

République Algérienne Démocratique et Populaire
Ministère de l'enseignement Supérieur et de la Recherche Scientifique
Université de Mohamed El Bachir El Ibrahimi de Borj Bou Arréridj
Faculté des Mathématiques et d'Informatique
Département d'informatique



MEMOIRE

Pour l'obtention du diplôme de
Master en informatique
Spécialité : Ingénierie de l'informatique décisionnelle

THEME

La Segmentation et La Détection des images IRM pour
identifier les tumeurs cérébrales par l'apprentissage
profond

Présenté par :
Derradj Zoubir
Sakhraoui belkacem

Soutenu publiquement le : Juin 2025
Devant le jury composé de :
Président : Boumaza Farid
Examineur : Belalta Ramla
Encadreur : ZOUAOUI Hakima

2024/2025

Dédicace

Je dédie mon travail à :

Mes parents

Les deux êtres les plus chers au monde, Les bougies qui m'ont toujours guidé sur le bon chemin :

À ma chère mère, source d'amour et de tendresse, mon véritable pilier dans la vie, celle qui a illuminé mon chemin par ses sacrifices et ses prières sincères. Je te dois une reconnaissance infinie et tout mon amour. Tu es la plus grande bénédiction dont je sois fier pour toujours

À mon père, source de tendresse, à qui je dois tout le respect et l'amour, pour son soutien inconditionnel et sa présence constante à mes côtés.

Mes frères et sœurs

anwer,mahdi,wafa,embarka,fatma

Mes chers amis

omar,kacem,amine,aymen,mohamed Il était grand temps de vous dire à quel point vous êtes importants pour moi. Sans vous, la vie serait bien triste et terne.

Tous les membres de la famille *Derradj* Merci pour votre amour, vos prières et votre bienveillance.

— Derradj Zoubir —

Dédicace

De tout mon cœur, je dédie ce travail à celles et ceux qui ont marqué ma vie de leur présence, leur amour et leur soutien indéfectible.

À ma chère grand-mère Fadhila, source inépuisable d'amour et de sagesse. Merci d'avoir toujours cru en moi, de m'avoir soutenu dans les moments de doute, et d'avoir semé en moi la force et les valeurs qui me portent aujourd'hui.

À mes parents adorés, Rachida et Abdelhak, pour leur amour inconditionnel, leurs sacrifices silencieux, et pour avoir toujours été à mes côtés dans cette belle aventure qu'est la vie. Vous êtes les fondations de tout ce que j'ai pu accomplir.

À mon frère Nadjib, pour sa bienveillance, son exemple et sa précieuse présence, ainsi qu'à sa petite famille que j'affectionne tant. À mes sœurs, pour leur tendresse, leur écoute et leur soutien constants, qui ont toujours été une lumière dans mon quotidien. À mes cousins et cousines, qui ont su être bien plus que de simples membres de la famille : des amis, des complices, des piliers. Une mention spéciale à ma chère cousine Maria, pour sa présence et son affection sincère. À mes amis fidèles, pour les moments de joie partagés, le soutien inestimable et les souvenirs gravés à jamais. En particulier Anis, Amine et Youcef, merci pour votre amitié vraie et constante. À tous ceux qui m'aiment, m'inspirent et me soutiennent, de près ou de loin, merci pour votre impact dans ma vie. Enfin, je dédie ce travail à tous mes enseignants, pour leur transmission du savoir et leur accompagnement tout au long de mon parcours. Et à mon encadrante, pour sa confiance, ses conseils et sa bienveillance.

Ce mémoire est bien plus qu'un simple travail : il est l'empreinte de toutes les personnes qui ont cru en moi. Merci.

Remerciement

Avant toute chose, nous adressons nos louanges et nos remerciements les plus sincères à ALLAH, Le Tout-Puissant, pour la force, la patience et la volonté qu'Il nous a accordées tout au long de ce travail. C'est grâce à Sa miséricorde que nous avons pu franchir les étapes qui ont mené à l'aboutissement de ce mémoire.

Nous exprimons notre profonde gratitude à notre encadrante, Madame (ASM ENCADRANTE) , pour son accompagnement bienveillant, la qualité de ses orientations, ainsi que pour ses précieux conseils et remarques, qui ont grandement enrichi notre réflexion.

Nos remerciements s'étendent à toutes les personnes, de près ou de loin, qui ont contribué à la réalisation de ce projet, que ce soit par leur aide matérielle, morale ou intellectuelle.

Nous tenons à remercier nos parents, pour leurs sacrifices inestimables, leur amour inconditionnel et leur soutien indéfectible. Grâce à eux, nous avons pu persévérer même dans les moments les plus difficiles.

À nos frères, sœurs , famille et amis, qui nous ont entourés de leur affection, de leur patience et de leurs encouragements constants tout au long de ce parcours.

Enfin, nos remerciements vont également à Messieurs les membres du jury, pour avoir accepté d'évaluer ce travail. Nous espérons qu'il saura répondre à leurs attentes et témoigner du sérieux et de l'engagement investis tout au long de cette recherche.

Résumé

Le traitement des images médicales est devenu un domaine central dans l'aide au diagnostic. Dans ce mémoire, nous proposons une approche automatique basée sur l'apprentissage profond pour détecter et segmenter les tumeurs cérébrales à partir d'images IRM. Deux architectures de réseaux neuronaux convolutifs (CNN) ont été utilisées : InceptionV3 pour la classification binaire et ResUNet pour la segmentation. L'ensemble de données utilisé provient de Kaggle. L'évaluation a montré une précision de 92.7% pour la classification et un Dice de 0.85 pour la segmentation. Ces résultats prouvent l'efficacité de notre méthode et son potentiel pour des applications médicales réelles.

Mots-clés : IRM, tumeur cérébrale, CNN, InceptionV3, ResUNet, classification, segmentation, apprentissage profond.

Abstract

Medical image analysis has become essential for early diagnosis. In this research, we propose a deep learning-based approach to automatically detect and segment brain tumors from MRI images. Two convolutional neural network (CNN) models were used : InceptionV3 for binary classification and ResUNet for segmentation. The dataset was obtained from Kaggle. The evaluation results show an accuracy of 92.7% for classification and a Dice score of 0.85 for segmentation. These results demonstrate the effectiveness of the proposed method and its relevance for real-world medical applications.

Keywords : MRI, brain tumor, CNN, InceptionV3, ResUNet, classification, segmentation, deep learning.

الملخص

تعد معالجة الصور الطبية من أبرز المجالات الحديثة في التشخيص الطبي، حيث تُسهم صوراً محورياً في الكشف المبكر وتحسين فرص العلاج. في هذا العمل، تمّ تطوير منهجية تعتمد على تقنيات التعلم العميق (Deep Learning) للكشف والتقسيم التلقائي للأورام الدماغية اعتماداً على صور الرنين المغناطيسي (IRM). تم استخدام نموذجين من الشبكات العصبية (CNN)، وهما InceptionV3 للتصنيف الثنائي، و ResUNet لتقسيم الصور. وقد اعتمدنا في Kaggle التقرب والتقييم على قاعدة بيانات متوفرة على منصة النموذج المقترح. أظهرت النتائج المحصلة أن Dice بلغ 92.7% ومعدل IoU بلغ 0.85، مما يدل على فعالية المنهجية المقترحة وإمكانية استخدامها في التطبيقات الطبية للمساعدة في التشخيص.

الكلمات المفتاحية: الرنين المغناطيسي (IRM)، الشبكات العصبية (CNN)، InceptionV3، ResUNet، التصنيف، التقسيم، Deep Learning.

Table des matières

Liste des abréviations	x
Liste des figures	xi
Liste des tableaux	xiii
1 Anatomie cérébrale et imagerie IRM	3
1.1 Introduction	3
1.2 Le système nerveux central (SNC)	3
1.2.1 La moelle épinière	4
1.2.2 L'encéphale	4
1.3 Les principaux tissus cérébraux	6
1.3.1 La substance grise	7
1.3.2 La substance blanche	7
1.3.3 Liquide céphalo-rachidien	7
1.4 Cycle vasculaire cérébral	8
1.5 Le cerveau au niveau cellulaire	8
1.5.1 Les neurones	8
1.5.2 Les cellules gliales	8
1.6 Lésions cérébrales	9
1.6.1 tumeur cérébrale	9
1.6.2 Classification des tumeurs cérébrales	9
1.7 Les différents types de tumeurs cérébrales	10
1.7.1 Gliomes	10
1.7.2 Les méningiomes	10

1.7.3	Les adénomes de l'hypophyse	11
1.7.4	Les neurinomes	11
1.8	Le diagnostic des tumeurs cérébrales	11
1.8.1	Examen clinique	11
1.8.2	Examens d'imagerie	11
1.9	Principe d'IRM	12
1.9.1	Mécanisme de travail d'IRM	12
1.9.2	Les composantes principales de IRM	12
1.9.3	Les différents IRM	13
1.10	Pourquoi pratiquer une IRM cérébrale ?	13
1.11	Conclusion	13
2	Apprentissage profond (Deep Learning)	15
2.1	Introduction	15
2.2	Qu'est-ce que Apprentissage profond (Deep Learning)	16
2.3	L'importance de l'apprentissage profond (Deep learning)	16
2.4	Plateformes d'apprentissages en profondeur	17
2.5	Comment fonctionne deep learning	18
2.6	Les types de modèles utilisant des architectures d'apprentissages en profondeur	19
2.6.1	Réseau de neurones profonds (DNN)	20
2.6.2	Réseau neuronal récurrent (RNN) et (LSTM)	20
2.6.3	Les réseaux adversaires génératifs (GAN)	21
2.6.4	Les réseaux de neurones convolutifs (CNN)	22
2.7	Les avantages et les inconvénients de CNN	27
2.8	Conclusion	28
3	Etat de l'art sur les méthodes la segmentation et la Détection	29
3.1	Introduction	29
3.2	Détection	29
3.3	Segmentation d'images cérébrales	30
3.4	Les méthodes pour segmentation les tumeurs cérébrales	31
3.4.1	La segmentation Manuel	31
3.4.2	La segmentation semi-automatique des IRM cérébrales	31

3.4.3	Méthode de segmentation entièrement automatique	32
3.5	Classification	32
3.6	Travaux connexes	32
3.7	Difficultés liées à la segmentation des images cérébrales	34
3.8	Conclusion	34
4	Contribution et résultats	36
4.1	Introduction	36
4.2	Approche proposée	36
4.2.1	Collection de l'ensemble de données	37
4.2.2	4.2.2 Préparation des données	38
4.2.3	Construction de modèle Proposée	39
4.3	Environnement de développement de système	45
4.3.1	Environnement logiciel	45
4.3.2	Environnement matériel	48
4.4	La phase d'évaluation, résultats et discussion	48
4.4.1	Évaluation du modèle Inception-V3 (Classification binaire)	49
4.4.2	Évaluation du modèle ResUNet (Segmentation)	51
4.4.3	Comparaison avec des méthodes existantes	53
4.5	La prédiction	53
4.5.1	Le fonctionnement de l'application	53
4.6	Conclusion	56
	Références	58

Liste des abréviations

- **IRM** : Imagerie par Résonance Magnétique
- **IA** : Intelligence Artificielle
- **ML** : Machine Learning (Apprentissage Automatique)
- **DL** : Deep Learning (Apprentissage Profond)
- **CNN** : Réseaux de Neurones Convolutionnels
- **RNN** : Réseau de Neurones Récurrents
- **GAN** : Modèle Génératif Profond
- **U-Net** : Réseau de Neurones pour la Segmentation d'Images

Table des figures

1.1	Système nerveux centrale et ses composants de base.[3]	4
1.2	La position des quatre lobes dans le cerveau[10]	6
1.3	Les substances du SNC[14]	7
1.4	Les différentes cellules du cerveau[18]	9
1.5	Image IRM normale et en présence d'une tumeur[23]	10
1.6	Les composants de IRM[28]	12
2.1	Représentation que qu'est-ce que Deep learning	17
2.2	ANN architecture[35]	19
2.3	Types de modèles utilisant des architectures d'apprentissages en profondeur[36]	20
2.4	Représentation construction du modèle de réseau neuronal profond -DNN[38]	21
2.5	Architecture de RNN pour l'ouverture d'un réseau[41]	21
2.6	Exemple d'un réseau de neurones convolutifs[44]	22
2.7	Architecture couche de convolution[46]	23
2.8	Fonction d'activation ReLU[48]	24
2.9	Max-pooling sur un canal 4*4 utilisant un noyau 2*2 et une foulée de 2[50]	25
2.10	Moyenne pooling[51]	25
2.11	Sum pooling[52]	26
2.12	La couche entièrement connectée[54]	27
3.1	La segmentation d'image de tumeur cérébrale	31
4.1	Architecture de méthode proposée.	37
4.2	tranche d'image avec leur masque de segmentation correspondante.	38
4.3	Structure du modèle Inception V3.	42
4.4	Architecture du modèle ResUNet	45

4.5	Paramètres de couche et d'étape de modèle proposés.	46
4.6	L'interface de latex.	46
4.7	Matrice de confusion du modèle inception v3	49
4.8	Les courbes de perte(Loss) et précision (Accuracy) de modèle Inception V3	50
4.9	Exemple d'image IRM et son masque segmenté par ResUNet	52
4.10	Les courbes de perte(Loss) et précision Dice score de modèle Res UNet	52
4.11	Accueil de l'application.	54
4.12	Insérer l'image d'IRM cérébrale originale	54
4.13	résultat de tumeur détecté avec segmentation	55
4.14	résultat de pas tumeur détecté	55

Liste des tableaux

3.1	Travaux connexes sur la tumeur au cerveau.	34
4.1	Configuration matérielle utilisée pour l'entraînement et l'évaluation des modèles	48
4.2	La performance de modèle proposée.	53

Introduction Générale

Les tumeurs cérébrales représentent un problème de santé publique majeur, affectant des millions de personnes dans le monde entier. Leur nature complexe, leur évolution imprévisible et leur localisation délicate dans les structures cérébrales rendent leur détection précoce et leur caractérisation précise indispensables pour améliorer le diagnostic, la planification du traitement et le suivi des patients.

La détection et la segmentation précises des tumeurs cérébrales permettent non seulement d'identifier la présence de l'anomalie, mais aussi de délimiter avec exactitude les régions tumorales, fournissant ainsi aux cliniciens des informations essentielles pour la prise de décision médicale.

L'imagerie par résonance magnétique (IRM) est la technique d'imagerie médicale la plus utilisée pour visualiser les tissus mous du cerveau. Elle permet de générer des images de haute résolution, non invasives, et offre différentes modalités (T1, T2, FLAIR, etc.) facilitant la visualisation des structures cérébrales et des anomalies telles que les tumeurs. Toutefois, l'interprétation manuelle des images IRM est une tâche fastidieuse, chronophage et fortement dépendante de l'expérience du radiologue. De plus, les limites de la perception humaine et les variations inter-observateurs introduisent un risque non négligeable d'erreurs dans le diagnostic et l'évaluation de l'évolution de la tumeur.

