nandi, Fellow, IEEE. Medical Image Segmentation Using Deep Learning: A Survey. arXiv:2009.13120v2 (2020).
- [26] M. Talo, O. Yildirim, Ulas Baran Baloglu, Galip Aydin, U Rajendra Acharya. Convolutional neural networks for multi-class brain disease detection using MRI images. *Computerized Medical Imaging and Graphics* 78 (2019).
- [27] S. Hao, Y. Zhou , Yanrong Guo. A Brief Survey on Semantic Segmentation with Deep Learning. *Neurocomputing* 406 (2020)
- [28] C. Sundar Rao & K. Karunakara. A comprehensive review on brain tumor segmentation and classification of MRI images. *Multimedia Tools and Applications* (2021).
- [29] M. Abu Bakr Siddique; Shadman Sakib; Mohammad Mahmudur Rahman Khan. Deep Convolutional Neural Networks Model-based Brain Tumor Detection in Brain MRI Images. Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC) (2020).
- [30] A. Mohammad Alqudah, Hiam Alquraan, Isam Abu Qasmieh, Amin Alqudah, Wafaa Al-Sharu. Brain Tumor Classification Using Deep Learning Technique - A Comparison between Cropped, Uncropped, and Segmented Lesion Images with Different Sizes. *International Journal of Advanced Trends in Computer Science and Engineering* (2019).
- [31] Z. Liu, Lei Tong, Zheheng Jiang, Long Chen, Feixiang Zhou, Qianni Zhang, Xiangrong Zhang, Yaochu Jin, Huiyu Zhou. Deep Learning Based Brain Tumor Segmentation: A Survey. arXiv:2007.09479v3. (2021).
- [32] D. Maji , P. Sigedar , Munendra Singh. Attention Res-UNet with Guided Decoder for semantic segmentation of brain tumors. *Biomedical Signal Processing and Control* 71 (2022).
- [33] S. Nema, A. Dudhane, S. Murala, Srivatsava Naidu. RescueNet: An unpaired GAN for brain tumor segmentation. *Biomedical Signal Processing and Control* 55 (2020).
- [34] S. Ramesh Gunasekara, H. N. T. K. Kaldera and Maheshi B. Dissanayake. A Systematic Approach for MRI Brain Tumor Localization, and Segmentation using Deep Learning and Active Contouring. *Journal of healthcare engineering* (2021).
- [35] D. Shen, Guorong Wu and Heung-Il Suk. Deep Learning in Medical Image Analysis. *Annu. Rev. Biomed. Eng.* (2017).

- [36] Othman MFB, Abdullah NB, Kamal NFB. MRI brain classification using support vector machine. 2011 4th International Conference on Modeling, Simulation and Applied Optimization (ICMSAO) April 2011. p. 1–4. <https://doi.org/10.1109/ICMSAO.2011.5775605>.
- [37] Nandpuru HB, Salankar SS, Bora VR. MRI brain cancer classification using support vector machine. 2014 IEEE Students' Conference on Electrical, Electronics and Computer Science (SCEECS) March 2014. p. 1–6. <https://doi.org/10.1109/SCEECS.2014.6804439>.
- [38] A. M. Sarhan, 'Brain Tumor Classification in Magnetic Resonance Images Using Deep Learning and Wavelet Transform', J. Biomed. Sci. Eng., vol. 13, no. 06, pp. 102–112, 2020, doi: 10.4236/jbise.2020.136010.
- [39] S. S. Begum and D. R. Lakshmi, 'Combining optimal wavelet statistical texture and recurrent neural network for tumour detection and classification over MRI', *Multimed. Tools Appl.*, vol. 79, no. 19–20, pp. 14009–14030, 2020, doi:10.1007/s11042-020-08643-w.
- [40] Deepa SN, Devi BA. Artificial neural networks design for classification of brain tumor. 2012 International Conference on Computer Communication and Informatics (ICCCI -2012) Jan 2012. p. 1–6. <https://doi.org/10.1109/ICCCI.2012.6158908>.
- [41] N.A. Ali, A.R. Syafeeza, L. J. Geok, Y. C. Wong, N. A. Hamid, and A. S. Jaafar, 'Design of Automated Computer-Aided Classification of Brain Tumor Using Deep Learning', Springer, Singapore, 2019, pp. 285–291.
