

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة

التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة بوابكر بكرايد -

تلمس -

Université Aboubakr Belkaïd - Tlemcen -

Faculté de TECHNOLOGIE



MEMOIRE

Présenté pour l'obtention du **Diplôme de MASTER**

En : Génie Biomédical

Spécialité : Imagerie médicale

Par: Boutbeig Nor El Houda & Bentaieb Fatma zohra

Sujet

Classification des tumeurs cérébrales à partir des images IRM en utilisant l'apprentissage profond

M.Boukli Hacène Ismail	Prof	Université de Tlemcen	Président
M.Messadi Mahamed	Prof	Université de Tlemcen	Examineur
Mme BENSMAIL Ilham	MCB	Université de Tlemcen	Encadreur
Mlle ELAOUABER Zineb Aziza	Docteur	Université de Tlemcen	Co-Encadrante

Année universitaire

2024-2025

Remerciement

Avant toute chose, nous exprimons notre profonde gratitude à Allah, pour la santé, la force et la foi dont Il nous a comblés tout au long de ce projet. Sans Sa volonté et Sa bienveillance, rien n'aurait été possible.

*Nous tenons à adresser nos remerciements les plus sincères à nos directrice de mémoire, Madame **Bensmail Ilham**, ainsi qu'à nos Co-encadrante, Mlle **ELAOUABER ZINEB AZIZA**, pour leur accompagnement précieux, leur disponibilité, leurs conseils avisés et leur soutien constant tout au long de ce projet.*

*Nos remerciements sincères vont également aux membres du jury, Monsieur **Boukli Hacène Ismaïl** docteur à l'Université de Tlemcen qui a bien voulu présider notre jury de mémoire.*

*Nous remercions également avec reconnaissance Monsieur **Messaadi Mohamed**, pour le temps qu'il a consacré à l'évaluation de ce travail et pour leurs remarques constructives.*

Enfin, nous remercions tous les enseignants et responsables de notre département pour leur contribution à notre formation.

Dédicaces

À ma merveilleuse mère,

Tu m'as toujours dit : « Je n'ai pas peur pour toi, j'ai confiance en toi ». Ces paroles ont été pour moi un moteur puissant dans les moments de doute. Ton amour, ta patience et ta présence bienveillante ont été un refuge essentiel. Je te dois beaucoup, et ce travail est aussi le fruit de ta foi en moi.

À mon cher père,

Tu m'as appris que « من جد وجد ومن زرع حصد ». Ce proverbe est devenu ma devise, un guide dans chaque étape. Par ta sagesse, ton calme et ta confiance, tu as toujours cru en moi, même quand moi-même j'avais des doutes. Ce travail porte aussi l'empreinte de ton amour discret mais profond. Merci pour tout, que Dieu te protège.

À mes frères,

À toi, mon petit frère, avec qui j'ai toujours partagé une complicité unique, presque comme des jumeaux. Ta simple présence m'a réconfortée plus d'une fois, même sans paroles. Merci pour ton amour sincère et pur.

Et à toi, mon grand frère, un véritable modèle de force et de persévérance. Tes conseils et ton soutien constants ont toujours été une source d'encouragement dans les moments difficiles.

Je vous aime profondément.

À mes sœurs,

Merci pour votre amour sincère, vos encouragements et la douceur que vous apportez à ma vie. Vous êtes des sources de lumière et de bonheur.

À mes amies « Manel, Meriem, Aicha, Aya »

Votre amitié, votre écoute et votre soutien ont été essentiels tout au long de ce parcours. Merci pour les moments partagés, les encouragements et la complicité qui ont rendu cette aventure plus belle.

Vous êtes une richesse précieuse dans ma vie.

Enfin, je remercie tous ceux qui, de près ou de loin, ont contribué à la réalisation de ce mémoire. Que Dieu vous bénisse tous.

Boutbeig Nor El Houda

Je dédie ce modeste travail

A ma merveilleuse mère et mon cher père,

Votre rôle dans ma vie dépasse les mots : vous êtes le socle sur lequel j'ai bâti chaque réussite. Maman, ta tendresse inépuisable et ton regard plein de foi ont bercé mes journées d'espoir. Papa, ta sagesse et ton travail acharné m'ont montré la voie de l'endurance et du dépassement de soi. Tout ce que j'ai accompli trouve sa source dans vos sacrifices, vos prières et votre confiance absolue en moi. Que ce mémoire vous rende un éclat de l'immense dette de gratitude que je vous dois ; puisse-t-il être le reflet de l'amour et du respect que je vous porte.

À mes chers frères et sœurs

Merci pour votre présence rassurante, votre soutien moral et vos encouragements. Chacun de vous a contribué à sa manière à mon cheminement. Vos mots, vos gestes, vos sourires m'ont donné du courage dans les moments de doute.

*À mes amis et à ma chère binôme **Boutbeïg Nour El Houda***

Je n'oublie pas mes chers amis, compagnons de route et sources de réconfort. Merci pour les fous rires partagés, les longues discussions, les moments d'entraide et de complicité. Avec vous, j'ai créé des inoubliables qui resteront gravés dans ma mémoire. souvenirs

*Un remerciement tout particulier à ma binôme **Boutbeïg Nour El Houda**, avec qui j'ai partagé cette aventure scientifique et humaine. Ton sérieux, ta disponibilité et ton esprit de collaboration ont rendu ce travail plus riche et plus agréable. Merci pour chaque étape parcourue ensemble.*

*Enfin, à mon amie et sœur de cœur **Benbouali Fatima**, je te remercie du fond du cœur. Ta présence constante, ta fidélité et ton soutien m'ont énormément aidée. Je sais qu'à l'avenir, peu importe les chemins que nous prendrons, nous continuerons à avancer ensemble, main dans la main, comme nous l'avons toujours fait.*

Bentaieb Fatma Zohra

Résumé

Les tumeurs cérébrales constituent un défi majeur en santé publique, en raison de leurs conséquences graves sur la vie des patients. Pour permettre une prise en charge adaptée, un diagnostic rapide et précis est essentiel. Toutefois, l'analyse manuelle des images IRM demeure complexe et sujette à l'erreur humaine.

Dans ce contexte, notre travail propose un système de classification automatique des tumeurs cérébrales à partir d'images IRM, en s'appuyant sur des techniques d'apprentissage profond. Trois architectures de réseaux de neurones ont été évaluées: un CNN classique, ResNet50 et EfficientNetB0.

Les résultats expérimentaux ont montré que le modèle ResNet50 a obtenu la meilleure précision avec 99,62 %, suivi d'EfficientNetB0 (98,77 %) et du CNN classique (97,62 %). Ces résultats confirment l'efficacité du deep learning pour assister les professionnels de santé dans le diagnostic des tumeurs cérébrales.

Mots clés : tumeurs cérébrales, IRM, classification automatique, apprentissage profond.

Abstract

Brain tumors pose a major public health challenge due to their severe consequences on patients' lives. In order to choose an appropriate treatment, it is important to establish an accurate and rapid diagnosis. However, manual examination of MRI images presents certain complexity and a risk of error.

In our own work, we proposed a system for automatic classification of brain tumors from MRI images using deep learning. Three neural network architectures were evaluated: ResNet50, and EfficientNetB0. The results showed that the ResNet50 model achieved the best accuracy of **99.62%**, compared to the EfficientNetB0 model, which achieved an accuracy of **98.77%**, and the convolutional neural network model, which achieved an accuracy of **97.62%**.

These results confirm the effectiveness of deep learning methods in assisting physicians in the diagnosis of brain tumors.

Keywords: Brain tumors, MRI images, automatic classification, deep learning.

ملخص

تشكل أورام الدماغ تحديًا صحيًا عامًا كبيرًا نظرًا لعواقبها الوخيمة على حياة المرضى. لاختيار العلاج المناسب، من المهم إجراء تشخيص دقيق وسريع. ومع ذلك، يُمثل الفحص اليدوي لصور الرنين المغناطيسي بعض التعقيدات واحتمالية الخطأ. في عملنا، اقترحنا نظامًا للتصنيف التلقائي لأورام الدماغ من صور الرنين المغناطيسي باستخدام التعلم العميق. اختبرنا هياكل مختلفة مثل الشبكة العصبية التلافيفية، وResNet50، و EfficientNetB0. أظهرت النتائج أن نموذج ResNet50 حقق أفضل دقة بنسبة 99.62%، مقارنةً بنموذج EfficientNetB0 الذي حقق دقة بنسبة 98.77%، ونموذج الشبكة العصبية التلافيفية الذي حقق دقة بنسبة 97.62%. تؤكد هذه النتائج فعالية أساليب التعلم العميق في مساعدة الأطباء في تشخيص أورام الدماغ.

الكلمات المفتاحية: أورام الدماغ، صور الرنين المغناطيسي، التصنيف التلقائي، التعلم العميق

Table de matière

Remerciement	2
Dédicaces	3
Résumé.....	5
Abstract	6
ملخص.....	7
Introduction Générale	1
<i>Chapitre 01 :Contexte Médical</i>	1
1. Introduction	2
2. Système Nerveux Central (SNC)	2
3. Morphologie du Cerveau.....	3
3.1. Les Lobes cérébraux.....	3
3.2. Substance Grise	4
3.3. Thalamus	4
3.4. Substance Blanche	5
3.5.L'hypophyse.....	5
3.6. Le Cervelet	6
3.7.Le tronc cérébral	7
3.8.Liquide céphalo-rachidien (LCR)	7
3.9.La Moelle Spinale	8
4.Les tumeurs cérébrales	8
4.1. Le méningiome.....	9
4.1.1 Les stades du méningiome	10
4.1.2 Les symptômes	10
4.1.3 Les facteurs de risque	10
4.2. Les gliomes	11
4.2.1 Les stade du gliome	11
4.2.2 Les symptômes	12
4.2.3Les facteurs de risque	12
4.3. Les maladies pituitaires	13
4.3.1 Les Symptômes	14
4.3.2 Facteurs de risque	14
5.Techniques de diagnostic des tumeurs cérébrales	15
5.1 L'imagerie médical	15
5.1.1 La Tomodensitométrie (TDM).....	15
5.1.2 L'imagerie par résonance magnétique IRM	16
5.2. Autres méthodes du diagnostic.....	18
5.2.1 Analyse du Liquide Céphalorachidien (LCR)	18

Table de matière

5.2.2 La Biopsie	18
6. Conclusion	19
<i>Chapitre 02 : Etat de l'art et principe de l'apprentissage profond</i>	21
1. Introduction.....	22
2. Etat de l'art.....	22
3. L'intelligence artificielle.....	25
4. Apprentissage automatique	26
5. Apprentissage profond	27
6. Réseaux neuronaux convolutifs	27
6.1. Les couches d'un CNN	28
6.1.1 Couche de convolution (CONV).....	29
6.1.2 Fonctions d'activation.....	30
6.1.3 Couche de pooling (POOL).....	31
6.1.4 Couche entièrement connectée (FC)	32
6.1.5 Couche de normalisation.....	33
6.1.6 Couche de Dropout.....	33
7. Fonction de perte.....	34
8. Les Algorithmes d'optimisation.....	34
9. Les hyperparamètres en apprentissage profond	35
10. Apprentissage par transfert (Transfer Learning TL)	36
11. Les architectures les plus performantes pour la classification d'images.....	36
11.1 ResNet50 (Residual Network 50).....	36
11.2 EfficientNet-B0.....	37
12. Les Métriques d'évaluation.....	38
13. Conclusion	39
<i>Chapitre 03 : Classification des tumeurs Cérébrales : Méthode et Résultats</i>	41
1. Introduction.....	42
2. Python : Le langage de programmation utilisé.....	42
3. Bases de données.....	43
4. Méthode proposée pour la classification des tumeurs cérébrales	44
4.1 Prétraitement	45
4.2 Augmentation des données.....	46
4.3 Classification des tumeurs cérébrales.....	47
4.3.1 Classification basée sur le modèle ResNet50	47
4.3.2 Classification basée sur le modèle EfficientNetB0	48
4.3.3 Classification basée sur le modèle CNN Classique.....	49
4.3.4 Les Hyperparamètres.....	50
5. Résultats et discussion.....	51
6. Conclusion	63
Conclusion général.....	64

Liste des figures

Figure 1.1 : Le système nerveux central

Figure 1.2 : Les lobes cérébraux

Figure 1.3 : Représentation du noyaux gris centraux

Figure 1.4 : l'hypophyse

Figure 1.5 : Anatomie du cerveau

Figure 1.6 : Représentation du canal vertébrale

Figure 1.7 : Images de tumeurs du cerveau

Figure 1.8 : Représentation de cas sain de cerveau et les meningiomes

Figure 1.9 : Représentation de cas sain de cerveau et les gliomes

Figure 1.10 : : Représentation de cas sain de cerveau et les adénomes hypophysaire

Figure 1.11 : Image TDM des tumeurs cérébrales

Figure 1.12- Image IRM des tumeurs cérébrales

Figure 1.13 : Cytopathologie du liquide de céphalorachidien

Figure 1.14 : Examen de biopsie cérébrale stéréotaxique

Figure2.1 : Représentation de la relation entre l'intelligence artificielle, machine learning et le deep Learning

Figure 2.2 :Représentation des différentes couches de CNN

Figure 2.3 :Représentation d'une opération de convolution avec une entrée de taille 4x4, un filtre de taille 3x3, et un pas de 1.

Figure 2.4 : Représentation des courbes des fonctions d'activation

Figure 2.5 : Représentation du fonctionnement de Max pooling et Average pooling

Figure2.6 :Représentation de couches entièrement connectées

Figure 2.7 :Schéma représentation de transfert learning

Figure2.8 :Architecture de ResNet50

Figure 2.9 :Architecture de EfficientNeT-B0

Figure 3.1 : Répartition des classes dans la base de données

Figure 3.2 :Exemples de quelques images IRM cérébrales de la base de données utilisée.

Figure 3.3 : Schéma générale de notre méthodologie

Figure 3.4 : exemples des images traitées

Figure3.5 :Répartition de chaque classe après l'équilibrage.

Figure 3.6 :Image augmentée .

Figure 3.7 :Architecture de modèle ResNet50 modifiée.

Figure 3.8 :Architecture de modèle EfficientNetB0 modifiée.

Figure 3.9 : Architecture de modèle CNN classique modifiée.

Figure 3.10 : Les matrices de confusions des modèles non traités et sans augmentation des données

Figure 3.11 : Les matrices de confusions des modèles non traités et Avec augmentation des données.

Figure 3.12 : Les matrices de confusions des modèles traités et sans augmentation des données.

Figure 3.13 : Les matrices de confusions des modèles traités et Avec augmentation des données

Figure 3.14 : Les courbes de performances des modèles traités et sans augmentation des données

Figure 3.15 : Les courbes de performances des modèles traités et avec augmentation des données

Figure 3.16 : prédictions des tumeurs cérébrales avec les niveaux de confiance associés de modèle ResNet50

Figure 3.17 : prédictions des tumeurs cérébrales avec les niveaux de confiance associés de modèle EfficientNetB0

Figure 3.18 : prédictions des tumeurs cérébrales avec les niveaux de confiance associés de modèle CNN classique

Liste des tableaux

Tableau 3.1 : Représentation des métriques d'évaluation

Tableau 3.2 : Représentation des métriques d'évaluations de chaque modèle sans prétraitement

Tableau 3.3 : Représentation des métriques d'évaluations de chaque modèle avec prétraitement

Tableau 3.4 : comparaison de nos méthodes de classification avec l'état de l'art

.

Les Abréviation

IRM :Imagerie par résonance magnétique

SNC :Système Nerveux Central

NGC :Noyaux gris centraux

GH:l'hormone de croissance

ACTH :la prolactine, la corticotrophine

TSH :l'hormone thyroïdienne

LH et FSH : les gonadotrophines

ADH: l'hormone antidiurétique

LCR :Liquide céphalo-rachidien

MEN1 :Néoplasie Endocrinienne Multiple de type 1

MEN4 :Néoplasie Endocrinienne Multiple de type 4

TDM :la tomographie par émission de positons

TEP : Tomographie par Émission de Positons

RMN : La magnétique nucléaire

OMS:Organisation mondiale de la santé

IA :L'intelligence artificielle

CNN :Les réseaux de neurones convolutifs (Convolutional Neural Networks)

DCNN : Un réseau de neurones convolutifs profonds

KNN :K-Nearest Neighbors

SVM : Support Vector Machine

ANN :Réseaux de neurones artificiels

CADx:Computer-Aided Diagnosis

ViT :Vision Transformer

LBP: Motifs binaires locaux

HOG :Les histogrammes de gradients orientés

ACP :Analyse de composant principale

ReLU :Rectified Linear Unit

Tanh :Tangente hyperbolique

POOL:Couche de pooling

FC :Couche entièrement connectée

MSE :Mean Squared Error

GD :Gradient Descent

SGD :Descente de gradient stochastique (Stochastic Gradient Descent)

Abréviation

SGDM :Descente de gradient stochastique avec momentum (Stochastic Gradient Descent with Momentum)

Adam: (Adaptive Moment Estimation)

TL : Transfer Learning

TP: Vrai Positif (True Positive)

FP : Faux Positif (False Positive)

TN : Vrai Négatif (True Négative)

FN : Faux Négatif (False Négative)

GPU :Graphics Processing Unit (*Unité de traitement graphique*)

Introduction Générale

Les maladies du système nerveux central, en particulier les tumeurs cérébrales, représentent aujourd'hui l'un des défis les plus complexes de la médecine moderne. En raison de leur gravité clinique et de leur impact direct sur les fonctions vitales (motrices, sensorielles et cognitives), ces pathologies exigent des outils de détection à la fois précis, rapides et fiables. Le cerveau, organe d'une complexité exceptionnelle, ne tolère que très peu d'erreurs lorsqu'il s'agit de poser un diagnostic.

Parmi les différentes formes de tumeurs cérébrales, trois types se distinguent par leur fréquence et leur impact clinique : les gliomes, les méningiomes et les adénomes hypophysaires. Ces tumeurs présentent une grande variabilité morphologique et biologique, rendant leur classification à partir d'images médicales particulièrement délicate.

Selon l'Organisation mondiale de la santé, les tumeurs du système nerveux central figurent parmi les premières causes de décès liés au cancer chez les jeunes adultes. En Algérie, les données GLOBOCAN 2022 font état de 2 038 nouveaux cas et 1 575 décès, ce qui représente 3,1 % des cas de cancer et 4,4 % des décès liés au cancer dans le pays [1]. Ces chiffres soulignent l'urgence de développer des méthodes de diagnostics plus performantes.

L'imagerie par résonance magnétique (IRM) est actuellement la méthode de référence pour visualiser les structures cérébrales en détail. Toutefois, l'interprétation manuelle des IRM reste un processus long, complexe et dépendant de l'expertise du radiologue, exposé à des risques d'erreurs ou de variabilité inter-observateur.

C'est dans ce contexte que l'intelligence artificielle, et plus particulièrement le deep learning, s'impose comme une solution prometteuse. Ces techniques permettent d'extraire automatiquement des caractéristiques complexes à partir d'images médicales et de fournir une classification rapide, reproductible et précise.