Dans cette optique, ces dernières années, l'intelligence artificielle, et plus particulièrement l'apprentissage profond (deep learning), a émergé comme une solution prometteuse pour automatiser et fiabiliser les tâches de détection et de segmentation d'images médicales. Le deep learning, en s'appuyant sur des réseaux de neurones profonds, permet d'extraire automatiquement des caractéristiques complexes à partir de grandes quantités de données d'imagerie, surpassant souvent les méthodes traditionnelles en termes de précision et de robustesse.

Pour la détection, les réseaux de neurones convolutifs (CNN) ont montré leur efficacité pour identifier automatiquement la présence de tumeurs dans les images IRM. Ces réseaux sont capables de capturer des motifs discriminants entre tissus sains et tissus pathologiques. Quant à la segmentation, des architectures comme U-Net et ses variantes ont été spécialement conçues pour localiser finement les contours des lésions tumorales, en combinant l'information spatiale globale avec les détails locaux.

Dans notre travail, nous exploitons la puissance de ces architectures en combinant des

modèles avancés tels que ResNet et Inception V3 pour renforcer la capacité d'extraction de caractéristiques, et des variantes de U-Net pour affiner la segmentation des régions tumorales. Cette combinaison vise à tirer parti des avantages complémentaires de chaque architecture, afin de développer un modèle capable de détecter et de segmenter avec précision les tumeurs cérébrales sur des images IRM multimodales.[1]

L'objectif principal de ce mémoire est donc de proposer une approche basée sur l'apprentissage profond pour la détection et la segmentation automatiques des tumeurs cérébrales. Nous visons ainsi à faciliter le diagnostic précoce et à réduire la charge de travail des professionnels de santé, tout en garantissant des résultats fiables et reproductibles.

Chapitre 1 : Anatomie cérébrale et imagerie IRM

Dans ce chapitre, nous avons examiné de manière approfondie tous les aspects liés aux tumeurs cérébrales.

Chapitre 2 : Apprentissage profond (Deep Learning)

Dans ce chapitre, nous abordons les principes fondamentaux du deep learning et décrivons les différentes architectures associées à cette technique, parmi ces architectures, nous détaillons le réseau de neurones convolutifs (CNN).

Chapitre 3 : Etat de l'art sur les méthodes la segmentation et la Détection

Dans ce chapitre, nous avons essayé de mettre en œuvre la notion de détection, classification et segmentation, en se basant sur quelques méthodes les plus connues.

Chapitre 4 : Contribution et Résultats

Dans ce chapitre, nous donnons une description pour l'approche proposée et aussi nous faisons une description des résultats obtenus.

Conclusion générale

Chapitre 1

Anatomie cérébrale et imagerie IRM

1.1 Introduction

Dans ce chapitre, nous allons introduire les concepts de base liés au contexte de notre travail, notamment l'anatomie cérébrale et les principales structures observées en imagerie médicale. Nous définirons des notions clés indispensables à la compréhension des images médicales, en particulier celles issues de l'imagerie par résonance magnétique (IRM). Nous aborderons également la question des tumeurs cérébrales, leurs symptômes, leurs classifications ainsi que les différents types existants. Enfin, nous expliquerons les principes fondamentaux du diagnostic par IRM et son rôle essentiel dans le dépistage des pathologies cérébrales.

1.2 Le système nerveux central (SNC)

également appelé névraxe, est l'un des composants fondamentaux du système nerveux. Il est composé de l'encéphale (cerveau, cervelet et tronc cérébral), protégé par la boîte crânienne, ainsi que de la moelle épinière, enveloppée par les méninges et logée dans la colonne vertébrale. Ce système est constitué de milliards de neurones interconnectés, accompagnés d'un tissu de soutien appelé névroglie. Le SNC joue un rôle central dans le traitement des informations sensorielles provenant du système nerveux périphérique, leur intégration, puis l'émission de commandes motrices vers les organes effecteurs (tels que les muscles et les glandes), permettant ainsi à l'organisme d'interagir avec son

environnement[2]




FIGURE 1.1 – Système nerveux centrale et ses composants de base.[3]

1.2.1 La moelle épinière

La moelle épinière est une structure allongée du système nerveux central logée dans la colonne vertébrale, mais sans en occuper toute la longueur. Elle s'étend de la base du crâne jusqu'à la première vertèbre lombaire. Elle est segmentée en 31 niveaux, chacun étant associé à une paire de nerfs rachidiens. Ces nerfs permettent la transmission des informations sensorielles via les racines dorsales et des commandes motrices par les racines ventrales. Anatomiquement, la moelle présente deux régions distinctes : une périphérie de substance blanche contenant les voies nerveuses ascendantes et descendantes, et une région centrale de substance grise en forme de papillon où transitent les signaux entre les neurones sensitifs et moteurs.[4]

1.2.2 L'encéphale

L'encéphale est la partie du système nerveux central incluse dans la boîte crânienne (ou crâne). Dans le langage courant, les termes « cerveau » et « encéphale » sont considérés comme équivalents, mais au sens strict, le cerveau ne correspond qu'à une partie de l'encéphale : les hémisphères cérébraux (à l'exclusion du tronc cérébral et du cervelet)[5]

Le tronc cérébral

Le tronc cérébral, situé entre la moelle épinière et le cerveau, est formé du bulbe rachidien, du pont de Varole et du mésencéphale (péduncules cérébraux). Il assure le relais des informations motrices et sensitives entre le cerveau et le reste du corps. Il contient les noyaux des nerfs crâniens, régule les fonctions autonomes essentielles telles que la respiration, la pression artérielle et le rythme cardiaque, et participe à la régulation du cycle veille-sommeil à travers la formation réticulée.[6]

Le cervelet

Le cervelet est une structure cérébrale située à l'arrière du tronc cérébral. Il se présente comme un petit cerveau, composé de deux hémisphères et d'un axe central appelé le vermis. Il reçoit des informations motrices et sensorielles provenant du cerveau, de la moelle épinière et des organes de l'équilibre. Son rôle principal est de coordonner le tonus musculaire, la posture, l'équilibre et la fluidité des mouvements. Un dysfonctionnement du cervelet, comme lors d'une ivresse alcoolique, perturbe ces fonctions.[7] Utilisez « nous » pour désigner l'auteur du mémoire.

Le cortex cérébral

Le cortex cérébral constitue le plus développé système nerveux central des mammifères, et en particulier chez l'homme. Des aires sont à ce niveau directement impliquées dans la réception de l'information ou dans l'élaboration de la commande motrice. On parle alors de cortex primaire : moteur pour le lobe frontal, sensitif pour le lobe pariétal, visuel pour l'occipital, auditif pour le temporal. Mais l'essentiel du cortex est remis aux tâches associatives, -applicatives, qui lient plusieurs aires corticales et permettent, au-delà de la sensation, la perception, puis la comparaison avec des traces mnésiques, l'émotion, enfin l'élaboration de comportements complexes et de processus d'idéation.[8]

Le cerveau

Il se compose de deux lobes latéraux, appelés hémisphères cérébraux qui sont reliés par le corps calleux. Chaque hémisphère, droit et gauche est creusé par trois ventricules (espaces) et un quatrième ventricule derrière le cervelet. Ils baignent dans le liquide céphalo-rachidien. L'hémisphère est divisé en lobes :

Lobe frontal : contient la parole, le langage, le raisonnement, mais aussi la fonction de gérer les mouvements des membres.

Lobe pariétal : la partie du repérage à l'espace, à sens, à lecture.

Lobe occipital : qui est responsable de la vision insula et corps calleux.

Lobe temporal où se trouve le langage, la mémoire, l'émotivité.

le cerveau est composé d'une couche périphérique de matière grise, le cortex cérébral et d'une couche centrale profonde de matière blanche .[9]




FIGURE 1.2 – La position des quatre lobes dans le cerveau[10]

1.3 Les principaux tissus cérébraux

Lorsqu'on observe le cerveau, on remarque que ce dernier est principalement constitué d'une substance blanche et une substance grise.

1.3.1 La substance grise

Dans le SNC, la substance grise correspond aux parties des neurones sans la gaine de myéline, soit les corps cellulaires des nerfs. Dans le cerveau, elle constitue à la fois le cortex cérébral en surface et les noyaux gris à l'intérieur. Dans la moelle, la substance grise réside dans le centre, étant entourée de matière blanche. Elle est également essentielle dans le traitement de l'information sensorielle et motrice.[11]

1.3.2 La substance blanche

La substance blanche du cerveau est essentiellement composée de fibres nerveuses axonales recouvertes de myéline, une substance lipidique et protéique. La myéline est impérative pour la fonction neuronale puisqu'elle permet une transmission rapide et efficace des impulsions électriques entre différentes régions cérébrales. Cette capacité accélérée est cruciale pour la coordination de diverses fonctions cognitives et motrices complexes.[12]

1.3.3 Liquide céphalo-rachidien

Le liquide céphalo-rachidien ou LCR correspond à un liquide enveloppant le système nerveux central, c'est-à-dire le cerveau et la moelle épinière. Il circule à travers le système ventriculaire (ventricules situés dans le cerveau) et l'espace sous-arachnoïdien.[13]




FIGURE 1.3 – Les substances du SNC[14]

1.4 Cycle vasculaire cérébral

Le cycle vasculaire cérébral correspond au flux sanguin et fournit le cerveau à travers un réseau de vaisseaux sanguins. Les artères transportent du sang contenant de l'oxygène et nutriments vers le cerveau, tandis que les veines évacuent le sang désoxygéné et les déchets métaboliques. Le système cérébro-vasculaire a plusieurs mécanismes préventifs, garantissant qu'il y a suffisamment d'irrigation dans le sang dans le cerveau.[15]

1.5 Le cerveau au niveau cellulaire

Le cerveau analyse les informations véhiculées par les récepteurs périphériques qui répondent à l'environnement. Il est considéré comme l'organe du corps responsable de la perception et de l'interprétation du monde extérieur. Il est composé de deux types de cellules : les neurones et les cellules gliales.

1.5.1 Les neurones

Les neurones sont les cellules principales du système nerveux, spécialisées dans la transmission rapide de l'information sous forme de signaux électriques et chimiques. Chaque neurone possède des dendrites (réception), un corps cellulaire (intégration) et un axone (transmission). Grâce aux synapses et aux neurotransmetteurs comme le glutamate, la dopamine ou le GABA, les neurones forment des réseaux complexes permettant les fonctions cérébrales telles que la pensée, la mémoire ou le mouvement.[16]

1.5.2 Les cellules gliales

Les cellules gliales, aussi nombreuses que les neurones, assurent des fonctions essentielles de soutien, de protection et de régulation dans le cerveau. Les astrocytes nourrissent les neurones et régulent le milieu chimique, les oligodendrocytes (dans le cerveau) et les cellules de Schwann (dans les nerfs) produisent la myéline, et la microglie joue un rôle immunitaire. Loin d'être passives, ces cellules participent activement au bon fonctionnement du système nerveux.[17]




FIGURE 1.4 – Les différentes cellules du cerveau[18]

1.6 Lésions cérébrales

Une lésion cérébrale est une blessure qui affecte le cerveau. En gros, il y en a un le tissu nerveux est plus ou moins largement détruit, entraînant une réduction des fonctions sensorielles, cognitives, de sensibilité ou motrices, selon le rôle que joue la zone touchée dans les structures neurocognitives.[19]

1.6.1 tumeur cérébrale

Une tumeur cérébrale est une masse anormale de cellules qui ne sont pas contrôlées dans le cerveau. Selon sa capacité à pénétrer ou à diffuser en substances adjacentes, elle pourrait être bénigne (non cancer) ou maligne (comme le cancer). Ces tumeurs proviennent de différents types de cellules (neurones, cellules gliales, méninges, etc.) et provoquent une variété de symptômes en fonction de leur taille et de leur emplacement.[20]

1.6.2 Classification des tumeurs cérébrales

• Les tumeurs cérébrales bénignes

Les tumeurs cérébrales bénignes se développent lentement à partir des cellules cérébrales elles-mêmes ou des cellules vaisseaux sanguins ou des nerfs à l'intérieur du cerveau. Les bords et les extrémités de ces tumeurs sont clairement visibles, mais elles sont moins dangereuses que les tumeurs malignes car elles ne se propagent pas aux organes environnants il peut être facilement géré par radiothérapie ou enlevé chirurgicalement en tout ou en partie.[21]

• Les tumeurs cérébrales malignes

Les tumeurs cérébrales malignes contiennent des cellules qui se multiplient relativement vite, ces tumeurs croissent donc rapidement. Elles consomment beaucoup d'énergie, leurs contours sont mal limités et aussi elles peuvent envahir endommager des structures cérébrales importantes, Ils peut être traité par chirurgie, radiothérapie, chimiothérapie, etc[22]




FIGURE 1.5 – Image IRM normale et en présence d'une tumeur[23]

1.7 Les différents types de tumeurs cérébrales

Il existe plusieurs types de tumeurs cérébrales. Le type de tumeur cérébrale est basé sur le type de cellules qui composent la tumeur on distingue :

1.7.1 Gliomes

Ce sont les tumeurs les plus courantes du cerveau qui se développent à partir des cellules gliales y compris les astrocytomes, les oligodendrogliomes et les épendymomes qui dérivent de la paroi des ventricules cérébraux. La majorité des tumeurs du cerveau sont des gliomes.

1.7.2 Les méningiomes

Ils se forment dans les membranes qui entourent le cerveau et la moelle épinière autrement dit se développant vers l'intérieur de la boîte crânienne. La plupart des méningiomes sont bénins, mais dans certains cas isolés, on peut observer une évolution défavorable.

1.7.3 Les adénomes de l'hypophyse

Ils se développent à partir de cellules de l'hypophyse. Cette tumeur peut causer des troubles hormonaux (arrêt des règles) sont des tumeurs bénignes dans la grande majorité des cas.

1.7.4 Les neurinomes

Également connus sous le nom de schwannomes, ils se développent à partir des cellules entourant les nerfs crâniens et en trouve aussi au niveau nerfs périphériques de tout le corps, le neurinome le plus fréquent se développe dans le cerveau sur le nerf acoustique qui est responsable de l'audition.

1.8 Le diagnostic des tumeurs cérébrales

1.8.1 Examen clinique

Si les médecins soupçonnent la présence de tumeurs cérébrales, il suppose un Mier A avec des tests cliniques profonds pour trouver les régions cérébrales affectées. Compte tenu du fait que toutes les zones du cerveau sont liées à des fonctions spécifiques du corps.[24]

1.8.2 Examens d'imagerie

L'imagerie avec la résonance du cerveau magnétique (IRM) est une technologie d'imagerie médicale non invasive qui utilise des champs magnétiques puissants et des ondes radio pour créer des images détaillées du cerveau. Cette technique d'imagerie est extrêmement utile pour diagnostiquer et surveiller le développement d'une variété de pathologie cérébrale, notamment des tumeurs, des souches, une sclérose en plaques, des maladies dégénératives et un traumatisme cérébral. (IRM) est considéré comme un test d'image très sûr, car il ne nécessite pas l'utilisation de rayons X ou d'autres rayonnements. Cependant, il peut être contre-indiqué pour certaines personnes avec des dispositifs électroniques implantés tels que implants métalliques ou dispositifs de stimulation cardiaque ou pompes à insuline. Dans ce cas, il est important de consulter un médecin avant d'émettre une IRM du cerveau.[25]

1.9 Principe d'IRM

1.9.1 Mécanisme de travail d'IRM

L'IRM est extrêmement efficace, complètement indolore et est une technique de test des risques.