- [42] Joshi DM, Rana NK, Misra VM. Classification of brain cancer using artificial neural network. International Conference on Electronic Computer Technology (ICECT) May 2010. p. 112–6. <https://doi.org/10.1109/ICECTECH.2010.5479975>.
- [43] K. Abbas, P.W. Khan, K.T. Ahmed, W.C. Song, "Automatic Brain Tumor Detection in Medical Imaging using Machine Learning," ICTC 2019 - 10th Int. Conf. ICT Converg. ICT Converg. Lead. Auton. Futur., pp. 531–536, 2019, doi: 10.1109/ICTC46691.2019.8939748.
- [44] Parveen, Singh A. Detection of brain tumor in MRI images using combination of fuzzy c-means and SVM. 2015 2nd International Conference on Signal Processing and Integrated Networks (SPIN) Feb 2015. p. 98–102. <https://doi.org/10.1109/SPIN.2015.7095308>.
- [45] A.N. Al-Zurfi, F. Meziane, R. Aspin, "A computer-aided diagnosis system for glioma grading using three-dimensional texture analysis and machine learning in mri brain tumour," BioSMART 2019 - Proc. 3rd Int. Conf. Bio-Engineering Smart Technol., pp. 1–5, 2019, doi: 10.1109/BIOSMART.2019.8734207.

- [46] B. El-Sherbiny et al., “BLB (Brain/Lung cancer detection and segmentation and Breast Dense calculation),” Proc. IWDRL 2018 2018 1st Int. Work. Deep Represent. Learn., pp. 41–47, 2018, doi: 10.1109/IWDRL.2018.8358213.
- [47] Zacharaki EI, Wang S, Chawla S, Yoo DS, Wolf R, Melhem ER. MRI-based classification of brain tumor type and grade using SVM-RFE. 2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro June 2009. p. 1035–8. <https://doi.org/10.1109/ISBI.2009.5193232>.
- [48] R. Pugalenth, M.P. Rajakumar, J. Ramya, V. Rajinikanth, Evaluation and classification of the brain tumor MRI using machine learning technique, Control Eng. Appl. Informatics 21 (4) (2019) 12–21.
- [49] Kumar V, Sachdeva J, Gupta I, Khandelwal N, Ahuja CK. Classification of brain tumors using PCA-ANN. 2011 World Congress on Information and Communication Technologies (WICT) Dec 2011. p. 1079–83. <https://doi.org/10.1109/WICT.2011.6141398>.
- [50] N. Bhaskarrao Bahadure, Arun Kumar Ray, Har Pal Thethi, Image Analysis for MRI Based Brain Tumor Detection and Feature Extraction Using Biologically Inspired BWT and SVM, Int. J. Biomed. Imaging 2017 (2017) 1–12, <https://doi.org/10.1155/2017/9749108>.
- [51-a] Chithambaram T, Perumal K (2017) Brain tumor segmentation using genetic algorithm and ANN techniques. IEEE International Conference on Power, Control, Signals and Instrumentation Engineering (ICPCSI), Chennai, pp 970–982
- [51-b] A. Çinar and M. Yildirim, ‘Detection of tumors on brain MRI images using the hybrid convolutional neural network architecture’, Med. Hypotheses, vol. 139, no. March, p. 109684, 2020, doi: 10.1016/j.mehy.2020.109684
- [52] M. Toğaçar, B. Ergen, and Z. Cömert, ‘BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model’, Med. Hypotheses, vol. 134, p. 109531, Jan. 2020, doi: 10.1016/j.mehy.2019.109531.
- [53] S. A. Abdelaziz Ismael, A. Mohammed, and H. Hefny, ‘An enhanced deep learning approach for brain cancer MRI images classification using residual networks’, Artif. Intell. Med., vol. 102, p. 101779, Jan. 2020, doi : 10.1016/j.artmed.2019.101779.
- [54] Anaraki AK, Ayati M, Kazemi F (2019) Magnetic resonance imaging-based brain tumor grades classification and grading via convolutional neural networks and genetic algorithms. Biocybernetics and Biomedical Engineering 39(1):63–74.