Dans le cadre de ce travail, nous avons développé un système de classification automatique des tumeurs cérébrales basé sur des images IRM, ciblant trois types majeurs de tumeurs : gliomes, méningiomes et tumeurs hypophysaires. Pour ce faire, nous avons exploité la puissance de trois architectures d'apprentissage profond : un réseau CNN classique, ResNet50 et EfficientNetB0. Ces modèles ont

été entraînés sur une base de données publique, puis comparés en termes de performances dans le but de proposer un outil fiable d'aide au diagnostic médical.

Notre projet de fin d'études s'articule autour de **trois chapitres principaux**, détaillant successivement les aspects médicaux, techniques et expérimentaux du travail réalisé.

- **Chapitre 1 : Contexte médical**

Ce chapitre présente les notions fondamentales liées à l'anatomie du cerveau et aux tumeurs cérébrales les plus fréquentes. Il aborde également les différentes modalités d'imagerie médicale utilisées pour le diagnostic, avec un accent particulier sur l'imagerie par résonance magnétique (IRM), en raison de sa précision et de sa pertinence dans le cadre de la détection des tumeurs.

- **Chapitre 2 : État de l'art et principes de l'apprentissage profond**

Ce chapitre est consacré à l'étude des travaux récents portant sur la classification automatique des tumeurs cérébrales à partir d'images IRM. Nous y présentons les concepts fondamentaux de l'apprentissage profond, les principales architectures de réseaux neuronaux utilisées, ainsi que les approches techniques adoptées dans notre propre méthodologie.

- **Chapitre 3 : Méthodologie, expérimentation et résultats**

Ce dernier chapitre détaille les étapes pratiques de notre approche, depuis le prétraitement des données jusqu'à la mise en œuvre des modèles de classification. Il expose les résultats obtenus, suivis d'une discussion comparative des performances des différentes architectures testées (CNN, ResNet50, EfficientNetB0).

Enfin, le mémoire se conclut par une conclusion générale, qui résume les apports du projet, ainsi que par des perspectives d'amélioration et d'évolution possibles pour les travaux futurs.

*Chapitre 01 :Contexte
Médical*

1. Introduction

Le cerveau est l'organe principal du système nerveux central, contrôlant les fonctions vitales, les pensées, les émotions...etc. Il peut être affecté par des pathologies, entre autre les tumeurs cérébrales qui sont des maladies graves et complexes à traiter. Ces dernières peuvent être bénignes ou malignes, et leurs détections précoces est essentielle pour améliorer les chances de survie et la qualité de vie des patients.

Les médecins utilisent différentes techniques d'exploration ou les plus utilisées sont : l'Imagerie par Résonance Magnétique (IRM) qui offre une bonne visualisation du cerveau. Ainsi que le scanner (tomodensitométrie), qui est basé sur l'utilisation des rayons X pour produire des images cérébrales. Ces outils permettent de localiser les tumeurs, d'évaluer leurs tailles et leurs impacts sur le cerveau. Nous avons aussi les analyses biologiques et la biopsie, aidant à déterminer le type de tumeur et son comportement.

Ce chapitre s'attache à explorer l'anatomie du cerveau, les principales catégories de tumeurs cérébrales, ainsi que les techniques de diagnostic actuellement utilisées pour leur détection et leur suivi, en mettant l'accent sur les approches les plus efficaces et les plus précises disponibles en pratique clinique.

2. Système Nerveux Central (SNC)

Le système nerveux central (SNC), aussi appelé névraxe, est une structure complexe et essentielle pour la régulation des fonctions corporelles et le traitement des informations. Il est composé de :

- La moelle épinière : Logée dans le canal vertébral.
- L'encéphale : Composé du tronc cérébral, du cervelet et du cerveau [2].




Figure1.1 : Le système nerveux central

3. Morphologie du Cerveau

Morphologiquement, le cerveau a une forme ovoïde et une organisation complexe. Il comprend plusieurs parties essentielles, notamment les lobes cérébraux, les substances gris et blanches, le tronc cérébral, ainsi que des structures sous-corticales comme le thalamus. À l'arrière du cerveau, le cervelet, bien que distinct du cerveau proprement dit, joue un rôle fondamental dans la coordination motrice, l'équilibre et l'ajustement postural. L'interconnexion de toutes ces structures permet le bon fonctionnement du système nerveux central.

3.1. Les Lobes cérébraux

Le cerveau est divisé en plusieurs lobes principaux, chacun ayant des fonctions spécifiques. Ces lobes coopèrent entre eux pour assurer les nombreuses fonctions complexes du cerveau (figure 1.2) [2]:

- **Lobe Frontal** : Associé à la planification, à la prise de décision et au contrôle moteur.
- **Lobe Pariétal** : Impliqué dans la perception sensorielle et l'intégration des informations sensorielles.
- **Lobe Temporal** : Crucial pour le traitement auditif et la mémoire.
- **Lobe Occipital** : Principalement responsable de la vision.

- **Lobe de l'Insula** : Situé en profondeur de la scissure de Sylvius, joue un rôle dans la perception des émotions et la conscience corporelle.
- **Lobe limbique** : situé au centre du cerveau, joue un rôle crucial dans les émotions, la mémoire et les comportements motivationnels.




Figure 1.2 : Les lobes cérébraux

3.2. Substance Grise

Elle comprend l'écorce grise ou cortex cérébral, qui est le siège des fonctions cognitives, sensorielles et de motrices. Cette substance inclut également les noyaux gris centraux (NGC) (figure 1.3) [2], dont font partie le **noyau caudé** et le **noyau lenticulaire**. Ces structures jouent un rôle clé dans la régulation des mouvements et le contrôle moteur.

3.3. Thalamus : Agit comme un carrefour pour les influx sensitivo-sensoriels, relayant les informations vers le cortex (figure 1. 3) [2].




Figure 1.3 : Représentation du noyaux gris centraux

3.4. Substance Blanche

Elle est située au centre du cerveau. Cette substance se compose de fibres nerveuses myélinisées, qui connectent les différentes régions du cortex, facilitant ainsi la communication neuronale. Parmi les principales structures de la substance blanche, nous citons [2] :

- **Centre Semi-Ovale (Corona Radiata) :** Contient des fibres ascendantes et descendantes, notamment des voies motrices et sensitives essentielles à la transmission des signaux entre le cortex et les structures profondes.
- **Capsules interne, externe et extrême :** Ces structures jouent un rôle vital dans la transmission des informations. La capsule interne est impliquée dans le transport des signaux moteurs et sensoriels entre le cortex cérébral, le tronc cérébral et la moelle épinière. *La capsule externe* contient principalement des fibres associatives reliant différentes parties du cortex. La capsule extrême, plus fine et située en périphérie, contient des fibres moins bien définies, mais elle participe aussi à la communication entre régions corticales.
- **Corps Calleux :** Constitue la principale commissure inter-hémisphérique. Il relie les hémisphères gauche et droit, crucial pour l'intégration des informations. Une lésion dans cette région peut provoquer un syndrome de déconnexion, perturbant la communication inter-hémisphérique et affectant les fonctions cognitives et motrices.

3.5.L'hypophyse

L'hypophyse (ou glande pituitaire) est une petite glande endocrine de la taille d'un haricot, situé dans la ligne médiane à la base du cerveau, derrière le chiasma optique, dans une cavité osseuse appelée selle turcique. Elle est reliée à l'hypothalamus par la tige pituitaire, formant ensemble l'axe hypothalamo-hypophysaire. Surnommée la glande maîtresse, elle joue un rôle central dans la régulation hormonale en contrôlant plusieurs autres glandes du corps (thyroïde, surrénales, gonades...) [3].

L'hypophyse est classiquement divisée en deux lobes [4] :

- **L'antéhypophyse** (ou adénohypophyse), responsable de la sécrétion de plusieurs hormones telles que : l'hormone de croissance (GH), la prolactine, la corticotrophine (ACTH), l'hormone thyroïdienne (TSH), et les gonadotrophines (LH et FSH).
- **La posthypophyse** (ou neurohypophyse), qui libère l'hormone antidiurétique (ADH) et l'ocytocine, produites dans l'hypothalamus et stockées dans la posthypophyse.




Figure 1.4 : l'hypophyse

3.6. Le Cervelet

Le cervelet, ou "petit cerveau", est une structure du système nerveux central, plus petite que le cerveau mais avec une organisation similaire. Il est essentiel pour le maintien de la posture, l'équilibre et la coordination des mouvements, en agissant de manière inconsciente. Il est situé dans la fosse crânienne postérieure, en arrière du tronc cérébral, séparé par le 4^{ème} ventricule, et communique avec celui-ci via trois pédoncules cérébelleux (supérieur, moyen et inférieur), qui assurent le passage des informations afférentes et efférentes.

Anatomiquement, le cervelet est formé de deux hémisphères latéraux reliés par une structure médiane appelée *vermis*. Il est divisé en trois lobes (antérieur, postérieur, flocculo-nodulaire), chacun étant subdivisé en lobules. Sa vascularisation est assurée par les artères cérébelleuses, garantissant l'oxygénation et le bon fonctionnement de ses structures [2].

Coupe du cerveau

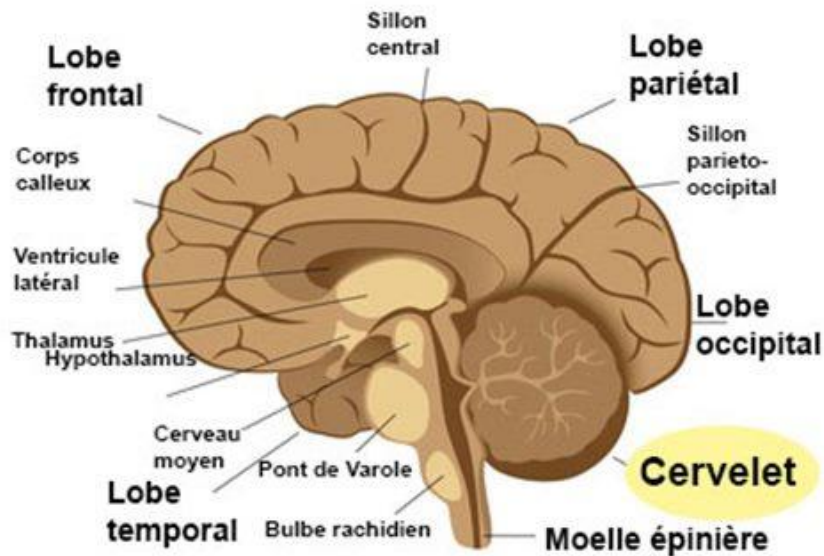


Figure 1.5 : Anatomie du cerveau

3.7. Le tronc cérébral

C'est une structure fondamentale du système nerveux central située au-dessus de la moelle épinière, sous le cerveau et en avant du cervelet. Il est composé de trois sections principales : le bulbe rachidien, le pont et le mésencéphale. Il constitue une voie de passage pour les fibres motrices et sensitives reliant le cerveau à la moelle épinière. C'est le point d'émergence de la plupart des nerfs crâniens, régulant des fonctions vitales telles que la respiration, le rythme cardiaque, la douleur, la vigilance et le sommeil. Sa vascularisation dépend du système vertébro-basilaire, qui assure un apport sanguin constant et indispensable à ses fonctions [2].

3.8. Liquide céphalo-rachidien (LCR)

L'ensemble du SNC baigne dans un coussin protecteur de liquide céphalorachidien (LCR). Ce fluide transparent assure la protection mécanique du cerveau et de la moelle épinière, en absorbant les chocs. Il facilite le transport des nutriments et l'élimination des déchets. Le LCR est produit par les plexus choroïdes situés dans les ventricules cérébraux. Il circule ensuite à travers le système ventriculaire puis dans l'espace sub-arachnoïdien. Son volume normal chez l'adulte est d'environ 150 ml, avec un renouvellement quotidien de 3 à 4 fois. Sa pression varie entre 5 et 15 cm d'eau, influencée par les activités cardiaques et respiratoires [2].

3.9.La Moelle Spinale

La moelle spinale ou bien **moelle épinière** est une partie du système nerveux central logée dans le canal vertébral, s'étendant de la base du crâne (au niveau de C1) jusqu'au cône médullaire à L1-L2. Elle n'occupe pas toute la hauteur de la colonne vertébrale en raison d'une croissance disproportionnée. Sa forme est celle d'une longue tige cylindrique en S, avec deux renflements : l'intumescence cervicale, qui innerve les membres supérieurs, et l'intumescence lombaire, qui innerve les membres inférieurs. Ces structures sont essentielles pour la distribution des nerfs et le bon fonctionnement moteur et sensoriel du corps [2].

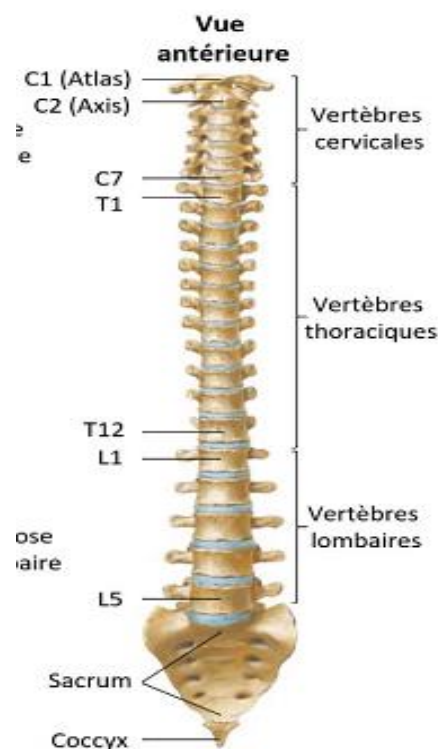


Figure 1.6 :Représentation du canal vertébrale

4.Les tumeurs cérébrales

Les tumeurs cérébrales sont des masses de cellules qui progressent rapidement, de façon incontrôlée, dans le cerveau. Elles sont de deux types :

- **Les tumeurs primitives** : naissent dans le cerveau. Nous distinguons les tumeurs bénignes, retrouvés dans environ les deux tiers des cas de tumeurs primitives [5]. Elles sont caractérisées par des cellules non cancéreuses. Et les tumeurs malignes, caractérisées par des cellules cancéreuses. Qu'elles soient bénignes ou malignes, les

tumeurs primaires peuvent entraîner des symptômes sérieux en particulier lorsqu'elles sont situées dans des zones fonctionnelles clés du cerveau.

- **Les tumeurs secondaires :** sont des métastases d'un cancer préexistant. Elles naissent lorsque des cellules d'une tumeur initiale située hors de l'encéphale parviennent à migrer, via la circulation sanguine, vers le tissu cérébral. Certains cancers au stade avancé sont fréquemment associés au développement de métastases cérébrales tels que les cancers du poumon, de la peau, du rein ou encore du sein [5].




Figure 1.7 : Images de tumeurs du cerveau

Il existe différents types de tumeurs cérébrales, parmi elles nous nous intéressons dans cette étude aux trois types les plus fréquents à savoir : méningiome, gliome et pituitaire.

4.1. Le méningiome

Il est parmi les tumeurs bénignes intracrâniennes les plus fréquentes des méninges. Ces dernières constituent l'enveloppe protectrice du cerveau et de la moelle épinière, et se composent de trois couches, appelées la dure-mère (pour la couche la plus externe), l'arachnoïde (pour la couche intermédiaire) et la pie-mère (pour la couche la plus interne). Le méningiome se développe dans la plupart des cas au niveau de la couche intermédiaire, c'est-à-dire l'arachnoïde. Dans la grande majorité des cas, le méningiome est une tumeur bénigne, mais quand la tumeur grossit, elle peut pousser les structures du cerveau vers l'intérieur et

causer des symptômes variés. Il touche préférentiellement les femmes âgées entre 40 et 70 ans [6].

4.1.1 Les stades du méningiome

Nous distinguons généralement trois stades de méningiome :

- **Bas grade** : c'est le premier stade et le plus fréquent. Il s'agit de méningiomes progressant lentement, pouvant même régresser sans envahir le tissu cérébral.
- **Grade 2** : c'est le deuxième stade, où les méningiomes peuvent récidiver et devenir agressifs.
- **Grade 3** : les méningiomes sont plus rares et plus agressifs. Ils sont généralement plus difficiles à traiter et récidivent dans la plupart des cas [6].




Figure 1.8 : Représentation de cas sain de cerveau et les méningiomes

4.1.2 Les symptômes

Ils varient en fonction de la localisation de la tumeur. En effet, en grossissant, le méningiome tend à compresser certaines zones du cerveau. Il peut donc engendrer des maux de tête, des changements de la personnalité, des troubles de l'équilibre, une faiblesse au niveau d'une partie du corps ou encore des crises d'épilepsie [6].

4.1.3 Les facteurs de risque

La cause principale de l'apparition de ce cancer n'est souvent pas connue.

Aujourd'hui, le facteur de risque clairement établi est celui de l'exposition à des radiations ionisantes [7]. En effet, les personnes ayant subi une radiothérapie crânienne dans leur enfance, ont plus de risques de développer un ou des méningiomes.

D'autres facteurs peuvent favoriser sa survenue et sa croissance tels que [7] :

- La présence de certains gènes hérités des ascendants.
- La grossesse, période marquée par des changements hormonaux chez la femme enceinte.
- Les facteurs hormonaux et en particulier certains traitements hormonaux par progestatifs, et acétate de cyprotérone. Pouvant aussi conduire au développement d'un méningiome chez l'homme.

4.2. Les gliomes

Il s'agit de tumeurs primitives du cerveau les plus fréquentes, correspondent à environ un tiers des cas. Les gliomes regroupent un ensemble de tumeurs plus ou moins infiltrantes nées au sein du cerveau à partir des cellules gliales (astrocytes ou oligodendrocytes). Lorsqu'un gliome est constitué majoritairement d'astrocytes, il est appelé astrocytome. S'il provient d'oligodendrocytes, nous parlons des oligodendrogliomes. Il existe aussi des gliomes mixtes où les deux types de cellules sont atteintes [8].

4.2.1 Les stade du gliome

Les gliomes sont classés selon leur degré de sévérité, du grade I au grade IV [8].

- **Les gliomes de grade I** sont généralement bénins et apparaissent majoritairement chez les enfants. Ils présentent une croissance lente et peuvent être traités efficacement par chirurgie.
- **Les gliomes de grade II** correspondent à des tumeurs de croissance lente, mais elles possèdent un potentiel évolutif vers une forme maligne. Ils sont souvent considérés comme des lésions précancéreuses, susceptibles de progresser vers un grade supérieur.
- **Les gliomes de grade III**, appelés gliomes anaplasiques, sont des tumeurs malignes caractérisées par une croissance plus rapide, une infiltration plus marquée et une réponse thérapeutique souvent limitée.
- **Les gliomes de grade IV**, appelés glioblastomes, sont systématiquement des tumeurs malignes à haut grade d'agressivité. Leur évolution est rapide et leur pronostic est réservé malgré les traitements disponibles. Les glioblastomes représentent la majorité des gliomes et approximativement 20% des tumeurs primitives cérébrales.