L'IRM n'utilise pas de rayons X, mais est basé sur le principe de la résonance magnétique dans le corps humain dans les champs électromagnétiques. Ce dernier est créé à par un aimant géant sous la forme d'un tunnel dans lequel le patient est situé. Les ondes électromagnétiques provoquent une magnétisation spécifique des noyaux d'hydrogène présents dans différentes parties de dans le tissu en fonction de la teneur en humidité. Le retour à l'état de base du signal émis par le proton, est l'origine de la création d'images. Les images obtenues sont gérées à partir de logiciels puissants. Cela vous permet de reconstruire diverses coupes. Ces images sont visualisées à l'écran et converties en un enregistrement radiologique.[26]

1.9.2 Les composants principales de IRM

Les principales composantes de l'IRM sont les suivantes :- L'aimant : l'IRM utilise un aimant puissant pour créer un champ magnétique uniforme. Un aimant super conducteurs refroidis à l'hélium liquide.- Les gradients de champ magnétique sont des champs magnétiques faibles appliqués dans une direction spécifique pour localiser les signaux IRM. La radiofréquence (RF) : un signal RF est utilisé pour exciter les atomes d'hydrogène dans le corps et produire un signal IRM détectable.- La bobine de réception : capter les signaux IRM du corps et les envoient à un ordinateur pour traitement.- L'ordinateur est utilisé pour traiter les signaux IRM et créer une image tridimensionnelle du corps. Il peut également être utilisé pour l'analyse quantitative et la mesure de précision.[27]




FIGURE 1.6 – Les composants de IRM[28]

1.9.3 Les différents IRM

IRM anatomique

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

IRM fonctionnelle

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

1.10 Pourquoi pratiquer une IRM cérébrale ?

L'Imagerie par Résonance Magnétique (IRM) cérébrale est un examen non invasif qui permet d'obtenir des images détaillées du cerveau. Elle est utilisée pour :

- Diagnostiquer des pathologies neurologiques telles que les tumeurs cérébrales, les accidents vasculaires cérébraux (AVC), la sclérose en plaques, les infections, et les malformations congénitales.
- Évaluer des symptômes persistants comme les maux de tête chroniques, les troubles de la mémoire, les convulsions, ou les troubles de l'équilibre.
- Surveiller l'évolution de certaines maladies neurologiques ou l'efficacité d'un traitement. L'IRM est particulièrement précieuse car elle offre une excellente résolution des tissus mous sans utiliser de rayons X, ce qui la rend sûre pour une utilisation répétée. [29]

1.11 Conclusion

Ce chapitre a introduit les principes fondamentaux de l'anatomie du cerveau en présentant des cellules cérébrales clés telles que les neurones et les cellules gliales, ainsi que

leurs rôles dans le fonctionnement du système nerveux. Ils ont également décrit divers types de tumeurs cérébrales et leurs origines, soulignant l'importance de la détection et de la surveillance des images médicales, y compris l'IRM. L'imagerie par résonance magnétique est un outil clé, non invasif et très précis pour visualiser la structure du cerveau et positionner des anomalies. Il constitue la base importante de l'analyse automatisée des images. Le chapitre suivant se concentre sur les méthodes d'apprentissage en profondeur (deep learning) qui extraient automatiquement les informations utiles des IRM pour reconnaître et surmonter les tumeurs plus rapidement et plus fiable.

Chapitre 2

Apprentissage profond (Deep Learning)

2.1 Introduction

L'intelligence artificielle (IA) et l'apprentissage automatique, aussi appelé machine learning, constituent aujourd'hui des champs de recherche en pleine expansion, ayant profondément transformé de nombreux secteurs de notre quotidien. L'IA désigne l'ensemble des méthodes et technologies permettant à des machines d'accomplir des tâches qui, en temps normal, nécessitent des capacités cognitives humaines.

L'apprentissage automatique représente une sous-discipline de l'IA, centrée sur la création d'algorithmes et de modèles capables d'extraire des connaissances à partir de données et de perfectionner leurs performances à travers l'expérience accumulée. À l'intérieur de ce domaine, l'apprentissage profond (deep learning) regroupe un ensemble de techniques exploitant des réseaux de neurones artificiels afin d'analyser des données complexes et d'en dégager des représentations utiles.

Dans le domaine médical, l'apprentissage profond ouvre la voie à des avancées significatives, notamment dans les domaines du diagnostic, du suivi des patients et de l'innovation en recherche biomédicale.

Ainsi, ce chapitre s'ouvre par une présentation approfondie de l'apprentissage profond. Nous y introduirons brièvement la notion d'algorithme d'apprentissage, avant de détailler les principes, le fonctionnement, et l'importance du deep learning. Ensuite, nous aborderons les concepts clés de l'apprentissage profond, avec un focus particulier sur les réseaux de neurones convolutifs (CNN), en explorant leur architecture, leurs avantages ainsi que

leurs limitations.

2.2 Qu'est-ce que Apprentissage profond (Deep Learning)

L'apprentissage profond constitue une branche avancée de l'apprentissage automatique, axée sur la conception et l'entraînement de réseaux de neurones artificiels capables d'analyser de vastes ensembles de données pour en extraire des connaissances et prendre des décisions. Ces réseaux sont formés de multiples couches successives de neurones artificiels interconnectés, chacun jouant un rôle dans le traitement progressif de l'information. À mesure que les données traversent les différentes couches, le réseau en extrait des représentations de plus en plus abstraites et complexes, ce qui lui permet de modéliser efficacement des structures sous-jacentes dans les données.

Cette capacité hiérarchique d'apprentissage rend l'approche particulièrement performante dans des domaines tels que la reconnaissance d'images, la compréhension de la parole, le traitement du langage naturel ou encore les jeux stratégiques. Par ailleurs, le deep learning connaît une adoption croissante dans des applications de pointe, notamment dans les systèmes de conduite autonome et les outils d'aide au diagnostic médical.[\[30\]](#)

2.3 L'importance de l'apprentissage profond (Deep learning)

L'importance de l'apprentissage profond réside principalement dans sa capacité à extraire automatiquement des modèles complexes à partir de données, sans nécessiter une programmation explicite pour chaque tâche. Contrairement aux méthodes traditionnelles reposant sur l'ingénierie manuelle des caractéristiques, le deep learning permet aux machines d'apprendre directement à partir de données brutes en ajustant dynamiquement les poids et les biais des réseaux de neurones artificiels via des algorithmes spécialisés.

L'un des avantages majeurs de cette approche est l'automatisation de tâches complexes, souvent considérées comme réservées à l'intelligence humaine, telles que la reconnaissance d'objets, l'analyse de textes ou la prise de décision. Grâce à sa capacité à traiter d'énormes volumes de données hétérogènes et non structurées, le deep learning atteint des niveaux de précision supérieurs dans des domaines aussi variés que la santé, la cybersécurité, la logistique, le marketing ou encore la finance.

En outre, les réseaux de neurones profonds ont la faculté de s'adapter continuellement à




FIGURE 2.1 – Représentation que qu'est-ce que Deep learning

de nouvelles données, assurant ainsi une amélioration progressive de leurs performances. Cette capacité d'évolution rend l'apprentissage profond particulièrement adapté aux environnements dynamiques et en constante mutation.[31]

2.4 Plateformes d'apprentissages en profondeur

Les plateformes d'apprentissage profond désignent un ensemble d'outils logiciels conçus pour assister les développeurs et les spécialistes des données dans la conception, l'entraînement et le déploiement de modèles de deep learning. Ces environnements mettent à disposition des fonctionnalités avancées, souvent accessibles via des interfaces conviviales, permettant de manipuler efficacement des volumes massifs de données, de bâtir des modèles complexes et de concevoir des architectures neuronales sophistiquées.

Ces plateformes sont largement utilisées pour traiter une variété de problématiques, telles que la segmentation et la classification d'images, la reconnaissance d'objets, la génération automatique de texte, ou encore la traduction neuronale.

Parmi les solutions les plus populaires figurent TensorFlow, Keras, PyTorch, Caffe, Theano,

MXNet et Torch, chacune proposant un écosystème riche de bibliothèques, d'API et de modules facilitant le développement, l'entraînement et la mise en production de modèles d'apprentissage profond.[32]

2.5 Comment fonctionne deep learning

L'apprentissage profond repose sur l'utilisation de réseaux de neurones artificiels (ANN), des structures computationnelles inspirées du fonctionnement biologique des neurones humains. Ces réseaux sont capables d'accomplir diverses tâches d'apprentissage automatique telles que la classification, la reconnaissance de motifs, la prédiction, la segmentation, entre autres. Le processus débute par la définition d'une architecture composée de couches successives de neurones interconnectés. Chaque neurone agit comme une unité de traitement qui reçoit des entrées, applique une fonction d'activation non linéaire, et génère une sortie. Les couches d'un réseau de neurones se répartissent généralement en trois catégories[33] :

Couche d'entrée : elle constitue le point de départ du traitement en recevant les données brutes, souvent sous forme de vecteurs ou de matrices multidimensionnelles.

Couches cachées : ces couches intermédiaires réalisent des transformations progressives et abstraites des données, en extrayant les représentations pertinentes pour la tâche visée. Un réseau peut comporter une ou plusieurs couches cachées.

Couche de sortie : elle produit le résultat final du modèle, adapté au type de tâche à résoudre (classification, régression, segmentation, etc.), sous forme scalaire, vectorielle ou matricielle. L'entraînement du réseau consiste à ajuster les poids et les biais des connexions neuronales à partir d'un jeu de données d'apprentissage. Cette optimisation est réalisée de manière itérative à l'aide d'une technique appelée descente de gradient, dont l'objectif est de minimiser une fonction de coût mesurant l'écart entre les prédictions du réseau et les valeurs attendues. Une fois entraîné, le réseau peut être utilisé pour effectuer des inférences sur de nouvelles données, en appliquant les calculs appris durant l'entraînement. Les réseaux de neurones profonds sont aujourd'hui déployés dans un large éventail d'applications, allant de la reconnaissance d'images et de la parole, à la

traduction automatique, la prédiction de séries temporelles, la détection de fraudes, et la segmentation d'images médicales.[34]




FIGURE 2.2 – ANN architecture[35]

2.6 Les types de modèles utilisant des architectures d'apprentissages en profondeur

Les architectures de l'apprentissage profond désignent des structures de modèles capables d'apprendre des représentations hiérarchisées et abstraites à partir de données complexes. Ces architectures reposent principalement sur des réseaux de neurones profonds, également appelés deep neural networks (DNN), qui se distinguent par la profondeur de leurs couches successives et leur capacité à modéliser des relations non linéaires de grande complexité. Selon les besoins spécifiques de la tâche à résoudre, différentes variantes de réseaux neuronaux sont employées. Parmi les plus courantes figurent :

les réseaux de neurones profonds (DNN) pour les tâches générales de classification ou de régression.

les réseaux de neurones convolutifs (CNN) particulièrement efficaces pour l'analyse et la reconnaissance d'images.

les réseaux neuronaux récurrents (RNN) et les réseaux à mémoire longue à court terme (LSTM) conçus pour le traitement de données séquentielles telles que les séries temporelles ou le langage naturel.

Chacune de ces architectures est adaptée à un type spécifique de données ou de problématique, et leur usage combiné dans certaines applications permet d'atteindre des

performances de pointe, notamment dans la vision par ordinateur, le traitement automatique du langage naturel, ou encore l'analyse biomédicale.

La figure 2.3 illustre ces principales architectures et leur domaine d'application respectif.

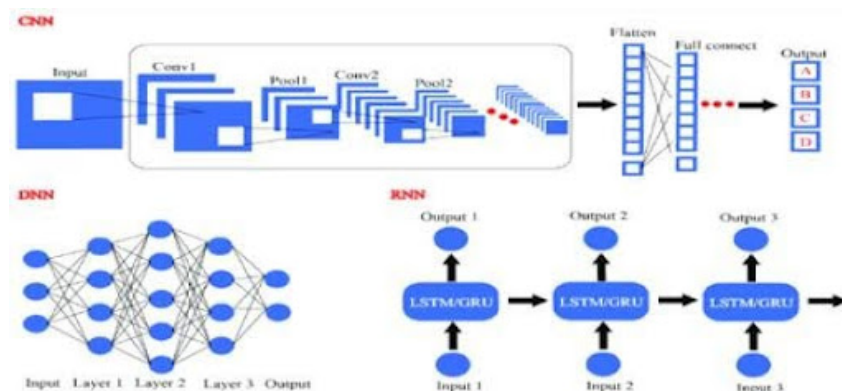


FIGURE 2.3 – Types de modèles utilisant des architectures d'apprentissages en profondeur[36]

2.6.1 Réseau de neurones profonds (DNN)

Les réseaux neuronaux profonds, appelés DNN (Deep Neural Networks), constituent une catégorie de réseaux artificiels composés de multiples couches de neurones interconnectés. Chaque couche traite les informations issues de la couche précédente avant de transmettre ses résultats à la suivante, jusqu'à ce que la dernière couche produise une sortie représentant une classification ou une prédiction.

La profondeur d'un DNN est déterminée par le nombre de couches cachées qui le composent. Grâce à cette structure, ces réseaux sont capables d'apprendre des représentations abstraites et sophistiquées des données d'entrée. L'apprentissage s'effectue via un mécanisme appelé rétropropagation, qui consiste à corriger les erreurs de sortie en ajustant progressivement les poids et biais dans le réseau, améliorant ainsi la performance globale. Les DNN sont largement appliqués dans divers domaines technologiques comme la vision par ordinateur, la reconnaissance de la parole, le traitement du langage naturel ainsi que dans la découverte de nouvelles molécules thérapeutiques.[37]

2.6.2 Réseau neuronal récurrent (RNN) et (LSTM)

Les réseaux neuronaux récurrents (RNN) ainsi que les réseaux à mémoire à long terme (LSTM) sont fréquemment utilisés pour l'analyse de données séquentielles telles




FIGURE 2.4 – Représentation construction du modèle de réseau neuronal profond -DNN[38]

que les textes ou les séries temporelles. Les RNN permettent une prise en compte des dépendances temporelles en intégrant des connexions récurrentes qui maintiennent une mémoire des états antérieurs, ce qui est idéal pour les tâches prédictives en série ou en langage. Néanmoins, leur efficacité à long terme est limitée par le phénomène de disparition du gradient, qui freine leur capacité à conserver des informations éloignées dans le temps.[39]

Pour pallier cette faiblesse, les LSTM intègrent des cellules spécialisées équipées de mécanismes appelés portes (entrée, sortie, oubli). Ces structures contrôlent le flux de l'information en sélectionnant les données pertinentes à mémoriser ou à écarter. Cette approche permet au réseau de conserver des séquences d'informations plus longues et de modéliser des structures temporelles complexes avec davantage de précision.[40]

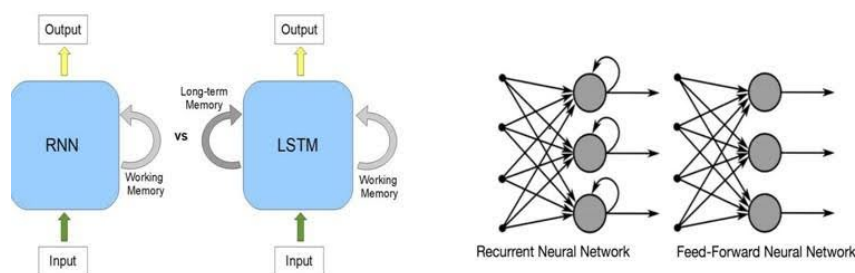


FIGURE 2.5 – Architecture de RNN pour l'ouverture d'un réseau[41]

2.6.3 Les réseaux adversaires génératifs (GAN)

Les réseaux adversaires génératifs, ou GAN, sont des modèles d'apprentissage reposant sur l'opposition de deux sous-réseaux : le générateur, qui produit des échantillons synthétiques à partir de bruit, et le discriminateur, qui tente de distinguer les échantillons

généérés des originaux. Grâce à ce jeu d’opposition, les deux réseaux s’améliorent mutuellement, ce qui permet au générateur de créer des données de plus en plus réalistes. Ces modèles sont utilisés dans la synthèse d’images, de sons, de vidéos, et dans la génération de données pour les simulations physiques.