- [55] N. Ghassemi, A. Shoeibi, and M. Rouhani, 'Biomedical Signal Processing and Control Deep neural network with generative adversarial networks pre-training for brain tumor classification based on MR images', *Biomed. Signal Process. Control*, vol. 57, p. 101678, 2020, doi: 10.1016/j.bspc.2019.101678.
- [56] F. Özyurt, E. Sert, and D. Avcı, 'An expert system for brain tumor detection: Fuzzy C-means with super resolution and convolutional neural network with extreme learning machine', *Med. Hypotheses*, vol. 134, no. September 2019, p. 109433, Jan. 2020, doi: 10.1016/j.mehy.2019.109433.
- [57] Sajjad M, Khan S, Muhammad K, Wu W, Ullah A, Baik SW (Jan. 2019) Multi-grade brain tumor classification using deep CNN with extensive data augmentation. *J Comput Sci* 30:174–182.
- [58] Y. Bhanothu, A. Kamalakannan, and G. Rajamanickam, 'Detection and Classification of Brain Tumor in MRI Images using Deep Convolutional Network', 2020 6th Int. Conf. Adv. Comput. Commun. Syst. ICACCS 2020, pp. 248–252, 2020, doi: 10.1109/ICACCS48705.2020.9074375.
- [59] M. H C, 'Evaluation of Brain Tumor MRI Imaging Test Detection and Classification', *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 8, no. 6, pp. 124–131, 2020, doi: 10.22214/ijraset.2020.6019.
- [60] C. Han et al., 'Infinite Brain MR Images: PGGAN-Based Data Augmentation for Tumor Detection', Springer, Singapore, 2020, pp. 291–303
- [61] Ejaz Ul Haq, Huang Jianjun, Kang Li, Hafeez Ul Haq, Tijiang Zhang. An MRI-based deep learning approach for efficient classification of brain tumors. *Journal of Ambient Intelligence and Humanized Computing*
<https://doi.org/10.1007/s12652-021-03535-9> (2021).
- [62] X. Wang, Gustavo Carneiro, Lin Yang Editors. *Deep Learning and Convolutional Neural Networks for Medical Imaging and Clinical Informatics. Advances in Computer Vision and Pattern Recognition* (2019).
- [63] H. Mohan Rai, K. Chatterjee. Detection of brain abnormality by a novel Lu-Net deep neural CNN model from MR images. *Machine Learning with Applications 2* (2020).
- [64] S. Ramesh & S. Sasikala & Nirmala Paramanandham. Segmentation and classification of brain tumors using modified median noise filter and deep learning approaches. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-020-10351-4> (2021).

- [65] Md. Badiuzzaman Shuvo, Rifat Ahommed, Sakib Reza, M.M.A. Hashem. CNL-UNet: A novel lightweight deep learning architecture for multimodal biomedical image segmentation with false output suppression. *Biomedical Signal Processing and Control* 70 (2021).
- [66] N. Cummins, Z. Ren, A. Mallol-Ragolta, B. Schuller. Machine learning in digital health, recent trends, and ongoing challenges. CHAPTER. *Artificial Intelligence in Precision Health*. <https://doi.org/10.1016/B978-0-12-817133-2.00005-7>.2020.
- [67] O. Sultan Al-Kadi. A GABOR FILTER TEXTURE ANALYSIS APPROACH FOR HISTOPATHOLOGICAL BRAIN TUMOUR SUBTYPE DISCRIMINATION. Preprint submitted to *ISESCO JST journal*, vol.12(22), 2017.
- [68] B. ALLEL, L. MIHOUBI. Analyse de texture par les filtres de Gabor et Laws. Mémoire de Master en Electronique. 2014.
- [69] M. Haghghat, S. Zonouz, M. Abdel-Mottaleb, "CloudID: Trustworthy cloud-based and cross-enterprise biometric identification". *Expert Systems with Applications*, vol. 42, no. 21, pp. 7905-7916, 2015.
- [70] B. Chen , L. Zhang , H. Chen , K. Liang , X. Chen. A novel extended Kalman filter with support vector machine based method for the automatic diagnosis and segmentation of brain tumors. *Computer Methods and Programs in Biomedicine* 200 (2021) 105797.