Figure 1.9 : Représentation de cas sain de cerveau et les gliomes

4.2.2 Les symptômes

Les signes cliniques du gliome varient selon la taille, la localisation, le type et le grade de la tumeur.

Les céphalées (ou maux de tête) représentent le symptôme initial le plus fréquent. Elles résultent généralement de la croissance tumorale, qui exerce un effet de masse sur les tissus environnants. Cet effet entraîne une pression dans la micro-vascularisation, provoquant un œdème cérébral. D'autres symptômes liés aux effets de masse comprennent les nausées, les vomissements et les troubles visuels.

En fonction de la localisation de la tumeur dans le cerveau, des signes spécifiques peuvent survenir :

- Les tumeurs du lobe frontal peuvent présenter des changements de comportement.
- Les tumeurs dominantes du lobe temporal peuvent entraîner des problèmes d'élocution réceptive.

Les convulsions constituent le deuxième symptôme le plus fréquent. Elles sont dues à l'irritation tumorale du cortex cérébral, entraînant des crises d'épilepsie focales ou généralisées.

Par ailleurs, d'autres signes peuvent apparaître à savoir des sensations de picotements, de la faiblesse, des difficultés à marcher et, dans de rares cas, les patients peuvent se présenter dans un état comateux en raison d'une hémorragie dans la tumeur qui conduisant à un syndrome de hernie aiguë [9].

4.2.3 Les facteurs de risque

La cause exacte des gliomes demeure inconnue. Toutefois, plusieurs facteurs sont suspectés de favoriser leur apparition [10] :

- **L'âge** : Les gliomes sont plus fréquemment observés chez les adultes âgés de 45 à 65 ans, bien qu'ils puissent survenir à tout âge. Certains types, tels que les gliomes de bas grade, sont plus fréquents chez les enfants et les jeunes adultes.
- **L'exposition aux radiations ionisantes** : Un antécédent d'exposition aux radiations comme la radiothérapie présentent un risque accru de développer un gliome.
- **Les antécédents familiaux** : Bien que rares, certains gliomes peuvent avoir une composante héréditaire. La présence de cas familiaux suggère une possible prédisposition génétique.

4.3. Les maladies pituitaires

Les maladies pituitaires désignent l'ensemble des affectations touchant l'hypophyse (ou glande pituitaire). Ces maladies peuvent être tumorales, fonctionnelles (excès ou déficit hormonal), ou inflammatoires/infectieuses.

Les tumeurs qui prennent naissance dans cette glande sont appelées adénomes hypophysaires. Il s'agit généralement de tumeurs bénignes, de bas grade, à croissance lente. Elles représentent environ 10 % des tumeurs cérébrales primitives, ce qui en fait la troisième tumeur intracrânienne la plus fréquente chez l'adulte [3]. Les tumeurs pituitaires peuvent survenir à tout âge, mais ils sont plus souvent diagnostiqués chez les personnes âgées. Par ailleurs, les femmes sont légèrement plus touchées que les hommes [3].

Ces affectations peuvent être fonctionnelles (sécrétrices) ou non fonctionnelles :

- **Les adénomes fonctionnels (ou sécrétants)** : ils produisent un excès d'hormones (prolactine, GH, ACTH...), entraînant des syndromes cliniques spécifiques (acromégalie, hyperprolactinémie, syndrome de Cushing...).
- **Les adénomes non fonctionnels (ou non sécrétants)** : ils ne produisent pas d'hormones mais peuvent entraîner des symptômes compressifs par effet de masse (troubles visuels, céphalées...).

D'autres pathologies hypophysaires peuvent également être rencontrées, notamment l'hypopituitarisme, qui correspond à une insuffisance partielle ou totale de sécrétion hormonale, souvent secondaire à une tumeur, à une chirurgie ou à une radiothérapie. Le diabète insipide, lié à un déficit en hormone antidiurétique, se manifeste quant à lui par une polyurie importante associée à une soif excessive. Dans de rares cas, des pathologies

inflammatoires, infectieuses ou vasculaires peuvent également affecter l'hypophyse, comme l'apoplexie hypophysaire, les hypophysites auto-immunes ou les infections granulomateuses.




Figure 1.10 : Représentation de cas sain de cerveau et les adénomes hypophysaire

4.3.1 Les Symptômes

Les symptômes les plus fréquemment observés dans le cas des tumeurs pituitaires comprennent :

- Croissance anormale des mains et des pieds.
- Croissance anormale des cheveux chez les femmes.
- Prise de poids inexplicable.
- Changements comportementaux et cognitif.
- Cessation des règles (aménorrhée).
- Dépression.
- Maux de tête.
- Dysfonction érectile chez les hommes.
- Nausées ou vomissements matinaux.
- Perte de vision [3].

Dans certains cas, les patients peuvent rester asymptomatiques pendant une longue période, notamment en cas d'adénomes non fonctionnels de petite taille.

4.3.2 Facteurs de risque

Les facteurs de risque identifiés pour les tumeurs pituitaires sont principalement associés à des syndromes génétiques héréditaires. Ces syndromes résultent de mutations génétiques spécifiques, c'est-à-dire de modifications anormales dans certains gènes, qui peuvent être transmises de parent à enfant. Parmi ces risques héréditaires [11] :

- **Néoplasie Endocrinienne Multiple de type 1 (MEN1) :** Cette condition est causée par des changements dans le gène MEN1. Il est associé à un risque accru de tumeurs des glandes endocrines, dont l'hypophyse. Un enfant dont l'un des parents est porteur d'une mutation du gène MEN1 a 50 % de risque d'en hériter.
- **Néoplasie Endocrinienne Multiple de type 4 (MEN4) :** Syndrome plus rare, causé par des modifications du gène CDKN1B pouvant être transmises par un parent. Les personnes atteintes présentent un risque plus élevé de tumeurs pituitaires et d'autres tumeurs endocriniennes.

D'autres syndromes génétiques rares, héréditaires ou non, peuvent également augmenter le risque de tumeur pituitaire. Il s'agit notamment du syndrome de McCune-Albright, du complexe de Carney...etc.

Dans de rares cas, les tumeurs pituitaires semblent être présentes dans certaines familles sans syndrome génétique connu [11].

5. Techniques de diagnostic des tumeurs cérébrales

Le diagnostic précis des tumeurs cérébrales repose sur un ensemble de techniques avancées permettant d'évaluer la localisation, la nature et l'impact de la tumeur sur les tissus avoisinants. Ces méthodes combinent l'imagerie médicale, l'évaluation clinique et les analyses biologiques.

5.1 L'imagerie médicale

L'imagerie constitue l'outil central du diagnostic des tumeurs cérébrales en réalisant des images cérébrales précises. Elle permet non seulement de visualiser la présence d'une lésion, son type, sa localisation et son grade mais aussi de guider les décisions thérapeutiques. Deux techniques principales sont utilisées : la tomodensitométrie (TDM) et l'imagerie par résonance magnétique (IRM).

5.1.1 La Tomodensitométrie (TDM)

La Tomodensitométrie appelée aussi scanner ou Tomographie axiale transverse assistée par ordinateur. Elle repose sur l'utilisation des rayons X pour obtenir des images détaillées des structures internes du cerveau. Elle permet une détection rapide et un diagnostic précis des

anomalies cérébrales, notamment en cas d'urgence (traumatismes, hémorragies, tumeurs, etc.).

Le scanner est une chaîne radiologique constitué d'un tube à rayons X et un ensemble de détecteurs disposés en couronne afin de mesurer l'atténuation d'un faisceau de rayons X qui traverse un segment du corps. Le tube et les détecteurs tournent autour de l'objet à examiner. De multiples profils d'atténuation sont obtenus à des angles de rotation différents. Les signaux recueillis sont numérisés, traités par un ordinateur, puis reconstruits en images 2D ou 3D du cerveau. Les données sont rétro projetées sur une matrice de reconstruction puis transformées en image analogique [12].

Cette technique d'imagerie apporte des informations différentes et est choisie par le médecin en fonction de l'objectif diagnostique. Elles constituent un outil irremplaçable de la médecine moderne. Toutefois, l'accumulation de doses de rayons X peut accroître légèrement le risque de développer un cancer à long terme. Ce risque augmente avec le niveau de dose de rayons X reçus et le nombre d'examens réalisés. Un scanner doit dans tous les cas être demandé et justifié par un médecin. Cette demande doit ensuite être validée par un radiologue, qui peut éventuellement la remplacer par un autre examen plus adapté et parfois moins irradiant [12].



Figure 1.11 : Image TDM des tumeurs cérébrales

5.1.2 L'imagerie par résonance magnétique IRM

L'imagerie par résonance magnétique (IRM) est une technique d'imagerie médicale non invasive permettant d'obtenir des vues en 2D ou 3D d'une partie du corps, notamment du cerveau. Elle est basée sur le principe de la résonance magnétique nucléaire (RMN),

exploitant les propriétés magnétiques des noyaux d'hydrogène présents dans les tissus biologiques. Grâce aux différentes séquences d'acquisition, il est possible d'examiner différentes structures anatomiques avec une grande précision. L'IRM se révèle particulièrement bien adaptée à l'étude non traumatique des organes profonds, réputés difficiles d'accès, tels que le cerveau, l'abdomen, pelvis, etc. Cette technique consiste à créer des images précises d'une partie du corps, grâce à des ondes radio et un champ magnétique. L'examen est indolore et dans certains cas, nécessite l'injection d'un produit de contraste pour améliorer la qualité des images [13]. Elle est utilisée pour le diagnostic et le suivi de certaines tumeurs.

L'IRM permet non seulement la détection des tumeurs, mais aussi l'évaluation de leur taille, de leur localisation ainsi que leur impact potentiel sur les zones fonctionnelles du cerveau .



Figure 1.12 : Image IRM des tumeurs cérébrales

○ Principe de l'IRM

L'IRM est une technique d'imagerie médicale avancée, reposant sur l'utilisation d'un champ magnétique puissant (gros aimant) permettant d'explorer les différents organes du corps humain dans les trois plans de l'espace.

Cette technique consiste à analyser le comportement des protons de l'eau présentes dans l'organisme. Lorsqu'ils sont exposés à un champ magnétique intense, ces protons s'alignent selon la direction du champ. Une fois soumis à une impulsion radiofréquence, ils se désalignent temporairement. En revenant à leur position initiale, ils émettent un signal

mesurable, qui est ensuite traité par un système informatique pour reconstruire des images à haute résolution. Ces images sont interprétées par le radiologue pour le diagnostic

En raison de la puissance du champ magnétique utilisé, l'IRM nécessite le respect de règles de sécurité strictes, notamment pour les patients porteurs de dispositifs métalliques (pacemaker, valves cardiaques mécaniques, etc.), pour lesquels l'examen est formellement contre-indiqué. Avant la réalisation de l'examen, un questionnaire de sécurité est systématiquement rempli pour prévenir tout risque [13].

5.2. Autres méthodes du diagnostic

En complément de l'imagerie médicale, certaines techniques biologiques sont également utilisées pour affiner le diagnostic et évaluer la dissémination tumorale.

5.2.1 Analyse du Liquide Céphalorachidien (LCR)

L'analyse du liquide céphalorachidien (LCR) est une méthode diagnostique importante pour certaines tumeurs cérébrales, en particulier dans le cas de suspicion de dissémination tumorale dans le système nerveux central ou d'atteinte des méninges. Elle consiste à prélever un échantillon de LCR par ponction lombaire pour une analyse biochimique, cytologique et parfois moléculaire [14].




Figure 1.13 : Cytopathologie du liquide de céphalorachidien

5.2.2 La Biopsie

La biopsie est une procédure médicale essentielle pour confirmer le diagnostic, la nature histologique et les caractéristiques moléculaires des tumeurs cérébrales. Elle consiste à prélever un échantillon du tissu tumoral en vue d'une analyse histopathologique, cytologique et, dans certains cas, moléculaire. Ces examens sont essentiels pour identifier le type exact de la tumeur, son grade selon la classification de l'OMS, ainsi que pour orienter la stratégie thérapeutique [15].

La procédure est réalisée au bloc opératoire, sous anesthésie locale ou générale, selon la localisation de la tumeur et l'état général du patient. Le neurochirurgien effectue d'abord une incision au niveau du cuir chevelu, puis réalise un trou de trépan dans l'os du crâne, d'un diamètre variant de quelques millimètres à deux centimètres, permettant d'accéder à la zone cérébrale cible. Le prélèvement est effectué à l'aide d'un système guidé, souvent assisté par imagerie stéréotaxique, pour garantir la précision et minimiser les risques [16].

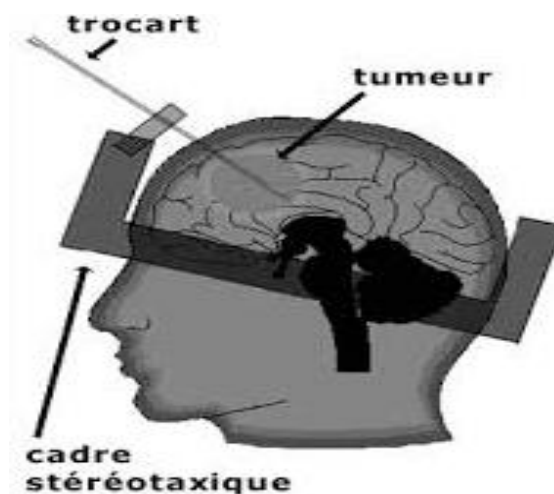


Figure 1.14 : Examen de biopsie cérébrale stéréotaxique

6. Conclusion

Dans ce chapitre, nous avons exploré les différents composants anatomiques et fonctionnelles du cerveau, ainsi que les différents types de tumeurs cérébrales et les méthodes diagnostiques associées. Parmi ces techniques, l'imagerie par résonance magnétique (IRM) occupe une place prépondérante, en raison de sa capacité à fournir des images détaillées, précises et non invasives des structures cérébrales. En complément, d'autres examens tels que le scanner (TDM), la biopsie cérébrale et l'analyse du liquide céphalorachidien (LCR) jouent également un rôle essentiel dans le processus diagnostique, en fournissant des informations cliniques et biologiques précieuses.

Le chapitre suivant sera consacré à l'état de l'art, en mettant l'accent sur les avancées technologiques récentes et les recherches actuelles portant sur la détection des tumeurs cérébrales à partir d'images IRM, notamment à travers l'intelligence artificielle et les approches de traitement d'images médicales.

*Chapitre 02 : Etat de l'art et principe
de l'apprentissage profond*

1. Introduction

L'imagerie médicale joue un rôle fondamental dans le diagnostic et le suivi des tumeurs cérébrales. La détection précoce de ces lésions à partir des images d'Imagerie par Résonance Magnétique (IRM) constitue une étape cruciale pour améliorer le traitement et augmenter les taux de survie des patients. Cependant, la détection manuelle des tumeurs sur ces images peut être difficile et complexe, nécessitant une expertise approfondie de la part des radiologues, ainsi qu'un temps d'analyse important.

Dans ce contexte, les techniques d'intelligence artificielle (IA), et en particulier l'apprentissage profond (deep learning), se sont imposées comme des outils révolutionnaires permettant une détection automatique des tumeurs cérébrales avec une grande précision, une efficacité accrue et une rapidité considérable. Ces avancées ouvrent des perspectives prometteuses pour améliorer la qualité du diagnostic, optimiser les plans de traitement personnalisés, et contribuer ainsi à une meilleure prise en charge des patients.

Ce chapitre est structuré en deux parties : la première présente un état de l'art des recherches récentes sur la classification des tumeurs cérébrales à partir des images IRM. Tandis que, la deuxième expose les principes du deep learning, en se concentrant notamment sur les réseaux de neurones convolutifs (CNN), leurs différentes couches, et les architectures couramment utilisées pour la classification automatique des images médicales.

2. Etat de l'art

Comme mentionné précédemment, les tumeurs cérébrales constituent une pathologie fréquente qui fait l'objet de nombreuses recherches. Ces études se concentrent notamment sur la détection automatique de ces lésions afin d'améliorer la précision et la rapidité du diagnostic. Les sections suivantes présenteront un état des lieux des travaux existants portant sur la détection des tumeurs cérébrales à partir d'images d'IRM.

B. Kokila et al. [17] ont utilisé l'apprentissage profond pour détecter et classifier les tumeurs cérébrales à partir d'images IRM. Leur approche multitâche combine un modèle U-Net pour la segmentation des tumeurs, avec un score Dice de 0,89, et un réseau ResNet34 pour la classification des types de tumeurs, atteignant une précision de 92 %. Cette méthode permet d'améliorer l'efficacité globale du système tout en réduisant la complexité computationnelle, notamment grâce à l'intégration conjointe des deux tâches dans un cadre unique, ce qui optimise l'apprentissage et le temps de traitement.

Ahmed S. Musallam et al. [18] ont développé un réseau de neurones convolutifs profonds (DCNN) pour la détection des tumeurs cérébrales à partir d'images IRM. Leur méthode intègre un prétraitement visant à améliorer la qualité des images, ainsi qu'une architecture optimisée pour la tâche. Le modèle atteint une précision de 98,22 %, surpassant les performances des architectures classiques telles que VGG16, VGG19 et le modèle CNN-SVM, tant en termes de rapidité que d'efficacité.

Neelum Noreen et al. [19] ont utilisé les architectures Inception-v3 et DenseNet201 pour extraire et combiner des caractéristiques multi-niveaux à partir d'images IRM. Leur approche atteint une précision de 99,34 % avec Inception-v3 et 99,51 % avec DenseNet201, surpassant ainsi les performances des méthodes existantes dans la classification des tumeurs cérébrales.

Muhammad Aamir et al. [20] ont amélioré l'analyse des images IRM en combinant EfficientNet-B0 et ResNet50 pour l'extraction des caractéristiques, ainsi qu'un clustering agglomératif pour la localisation des tumeurs. Leur approche a atteint une précision de 98,95 %, surpassant les méthodes existantes.

Soheila Saeedi et al. [21] ont développé un modèle basé sur un CNN 2D et un auto-encodeur pour l'analyse des images IRM. Le CNN 2D, comprenant huit couches de convolution, a atteint une précision de 96,47 %, surpassant l'auto-encodeur qui a obtenu 95,63 %, ainsi que les méthodes classiques telles que KNN et SVM.

Zheshu Jia et Deyun Chen [22] ont développé la méthode FAHS-SVM, qui combine une segmentation basée sur les ondelettes avec une classification utilisant un classificateur ELM-SVM. Cette approche a atteint une précision de 98,51 %.

P. Gokila Brindha et al. [23] ont combiné des réseaux de neurones artificiels (ANN) et des réseaux de neurones convolutifs (CNN) pour analyser les images IRM. Le modèle CNN a atteint une précision de 89 %, surpassant largement l'ANN qui a obtenu 65,21 %, grâce à sa capacité supérieure à extraire automatiquement des caractéristiques pertinentes à partir des images, conduisant à de meilleures performances globales.