2.6.4 Les réseaux de neurones convolutifs (CNN)

Les CNN constituent une classe de réseaux artificiels dédiée à l’analyse de données structurées en deux dimensions, comme les images. Leur objectif principal est d’extraire automatiquement des caractéristiques pertinentes à l’aide de filtres convolutifs qui scannent les régions locales d’une image. Ces caractéristiques sont ensuite compilées en cartes de représentations, servant à la classification ou à la segmentation. Les CNN ont démontré leur efficacité dans de nombreuses tâches visuelles telles que la reconnaissance d’objets, la segmentation sémantique ou encore l’estimation de profondeur.[42]

Dans le domaine médical, ces réseaux sont largement exploités pour détecter des anomalies dans les imageries médicales, comme les tumeurs, les lésions dermatologiques ou pour segmenter les organes sur les images IRM.[43]

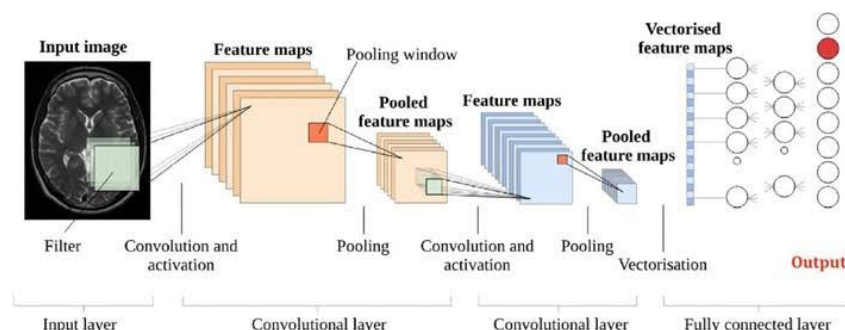


FIGURE 2.6 – Exemple d’un réseau de neurones convolutifs[44]

2.6.4.1 Les différentes couches de CNN

a) Couche de convolution :

La couche de convolution constitue une étape cruciale dans les réseaux de neurones convolutifs (CNN), car elle permet d’extraire automatiquement des caractéristiques locales à partir d’une image ou d’un volume de données. Cette opération se réalise à l’aide de filtres de convolution, aussi appelés noyaux, qui sont glissés sur les différentes régions de l’entrée. L’image d’entrée est généralement représentée sous forme de tenseur à trois di-

mensions comprenant la largeur, la hauteur et la profondeur (correspondant aux canaux de couleur).

Chaque filtre opère en balayant l'image selon une fenêtre fixe, réalisant à chaque position une multiplication élément par élément entre les valeurs de la région couverte et celles du filtre. Les produits obtenus sont ensuite sommés pour générer un seul pixel dans une nouvelle carte appelée feature map. Ce processus est répété pour tous les filtres, produisant ainsi plusieurs cartes de caractéristiques représentant diverses informations locales. Le rôle principal de cette couche est de détecter des motifs spécifiques comme des bords, des textures ou des formes simples. En outre, une fonction d'activation, souvent ReLU, est appliquée à la sortie de chaque neurone pour introduire une non-linéarité. Les valeurs négatives sont ainsi supprimées, ce qui permet au réseau d'apprendre des représentations plus complexes. Enfin, la sortie de cette couche est transmise à d'autres couches comme celle de pooling ou une nouvelle couche de convolution pour approfondir l'analyse.[45]

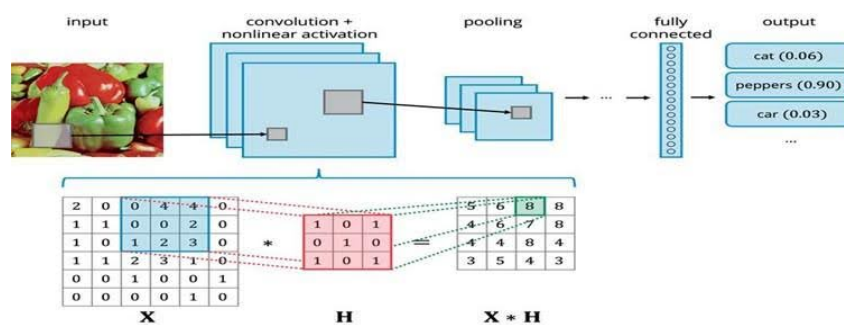


FIGURE 2.7 – Architecture couche de convolution[46]

b) Couche ReLU (Rectified Linear Unit) :

La couche ReLU, abréviation de Rectified Linear Unit, joue un rôle essentiel dans les réseaux de neurones convolutifs en introduisant une non-linéarité nécessaire au bon fonctionnement de l'apprentissage profond. Elle intervient immédiatement après les opérations de convolution et agit sur chaque pixel ou activation de la carte de caractéristiques générée par la couche précédente.

La fonction ReLU applique une transformation simple mais efficace définie mathématiquement par :

$f(x) = \max(0, x)$ Autrement dit, toute valeur négative est remplacée par zéro, tandis que les valeurs positives sont conservées telles quelles. Cette opération permet d'introduire

un mécanisme de seuillage qui favorise la propagation des activations significatives tout en supprimant le bruit potentiel contenu dans les valeurs négatives.

Ce filtrage non linéaire présente plusieurs avantages : il réduit la probabilité de saturation des neurones, phénomène où les gradients deviennent quasi nuls, ralentissant l'apprentissage. En supprimant les valeurs inutiles, ReLU accélère également la convergence du réseau en permettant un calcul plus efficace. Grâce à sa simplicité de mise en œuvre et à ses performances élevées, ReLU est devenue l'une des fonctions d'activation les plus utilisées dans les architectures CNN modernes.[47]




FIGURE 2.8 – Fonction d'activation ReLU[48]

c) La Couche d'union (Pooling)

La couche de pooling est une composante fondamentale dans les réseaux de neurones convolutifs, utilisée principalement pour réduire la dimension spatiale des cartes de caractéristiques générées par les couches de convolution. Cette réduction permet de limiter le nombre de paramètres du modèle, d'augmenter la robustesse aux variations mineures dans les données d'entrée, et d'accélérer le processus d'apprentissage.

Le fonctionnement de cette couche repose sur une opération de sous-échantillonnage : l'image ou la carte de caractéristiques est divisée en régions fixes, généralement carrées, sur lesquelles une fonction de regroupement est appliquée. Plusieurs méthodes de pooling existent, les plus couramment utilisées étant[49] :

- **Max pooling :** cette méthode extrait la valeur maximale de chaque région. Elle est très efficace pour mettre en évidence les caractéristiques les plus importantes d'une image, car elle conserve uniquement l'activation la plus forte.




FIGURE 2.9 – Max-pooling sur un canal 4*4 utilisant un noyau 2*2 et une foulée de 2[50]

- **Average pooling :** elle calcule la moyenne des valeurs dans chaque sous-région, ce qui permet de lisser l'image et de réduire l'impact des fluctuations locales.



FIGURE 2.10 – Moyenne pooling[51]

- **Sum pooling :** elle additionne toutes les valeurs de la région, ce qui est utile pour détecter des zones d'intensité globale élevée dans l'image.




FIGURE 2.11 – Sum pooling[52]

L'utilisation de la couche de pooling permet également de rendre le réseau moins sensible aux translations et aux déformations mineures dans l'image. Ainsi, elle contribue à une généralisation plus efficace du modèle tout en maintenant la cohérence des caractéristiques extraites.

d) La Couche entièrement connectée (FC) :

La couche entièrement connectée, connue sous le nom de Fully Connected Layer (FC), constitue une composante centrale dans les réseaux de neurones profonds, notamment dans les étapes finales des architectures CNN. Elle établit une connexion dense entre tous les neurones de la couche précédente et ceux de la couche actuelle, assurant ainsi une transmission complète de l'information.

Sur le plan fonctionnel, chaque neurone de cette couche reçoit l'ensemble des activations issues des couches antérieures souvent linéarisées sous forme d'un vecteur, sur lequel il applique une opération de transformation linéaire. Cette transformation prend la forme d'une multiplication matricielle entre les entrées et une matrice de poids, à laquelle s'ajoute un vecteur de biais. Le résultat est ensuite passé à travers une fonction d'activation non linéaire, telle que ReLU, afin de modéliser des relations complexes dans les données.

La couche FC joue un rôle crucial dans la prise de décision finale du réseau. Elle sert de pont entre les caractéristiques extraites par les couches précédentes (convolutives, pooling) et les sorties du modèle, généralement sous la forme de probabilités associées à différentes classes. En raison de sa forte capacité de représentation, cette couche est couramment utilisée dans les tâches de classification, de reconnaissance ou encore de régression dans les systèmes d'apprentissage profond.[53]




FIGURE 2.12 – La couche entièrement connectée[54]

2.7 Les avantages et les inconvénients de CNN

Les réseaux de neurones convolutifs (CNN) ont profondément transformé le domaine de la vision par ordinateur, en apportant des progrès considérables dans diverses applications telles que la classification d’images, la détection d’objets, ainsi que la segmentation d’images. Leur architecture permet d’analyser efficacement les données visuelles en capturant des motifs complexes, rendant leur utilisation incontournable dans de nombreux systèmes intelligents. Toutefois, malgré leurs performances remarquables, les CNN présentent également certaines limites qu’il convient de considérer.

Avantages des CNN :

- Les CNN offrent des performances très élevées dans les tâches d’analyse d’images. Des architectures avancées comme ResNet et VGG ont démontré leur efficacité sur des benchmarks standards et des cas d’usage réels[55].
- Ils permettent un traitement parallèle efficace : les opérations de convolution et de pooling sont hautement parallélisables sur des GPU, ce qui réduit considérablement les temps de calcul[55].
- Grâce à leur structure hiérarchique, les CNN peuvent apprendre des représentations à plusieurs niveaux de granularité, rendant possible la reconnaissance précise d’objets complexes dans des environnements variés[56].
- L’apprentissage des caractéristiques se fait automatiquement à partir des données d’entrée, ce qui évite la phase fastidieuse d’ingénierie manuelle des attributs.
- En utilisant des techniques de régularisation et d’optimisation, les CNN peuvent être entraînés efficacement même avec des ensembles de données réduits, tout en maintenant de bonnes performances[55].

Inconvénients des CNN :

- Les performances des CNN peuvent être fortement affectées par la qualité des images d'entrée. Des problèmes comme une faible résolution ou un mauvais éclairage peuvent nuire à l'extraction correcte des caractéristiques.
- Leur efficacité dépend d'un volume important de données bien annotées. Le processus de collecte et de nettoyage de ces données peut être long, coûteux et sujet à des erreurs.
- Enfin, dans certaines situations, les CNN manquent de capacité à exprimer des relations complexes ou abstraites entre les données, ce qui limite leur adaptabilité à des tâches très spécifiques. [56][57]

2.8 Conclusion

Ce chapitre a permis d'explorer en profondeur les fondements de l'apprentissage profond, en mettant l'accent sur les types de réseaux de neurones les plus utilisés. Le choix s'est porté sur les CNN en raison de leur efficacité prouvée dans les applications de traitement d'image. Nous avons étudié leurs composants, leur structure ainsi que leurs avantages et limites. Dans le prochain chapitre, un état de l'art sera présenté sur les techniques de segmentation des images IRM, avec un focus particulier sur les approches basées sur les CNN pour la détection des tumeurs cérébrales.

Chapitre 3

Etat de l'art sur les méthodes la segmentation et la Détection

3.1 Introduction

L'imagerie par résonance magnétique (IRM) est un instrument essentiel pour identifier et évaluer les tumeurs cérébrales. Les techniques de segmentation et de détection jouent un rôle clé dans l'amélioration de l'analyse de ces images. Cette segmentation permet à la région d'intérêt, en particulier la tumeur, d'être isolée et la détection localise automatiquement l'anomalie. Ces deux tâches sont souvent combinées pour améliorer la précision du diagnostic. Ce chapitre est appliqué aux images Brain-MRI et met en évidence les méthodes traditionnelles et les approches récentes basées sur l'apprentissage automatisé.

3.2 Détection

La détection d'image est un type de technique de vision par ordinateur qui consiste à identifier la présence ou l'absence d'un objet ou d'un événement spécifique dans un flux de données. Ce processus consiste généralement à utiliser des algorithmes d'apprentissage profond pour former un ordinateur à reconnaître certaines caractéristiques visuelles dans une image, comme la couleur, la forme, la texture et la taille, il existe plusieurs types de détection d'images en vision par ordinateur, dont voici quelques exemples :

Détection d'objet : c'est l'un des types de détection d'images les plus courants. Il consiste à identifier la présence d'un objet spécifique dans une image. Les algorithmes utilisés pour ce type de détection sont souvent basés sur des réseaux de neurones convolutifs (CNN) qui sont entraînés sur des ensembles de données contenant des exemples d'objets que le système doit détecter.

Détection de visage : comme son nom l'indique, la détection de visage est utilisée pour identifier les visages dans une image. Cette technique est souvent utilisée pour la reconnaissance faciale, la surveillance de la sécurité et d'autres applications similaires.

Détection de texte : la détection de texte est utilisée pour identifier la présence de texte dans une image. Les algorithmes utilisés pour ce type de détection sont souvent basés sur des réseaux de neurones récurrents (RNN) ou des réseaux de neurones transformer (TNN).

Détection de mouvement : ce type de détection est utilisé pour identifier les objets qui se déplacent dans une séquence d'images. Il est souvent utilisé dans les systèmes de surveillance vidéo pour détecter les intrus ou les objets suspects. Détection de contour : la détection de contour est utilisée pour identifier les contours des objets dans une image. Cette technique est souvent utilisée pour améliorer la qualité des images, pour détecter les bords des objets ou pour effectuer des mesures de surface et de forme. Ces différents types de détection d'images sont souvent utilisés en combinaison pour effectuer des tâches plus complexes en vision par ordinateur[58].