Mahfujur Rahman [24] a utilisé plusieurs modèles, dont InceptionV3 et un réseau neuronal convolutionnel optimisé. Le modèle optimisé a atteint une précision de 96 %, tandis qu'une approche par ensemble a amélioré la robustesse globale, avec une précision de 93 %.

R. Preetha et al. [25] ont développé un modèle basé sur EfficientNet-B4 pour la détection des tumeurs cérébrales sur des images IRM. Leur approche a atteint une précision de 99,33 %, une sensibilité de 100 % et un F1-score de 99,34 %, démontrant une détection très fiable aussi bien des tumeurs que des cas normaux.

Andrés Anaya-Isaza et al. [26] ont proposé un modèle Cross-Transformer pour la détection des tumeurs cérébrales à partir d'images IRM. Leur approche, combinée avec le modèle InceptionResNetV2, a atteint une précision de 97 %. De plus, grâce à l'augmentation des données et à l'apprentissage par transfert, ils ont amélioré la performance de 6 %.

Ratha et al. [27] ont développé un modèle basé sur ResNet50 pour la détection des tumeurs cérébrales à partir d'images IRM, atteignant une précision de 97,35 %. L'utilisation de techniques d'augmentation des données a renforcé la généralisation du modèle, qui a obtenu des scores élevés en rappel et en F1-score, rendant cette approche particulièrement adaptée au diagnostic clinique.

M.S. Mithun et S. Joseph Jawhar [28] ont utilisé le modèle YOLO NAS pour détecter et classifier les tumeurs cérébrales sur des images IRM, atteignant une précision de 99,7 %. Leur approche comprenait un filtrage hybride pour améliorer la qualité des images et une segmentation par U-Net. Ils ont testé leur méthode sur le jeu de données REMBRANDT.

Ji-Hyeon Lee, Jung-Woo Chae et Hyun-Chong Cho [29] ont développé une méthode de classification des tumeurs cérébrales basée sur un système CADx (Computer-Aided Diagnosis) optimisé, atteignant une précision de 97,74 % et un score F1 de 97,75 %. Leur approche comprenait l'utilisation de filtres gaussiens pour le prétraitement des images ainsi que la technique Patterned-GridMask, utilisée comme méthode d'augmentation de données pour améliorer la robustesse et la généralisation du modèle.

Md. Naim Islam et al. [30] ont développé un modèle hybride d'apprentissage profond pour la détection des tumeurs cérébrales à partir d'images IRM, combinant des réseaux de neurones convolutifs (CNN) de 13 et 9 couches avec un modèle CNN-LSTM. En utilisant trois ensembles de données, leur approche a atteint une précision de 98,47 % avec le modèle CNN-LSTM, et 98,82 % avec une méthode d'apprentissage par ensemble, obtenant également une précision et un rappel de 99 %.

Bhumil Kukadiya [31] ont proposé une méthode basée sur des réseaux de neurones convolutifs (CNN) pour l'identification des tumeurs cérébrales. Leur approche utilisant un modèle d'ensemble a obtenu une précision de 98,2 %. Par ailleurs, le modèle Xception a atteint une précision de 97,3 %, avec une réduction notable des faux positifs, grâce à l'utilisation combinée de techniques d'augmentation de données et d'apprentissage par transfert.

C. Kishor Kumar Reddy et al. [32] ont proposé une méthode avancée pour la classification des tumeurs cérébrales à partir d'images IRM, basée sur des modèles Vision Transformer finement ajustés (FTVT). Leur approche a obtenu d'excellents résultats, atteignant une

précision de 98,70 % avec le modèle FTVT-116, surpassant ainsi d'autres architectures de deep learning populaires telles que ResNet50, MobileNetV2 et EfficientNet-B0.

Rezuana Haque et al. [33] ont développé NeuroNet19, un modèle de réseau de neurones profond spécialement conçu pour la classification des tumeurs cérébrales. Ce modèle a atteint une précision de 99,3 % ainsi qu'un F1-score de 99,20 %.

Mustafa Basthikodi et al. [34] ont appliqué un modèle SVM pour la classification multi-classes des tumeurs cérébrales, en utilisant des techniques d'extraction de caractéristiques telles que les motifs binaires locaux (LBP) et les histogrammes de gradients orientés (HOG). Ces caractéristiques ont été combinées à une réduction de dimensionnalité par analyse en composantes principales (ACP ou PCA). Le modèle a obtenu une performance globale de 96,03 % avec un F1-score de 96,00 %.

Mohammed Jajere Adam et al. [35] ont proposé un modèle hybride combinant MobileNetV2 pour l'extraction des caractéristiques et un classificateur SVM pour la classification des tumeurs cérébrales. Cette approche a permis une classification efficace, avec une précision de 99,1 % et un F1-score de 91,97 %.

3.L'intelligence artificielle

L'intelligence artificielle (IA) est un domaine visant à imiter l'intelligence humaine en développant et en appliquant des algorithmes exécutés dans des environnements informatiques dynamiques. Son objectif est de permettre aux ordinateurs de penser et d'agir de manière similaire aux êtres humains.

Pour atteindre cet objectif, trois composants sont essentiels :

- Des systèmes informatiques performants,
- Des données abondantes accompagnées de systèmes efficaces de gestion des données,
- Des algorithmes d'IA avancés (code) capables d'apprendre et de prendre des décisions.

Pour se rapprocher au maximum du comportement humain, l'intelligence artificielle nécessite une grande quantité de données ainsi qu'une capacité de calcul élevée [36].

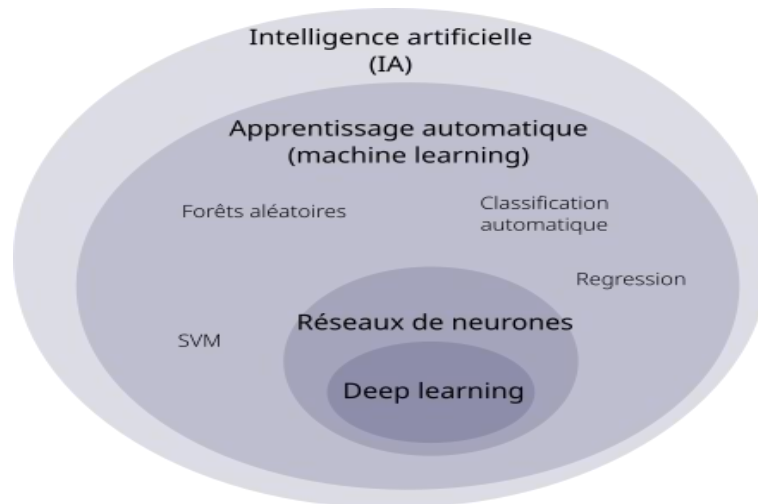


Figure 2.1: Relation entre l'intelligence artificielle, le machine learning et le deep learning

4.Apprentissage automatique

L'apprentissage automatique (ou machine learning) est un domaine de l'intelligence artificielle qui s'appuie sur des méthodes mathématiques et statistiques pour permettre aux ordinateurs d'apprendre à partir de données. Cela signifie qu'ils peuvent améliorer leurs performances dans la réalisation de tâches spécifiques sans être programmés explicitement pour chacune. Plus largement, ce domaine englobe la conception, l'analyse, l'optimisation, le développement et la mise en œuvre de ces méthodes.

Il existe deux types d'apprentissages automatique, classés selon le type de données utilisées :

L'apprentissage supervisé : c'est le plus simple et le plus utilisé en apprentissage automatique. Il est employé lorsque la classe ou la sortie de l'ensemble des données est prédéfinie par des experts. Les algorithmes d'apprentissage supervisé passent par deux étapes principales : l'apprentissage qui permet à un modèle d'entraîner et d'apprendre en utilisant une sous partie de la base de données étiquetée. Ensuite l'étape de test est entamée pour prédire la classe de nouvelles données à partir du modèle déjà entraîné et évaluer la capacité réelle de la méthode à identifier ces données.

L'apprentissage non-supervisé : Il est employé dans le cas où les données sont non étiquetées. Il consiste de regrouper un ensemble de points en classes selon un critère de similarité fixé à l'avance. Ce type d'apprentissage permet de construire automatiquement des classes sans avoir été explicitement informé des relations existantes dans les données. Une bonne technique de regroupement garantie une grande similarité intra-classe et une faible

similarité inter-classe. Il nécessite cependant un bon choix du nombre de classes et du critère de similarité. La classification non-supervisée est largement appliquée dans la segmentation en partitionnant l'image en régions homogènes selon une mesure de proximité.

L'apprentissage semi-supervisé : il s'agit d'une combinaison de l'apprentissage supervisé et non-supervisé. Il est utilisé lorsque le jeu de données contient une petite partie étiquetée et une grande partie non étiquetée. Les algorithmes d'apprentissage semi-supervisé utilisent des données étiquetées pour l'entraînement, puis exploitent les données non-étiquetées à l'aide de l'algorithme déjà entraîné [37].

5.Apprentissage profond

L'apprentissage profond (ou deep learning en anglais) est une branche de l'intelligence artificielle et plus précisément l'apprentissage automatique qui repose sur l'utilisation de réseaux de neurones artificiels convolutifs pour apprendre à partir de données. Ces réseaux sont des modèles mathématiques inspirés du fonctionnement du cerveau humain, composés de plusieurs couches de neurones interconnectés, capables de traiter et d'extraire des caractéristiques complexes des données.

L'apprentissage en profondeur permet de résoudre des problèmes complexes tels que la reconnaissance d'images, la traduction automatique, la reconnaissance vocale, etc ..., en utilisant des algorithmes d'apprentissage automatique pour entraîner ces réseaux à partir de grandes quantités de données [38].

6.Réseaux neuronaux convolutifs

Les réseaux de neurones convolutifs (Convolutional Neural Networks, CNN) sont une évolution des réseaux de neurones artificiels classiques, composés de plusieurs couches cachées. Ils sont constitués de couches interconnectées qui effectuent des traitements spécifiques, permettant d'apprendre des représentations hiérarchiques des données à différents niveaux d'abstraction.

Les neurones des couches inférieures détectent des caractéristiques simples et locales des données d'entrée (comme des contours ou des textures), tandis que ceux des couches supérieures combinent ces informations pour former des représentations plus abstraites et complexes, adaptées à des tâches telles que la reconnaissance d'objets.

Les CNN exploitent cette structure pour modéliser la complexité de grands ensembles de données. Ils sont entraînés grâce à l'algorithme de rétropropagation, qui ajuste les paramètres

internes (poids et biais) en fonction de l'erreur entre la sortie prédite et la sortie attendue, afin d'optimiser la représentation calculée à chaque couche à partir de la précédente.

Ils sont composés d'un empilement de différentes couches, parmi lesquelles les deux plus courantes sont la couche de convolution et la couche de pooling. La couche de convolution, élément central du CNN, applique un ensemble de petits filtres sur l'image d'entrée afin d'en extraire des caractéristiques pertinentes.

Cette couche est généralement suivie par une couche de pooling, qui a pour rôle de réduire la dimension spatiale de l'image tout en conservant les informations les plus importantes, ce qui permet de diminuer la complexité computationnelle et d'améliorer la robustesse du modèle.

Les premières couches de convolution détectent des caractéristiques simples, telles que des bords, des lignes et des textures, tandis que les couches plus profondes extraient des motifs plus complexes comme des formes et des objets spécifiques.

Après l'extraction des caractéristiques, la sortie de la dernière couche de convolution est aplatie en un vecteur de caractéristiques. Ce vecteur sert ensuite d'entrée à une ou plusieurs couches entièrement connectées (dense), qui effectuent la classification.

La dernière couche du réseau est souvent une couche de classification qui utilise une fonction d'activation (comme la fonction softmax) pour produire des probabilités associées aux différentes classes que le réseau doit reconnaître.

L'ensemble du réseau est entraîné via un algorithme de rétropropagation du gradient, qui ajuste les poids des connexions entre neurones afin de minimiser une fonction de perte, c'est-à-dire l'erreur entre les prédictions du modèle et les véritables étiquettes des données.

Dans la section suivante, nous allons fournir une description détaillée qui explique la fonction de chaque couche dans un réseau de neurones profond [37].

6.1. Les couches d'un CNN

Un CNN se constitue d'un ensemble de couches, spécialement conçues pour extraire des caractéristiques pertinentes à partir d'images. Chaque couche joue un rôle spécifique dans la transformation progressive des données. Il existe principalement quatre types de couches : la couche de convolution, la couche d'activation (ou fonction d'activation), la couche de pooling, et la couche entièrement connectée.

En complément, il existe d'autres couches utilisées selon les besoins, telles que la couche de déconvolution (ou convolution transposée), souvent employée dans les tâches de segmentation, la couche de normalisation (comme la batch normalization) pour stabiliser et

accélérer l'apprentissage, ainsi que la couche de régularisation (comme le dropout) pour réduire le surapprentissage [37].

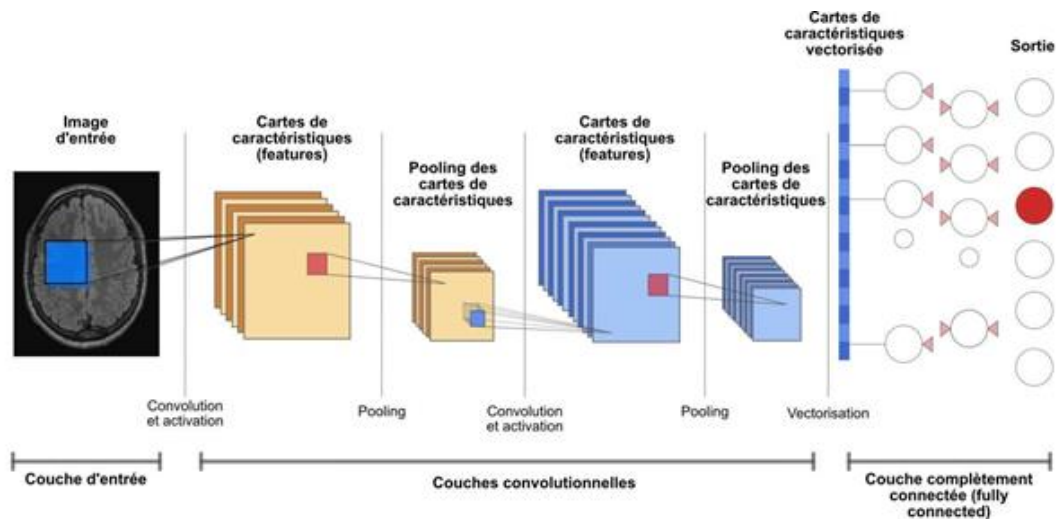


Figure 2.2 : Représentation des différentes couches de CNN

6.1.1 Couche de convolution (CONV)

C'est l'élément fondamental d'un réseau de neurones convolutifs (CNN) [37]. Elle est utilisée pour extraire un ensemble de caractéristiques locales à partir des images d'entrée en appliquant une série de filtres, souvent de petite taille, généralement de 3x3 ou 5x5. Pour chaque région de l'image, les coefficients du filtre sont multipliés par les valeurs correspondantes de l'image, puis les produits sont additionnés pour générer une nouvelle valeur. Cette valeur est enregistrée dans une nouvelle image appelée carte de caractéristiques (feature map en anglais).

La première couche de convolution capture les caractéristiques de bas niveau, telles que les contours et les textures simples, tandis que les couches suivantes extraient des caractéristiques de plus haut niveau, plus complexes. Ces cartes de caractéristiques sont ensuite utilisées comme entrées pour la couche suivante. Le but de cette opération est de détecter des motifs spécifiques dans l'image, tels que des lignes, des courbes ou des textures.

Les filtres sont des matrices de poids initialisés aléatoirement au début, puis mis à jour et optimisés au cours de l'entraînement du modèle pour mieux extraire les caractéristiques pertinentes des images et s'adapter aux données d'entraînement.

Pour chaque couche de convolution, quatre hyperparamètres doivent être définis au préalable : la taille des filtres, leur nombre, le pas (stride en anglais) et le remplissage par des zéros (zero padding en anglais).

- **La taille des filtres** : elle doit être inférieure à la taille de l'image d'entrée. Les filtres de petite taille, utilisés dans plusieurs couches de convolution empilées, ont tendance à mieux fonctionner que peu de couches avec des filtres plus grands. De plus, une augmentation de la taille du filtre entraîne une augmentation du temps d'apprentissage.
- **Le nombre de filtres** : il contrôle le nombre de cartes de caractéristiques produites pour une seule image d'entrée. Ce nombre correspond à la troisième dimension (profondeur) du volume de sortie. L'utilisation de plusieurs filtres différents permet d'extraire diverses caractéristiques au cours de l'entraînement. Les cartes générées peuvent ensuite être combinées pour obtenir une représentation plus riche et complexe de l'image.
- **Le pas (stride)** : c'est le nombre de pixels de décalage du filtre après chaque calcul. Il contrôle la manière dont le filtre se déplace sur l'image. Plus le pas est petit, plus la taille de la sortie est grande, car les zones couvertes par les filtres se chevauchent davantage. Inversement, un pas plus grand réduit la taille de la sortie.
- **Le remplissage par des zéros (zero padding)** : il consiste à ajouter des pixels nuls (zéros) sur les bords de l'image d'entrée afin de contrôler la taille des sorties. Ce paramètre permet notamment de conserver la même taille d'image après la convolution.

Tous ces paramètres doivent être choisis et fixés avec soin, car certaines valeurs permettent d'obtenir de meilleures performances et une convergence plus rapide du modèle .




Figure 2.3 : Représentation d'une opération de convolution avec une entrée de taille 4x4, un filtre de taille 3x3, et un pas de 1.

6.1.2 Fonctions d'activation

Après chaque couche de convolution, une fonction d'activation est appliquée aux valeurs de la carte des caractéristiques. Elle permet d'introduire de la non-linéarité dans le modèle, ce qui est essentiel pour modéliser des relations complexes entre les entrées et les sorties. Parmi

les fonctions d'activation les plus couramment utilisées, on trouve : la sigmoïde, la tangente hyperbolique (tanh), la ReLU (Rectified Linear Unit), la Leaky ReLU, ainsi que la Softmax.

- **Sigmoïde** : transforme les valeurs en un intervalle compris entre 0 et 1, avec une courbe en forme de S. Elle est souvent utilisée pour les sorties binaires ou probabilistes.
- **Tangente hyperbolique (tanh)** : transforme les valeurs en un intervalle compris entre -1 et 1, avec une courbe en forme de S centrée autour de zéro. Elle permet une meilleure convergence que la sigmoïde dans certains cas.
- **ReLU (Rectified Linear Unit)** : retourne zéro pour les valeurs négatives et conserve les valeurs positives, offrant une activation simple, efficace et favorisant la rapidité d'apprentissage.
- **Leaky ReLU** : variante améliorée de ReLU qui applique une petite pente constante aux valeurs négatives, évitant ainsi le problème des « neurones morts » (c'est-à-dire des neurones qui ne s'activent plus).
- **Softmax** : utilisée en couche de sortie, elle transforme les valeurs en probabilités normalisées qui somment à 1, ce qui est particulièrement utile pour la classification multi-classes [37].