3.3 Segmentation d'images cérébrales

Dans cette partie, nous introduisons la finalité de la segmentation de l'image cérébrale dans le domaine médical et la difficulté de l'imagerie cérébrale. La segmentation d'images de tumeurs cérébrales à partir d'IRM est un domaine de recherche très actif dans le domaine médical et le traitement d'images. Les techniques d'imagerie médicale permettent d'extraire des informations sur les tissus cérébraux (substance grise, substance blanche, liquide céphalo-rachidien, etc.) et sur les éventuelles anomalies présentes. De nombreuses études du tissu cérébral dans les images IRM ont été réalisées et décrites dans la litté-

rature, y compris des méthodes basées sur les réseaux de neurones, la logique floue, les méthodes statistiques, les coupes de graphes et d'autres.




FIGURE 3.1 – La segmentation d'image de tumeur cérébrale

3.4 Les méthodes pour segmentation les tumeurs cérébrales

Nous présenterons plusieurs méthodes pour segmenter les tumeurs cérébrales à partir d'IRM, parmi lesquelles :

3.4.1 La segmentation Manuel

La segmentation manuelle permet d'utiliser des informations multimodales pour les radiologues. Cette procédure implique un radiologue qui a diagnostiqué la tumeur par plusieurs images coupées par des tranches et ont tiré manuellement la zone tumorale. En plus des tâches qui prennent du temps. Il est important de noter que cette méthode peut être affectée par différentes variations entre les observateurs, car différents utilisateurs peuvent segmenter la même image différemment. En conséquence, plusieurs segmentations manuelles sont utilisées pour améliorer la précision et pour diriger les milieux ou la segmentation mutuelle, le est souvent recommandé. La segmentation manuelle est souvent utilisée pour évaluer les résultats d'autres méthodes (méthode semi-automatique et entièrement automatique)[59].

3.4.2 La segmentation semi-automatique des IRM cérébrales

La segmentation semi-automatique du cerveau est une méthode de traitement des images et utilise la technologie de traitement d'images assistée par ordinateur pour distin-

guer la structure du cerveau dans les images IRM. Cette méthode combine l'intervention et l'automatisation humaines pour améliorer l'efficacité et la précision de la segmentation. Le processus de segmentation semi-automatique est suivi d'une initialisation manuelle de la segmentation, suivie de transactions qui ajustent et affinent la segmentation. Cette technique est utilisée fréquemment pour segmenter les structures cérébrales telles que le cerveau entier, le cortex cérébral, ventricule et le rapport.

3.4.3 Méthode de segmentation entièrement automatique

Une méthode de segmentation des tumeurs cérébrales entièrement automatisée qui ne nécessite aucune interaction de l'utilisateur. Les principaux sont artificiels combine l'intelligence avec les connaissances préalables pour résoudre les problèmes de segmentation. Elle est un domaine de recherche actif en imagerie médicale. Cette tâche consiste à identifier et à délimiter les régions tumorales sur des images CT ou IRM du cerveau sans intervention humaine[60].

3.5 Classification

La classification des pictures a un éventail d'applications, y compris la reconnaissance d'objets, la surveillance faciale, le démonstratif médical et l'observation. Il s'agit d'une tâche fondamentale en vision informatique et d'un domaine actif de recherche et de développement. En apprentissage profond, la classification des pictures est généralement effectuée à l'aide d'une engineering de réseau neuronal appelée réseau de neurones convolutionnels. Un CNN est conçu pour apprendre une hiérarchie de caractéristiques à partir des données d'image d'entrée en appliquant des filtres convolutionnels à l'image à chaque couche du réseau. Ces filtres détectent les thèmes et les caractéristiques de l'image, tels que les bords, les coins et les surfaces, transmettent ces informations aux couches suivantes pour un traitement ultérieur.

3.6 Travaux connexes

De nombreux chercheurs ont réalisé des avancées significatives dans le domaine de la détection et de la segmentation des tumeurs cérébrales à partir d'images IRM, grâce

à des techniques avancées d'apprentissage profond. Ces approches ont grandement amélioré la précision des diagnostics et accéléré l'interprétation des images médicales. Les réseaux de neurones profonds parviennent en effet à extraire automatiquement les caractéristiques distinctives des tumeurs depuis un vaste ensemble d'images, diminuant ainsi la dépendance vis-à-vis de l'expertise humaine et réduisant les erreurs potentielles. Certains chercheurs ont proposé des méthodes innovantes, combinant diverses techniques telles que les hypercolonnes, les modules d'attention, les blocs résiduels, ainsi que les architectures CNN classiques et hybrides. D'autres études se sont concentrées sur des architectures plus robustes comme ResUNet, nnU-Net ou InceptionV3 pour détecter ou segmenter les tumeurs cérébrales avec une grande précision.

Dans le tableau suivant, nous présentons un résumé des contributions principales issues de travaux récents, en mettant en avant les méthodes employées, les bases de données utilisées, les tâches effectuées (classification, détection, segmentation), et les performances atteintes. Ce tableau situe notre approche proposée dans un contexte comparatif avec l'état actuel de la recherche. Que les hypercolonnes, les modules d'attention, les blocs résiduels, ainsi que les architectures CNN classiques et hybrides...

Auteur(s)	Méthode	Jeu de données	Performance / Tâche
Micah J. Sheller et al. (2019)[61]	Segmentation sémantique	BRATS 2018	Dice = 85.2% (similaire à 86.2%)
Mahnoor Ali et al. (2020)[62]	3D CNN + U-Net	BRATS 2019	Dice = 75%, 90.6%, 84.6%
B. Kokila et al. (2021)[63]	U-Net + ResNet	Kaggle (3064 images)	Accuracy = 92%
Amran Hossain et al. (2021)[64]	YOLOv3 (DCNN)	BRATS (1000 images)	Accuracy = 95.62%
Tingting Liu et al.[65]	CNN simple	BRATS	Accuracy = 94.77%
Sarang Sharma et al. (2021)[66]	VGG19	Kaggle	Accuracy = 98%
Muhammad A. Aish et al.[67]	ResNet-50 + U-Net	TCGA-LGG (TCIA)	Dice = 0.95

Li P. et al. (2023)[68]	mResU-Net	BRATS 2021	Dice = 92.89%
Kavitha V. et al. (2023)[69]	Inception V3	IRM	Accuracy = 89%

TABLE 3.1 – Travaux connexes sur la tumeur au cerveau.

3.7 Diffultés liées à la segmentation des images cérébrales

En raison d'une multitude de contraintes technologiques et biologiques, la segmentation des images cérébrales, en particulier pour la détection des tumeurs, est un défi difficile.

Le mauvais contraste entre certains tissus cérébraux (matière blanche, matière grise, LCR) représente un défi important, car il rend la distinction de structures anatomiques peu fiable. De plus, les images IRM sont souvent affectées par divers bruits et artefacts qui dégradent leur fiabilité et compliquent la détection précise des régions préoccupantes. Les tumeurs sont particulièrement complexes en termes d'apparence, de forme et de texture, ajoutant à la complexité, qui nécessite des stratégies adaptatives qui peuvent être utilisées pour traiter ces différentes conditions. Un autre sujet est les inégalités des données : les tumeurs occupent généralement une petite partie de l'image, mais les algorithmes peuvent sous-estimer ces domaines pendant l'apprentissage. Enfin, les annotations manuelles, qui sont souvent compliquées et difficiles à interpréter, ainsi que le coût de calcul élevé des algorithmes modernes, contribuent tous à limiter l'applicabilité clinique de ces méthodes avancées. Selon Pham et al. (2000), ces causes combinées expliquent pourquoi les images médicales, en particulier les tumeurs cérébrales, restent un problème non résolu dans l'imagerie biomédicale[70].

3.8 Conclusion

Dans ce chapitre, nous avons exploré les principales méthodes utilisées pour la détection, la classification et la segmentation des tumeurs cérébrales à partir d'images IRM. L'accent a été mis sur l'apport des techniques d'apprentissage profond dans ce domaine. En analysant différentes approches proposées dans la littérature, nous avons pu identifier les modèles les plus efficaces tels que Inception V3 pour la classification binaire et ResU-

Net pour la segmentation. Cette analyse nous a permis de mieux orienter notre propre méthodologie.

Chapitre 4

Contribution et résultats

4.1 Introduction

Les tumeurs cérébrales représentent un défi clinique important en raison de leur complexité morphologique et de la variabilité des images IRM. La détection précoce et la segmentation précise de ces tumeurs sont essentielles pour un diagnostic fiable et une prise en charge efficace. Dans ce contexte, les méthodes de deep learning, et notamment les réseaux de neurones convolutifs (CNN), se sont imposées comme des solutions prometteuses.

Dans ce chapitre, nous présentons notre contribution à travers le développement d'une application basée sur deux modèles complémentaires : un modèle de classification binaire pour détecter la présence ou non d'une tumeur à partir d'une image IRM, et un modèle de segmentation pour localiser précisément la région tumorale si elle est détectée. Nous avons opté pour l'architecture Inception v3 pour la classification, et Res-UNet pour la segmentation, en raison de leur efficacité reconnue dans le traitement des données médicales.

4.2 Approche proposée

Dans notre approche, nous avons proposé un système basé sur l'apprentissage profond pour détecter et localiser automatiquement les tumeurs cérébrales à partir des images IRM. Le processus commence par une classification binaire à l'aide du modèle Inception

V3 afin de prédire si une image IRM contient une tumeur ou non. Si la présence d'une tumeur est détectée, une deuxième étape est lancée : la segmentation de la tumeur à l'aide du modèle Res-UNet, qui permet d'identifier précisément la zone atteinte.

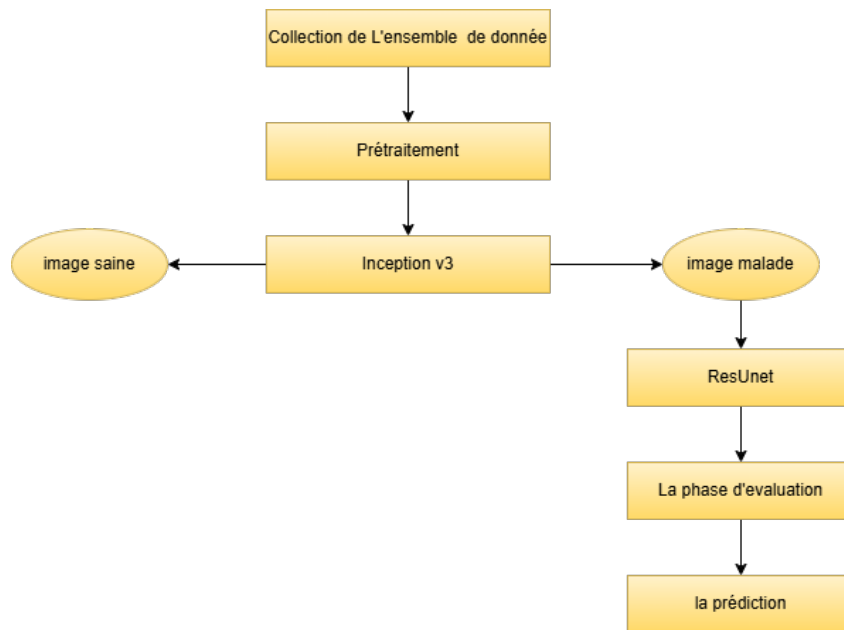


FIGURE 4.1 – Architecture de méthode proposée.

4.2.1 Collection de l'ensemble de données

La base de données de segmentation IRM cérébrale sur Kaggle fournit un ensemble de données étiqueté avec des images IRM cérébrales prétraitées et des masques de segmentation correspondants, permettant aux chercheurs et aux praticiens de développer et d'évaluer des méthodes de segmentation précise des images. Cet ensemble de données contient des images IRM cérébrales avec des masques manuels de segmentation anormale. Image du cancer Archives d'images (TCIA). Ils correspondent aux 110 patients collectés Gliomes de bas grade du Cancer Genome Atlas (TCGA) avec au moins une séquence Récupération par inversion atténuée par fluide (FLAIR) et données de clustering La génomique est disponible. L'image suivante montre quelques tranches d'image utilisant des masques. Segmentation correspondante[71].

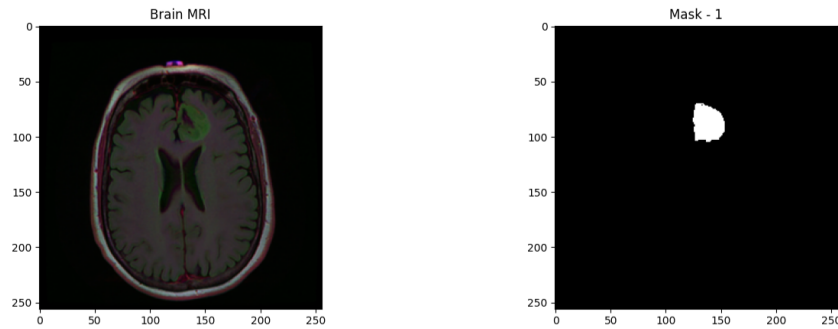


FIGURE 4.2 – tranche d’image avec leur masque de segmentation correspondante.

4.2.2 Préparation des données

La préparation des données est une étape cruciale dans tout projet d’apprentissage en profondeur, en particulier dans le domaine médical, où la qualité des données affecte directement les performances du modèle. Dans notre cas, les données d’IRM cérébrale ont été traitées avec un soin particulier afin de garantir une base solide pour les étapes de classification et de segmentation.

1. Création de la structure de donnée

Nous organisons d’abord les images IRM et leurs masques de segmentation correspondants. Chaque image IRM (fichier .png) est associée à un masque binaire (également .png) représentant la région tumorale. Cette correspondance est effectuée en lisant les noms de fichiers et en les faisant correspondre à l’aide d’une liste `sorted()`, garantissant un alignement parfait entre chaque image et son masque.

```
image_list = sorted([os.path.join(image_dir, f) for f in os.listdir(image_dir)])  
mask_list = sorted([os.path.join(mask_dir, f) for f in os.listdir(mask_dir)])
```

2. Exploration et visualisation des données

Une étape d’exploration visuelle a été menée pour vérifier la cohérence des données. Des exemples d’images et leurs masques correspondants sont affichés pour garantir que la région tumorale est bien annotée. Cela permet également d’identifier d’éventuelles anomalies ou erreurs d’étiquetage.

3. Prétraitement d’image

Selon le type de modèle utilisé, le prétraitement diffère :

Pour le modèle de classification (Inception V3) :

Redimensionner à 256x256.

Normaliser les pixels en divisant par 255 pour obtenir des valeurs comprises entre 0 et 1. Si nécessaire, convertissez les images au format RVB (certaines images peuvent être en niveaux de gris).

Pour le modèle de segmentation (Res-UNet) :

Également redimensionné à 256x256.

Normalisation : Soustrayez la moyenne et divisez par l'écart type de l'image pour centrer et normaliser les données (score z).

Cela permet au modèle de converger plus rapidement et de mieux gérer les variations d'intensité dans les images IRM.

4 Division des ensembles de données

Pour garantir une évaluation objective du modèle, les données ont été divisées en trois sous-ensembles :

Ensemble d'entraînement (train) : utilisé pour entraîner les poids du modèle.