Figure 2.4 : Représentation des courbes des fonctions d'activation

6.1.3 Couche de pooling (POOL)

Le pooling est une technique de sous-échantillonnage qui réduit la taille spatiale (hauteur et largeur) d'une image intermédiaire (carte de caractéristiques) tout en conservant les informations les plus importantes [37]. Cela permet de diminuer le nombre de paramètres et le temps de calcul dans le réseau. Le pooling est généralement ajouté juste après une couche de convolution pour limiter le sur-apprentissage et renforcer la robustesse du modèle.

Le principe du pooling consiste à diviser l'image d'entrée en petites fenêtres de taille $n \times n$ pixels, généralement non chevauchantes, puis à extraire une seule valeur représentative par fenêtre, selon le type de pooling choisi. La taille des fenêtres est souvent de 2×2 ou 3×3 pixels.

Il existe principalement deux types de pooling :

- **Max-pooling**, le plus couramment utilisé dans les CNN, qui conserve la valeur maximale de chaque fenêtre dans la carte des caractéristiques.
- **Average pooling**, qui conserve la valeur moyenne de chaque fenêtre.




Figure 2.5 : Représentation du fonctionnement de Max pooling et Average pooling

6.1.4 Couche entièrement connectée (FC)

C'est une couche d'un réseau de neurones où chaque neurone est connecté à tous les neurones de la couche précédente. Elle transforme ces connexions en un vecteur de sortie utilisé pour des tâches spécifiques telles que la classification ou la régression. Comme dans un réseau de neurones artificiels classique (ANN), chaque neurone de la couche FC est relié à tous les neurones de la couche précédente.

Le nombre de neurones dans cette couche est généralement déterminé par la taille du problème, par exemple le nombre de classes dans une tâche de classification. Cette couche est souvent suivie d'une fonction d'activation, comme la Softmax, qui normalise les sorties afin

de produire une distribution de probabilités sur les différentes classes possibles. La classe avec la probabilité la plus élevée est alors choisie comme prédiction finale du modèle [37].




Figure 2.6 : Représentation de couches entièrement connectées

6.1.5 Couche de normalisation

La couche de normalisation par lot (batch normalization en anglais) est une technique de régularisation largement utilisée en apprentissage profond pour accélérer la convergence et améliorer les performances des modèles. Cette couche est généralement placée entre la couche de convolution et la fonction d'activation. Elle normalise les entrées (activations) en calculant la moyenne et l'écart-type pour chaque mini-lot, plutôt que sur l'ensemble des données d'entraînement.

Cette normalisation réduit la sensibilité du modèle aux changements de distribution des entrées, stabilise le processus d'apprentissage et diminue considérablement le nombre d'époques nécessaires pour entraîner des réseaux profonds. La batch normalisation peut être combinée avec d'autres méthodes de régularisation, comme le dropout, afin d'améliorer la précision, renforcer la robustesse de l'initialisation des poids et réduire le sur-apprentissage [37].

6.1.6 Couche de Dropout

Le dropout est une technique de régularisation utilisée pour lutter contre le sur-apprentissage (overfitting) et améliorer l'apprentissage des réseaux de neurones profonds. Elle consiste à désactiver temporairement et aléatoirement, à chaque itération d'entraînement (ou époque), un certain nombre de neurones ainsi que toutes leurs connexions entrantes et sortantes, en les mettant à zéro.

Le nombre de neurones désactivés est déterminé par une probabilité prédéfinie, généralement notée p , qui varie entre 0 et 1 (souvent $p=0,5$). À chaque itération, chaque neurone a donc une probabilité p d'être désactivé, ce qui revient à entraîner un sous-ensemble différent du réseau à chaque fois. Cette approche permet d'entraîner implicitement plusieurs réseaux différents simultanément, réduisant ainsi les dépendances entre neurones et encourageant chacun à contribuer de manière utile à la représentation de l'information.

Lors de la phase de test, le dropout est désactivé : tous les neurones sont alors actifs, et leurs sorties sont pondérées pour compenser le déséquilibre introduit par le dropout durant l'entraînement [37].

7. Fonction de perte

Egalement appelée fonction d'erreur ou de coût, elle mesure la différence entre la sortie prédite par le modèle et la sortie réelle. Elle retourne une valeur scalaire représentant l'erreur moyenne du modèle sur les données d'entraînement. Cette erreur sert à évaluer la qualité des prédictions et à ajuster les paramètres du modèle via un algorithme d'optimisation, dans le but de minimiser cette erreur.

Il existe différents types de fonctions de perte, chacune adaptée à une tâche spécifique. Par exemple, l'erreur quadratique moyenne (Mean Squared Error, MSE) est couramment utilisée pour les problèmes de régression, tandis que la perte d'entropie croisée (cross-entropy loss) est employée pour les tâches de classification. La perte d'entropie croisée calcule la somme des erreurs en utilisant le logarithme, et est souvent associée à la fonction Softmax en dernière couche afin de transformer les sorties du réseau en une distribution de probabilités normalisées [37].

8. Les Algorithmes d'optimisation

Ils sont utilisés pour modifier les poids et les biais des neurones d'un réseau afin de réduire la fonction de perte. Ils jouent un rôle essentiel en apprentissage profond, car ils permettent de déterminer les paramètres optimaux qui améliorent les performances du modèle. Il existe de nombreux algorithmes d'optimisation, chacun avec ses caractéristiques propres, tels que la descente de gradient, la descente de gradient stochastique, la descente de gradient avec momentum et Adam.

Ces algorithmes reposent sur une méthode itérative appelée descente de gradient (Gradient Descent, GD), qui calcule le gradient de la fonction de coût sur l'ensemble des données et

ajuste successivement les paramètres dans la direction de la pente la plus forte, afin de converger vers un minimum (idéalement global). Un hyperparamètre clé à définir est le taux d'apprentissage, qui détermine la taille des pas effectués dans la direction du gradient [37].

- **Descente de gradient stochastique (Stochastic Gradient Descent, SGD)** : variante de la descente de gradient qui calcule le gradient et ajuste les poids pour chaque échantillon individuel des données d'entraînement. Cette méthode peut être plus rapide, mais peut aussi provoquer des oscillations et entraîner la convergence vers des minima locaux.
- **Descente de gradient stochastique avec momentum (Stochastic Gradient Descent with Momentum, SGDM)** : amélioration de la SGD qui introduit un terme de momentum. Ce terme combine les gradients précédents via une moyenne mobile, ce qui permet d'accélérer la convergence en donnant plus de poids aux directions cohérentes dans le temps. Ainsi, les mises à jour sont plus importantes lorsque la pente est forte, aidant à surmonter les ralentissements.
- **Adam (Adaptive Moment Estimation)** : méthode adaptative qui reprend l'idée de SGDM en conservant la moyenne mobile des gradients (moment d'ordre 1) et en ajoutant une moyenne mobile des gradients au carré (moment d'ordre 2). Cette double estimation permet d'ajuster automatiquement le taux d'apprentissage pour chaque paramètre, ce qui accélère la convergence et améliore l'efficacité de l'apprentissage. Grâce à ses performances robustes, Adam est l'un des optimisateurs les plus utilisés en apprentissage profond .

9. Les hyperparamètres en apprentissage profond

- **Taux d'apprentissage (learning rate)** : Définit la taille des ajustements apportés aux poids du modèle pendant l'entraînement. Un taux d'apprentissage trop élevé peut entraîner une divergence, tandis qu'un taux trop bas peut ralentir la convergence [39].
- **Nombre d'époques (epochs)** : Indique le nombre de fois que le modèle parcourt l'ensemble de données d'entraînement. Un nombre trop élevé d'époques peut entraîner un surapprentissage, tandis qu'un nombre trop faible peut empêcher le modèle d'apprendre efficacement [40].
- **Taille du lot (batch size)** : Nombre d'échantillons traités avant que le modèle ne mette à jour les poids. De petites tailles de lot peuvent offrir des estimations de gradient

broyantes, ce qui peut aider à échapper aux minima locaux, tandis que des tailles plus grandes peuvent stabiliser l'apprentissage [39].

- **Architecture du modèle** : Comprend le nombre de couches et de neurones dans chaque couche, influençant la capacité du modèle à apprendre des représentations complexes. Une architecture trop simple peut ne pas capturer la complexité des données, tandis qu'une architecture trop complexe peut entraîner un surapprentissage [40].
- **Régularisation** : Techniques utilisées pour éviter le surapprentissage, telles que la régularisation L1 ou L2, et le dropout. Ces méthodes aident à généraliser le modèle en pénalisant des poids excessifs ou en désactivant aléatoirement des neurones pendant l'entraînement [40].

10.Apprentissage par transfert (Transfer Learning TL)

Le transfert learning est une technique de deep learning dans laquelle un modèle pré-entraîné sur une tâche donnée est réutilisé et adapté pour une nouvelle tâche connexe. En effet, l'entraînement d'un nouveau modèle à partir de zéro est un processus long et coûteux, nécessitant d'importants volumes de données, une forte puissance de calcul et de nombreuses itérations avant d'être opérationnel en production [41]. Le transfert learning permet de gagner du temps et d'améliorer les performances en tirant parti des connaissances acquises lors d'un entraînement préalable sur des données similaires ou relatives.

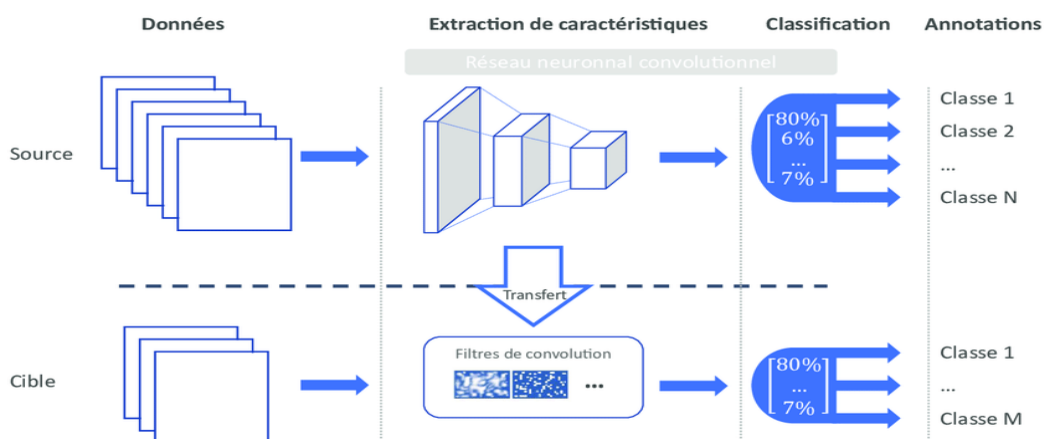


Figure 2.7 : Schéma représentation de transfert learning

11. Les architectures les plus performantes pour la classification d'images

11.1 ResNet50 (Residual Network 50)

Le modèle **ResNet50** est un réseau de neurones convolutionnels (CNN) appartenant à la famille des architectures **ResNet**, introduites par Kaiming He et ses collègues en 2015. Ce modèle est particulièrement reconnu pour sa capacité à entraîner des réseaux très profonds tout en évitant le problème de la dégradation des performances, souvent rencontré avec des architectures plus profondes.

ResNet50 comprend 50 couches, dont 48 couches de convolution, une couche de MaxPooling et une couche de pooling moyen (average pooling). Il utilise des **blocs résiduels** qui permettent à chaque couche d'apprendre une fonction résiduelle par rapport à l'identité, facilitant ainsi la propagation du gradient et améliorant la convergence du réseau [42].

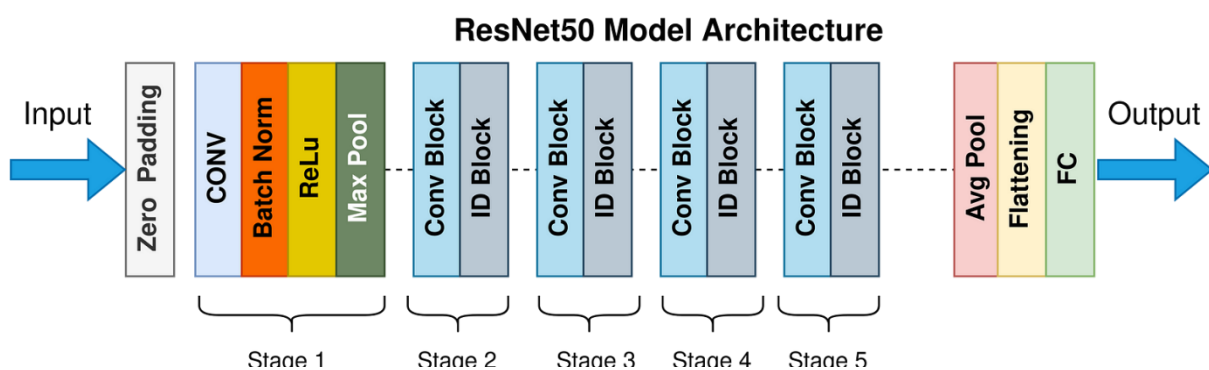


Figure2.8 : Architecture de ResNet50

11.2 EfficientNet-B0

EfficientNet-B0 est un modèle de réseau de neurones convolutionnels (CNN) composé de 237 couches. Il se distingue par son approche systématique visant à optimiser l'architecture du réseau en équilibrant simultanément la profondeur, la largeur et la résolution des images d'entrée. Développé par Mingxing Tan et Quoc V. Le en 2019, EfficientNet-B0 utilise une méthode de recherche automatisée (AutoML) pour déterminer la meilleure combinaison de ces trois dimensions, ce qui lui permet d'atteindre des performances de pointe tout en étant plus efficace en termes de nombre de paramètres et de consommation de puissance de calcul [43].

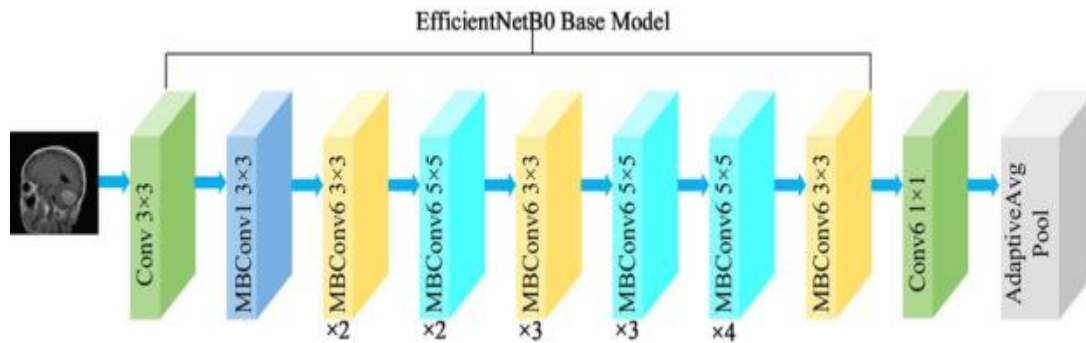


Figure 2.9 : Architecture de EfficientNeT-B0

12. Les Métriques d'évaluation

Les métriques d'évaluation sont des mesures quantitatives utilisées pour apprécier la performance d'un modèle, d'un algorithme ou d'un système. Elles permettent de comparer différentes approches ou configurations d'apprentissage d'un CNN. Ces mesures sont calculées en confrontant les valeurs prédites par le modèle aux valeurs réelles fournies par des experts. À partir de cette comparaison, divers paramètres sont déduits pour valider la pertinence des résultats et l'efficacité du modèle dans la résolution d'un problème donné. Parmi ces paramètres figurent les vrais positifs, faux positifs, vrais négatifs et faux négatifs [37].

- **L'exactitude (Accuracy)** : indique le pourcentage des cas correctement classés par rapport au nombre total des cas dans l'ensemble de données. Elle est calculée comme suit :

$$\text{Accuracy} = \frac{\text{vrais positifs} + \text{vrai négatifs}}{\text{vrais positifs} + \text{vrai négatifs} + \text{faux positifs} + \text{faux négatifs}}$$

- **Matrice de confusion** : La matrice de confusion est un tableau qui permet d'évaluer la performance d'un modèle de classification en comparant les prédictions du modèle avec les valeurs réelles. Elle représente les résultats de la classification en distinguant les vrais positifs, les vrais négatifs, les faux positifs et les faux négatifs [37].
 - **Vrais Positifs (TP)** : Nombre de cas positifs correctement identifiés.
 - **Faux Positifs (FP)** : Nombre de cas négatifs incorrectement classés comme positifs.
 - **Vrais Négatifs (TN)** : Nombre de cas négatifs correctement identifiés.

- **Faux Négatifs (FN):** Nombre de cas positifs incorrectement classés comme négatifs.
- **Rappel (ou sensibilité) :** Le rappel est une mesure qui indique la proportion de cas réels positifs, qui ont été correctement identifiés par un modèle. Un rappel élevé signifie que le modèle réussit à détecter la majorité des tumeurs positives, minimisant ainsi le risque de faux négatifs[37].

Le rappel (ou sensibilité) est calculé selon la formule suivante :

$$\text{Sensibilité} = \frac{\text{vrais positifs}}{\text{vrais positifs} + \text{faux Négatifs}}$$

- **Spécificité :** La spécificité est une mesure qui évalue la capacité d'un modèle à identifier correctement les cas négatifs. Elle indique la proportion de véritables négatifs qui ont été correctement classés par le modèle [37].

La spécificité est calculée selon la formule suivante :

$$\text{Spécificité} = \frac{\text{vrais Négatifs}}{\text{vrais Négatifs} + \text{faux positifs}}$$

- **F1 Score :** Le F1-Score est une mesure qui combine la précision et la sensibilité en une seule métrique, en prenant leur moyenne harmonique [37].

Il est calculé comme suit :

$$\text{F1 score} = 2 \times \frac{\text{précision} \times \text{Rappel}}{\text{précision} + \text{Rappel}}$$

13.Conclusion

Ce chapitre a synthétisé les avancées récentes majeures dans la littérature concernant la détection automatique des tumeurs cérébrales, en mettant en lumière les fondements de l'apprentissage profond ainsi que les différentes méthodes innovantes qui en découlent pour la détection et la classification. Cette revue exhaustive établit une base solide pour la compréhension des enjeux et des solutions actuelles dans ce domaine critique.

Le chapitre suivant dévoilera en détail les algorithmes que nous avons développés pour la classification des tumeurs cérébrales à partir d'images IRM, en exploitant pleinement le

potentiel de l'apprentissage profond. Nous y présenterons également une analyse approfondie des résultats obtenus, accompagnée d'une discussion comparative qui mettra en évidence les performances et les contributions de notre approche dans le contexte scientifique actuel.

***Chapitre03 :Classification des tumeurs
Cérébrales :Méthode et Résultats***

1. Introduction

La **classification des tumeurs cérébrales** constitue une étape cruciale dans le processus de diagnostic et de prise en charge thérapeutique. Une classification précise permet non seulement de différencier les types de tumeurs (bénignes, malignes, primitives, métastatiques), mais également d'adapter les stratégies thérapeutiques, d'évaluer le pronostic et d'améliorer la qualité de vie des patients. Toutefois, la nature hétérogène des tumeurs cérébrales et la complexité des images médicales posent un défi important aux cliniciens.

Dans ce contexte, les **avancées récentes en imagerie médicale** (IRM, TEP, scanner) associées à l'**intelligence artificielle**, en particulier au **Deep Learning**, ont ouvert de nouvelles perspectives. Ces technologies permettent de traiter un grand volume de données visuelles, d'**extraire automatiquement des caractéristiques discriminantes** et d'optimiser les performances de classification. Grâce à des réseaux de neurones profonds, il est désormais possible de détecter, segmenter et classifier les tumeurs avec un niveau de précision comparable, voire supérieur, à celui des experts humains dans certains cas. Parmi les architectures les plus prometteuses pour cette tâche, nous retrouverons notamment : **ResNet50, EfficientNetB0 et CNN (Convolutional Neural Network) classique.**

Ce chapitre se propose d'explorer en détail ces différentes approches de classification, en mettant l'accent sur leur architecture, leur mode de fonctionnement, la base de données utilisé, les performances obtenues (précision, rappel, F1-score, etc.) ainsi que les limites rencontrées. L'objectif est de fournir une vision complète de l'apport du Deep Learning dans le diagnostic automatisé des tumeurs cérébrales, tout en identifiant les pistes d'amélioration futures.

2. Python : Le langage de programmation utilisé

Python est un langage de programmation interprété, orienté objet et multiplateforme, largement utilisé dans le domaine de l'intelligence artificielle et de la science des données. Il favorise la programmation impérative et orientée objet, et se distingue par un typage dynamique fort, une gestion automatique de la mémoire ainsi qu'une portabilité élevée sur la plupart des systèmes d'exploitation. Grâce à sa syntaxe claire et concise, Python améliore considérablement la productivité des développeurs, tout en offrant des outils de haut niveau adaptés à des applications complexes [44].

Dans le cadre de notre étude, nous avons utilisé Python sur la plateforme Kaggle, qui fournit un environnement de développement en ligne puissant, intégrant des ressources matérielles performantes, notamment un GPU NVIDIA Tesla P100. Cette configuration permet de faciliter et d'accélérer l'entraînement de modèles d'intelligence artificielle, en particulier ceux reposant sur l'apprentissage profond.

Pour la mise en œuvre de nos modèles, nous avons eu recours à **TensorFlow**, une bibliothèque open source développée par Google, spécialement conçue pour la formation et l'inférence de réseaux de neurones profonds, facilitant le développement, l'optimisation et le déploiement des modèles [45].

3.Bases de données

Dans notre étude, nous avons utilisé la base de données **Brain_Tumor_MRI Scans** [46] dédiée à la classification multi-classes des tumeurs cérébrales. Cette base est accessible sur la plateforme **Kaggle**, contient **7 023 images IRM 2D avec JPEG**, réparties en quatre classes : **gliomes, méningiomes, tumeurs pituitaires, et cas normaux**. Les images sont soigneusement étiquetées, ce qui facilite l'entraînement de modèles d'intelligence artificielle. La présence à la fois de cas pathologiques (plusieurs types de tumeurs) et de cas sains permet au modèle d'apprendre non seulement à détecter une tumeur, mais aussi à en distinguer le type. Cela améliore la capacité du modèle à effectuer une **classification fine** et à **différencier les états pathologiques des états normaux**.

Cette base de données constitue une ressource précieuse pour les chercheurs et les professionnels de santé, car elle peut contribuer à améliorer la **précision du diagnostic** et à optimiser les **stratégies de traitement** des tumeurs cérébrales. La figure 3.1 ci-dessous présente le nombre d'images par classe.

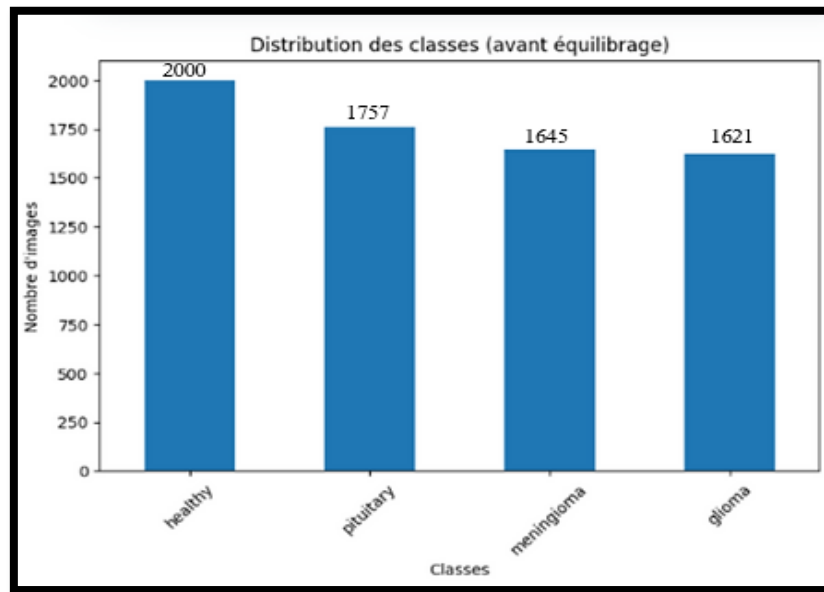




Figure 3.1 : Répartition des classes dans la base de données


La figure 3.2 suivante illustre un exemple d'image IRM pour chaque classe.




Gliome



Méningiome



Hypophysaire



Normal

Figure 3.2 :Exemples de quelques images IRM cérébrales de la base de données utilisée.

4.Méthode proposée pour la classification des tumeurs cérébrales

Dans le cadre de cette étude, nous avons développé **quatre systèmes distincts** pour la **classification automatique des tumeurs cérébrales**. Cette approche multi-modèle nous a permis d'atteindre des **résultats significatifs en termes de précision et de robustesse**. L'organigramme ci-dessous (figure 3.3) montre les **étapes clés du processus méthodologique** adopté, depuis la préparation des données jusqu'à l'évaluation des performances des modèles :



Figure 3.3 : schéma générale de notre méthodologie

Dans ce qui suit, **chaque étape du processus est décrite en détail.**

4.1 Prétraitement

L'étape de prétraitement a été appliquée de manière uniforme à l'ensemble des modèles utilisés dans cette étude, notamment ResNet50, EfficientNetB0 et un CNN classique. Elle joue un rôle essentiel dans la préparation des images avant leur utilisation dans l'entraînement des modèles de Deep Learning.

Dans un premier temps, toutes les images ont été redimensionnées à une taille standard de 128×128 pixels, afin de garantir une cohérence dimensionnelle entre les échantillons et de réduire la complexité computationnelle.

Ensuite, une étape de **normalisation** a été appliquée pour ramener les valeurs de pixels dans l'intervalle [0, 1], ce qui permet de stabiliser et d'accélérer le processus d'apprentissage. Cette opération est particulièrement importante dans les réseaux neuronaux, car elle permet d'éviter les écarts de distribution qui pourraient nuire à la convergence des modèles.

Ce prétraitement standardisé assure ainsi une meilleure efficacité du modèle, une réduction des biais liés à l'échelle des données et une amélioration de la généralisation lors de la phase de test.

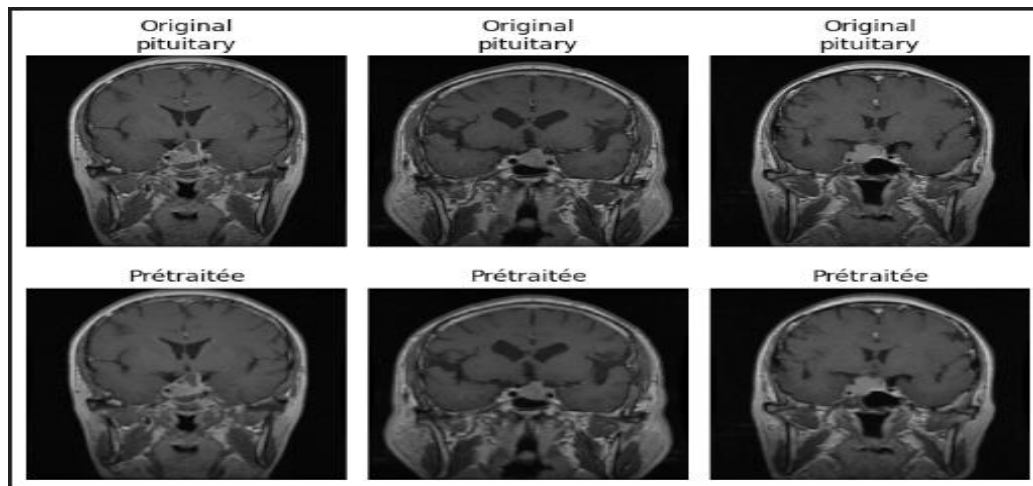


Figure 3.4 : Exemples des images traitées

Cette étape consiste à **s'assurer que chaque classe est représentée de manière équilibrée** dans les données, c'est-à-dire que toutes les classes ont un nombre d'exemples similaire. Cela permet d'**éviter les biais de classification** en faveur des classes majoritaires et contribue à **améliorer la performance et la fiabilité des modèles d'apprentissage automatique**.

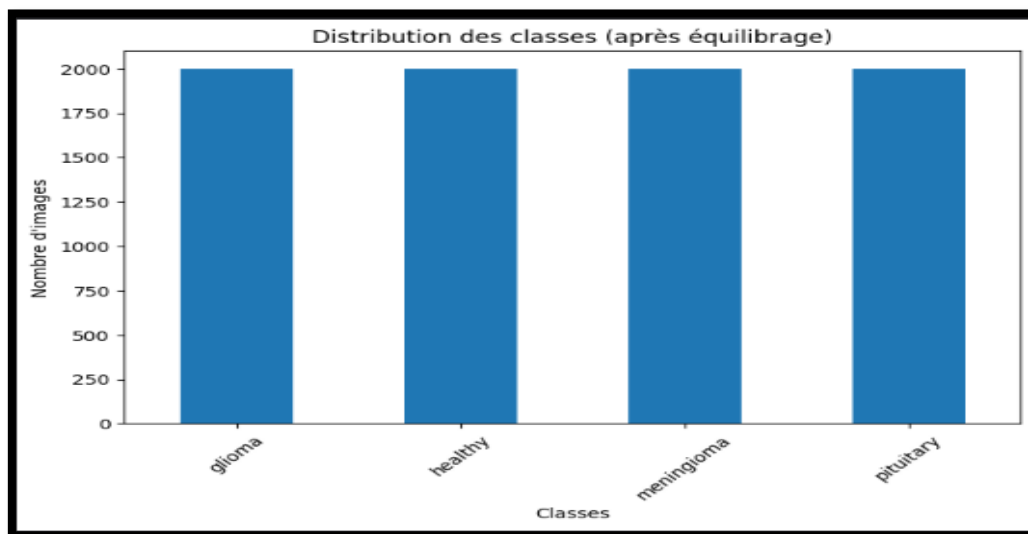


Figure3.5 : Répartition de chaque classe après l'équilibrage

Par ailleurs, dans le cadre de notre étude, les données ont été divisées en deux ensembles distincts : **80 % pour l'entraînement** et **20 % pour les tests (choix retenu pour notre étude)**, afin d'évaluer la performance des modèles de manière rigoureuse.

4.2 Augmentation des données

Pour **améliorer la qualité et la diversité de l'ensemble d'entraînement**, nous avons appliqué des techniques d'**augmentation des données** (*data augmentation*). Cette stratégie consiste à générer de nouvelles images à partir des images existantes en appliquant diverses **transformations géométriques**, notamment :

- **Rotation** aléatoire,
- **Décalage** horizontal et vertical (*shift*),
- **Zoom** avant ou arrière,
- **Retournement horizontal**.

Ces transformations permettent d'**enrichir artificiellement le jeu de données** sans en modifier la nature, ce qui aide le modèle à **généraliser davantage** et à **réduire le risque de surajustement (overfitting)**. En exposant le modèle à un plus large éventail de variations visuelles, on améliore sa capacité à reconnaître les tumeurs cérébrales dans des conditions réelles et variées.




Figure 3.6 : Image augmentée

4.3 Classification des tumeurs cérébrales

Dans la suite de cette étude, nous présentons en détail les différentes architectures de réseaux de neurones utilisées pour la classification des tumeurs cérébrales : **ResNet50**, **EfficientNetB0** et un **CNN classique**. Nous décrivons leur fonctionnement, les adaptations spécifiques réalisées, ainsi que les choix d'**hyperparamètres** qui ont permis d'optimiser leurs performances sur nos jeux de données.

4.3.1 Classification basée sur le modèle ResNet50

ResNet50 est un modèle de réseau de neurones convolutifs profond, reconnu pour sa précision et son efficacité dans la classification d'images. Il est composé de 50 couches convolutionnelles, avec des connexions résiduelles qui facilitent l'entraînement de réseaux

très profonds sur de grands ensembles de données, permettant d'atteindre des résultats significatifs.

Pour adapter ResNet50 à notre tâche de classification des tumeurs cérébrales, plusieurs modifications ont été apportées, notamment :

- Tout d'abord, la sortie du dernier bloc convolutionnel en 2D a été transformée en un vecteur 1D à l'aide d'une **couche Flatten**.
- Ensuite, une **couche Dense** de 512 neurones avec une fonction d'activation **ReLU** a été ajoutée pour introduire une non-linéarité et permettre l'apprentissage de représentations complexes.
- Une **couche de normalisation par lots (Batch Normalization)** a également été intégrée afin de stabiliser et d'accélérer l'entraînement en normalisant les activations.
- Pour réduire le risque de surapprentissage (*overfitting*), une **couche Dropout** avec un taux de 0,5 a été insérée, désactivant aléatoirement 50 % des neurones durant chaque itération d'entraînement.

Enfin, la **couche de sortie** est une couche Dense de 4 neurones, correspondant au nombre de classes à prédire, avec une fonction d'activation **Softmax** pour produire une distribution de probabilité sur ces classes.

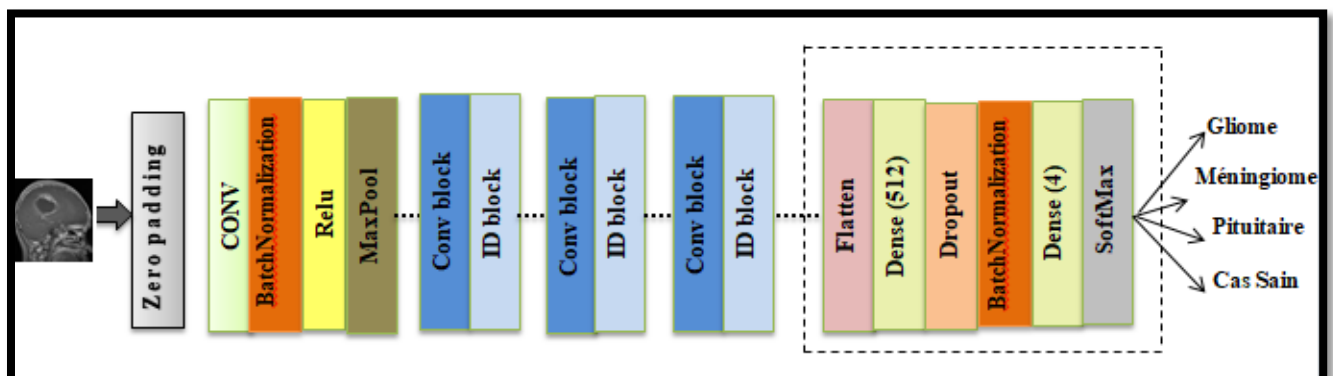


Figure 3.7 : Architecture de modèle ResNet50 modifiée

4.3.2 Classification basée sur le modèle EfficientNetB0

EfficientNetB0 est une architecture CNN optimisée qui offre de très bonnes performances tout en utilisant moins de paramètres comparativement à ResNet50, ce qui le rend plus léger et plus rapide à entraîner.

Dans notre modèle, nous avons procédé à quelques adaptations :

- La sortie du réseau a été convertie en vecteur 1D grâce à une **couche Flatten**.

- Une **couche Dropout** avec un taux de 0,5 a été ajoutée pour désactiver aléatoirement des neurones pendant l'entraînement, ce qui aide à prévenir le surapprentissage.
- Enfin, la couche de sortie est une **couche Dense** dont le nombre de neurones correspond au nombre de classes présentes dans notre base de données, suivie d'une activation **Softmax**. Cette configuration est adaptée à la classification multi-classes, comme pour le modèle ResNet50.

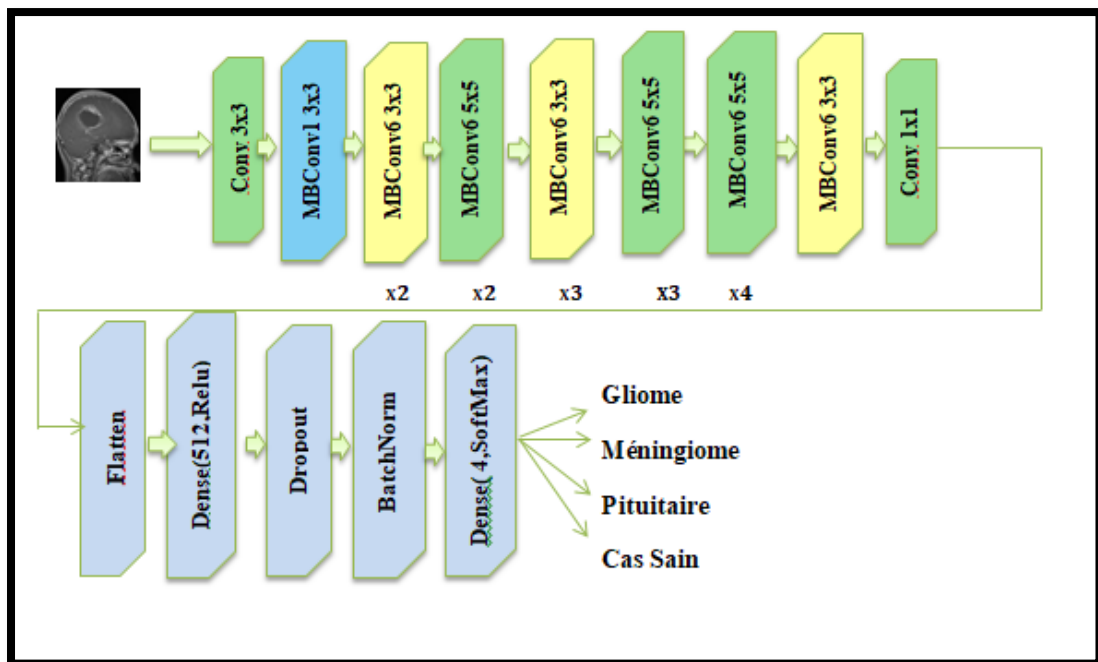


Figure 3.8 : Architecture du modèle EfficientNetB0 modifié

4.3.3 Classification basée sur le modèle CNN Classique

Le **CNN classique** est un type de réseau de neurones profond composé de plusieurs couches convolutionnelles et de couches de traitement intermédiaires. Pour l'adapter à notre étude, nous avons conçu un modèle comportant **trois blocs convolutionnels**, chacun suivi d'une fonction d'activation **ReLU**.