Ensemble de validation (optionnel) : permet de surveiller la performance pendant l'entraînement. Ensemble de tests : réservé à l'évaluation finale. Cette division a été réalisée à l'aide de la fonction train test split avec un ratio de test de 20

4.2.3 Construction de modèle Proposée

Dans le cadre de notre travail, nous avons conçu une architecture basée sur deux modèles complémentaires d'apprentissage profond, dans le but d'assurer à la fois la détection et la segmentation des tumeurs cérébrales à partir d'images IRM.

4.2.3.1 Modèle de classification binaire Inception V3

L'architecture du modèle Inception V3, introduite par Christian Szegedy et ses collaborateurs en 2016, représente une avancée notable dans le domaine des réseaux neuronaux convolutifs (CNN). Il appartient à la lignée des modèles GoogLeNet et a été élaboré pour améliorer l'efficacité des tâches de classification d'images tout en diminuant la complexité computationnelle.

Le concept principal de Inception V3 se fonde sur l'emploi de modules Inception, qui fusionnent diverses convolutions de différentes dimensions (1×1 , 3×3 , 5×5) en plus des

couches de réduction de dimensionnalité. Cette combinaison facilite la capture de caractéristiques à multiples échelles tout en conservant une profondeur du réseau maîtrisée. Inception V3 fait également appel à des méthodes telles que la factorisation des convolutions, la normalisation par lot et l'emploi de couches auxiliaires pour améliorer la rapidité de l'apprentissage. Ce modèle est pré-entraîné sur ImageNet, et peut être adapté à des tâches de classification spécifiques, comme dans notre cas la classification binaire des IRM cérébrales (présence ou absence de tumeur).

a) Rôle du modèle dans notre travail

Pour notre projet de mémoire, nous avons employé le modèle Inception V3 afin d'exécuter une classification binaire des images IRM du cerveau. En d'autres termes, il s'agit de décider automatiquement si une image présente la présence d'une tumeur. Ce modèle pré-entraîné a été ajusté à notre problème spécifique en intégrant une couche dense finale avec une activation sigmoïde, ce qui donne la capacité de générer une probabilité entre 0 et 1 pour déterminer si l'image est « saine » ou « atteinte ». C'est le premier élément de notre système, qui facilite une prise de décision initiale avant d'aborder la segmentation. Le choix de Inception V3 est motivé par sa compétence à dégager des attributs complexes à divers stades, ce qui renforce la crédibilité de la détection malgré un nombre restreint d'images. Par ailleurs, son efficacité dans la classification des images médicales a été prouvée dans plusieurs recherches récentes.

b) Les principales étapes de son fonctionnement

1. Couche d'entrée (Input Layer)

L'image IRM est ajustée à une dimension standard de 256×256 pixels, transformée en RGB si besoin, puis normalisée (valeurs des pixels allant de 0 à 1). Cette phase garantit une introduction uniforme dans le réseau, indépendamment de l'image initiale.

2. Étape de traitement initial (Stem Block)

C'est un ensemble de couches convolutives et de pooling (réductions spatiales) qui permet d'éliminer les détails non pertinents et de compresser les données tout en préservant les informations cruciales. Cette phase établit les bases pour l'extraction de caractéristiques plus sophistiquées.

3. Blocs Inception (Inception Blocks)

Le cœur du modèle est composé de plusieurs blocs Inception (généralement 5 à 10), chacun combinant plusieurs types de convolutions (1×1 , 3×3 , 5×5) exécutées en parallèle. Chaque bloc traite l'image avec différentes tailles de filtres, ce qui permet au réseau de capturer à la fois les détails fins et les structures globales. Les sorties sont ensuite concaténées (fusionnées) sur le plan de profondeur.

4. Pooling global (Global Average Pooling)

Plutôt que d'utiliser une couche Dense avec flatten, cette couche réduit chaque carte de caractéristiques à une seule valeur moyenne. Cela permet de réduire le nombre de paramètres, limiter le overfitting, et accélérer l'apprentissage.

5. Couche entièrement connectée (Fully Connected Layer)

Suite au processus de regroupement, les caractéristiques globales sont transmises à une couche dense contenant une ou deux unités en sortie. Dans notre contexte, nous utilisons une fonction d'activation sigmoïde pour générer une probabilité variant entre 0 et 1, symbolisant la présence ou l'absence d'une tumeur.

6. Sortie (Output Layer)

Le modèle donne en sortie une prédiction binaire :

0 : pas de tumeur détectée.

1 : tumeur détectée.

Si la probabilité dépasse un seuil (généralement 0.5), l'image est classée comme contenant une tumeur.

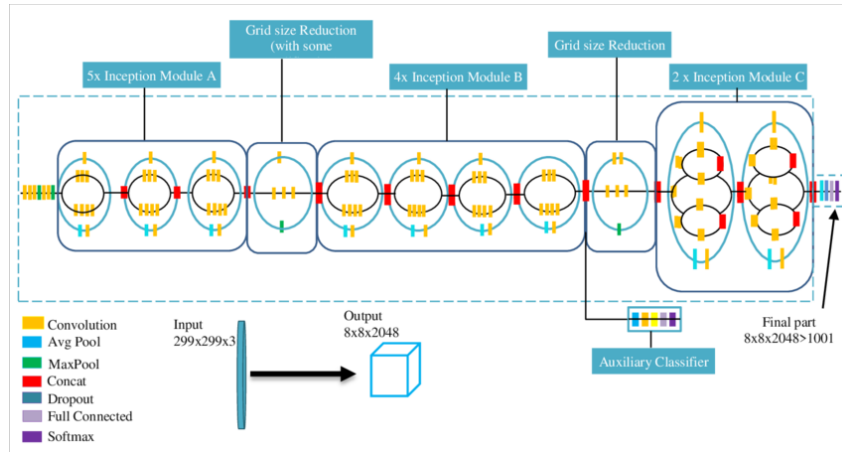


FIGURE 4.3 – Structure du modèle Inception V3.

On utilise Inception V3 dans la première étape, afin d'identifier la présence d'une tumeur sur l'image IRM. Si une détection positive est effectuée, l'image est ensuite envoyée au modèle Res-UNet pour le processus de segmentation (détermination précise de l'emplacement de la tumeur). Cette méthode aide à diminuer le temps de traitement en évitant la segmentation d'images ne présentant aucune anomalie.

4.2.3.2 Modèle de Segmentation ResUnet

Res-UNet est un modèle de réseau de neurones convolutif (CNN) spécifiquement élaboré pour la segmentation d'images médicales. Il fusionne l'architecture traditionnelle du U-Net, couramment employée dans l'imagerie biomédicale, avec les blocs résiduels du ResNet. Grâce à cette fusion, le modèle peut perfectionner l'apprentissage des caractéristiques complexes tout en assurant une stabilité optimale durant la formation. Res-UNet, grâce à ses liaisons résiduelles, favorise la transmission d'informations entre les différentes couches, ce qui renforce la précision de la segmentation, en particulier pour l'identification des tumeurs cérébrales sur les IRM. Il est particulièrement performant pour identifier des structures de petite taille ou dispersées dans les images.

a) Les couches du modèle Res-UNet

L'architecture Res-UNet est une version améliorée du célèbre réseau U-Net, intégrant des blocs résiduels inspirés de ResNet afin d'améliorer l'apprentissage des caractéristiques profondes tout en évitant la dégradation des performances dans les couches profondes. Elle se compose de plusieurs étapes structurées autour de trois parties principales : l'encodeur,

le goulot (bottleneck) et le décodeur.

1. Couche d'entrée

Le modèle débute avec une couche d'entrée qui prend en charge une image IRM normalisée, généralement de dimensions 256×256 . Une première convolution est appliquée à cette image pour ajuster ses dimensions au réseau.

2. Bloc d'encodage (chemin descendant)

La tâche de l'encodage est de dégager graduellement des caractéristiques de plus en plus abstraites. Elle se compose de plusieurs segments, chacun contenant :

- Deux convolutions 2D consécutives utilisant un noyau 3×3 , qui permettent de saisir les détails à l'échelle locale.
- L'application d'une normalisation par lot (Batch Normalisation) suite à chaque convolution afin de stabiliser le processus d'apprentissage.
- Une fonction d'activation ReLU est utilisée pour introduire la non-linéarité.
- Un lien résiduel (skip interne) : l'entrée du bloc est directement reliée à la sortie, favorisant ainsi le passage de l'information dans le réseau.
- Une procédure de sous-échantillonnage (Max Pooling) est effectuée pour abaisser la résolution spatiale de l'image et élargir le champ de vision du modèle.

3. Couche de transition (bottleneck)

Située entre l'encodeur et le décodeur, cette couche représente le cœur du réseau. Elle comprend un bloc résiduel similaire à ceux de l'encodeur mais sans opération de réduction. Elle permet de synthétiser les représentations les plus complexes et denses de l'image d'entrée.

4. Bloc de décodage (chemin ascendant)

Le décodeur vise à reconstruire la carte de segmentation finale en utilisant les caractéristiques extraites précédemment. Chaque étape du décodeur contient :

- Une opération de upsampling (souvent une convolution transposée) pour doubler la taille spatiale.
- Une concaténation avec les cartes de caractéristiques issues de l'encodeur (skip connections) afin de restaurer les détails perdus lors du downsampling.

- Deux convolutions 3×3 , suivies de Batch Normalisation et ReLU, formant un bloc résiduel qui affine les caractéristiques.

5. Couche de sortie Pour produire la carte de probabilité de segmentation, une convolution 1×1 est appliquée en phase finale. On utilise une fonction d'activation sigmoïde pour la segmentation binaire (tumeur / non tumeur), ou softmax pour des scénarios impliquant plusieurs classes.

Dans le contexte de notre projet, nous avons employé le modèle ResUNet pour effectuer une segmentation précise des tumeurs cérébrales à partir d'images IRM. ResUNet, en associant les caractéristiques contextuelles approfondies (grâce à l'encodeur) aux détails précis de l'image (par le biais des connexions latérales), offre une délimitation précise et détaillée des zones tumorales. Son architecture résiduelle facilite aussi un apprentissage plus stable, en particulier sur de petits ensembles de données médicales. Ainsi, ce modèle se présente comme un instrument efficace pour assister les cliniciens dans l'évaluation automatique des IRM et renforcer la crédibilité des diagnostics.

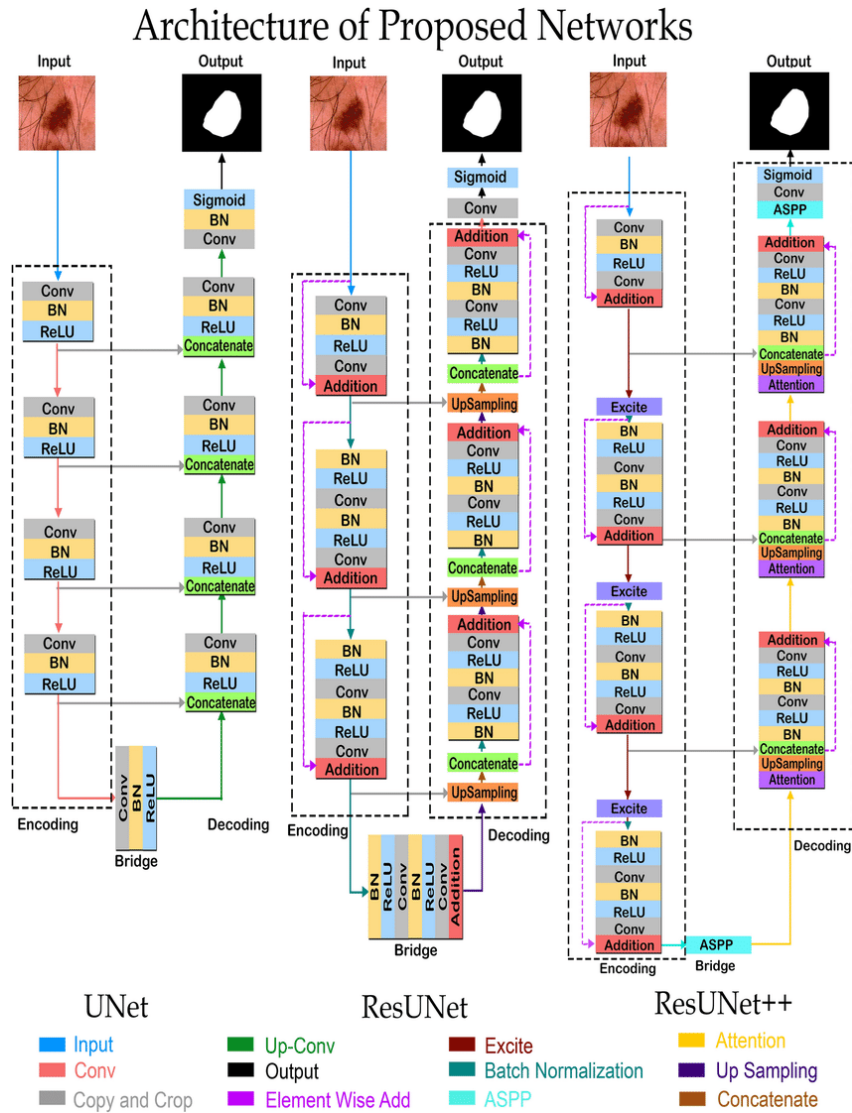


FIGURE 4.4 – Architecture du modèle ResUNet .

4.3 Environnement de développement de système

Dans cette section, nous présentons les outils (matériel et logiciel) que nous avons utilisés dans notre travail :

4.3.1 Environnement logiciel

- **kaggle** : une filiale de Google, est une communauté en ligne regroupant des data scientists et des praticiens de l'apprentissage automatique. Il offre un environnement basé sur le Web pour la recherche, la publication et l'exploration de données, ainsi que la création de modèles. Kaggle permet également la collaboration, la participation à des concours de science des données et propose Kaggle Kernels, un atelier cloud pour le

Layer (type)	Output Shape	Param #	Connected to
input_layer_5 (InputLayer)	(None, 256, 256, 3)	0	-
conv2d_188 (Conv2D)	(None, 256, 256, 16)	448	input_layer_5[0][0]
batch_normalization_188 (BatchNormalization)	(None, 256, 256, 16)	64	conv2d_188[0][0]
conv2d_189 (Conv2D)	(None, 256, 256, 16)	2,320	batch_normalization_1...
batch_normalization_189 (BatchNormalization)	(None, 256, 256, 16)	64	conv2d_189[0][0]
max_pooling2d_8 (MaxPooling2D)	(None, 128, 128, 16)	0	batch_normalization_1...
conv2d_190 (Conv2D)	(None, 128, 128, 32)	544	max_pooling2d_8[0][0]
batch_normalization_190 (BatchNormalization)	(None, 128, 128, 32)	128	conv2d_190[0][0]
activation_188 (Activation)	(None, 128, 128, 32)	0	batch_normalization_1...

FIGURE 4.5 – Paramètres de couche et d’étape de modèle proposés.

partage de code et d’analyses en Python.