- **Couches convolutionnelles**

1. La première couche utilise **32 filtres de taille 3×3** pour extraire des caractéristiques de bas niveau.
2. La deuxième couche comporte **64 filtres de taille 3×3** afin de capturer des motifs plus complexes.
3. La troisième couche comprend **128 filtres de taille 3×3** pour extraire des caractéristiques encore plus complexes.

- **Couches de MaxPooling**

Après chaque couche convolutionnelle, une couche de **MaxPooling (2×2)** est ajoutée pour réduire la dimensionnalité des cartes de caractéristiques tout en conservant les informations importantes. Ainsi, trois couches de MaxPooling sont insérées dans le modèle.

- **Couche Flatten**

Cette couche convertit la sortie 2D issue des couches précédentes en un vecteur 1D, prêt à être traité par des couches entièrement connectées.

- **Couche Dense cachée**

Une couche dense de **128 neurones** est utilisée pour apprendre des combinaisons complexes des caractéristiques extraites et améliorer la qualité des prédictions.

- **Couche Dropout**

Un taux de **0,5** est appliqué pour désactiver aléatoirement la moitié des neurones pendant l'entraînement, ce qui permet de réduire le risque de surapprentissage (*overfitting*).

- **Couche Dense de sortie**

La couche finale contient **4 neurones**, correspondant aux 4 classes de notre problème, avec une fonction d'activation **Softmax** (à ajouter si ce n'est pas mentionné), adaptée à la classification multi-classes.

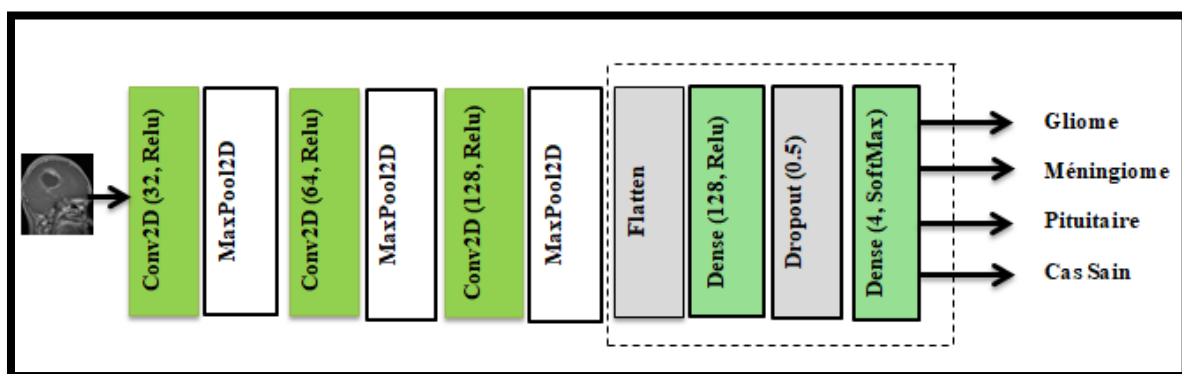


Figure 3.9 : Architecture du modèle CNN classique modifié

4.3.4 Les Hyperparamètres

Le Tableau 3.1 suivant résume les hyperparamètres fixés pour chaque modèle afin d'optimiser les performances des résultats.

Modèle	Taille de lot	Epoque	Taux d'erreur	Callbacks
CNN classique	32	25	0.005	-----
ResNet50	32	50	0.0038	<ul style="list-style-type: none"> ▪ EarlyStopping : patience 5 ▪ ModelCheckpoint
EfficientNetB0	32	50	0.015	<ul style="list-style-type: none"> ▪ EarlyStopping : patience 10 ▪ ReduceLROnplateau : patience 5

Tableau 3.1 : Représentation des métriques d'évaluation

5. Résultats et discussion

Dans le cadre de l'évaluation de nos modèles, nous avons analysé leurs performances dans deux contextes distincts : **sans augmentation des données** et **avec augmentation des données**. Après avoir obtenu les résultats pour ces deux configurations, nous avons également étudié l'impact de l'**équilibre des données** sur les performances, aussi bien en présence qu'en l'absence d'augmentation. Cette démarche nous a permis de mieux comprendre l'influence de ces prétraitements sur la qualité et la robustesse des modèles. Les tableaux suivants montrent la représentation des métriques d'évaluations de chaque modèles pour les images sans prétraitement (Tableau 3.2), et les images avec prétraitement (Tableau 3.3).

Modèle	Augmentation	Accuracy	Précision	F1-Score	Recall	Spécificité
ResNet50	Sans	98,72%	98,75%	98,50%	98,75%	99,75%
	Avec	96,80%	98,50%	98,50%	97%	99%
EfficientNetB0	Sans	98,77%	98,75%	99%	99%	99,75%
	Avec	98,29%	97,50%	97,25%	97%	99,25%
CNN classique	Sans	97,08%	97%	97%	98%	98,75%
	Avec	96,80%	96,75%	97%	94,50%	98,25%

Tableau 3.2 : Représentation des métriques d'évaluations de chaque modèle sans prétraitement

Modèle	Augmentation	Accuracy	Précision	F1-Score	Recall	Spécificité
ResNet50	Sans	99,31%	99%	99,25%	98,50%	99,50%
	Avec	99,62%	99,50%	99,75%	99,75%	100%
EfficientNetB0	Sans	98,50%	99,75%	99,50%	99,50%	100%
	Avec	98,37%	98,50%	98,25%	98,25%	99,50%
CNN classique	Sans	98,50%	99%	99,25%	98,50%	99,50%
	Avec	97,62%	99,50%	99,97%	99,75%	100%

Tableau 3.3 : Représentation des métriques d'évaluations de chaque modèle avec prétraitement

Les résultats présentés dans les tableaux mettent en évidence **l'importance de l'équilibrage des données** dans l'amélioration des performances des modèles de classification. **Sans équilibrage**, **l'augmentation des données seule** semble parfois entraîner une **baisse des performances**, probablement en raison d'un déséquilibre initial accentué par la génération de nouvelles images.

En revanche, **lorsque les données sont préalablement équilibrées**, la capacité des modèles à identifier correctement les différentes classes s'améliore de manière significative. Plus particulièrement, la **combinaison de l'équilibrage avec l'augmentation des données** permet au modèle **ResNet50** d'atteindre une **excellente performance**, avec un **taux de classification de 99,62 %**.

Cependant, pour les modèles **EfficientNetB0** et **CNN classique**, cette combinaison n'a pas conduit à une amélioration aussi marquée. Malgré cela, l'équilibrage des classes reste une **étape essentielle**, contribuant de manière significative à la stabilité et à la précision des résultats, même en l'absence d'augmentation.

Enfin, comme l'ont montré les résultats précédemment présentés, **ResNet50 s'est révélé être le modèle le plus performant** parmi ceux testés, surpassant EfficientNetB0 et le CNN classique en termes de précision et de capacité de généralisation.

- **Les Matrices de confusion**

- Ci-dessous sont présentées les **matrices de confusion** obtenues pour les images IRM **sans prétraitement** et **sans augmentation des données**. Ces matrices permettent d'évaluer la capacité des modèles à distinguer les différentes classes de tumeurs cérébrales dans des conditions de données brutes.

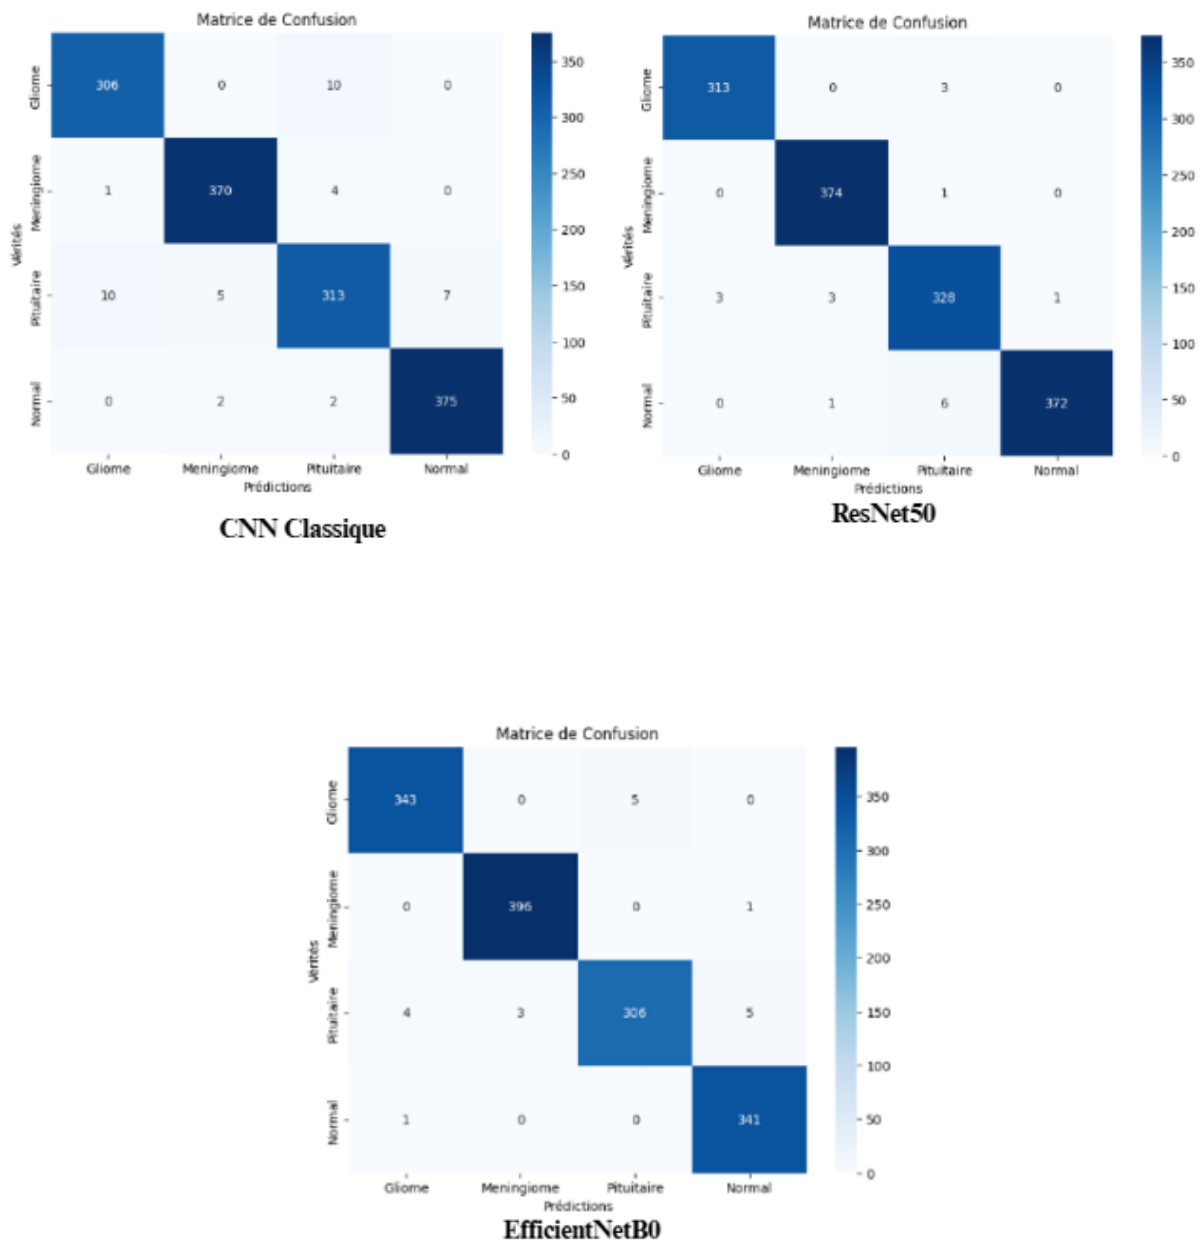


Figure 3.10 : Les matrices de confusions des modèles non traités et sans augmentation des données

- Les matrices de confusion suivantes illustrent les résultats obtenus après l'application de **techniques d'augmentation des données** sur les images IRM sans prétraitement. Elles permettent d'analyser l'impact de cette augmentation sur la **capacité des modèles à mieux distinguer les différentes classes**, en enrichissant l'ensemble d'entraînement par des variations d'images.

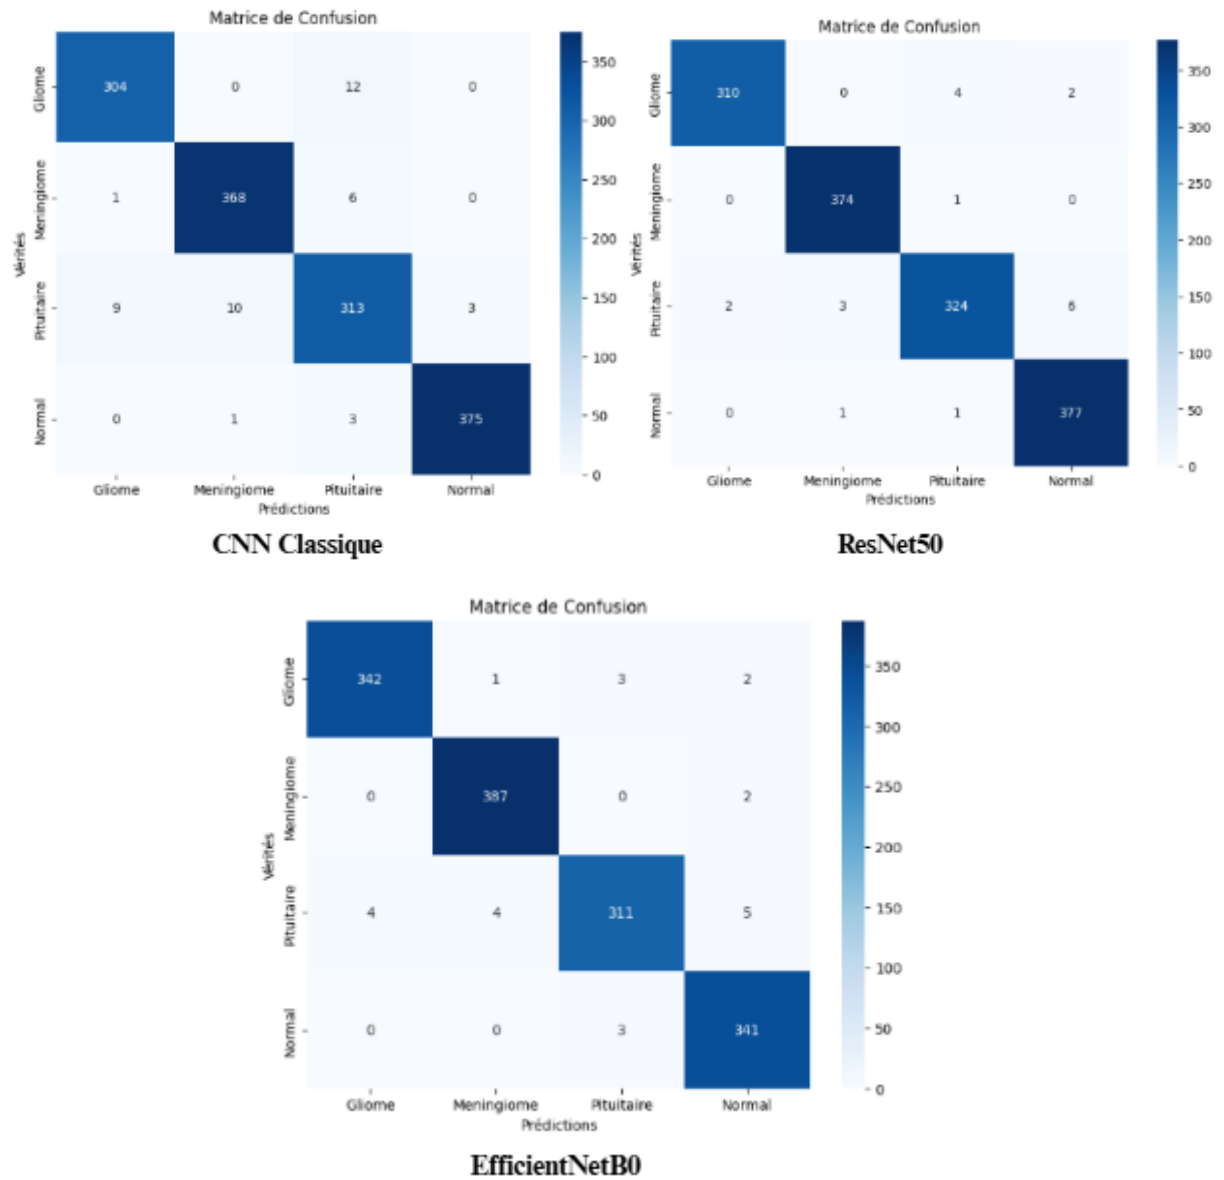


Figure 3.11 :Les matrices de confusions des modèles non traités avec augmentation des données

Interprétation des matrices de confusion :

Les images ci-dessous représentent les matrices de confusion des trois modèles utilisés pour la classification des tumeurs cérébrales. Ces matrices comparent les classes réelles aux classes prédites pour les quatre catégories : gliomes, méningiomes, tumeurs pituitaires et cas sains. La **diagonale** de la matrice correspond aux **vrais positifs**, c'est-à-dire les cas correctement classés. Les éléments **au-dessus** de la diagonale représentent les **faux négatifs** (cas mal classés comme appartenant à une autre classe), tandis que ceux **en dessous** indiquent les **faux positifs** (autres classes incorrectement attribuées à celle-ci).

En comparant les résultats avec et sans augmentation des données, on observe que :

- Les **gliomes** étaient déjà bien classés sans augmentation, et les performances sont restées stables après augmentation, avec une légère réduction des confusions avec les tumeurs pituitaires.
- Les **méningiomes** étaient également bien identifiés sans augmentation, mais ont montré une amélioration notable après l'augmentation des données.
- Les **tumeurs pituitaires** constituaient la classe la plus difficile à classer sans augmentation, notamment à cause de confusions fréquentes avec les gliomes. L'augmentation des données a permis d'améliorer sensiblement la classification de cette catégorie.
- Enfin, les **cas sains** ont été correctement identifiés dans les deux cas.

Ces résultats soulignent l'intérêt de l'augmentation des données, notamment pour les classes initialement les moins bien reconnues.

➤ Nous présentons à présent les **matrices de confusion** obtenues à partir des **images IRM prétraitées**, mais **sans application de techniques d'augmentation des données**. Le prétraitement inclut notamment le redimensionnement, la normalisation et l'équilibrage éventuel des classes. Ces matrices permettent d'analyser la performance des modèles dans un contexte où les données ont été nettoyées et standardisées, mais sans enrichissement artificiel. Elles offrent une vision plus précise de l'impact du **prétraitement seul** sur la capacité des modèles à **reconnaître correctement les différentes classes de tumeurs cérébrales**.