- **Python :** Python : est un langage polyvalent et largement utilisé pour sa compatibilité avec diverses plateformes et systèmes. Sa vaste bibliothèque et sa communauté active offrent de nombreuses fonctionnalités, frameworks et outils open-source qui améliorent la productivité des développeurs. Python est populaire en apprentissage automatique, big data et science des données. Dans notre travail, nous avons utilisé spécifiquement Python 3.10.

- **Latex :** Un système de composition de haute qualité. Il contient des fonctionnalités conçues pour cette rédaction de documents techniques et scientifiques. Latex est le facteur par défaut pour la communication et la publication de documents scientifiques. est disponible comme logiciel gratuit.

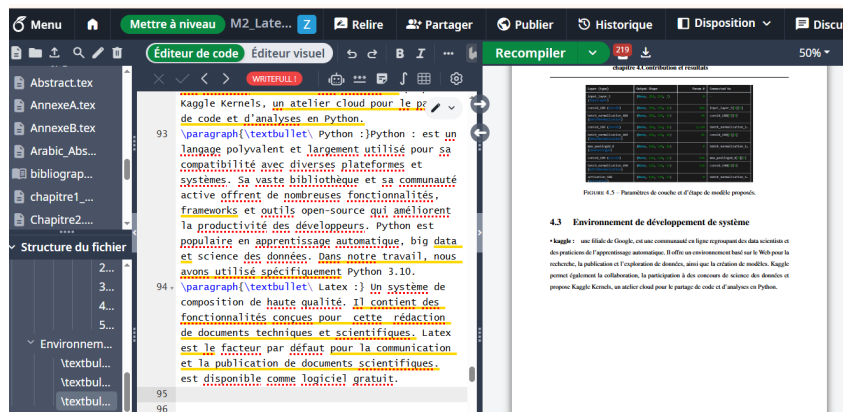


FIGURE 4.6 – L’interface de latex.

• **Kaggle Notebooks** : est un environnement de programmation en ligne proposé par la plateforme Kaggle. Il permet d'écrire et d'exécuter du code Python ou R directement dans un navigateur, sans installation locale. Cet outil facilite le travail avec des données et le développement de modèles d'apprentissage automatique, en offrant un accès facile aux ressources matérielles comme les GPU. Il est particulièrement utile pour tester et entraîner des modèles sur des bases de données publiques, comme celles utilisées dans la détection et la segmentation des tumeurs cérébrales.

• **Tensor Flow** : Tensor Flow est une plate-forme open source de bout en bout. Apprentissage automatique, il dispose d'un écosystème riche et flexible d'outils, de bibliothèques et de ressources communautaires qui permettent aux chercheurs de faire avancer le statu quo.

• **Keras** : Keras est une bibliothèque open source populaire écrite en python qui fournit une interface facile à utiliser pour créer, former et déployer des réseaux de neurones. Il est conçu pour être simple et facile à utiliser tout en étant capable de gérer des tâches complexes d'apprentissage automatique. L'objectif principal de Keras est de fournir une interface de haut niveau pour la création et la formation de modèles d'apprentissage automatique, en masquant des détails techniques complexes et en fournissant une abstraction intuitive des concepts clés. Il permet aux utilisateurs d'empiler simplement des couches pour définir une architecture de réseau de neurones, configurer des hyperparamètres de formation, compiler un modèle avec des fonctions de perte et d'optimisation et démarrer le processus de formation avec des données. "Encadrement".

• **Numpy** : est une bibliothèque Python open source populaire. Numpy est largement utilisé dans la science et l'analyse de données en raison de ses hautes performances et de sa facilité d'utilisation. Il fournit des structures de données efficaces pour stocker et manipuler de grandes quantités de données, permettant d'effectuer rapidement et efficacement des opérations mathématiques et statistiques.

• **Pandas** : créé par wes mckinney en 2008. Une bibliothèque écrite en python utilisée pour l'analyse de données.

- **Streamlit** : est une bibliothèque Python open-source qui facilite la création et le partage d'applications Web personnalisées pour le machine learning et la science des données. En utilisant Streamlit , vous pouvez rapidement créer et déployer des applications de données puissantes.
- **OpenCV** : (Open Computer Vision) est une bibliothèque graphique. Elle est spécialisée dans le traitement d'images, que ce soit pour de la photo ou de la vidéo.
- **Pillow** : est une bibliothèque de traitement d'image, qui est un fork et successeur du projet PIL (Python Imaging Library). Elle est conçue de manière à offrir un accès rapide aux données contenues dans une image, et offre un support pour différents formats de fichiers tels que PPM, PNG, JPEG, GIF, TIFF et BMP.

4.3.2 Environnement matériel

Composant matériel	Configuration
Ordinateur	Toshiba (portable)
Processeur central (CPU)	Intel Core i5-8250U @ 1.60GHz (up to 3.40GHz)
Mémoire (RAM)	8 Go DDR4
Système d'exploitation	Windows 10 / Ubuntu 20.04 LTS (dual boot si applicable)
Unité de traitement graphique (GPU)	Intel UHD Graphics 620 (intégrée)
Stockage principal	Disque SSD 256 Go

TABLE 4.1 – Configuration matérielle utilisée pour l'entraînement et l'évaluation des modèles

4.4 La phase d'évaluation, résultats et discussion

L'évaluation joue un rôle essentiel dans la vérification de l'efficacité des modèles d'apprentissage profond suggérés. Nous avons examiné deux modèles distincts : Inception V3 pour la classification binaire (tumeur ou pas tumeur), et Res-UNet pour la segmentation des tumeurs du cerveau sur les images IRM. Les résultats sont exposés en termes de métriques, de matrices de confusion et de courbes d'apprentissage, offrant une évaluation exhaustive de chaque modèle.

4.4.1 Évaluation du modèle Inception-V3 (Classification binaire)

Ce modèle a été utilisé pour prédire si une image IRM contient une tumeur ou non. Les prédictions sont comparées aux vérités de terrain (labels) pour établir la qualité du modèle.

	Prédit : Non Tumeur	Prédit : Tumeur
Réel : Non Tumeur	350 (TN)	38 (FP)
Réel : Tumeur	7 (FN)	190 (TP)




FIGURE 4.7 – Matrice de confusion du modèle inception v3

- **TP** : Prédiction correcte d'une image tumorale.
- **TN** : Prédiction correcte d'une image saine.
- **FP** : Image saine classée incorrectement comme tumorale.
- **FN** : Tumeur non détectée par le modèle.

Métriques calculées :

$$\text{Accuracy} = (TP + TN) / \text{Total} = (190 + 350) / 585 = 92.73\%$$

$$\text{Precision} = TP / (TP + FP) = 190 / (190 + 38) = 83.3\%$$

$$\text{Recall (Sensibilité)} = TP / (TP + FN) = 190 / (190 + 7) = 96.4\%$$

$$\text{F1-score} = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall}) \approx 89.3\%$$

Analyse des courbes d'apprentissage :

Cette figure illustre l'évolution de la fonction de perte (*Loss*) et de la précision (*Accuracy*)

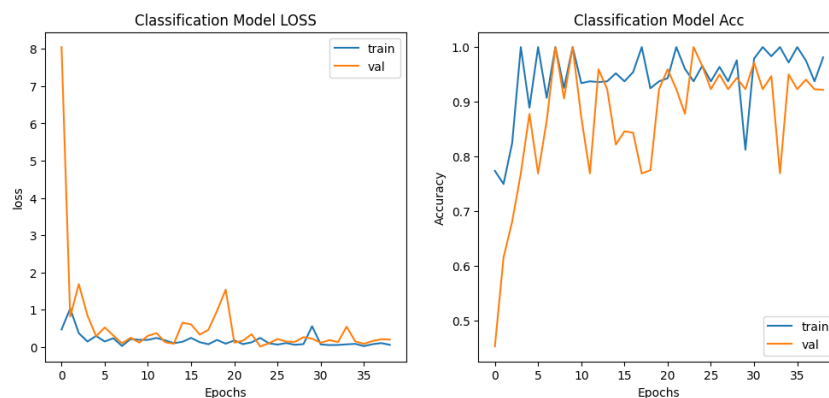


FIGURE 4.8 – Les courbes de perte(Loss) et précision (Accuracy) de modèle Inception V3

du modèle **Inception V3** au cours de l'entraînement, réalisé sur un total de **38 époques**.

Le graphique de gauche montre une diminution rapide de la perte pour les ensembles d'apprentissage (*train*) et de validation (*val*), atteignant des valeurs proches de zéro dès les premières époques. Cela indique un bon apprentissage du modèle. La courbe corres-

pendant à la validation présente quelques fluctuations, mais reste globalement stable, ce qui suggère l'absence de surapprentissage notable.

Quant au graphique de droite, il illustre l'évolution de la précision. Celle-ci augmente progressivement au fil de l'entraînement. La précision sur les données d'apprentissage dépasse **97 %**, tandis que celle sur les données de validation se stabilise autour de **93 %**. Ces résultats témoignent de la capacité du modèle à généraliser correctement sur des images non vues.

Dans l'ensemble, le modèle **Inception V3** démontre une excellente performance pour la classification binaire des images IRM, distinguant efficacement la présence ou l'absence de tumeur.

4.4.2 Évaluation du modèle ResUNet (Segmentation)

Ce modèle sert à **identifier précisément l'emplacement de la tumeur** dans les images par IRM. Il prédit un **masque binaire** qui est comparé au **masque de vérité terrain**.

Métriques utilisées :

- **Dice Coefficient :**

$$\text{Dice} = \frac{2 \times (A \cap B)}{|A| + |B|} \quad \text{Résultat obtenu : } \mathbf{0,85} \text{ (moyenne)}$$

- **Intersection over Union (IoU) :**

$$\text{IoU} = \frac{A \cap B}{A \cup B} \quad \text{Résultat obtenu : } \sim \mathbf{0,78} \text{ (moyenne)}$$

Ces deux métriques montrent que le **masque généré par le modèle se superpose de façon satisfaisante** au masque réel.




FIGURE 4.9 – Exemple d'image IRM et son masque segmenté par ResUNet




FIGURE 4.10 – Les courbes de perte(Loss) et précision Dice score de modèle Res UNet

Analyse des courbes Res UNet : Sur la courbe de gauche, on observe une diminution continue de la Loss sur l'ensemble d'entraînement, passant de valeurs initiales élevées à des niveaux très bas à la fin de l'entraînement. La courbe de validation suit une tendance similaire avec une stabilité relative, ce qui reflète une bonne capacité de généralisation du modèle. La courbe de droite affiche l'évolution du Dice Coefficient, une métrique clé pour évaluer la qualité de segmentation. On remarque une augmentation progressive de cette métrique jusqu'à atteindre une valeur moyenne d'environ 0.85 sur l'ensemble de validation. Cela indique que le modèle parvient à bien recouvrir les zones tumorales avec les masques prédits. Ces résultats confirment que ResUNet est un modèle efficace pour la segmentation précise des tumeurs cérébrales, en assurant une bonne séparation entre les zones saines et les régions pathologiques.

4.4.3 Comparaison avec des méthodes existantes

Dans le cadre de cette étude, nous avons également comparé notre approche basée sur Inception V3 (classification binaire) et ResUNet (segmentation) avec plusieurs travaux récents présents dans la littérature, en termes de précision, complexité, et efficacité sur les images IRM.

Le tableau ci-dessous résume quelques études clés :

Auteurs	Méthode utilisée	Base de données	Métriques rapportées
Togaçar et al. (2020)	Hypercolumn + Attention + CNN	Kaggle (253 IRM)	Accuracy : 96.05%
Özyurt et al. (2019)	Neutrosophic CNN (NS-CNN)	TCGA-GBM (TCIA)	Accuracy : 95.62%
Notre étude	Inception V3 + ResUNet	Kaggle (Buda, 2019)	Acc : 92.7%, F1 : 89%, Dice : 0.85

TABLE 4.2 – La performance de modèle proposée.

4.5 La prédiction

4.5.1 Le fonctionnement de l'application

A) Espace d'accueil

La figure 4.10 montre l'écran d'accueil de notre application, où toutes les fonctionnalités sont accessibles. cette fenêtre contient

B) Zone d'importation des images

La première étape de notre méthode consiste à importer l'image afin d'obtenir une image

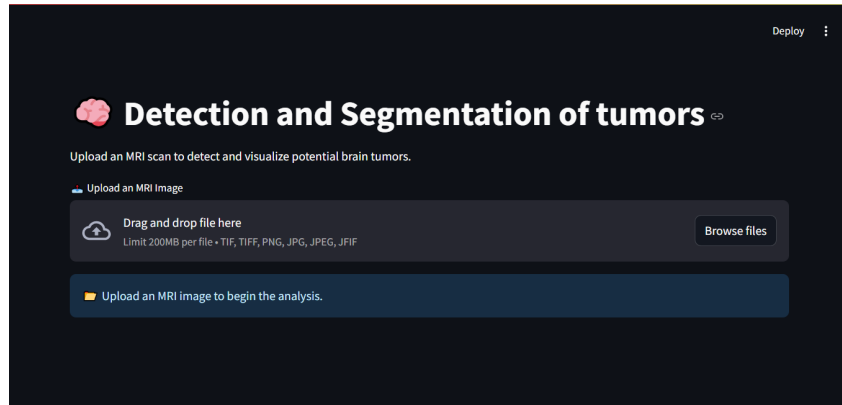


FIGURE 4.11 – Accueil de l'application.

nette pour l'analyse. À cet effet, nous importons une image d'IRM cérébrale




FIGURE 4.12 – Insérer l'image d'IRM cérébrale originale

C) Exemple de présence de la tumeur cérébrale avec résultat

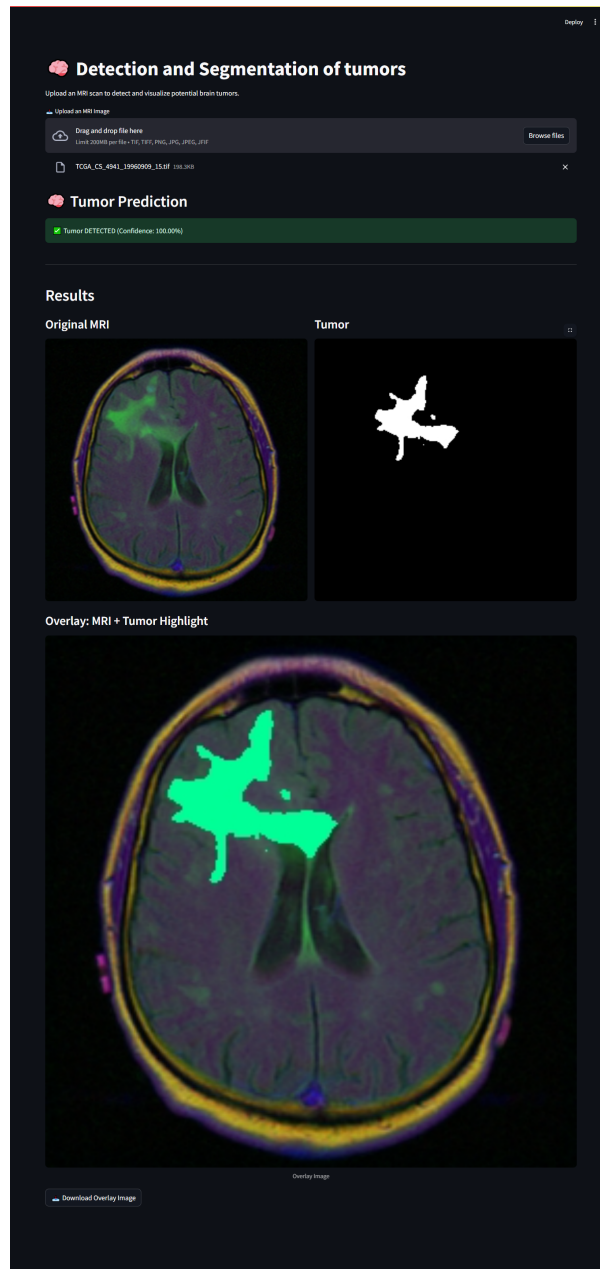


FIGURE 4.13 – résultat de tumeur détecté avec segmentation

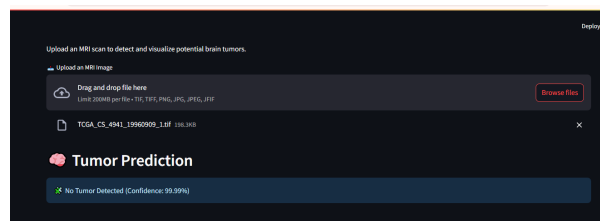


FIGURE 4.14 – résultat de pas tumeur détecté

4.6 Conclusion

Dans ce chapitre, nous avons présenté en détail l'approche expérimentale adoptée pour la détection et la segmentation des tumeurs cérébrales à partir des images IRM. Deux modèles d'apprentissage profond ont été mis en œuvre : InceptionV3 pour la classification binaire (présence ou absence de tumeur), et ResUNet pour la segmentation précise des régions tumorales. L'évaluation des performances a démontré que cette approche combinée permet d'obtenir à la fois une détection fiable et une localisation visuelle précise. Les résultats obtenus, illustrés par les courbes et métriques, confirment l'efficacité des modèles utilisés. Ces performances témoignent du potentiel des réseaux de neurones convolutifs (CNN) dans le domaine de l'analyse d'images médicales.

Conclusion Générale

Conclusion Générale Dans ce mémoire, nous avons proposé une approche basée sur l'apprentissage profond pour la détection et la segmentation automatique des tumeurs cérébrales à partir d'images d'IRM. L'objectif principal était de développer un système intelligent capable de détecter la présence de tumeurs (classification binaire) et de localiser précisément les régions tumorales (segmentation), en combinant la robustesse des réseaux de neurones convolutifs avec des modèles adaptés à chaque tâche.

Nous avons commencé par une étude approfondie de l'anatomie cérébrale, des types de tumeurs et des principes de l'IRM, puis exploré les architectures les plus utilisées en deep learning, notamment InceptionV3 pour la classification et ResUNet pour la segmentation. Ensuite, nous avons préparé et traité les données médicales, provenant de la base Kaggle (« Brain MRI Segmentation » de Buda, 2019), afin d'alimenter nos modèles. Sur le plan expérimental, le modèle InceptionV3 s'est avéré performant pour classer les images en « tumeur » et « non tumeur », atteignant un taux de précision de 92,7% et un F1-score de 89,3%. En parallèle, le modèle ResUNet a permis d'effectuer une segmentation fine des régions tumorales, avec un coefficient de Dice de 0,85, confirmant son efficacité dans la délimitation des lésions. L'analyse des résultats montre que la combinaison de ces deux modèles permet d'apporter à la fois une décision diagnostique rapide et une localisation précise, ce qui constitue un outil précieux pour l'aide au diagnostic médical. Notre application finale (interface utilisateur *Streamlit*) rend cette approche accessible et applicable en pratique clinique. Enfin, cette étude ouvre la voie à plusieurs perspectives : intégrer davantage de classes tumorales (multi-class), expérimenter avec d'autres architectures hybrides, et enrichir la base de données pour améliorer la généralisation du modèle.

Bibliographie

- [1] H. LAGHOUATI, “Segmentation d’images médicales par classification de superpixels en utilisant des caractéristiques issues de la transformée en ondelettes,” Mémoire de Master, Université Abou Bekr Belkaid – Tlemcen, 2015.
- [2] C. RAY. “Système nerveux central : qu’est-ce que c’est ?” Consulté en 2025. (2015).
- [3] DOCTEURCLIC. “Système nerveux central.” Consulté en 2025. (2025).
- [4] “La moelle épinière.” Consulté en 2025. (2025).
- [5] LAROUSSE. “L’encéphale.” Consulté en avril 2025. (2025).
- [6] LAROUSSE. “Tronc cérébral.” Consulté en 2025. (2025).
- [7] LAROUSSE. “Cervelet.” Consulté en 2025. (2025).
- [8] LAROUSSE. “Le cortex cérébral.” Consulté en mai 2025. (2025).
- [9] CEA. “L’essentiel sur le cerveau.” Consulté en 2025. (mars 2023).
- [10] J. HUANG. “Revue générale des fonctions cérébrales.” Révisée en août 2023. (2023).
- [11] V. T. LOCH. “Substance grise.” Dernière modification le 15 avril 2019. (2019).
- [12] FUTURA. “Substance blanche : qu’est-ce que c’est ?” (Nov. 2024).
- [13] D. LATY. “Qu’est-ce que le liquide céphalorachidien ?” Mise à jour le 21 janvier 2025. (2025).
- [14] G. DEHAENE, *Le cerveau, un organe complexe*. Mon Cerveau à L’école, 2012.
- [15] G. FLORENCE, “La physiologie de la circulation cérébrale,” *Bulletin de l’académie vétérinaire de France*, p. 19-30, 2004.
- [16] E. R. KANDEL et al., *Principles of Neural Science*. McGraw-Hill, 2013, « Les neurones constituent l’unité fondamentale de traitement de l’information... ».
- [17] A. VERKHRATSKY et A. M. BUTT, *Glial Physiology and Pathophysiology*. Wiley-Blackwell, 2013, « La glie, loin d’être un simple tissu de remplissage... ».
- [18] “Neurons et cellules gliales dans le cerveau.” Consulté en 2025. (2019).

- [19] N. BAZIZ et Z. RAI, “Classification des images tumorales cérébrales,” thèse de doct., Université Akli Mohand Oulhadj-Bouira, 2021.
- [20] A. S. CAPELLE, “Segmentation d’image IRM multi-échocs tridimensionnelles pour la détection des tumeurs cérébrale par la théorie de l’évidence,” thèse de doct., Université de Poitiers, 2003.
- [21] C. LAIZÉ et A. SOPHIE, “Segmentation d’images IRM multi-échocs tridimensionnelles pour la détection des tumeurs cérébrales par la théorie de l’évidence,” thèse de doct., Université de Poitiers, 2003.
- [22] D. IBRAHIMI et H. SAOU, “Segmentation et classification d’image : Application à l’imagerie par résonance magnétique (IRM),” thèse de doct., Université de A. Mira-Béjaia, 2020.
- [23] Y. ZHENZHEN. “Exemple d’IRM de cerveau humain normal et anormal.” (2017).
- [24] “Le cancer.” (2021).
- [25] “Imagerie médicale pratique.” (2019).
- [26] A. MEKHMOUKH, “Segmentation d’images IRM par améliorations de l’algorithme FCM,” thèse de doct., Université de A. Mira-Béjaia, 2016.
- [27] M. ZERROUGUI et S. HAMADENE, “Détection de la tumeur cérébrales dans l’image IRM par l’apprentissage en profondeur,” thèse de doct., Université Mohamed El Bachir El Ibrahimi Bordj Bou Arréridj, 2021.
- [28] M. COUSINEAU. “Composantes importantes des scanners IRM Al-Tamimi et Sulong.” (2017).
- [29] W. G. BRADLEY, *MRI of the Brain and Spine*. Lippincott Williams Wilkins, 2012, « L’IRM cérébrale est devenue un outil fondamental pour l’évaluation morphologique et fonctionnelle du cerveau ».
- [30] PSYCHOMÉDIA. “Définition apprentissage profond.” (2016).
- [31] G. I. PARISI, R. KEMKER, J. L. PART, C. KANAN et S. WERMTER, “Continual lifelong learning with neural networks : A review,” *Neural Networks*, t. 113, p. 54-71, 2019.
- [32] A. GÉRON, *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*, 2^e éd. O’Reilly Media, 2019.
- [33] I. GOODFELLOW, Y. BENGIO et A. COURVILLE, *Deep Learning*. MIT Press, 2016.
- [34] J. SCHMIDHUBER, “Deep learning in neural networks : An overview,” *Neural Networks*, t. 61, p. 85-117, 2015.

- [35] S. NOSRATABADI, A. MOSAVI, P. DUAN et al., “Data science in economics : Comprehensive review of advanced machine learning and deep learning methods,” *MDPI*, 2020.
- [36] J. AHMED, *A Comparison of DNN, CNN and LSTM using TF/Keras*, LinkedIn, Accessed online, 2020.
- [37] J. JUMPER, R. EVANS, A. PRITZEL, T. GREEN, M. FIGURNOV, O. RONNEBERGER et al., “Highly accurate protein structure prediction with AlphaFold,” *Nature*, t. 596, n° 7873, p. 583-589, 2021.
- [38] P. PEDAMKAR, *DNN neural network*, Educba, Accessed online, 2018.
- [39] Y. BENGIO, P. SIMARD et P. FRASCONI, “Learning long-term dependencies with gradient descent is difficult,” *IEEE Transactions on Neural Networks*, t. 5, n° 2, p. 157-166, 1994.
- [40] S. HOCHREITER et J. SCHMIDHUBER, “Long short-term memory,” *Neural Computation*, t. 9, n° 8, p. 1735-1780, 1997.
- [41] *Figure issue du document original, sans source textuelle explicite*, Figure extraite sans source textuelle.
- [42] Y. LECUN, L. BOTTOU, Y. BENGIO et P. HAFFNER, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, t. 86, n° 11, p. 2278-2324, 1998.
- [43] H. YU, T. L. YANG et Q. ZHANG, “Convolutional neural networks for medical image analysis : State-of-the-art, comparisons, improvement and perspectives,” *Neurocomputing*, t. 444, p. 92-110, 2021.
- [44] *What is a convolutional neural network (CNN) and how does it work ? Question And Answers In MRI*, 2023.
- [45] M. SEMCHEDINE, *Les séquences IRM à image pondérée en T1 et en T2*, ResearchGate, 2018.
- [46] L. Y. JIANG, M. CHEUNG, J. SHI, O. WRIGHT, X. LIU et J. M. F. MOURA, *Graph signal processing and deep learning : convolution, pooling and topology*, ArXiv, 2020.
- [47] X. GLOROT, A. BORDES et Y. BENGIO, “Deep sparse rectifier neural networks,” in *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, 2011, p. 315-323.
- [48] *Convolutional neural network ou réseaux de neurones convolutifs : tout ce qu’il y a à savoir*, DataScientest, 2023.
- [49] B. GRAHAM, *Fractional max-pooling*, arXiv preprint arXiv :1412.6071, 2014.

- [50] M. MUDARAGADDA, *Max Pooling in Convolutional Neural Network and Its Features*, Aim Expert Network, 2020.
- [51] S. KHOSLA, *CNN | Introduction to Pooling Layer*, Easy, 2019.
- [52] V. VEERAMSETTY, T. BADAL et G. SINGAL, “Coinnet : platform independent application to recognize Indian currency notes using deep learning techniques,” *Multimedia Tools and Applications*, 2020.
- [53] K. KANG et X. WANG, *Fully convolutional neural networks for crowd segmentation*, arXiv preprint arXiv :1411.4464, 2014.
- [54] C. PELLETIER, G. I. WEBB et F. PETITJEAN, “Temporal Convolutional Neural Network for the Classification of Satellite Image Time Series,” *MDPI*, 2019.
- [55] M. D. ZEILER et R. FERGUS, “Visualizing and understanding convolutional networks,” in *Computer Vision*, 2014, p. 818-833.
- [56] P. SHARMA, *Disadvantages of CNN models*.
- [57] S. ZINEDDINE, “Optimisation du CNN par l’algorithme génétique pour la reconnaissance de visage,” Mémoire de Master, Université de Biskra, 2019.
- [58] S. BAHNES, *Détection des tumeurs cérébrales dans les images IRM par l’apprentissage profond*, Mémoire de Master, Université Mohamed El Bachir El Ibrahimy de Bordj Bou Arréridj, 2023.
- [59] I. ALI, D. CEM et S. MELIKE, “Review of MRI-based Brain tumor image segmentation Using Deep Learning methods,” *Procedia Computer Science*, 2016.
- [60] I. ALI, D. CEM et S. MELIKE, “Review of MRI-based Brain tumor image segmentation Using Deep Learning methods,” *Procedia Computer Science*, 2016.
- [61] M. J. SHELLER, G. A. REINA, B. EDWARDS, J. MARTIN et S. BAKAS, *Multi-institutional deep learning modeling without sharing patient data : A feasibility study on brain tumor segmentation*. Springer International Publishing, 2019.
- [62] M. ALI, S. O. GILANI, W. ASIM, Z. KASHAN et J. MOHSIN, *Brain Tumour Image Segmentation Using Deep Networks*, 2020.
- [63] B. KOKILA, M. S. DEVADHARSHINI et ANITHA, “Brain Tumor Detection and Classification Using Deep,” in *Journal of Physics : Conference Series*, Department of Computer Science et Engineering, 2021.
- [64] A. HOSSAIN, QUTAIBA et REZZOUQI, “A YOLO v3 Deep Neural Network Model,” *IEEE Access*, 2021, Article No. 3086624, June 4.

- [65] T. LIU, Z. YUAN et B. BADAMI, “An optimal brain tumor detection convolutional neural network and Enhanced Sparrow Search Algorithm,” *J Engineering in Medicine*, t. 235, 2021.
- [66] S. SHARMA et al., “Deep Learning Model for Automatic Classification and Prediction of Brain Tumor,” *Hindawi*, avr. 2022.
- [67] M. A. AISH et al., “Brain Tumor Segmentation and Classification Using ResNet50 and U-Net with TCGA-LGG and TCIA MRI Scans,” *Journal of Computing & Biomedical Informatics*, t. 8, n° 01, 2024.
- [68] P. LI, Z. LI, Z. WANG, C. LI et M. WANG, “mResU-Net : Multi-scale residual U-Net-based brain tumor segmentation from multimodal MRI,” *Frontiers in Neuroscience*, t. 17, 2023, Article 37981627.
- [69] V. KAVITHA et K. ULAGAPRIYA, “Comparative Evaluation for Brain Tumor Detection Using Inception-V3 Architecture,” *International Journal of Intelligent Systems and Applications in Engineering*, t. 11, n° 2, 2023, Article 3892.
- [70] D. L. PHAM, C. XU et J. L. PRINCE, “Current methods in medical image segmentation,” *Annual Review of Biomedical Engineering*, t. 2, n° 1, p. 315-337, 2000.
- [71] M. BUDA, *Brain MRI Segmentation*, Kaggle, 2019.