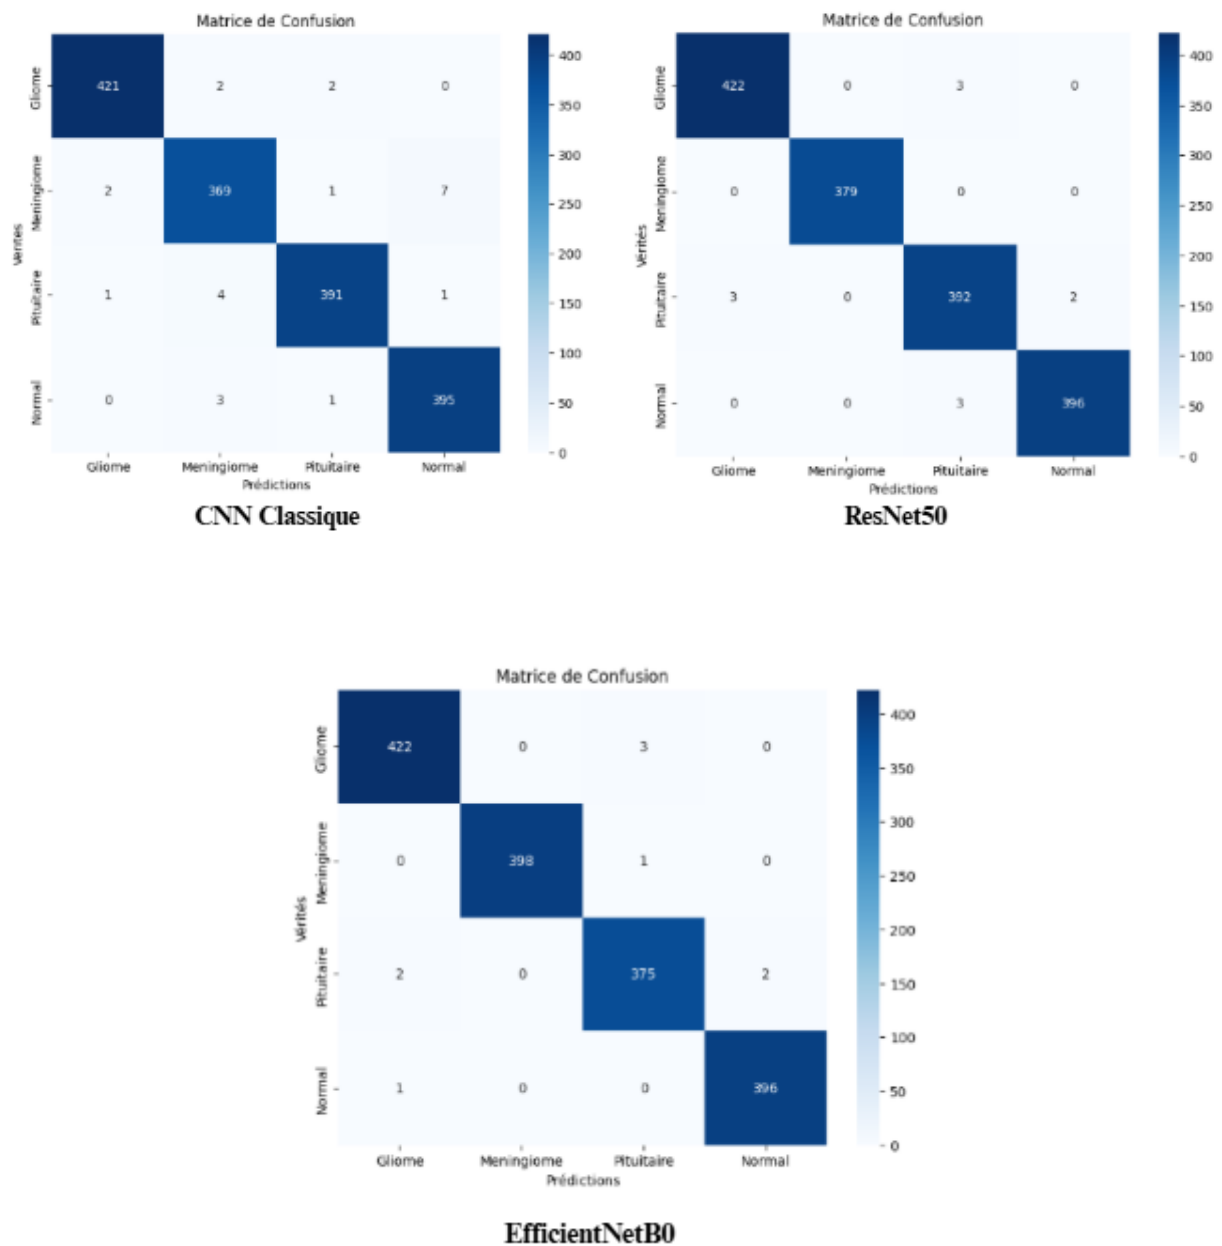


Figure 3.12 : Les matrices de confusions des modèles traités et sans augmentation des données

- Enfin, les **matrices de confusion suivantes** correspondent aux résultats obtenus à partir des **images IRM prétraitées** et ayant subi une **augmentation des données**. Cette configuration combine les avantages du **prétraitement standardisé** (redimensionnement, normalisation, équilibrage) avec ceux de l'**enrichissement des données** via des transformations (rotation, zoom, décalage, etc.). Elle permet d'évaluer la **performance optimale** des modèles dans des conditions d'apprentissage améliorées, en fournissant une

diversité d'exemples tout en conservant des données bien structurées. Ces matrices permettent ainsi d'observer **l'impact combiné** de ces deux étapes sur la capacité des modèles à classifier correctement les différents types de tumeurs cérébrales.

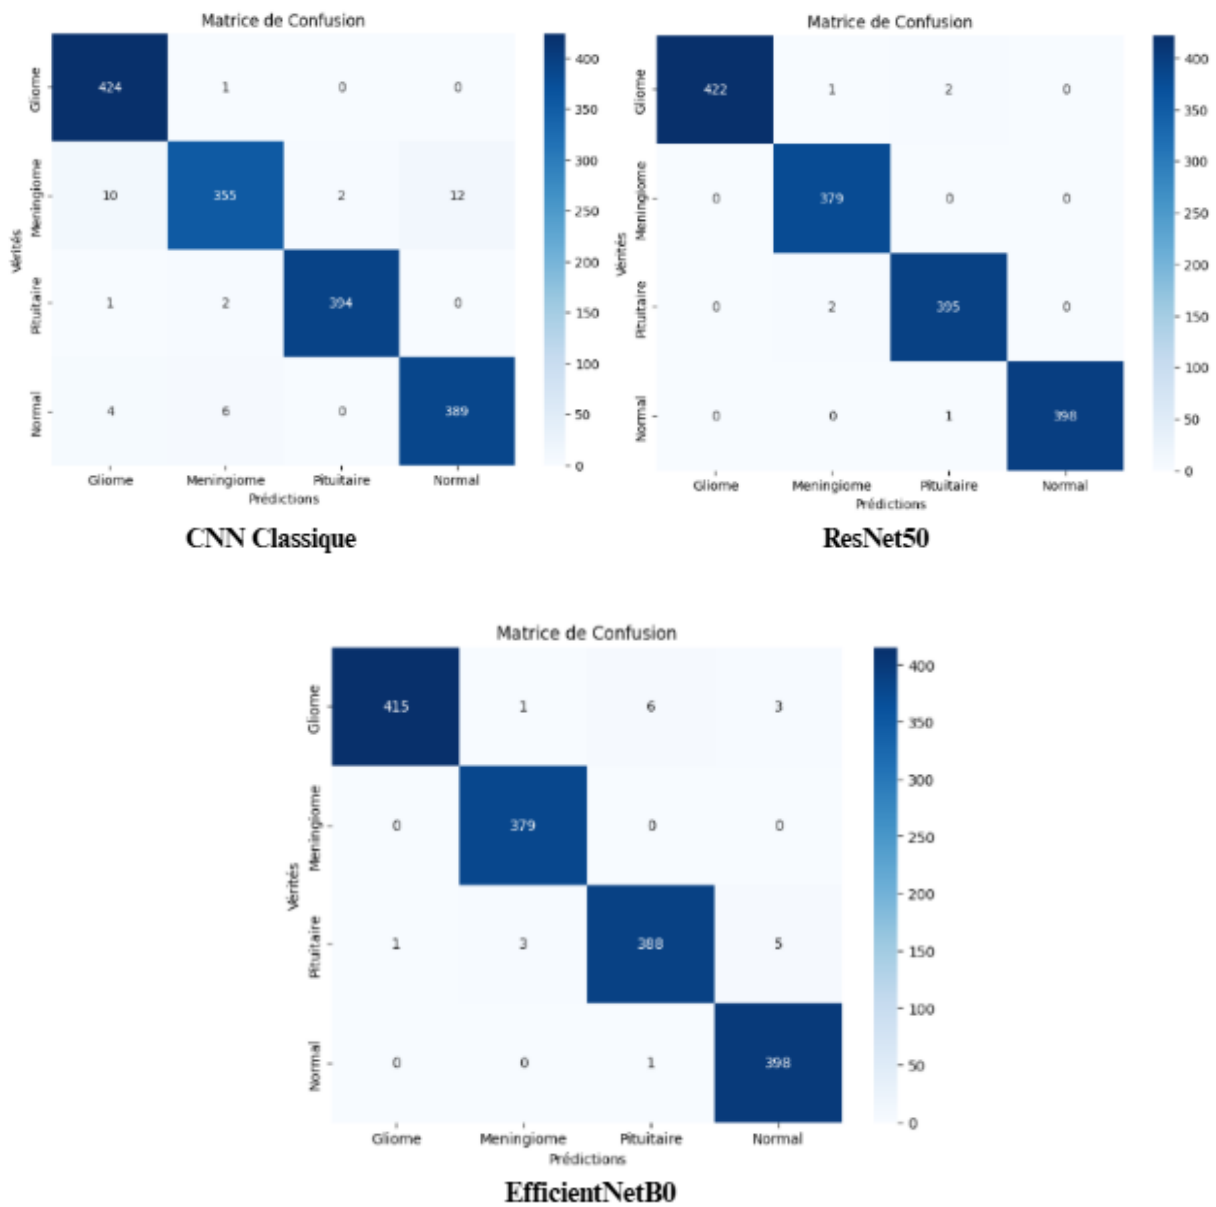


Figure 3.13 : Les matrices de confusions des modèles traités et Avec augmentation des données

Interprétation des matrices de confusion

Les résultats obtenus à travers les **matrices de confusion** permettent de comparer les performances des modèles **avec et sans augmentation des données**.

Les **gliomes** ont été globalement bien classés dans les deux configurations, bien que l'on observe quelques **confusions récurrentes avec les tumeurs pituitaires**, et dans une moindre mesure, avec les **méningiomes**.


Les **méningiomes** ont également montré de bonnes performances globales, mais présentent une **confusion plus marquée avec les tumeurs pituitaires**, notamment sans augmentation.

Concernant les **tumeurs pituitaires**, elles constituent la classe la plus difficile à classer **sans augmentation**, avec des **confusions fréquentes avec les méningiomes**. Cependant, **après l'augmentation des données**, une **amélioration significative** de leur classification a été constatée.

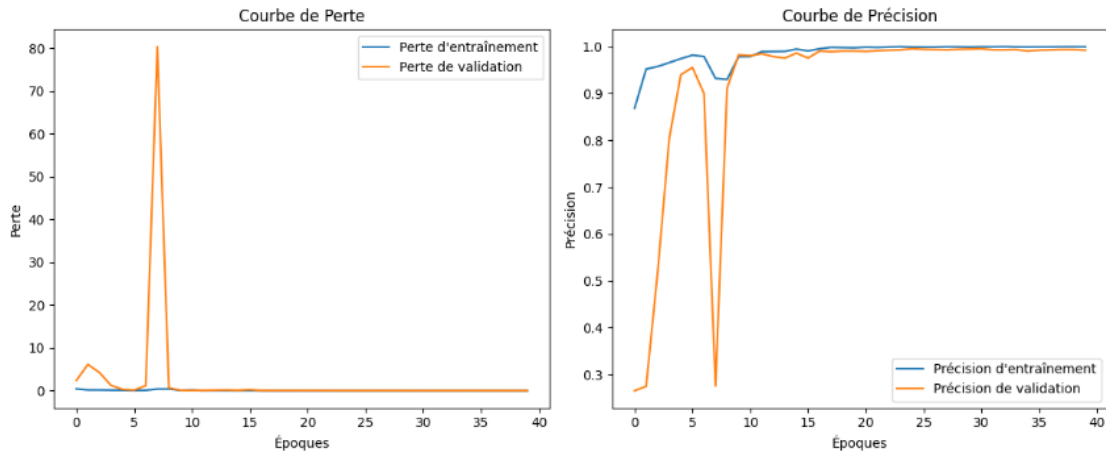
Enfin, les **cas sains** sont correctement reconnus dans toutes les configurations, avec seulement quelques erreurs isolées, principalement vers les classes des gliomes ou des méningiomes.

- **Les courbes de performances**


Les **figures suivantes** illustrent les **courbes de performance** des modèles appliqués aux images IRM dans deux configurations différentes. La **figure 3.14** présente les courbes obtenues **sans prétraitement ni augmentation des données**, tandis que la **figure 3.15** montre les performances **après application de techniques d'augmentation des données**. Ces courbes permettent d'analyser visuellement l'évolution de la **précision (accuracy)** et de la **perte (loss)** au cours de l'entraînement et de la validation, et ainsi de mieux évaluer l'impact de l'augmentation sur la qualité de l'apprentissage.



ResNet50




EfficientNetB0



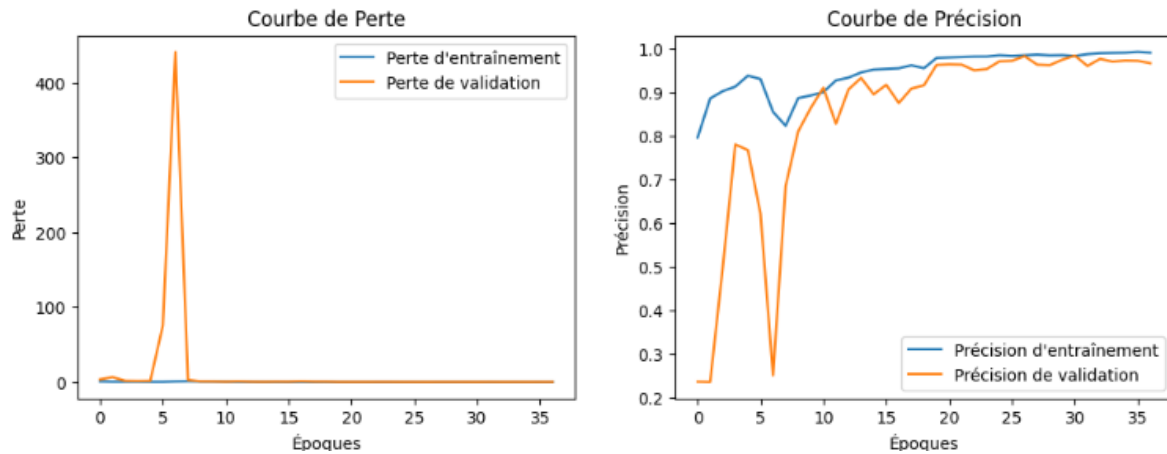
CNN Classique

Figure 3.14 : Les courbes de performances des modèles traités et sans augmentation des données


- **Images IRM sans prétraitement et Avec augmentation de données**



ResNet50



EfficientNetB0



CNN Classique

Figure 3.15 : Les courbes de performances des modèles traités et avec augmentation des données

Les **trois modèles** testés présentent dans l'ensemble de **bonnes performances**, sans signe apparent de **surapprentissage (overfitting)**.

Sans augmentation des données, le modèle **ResNet50** affiche une **diminution rapide de la perte** et une **précision de validation** qui se rapproche rapidement de 1, ce qui témoigne d'un **apprentissage efficace**. Lorsque l'**augmentation des données** est appliquée, ses performances deviennent **plus stables**, et sa **capacité de généralisation** s'améliore visiblement.

En ce qui concerne **EfficientNetB0**, sans augmentation, la **courbe de perte est instable** au début de l'entraînement, tandis qu'une **précision de validation très élevée** peut indiquer une **trop forte adaptation aux données d'entraînement**, voire un début de surapprentissage. L'ajout d'une augmentation des données contribue à **régulariser l'apprentissage**.

Enfin, le **CNN classique**, même sans augmentation, montre une **grande stabilité**, avec une perte qui diminue régulièrement et une précision de validation qui se **stabilise rapidement autour de 1**, signe d'une **excellente performance** sur cet ensemble de données.

Ainsi, l'**augmentation des données** permet dans tous les cas d'**améliorer la stabilité** de l'apprentissage et d'**éviter les fluctuations** des courbes, contribuant ainsi à une meilleure robustesse des modèles.

Évaluation des Prédictions sur la Base de Test

Nous avons testé nos modèles en effectuant des prédictions sur un échantillon d'images issues de la base de test. Globalement, les résultats obtenus sont satisfaisants, la majorité des images ayant été correctement classifiées. Cela indique que les trois modèles disposent de bonnes capacités de généralisation et d'identification des différents types de tumeurs cérébrales. Bien que les performances soient généralement élevées, certains cas demeurent difficiles à classer pour les modèles. Nous travaillons actuellement à corriger ces erreurs afin d'améliorer la fiabilité et la précision de nos systèmes de classification des tumeurs cérébrales.




Figure 3.16 : prédictions des tumeurs cérébrales avec les niveaux de confiance associés de modèle ResNet50




Figure 3.17 : prédictions des tumeurs cérébrales avec les niveaux de confiance associés de modèle EfficientNetB0




Figure 3.18 : Prédications des tumeurs cérébrales avec les niveaux de confiance associés de modèle CNN classique

Comparaison de nos résultats avec l'état de l'art

Le tableau suivant représente une comparaison du taux de classification, et du le F1-score obtenus par des études récentes avec notre approche.

Méthode	Taux de classification	F1-Score
C Kishor Kumar Reddy et Al (2024) [32]	98,70%	98,70%
Mahfujur Rahman et Al (2025) [24]	96%	80,2%
Mustafa Basthikodi et Al (2024)[34]	96,03%	96%
Rezuana Haque et Al(2024)[33]	99,30%	99,20%
Notre travaille	99,62%	99,75%

Tableau 3.4 : Comparaison de nos méthodes de classification avec l'état de l'art

Plusieurs recherches récentes ont démontré l'efficacité des méthodes d'**apprentissage profond** pour la **détection et la classification des tumeurs cérébrales**.

Mahfujur Rahman et al. [24] ont proposé une méthode basée sur une **architecture CNN optimisée**, atteignant un **taux de classification de 96 %** et un **F1-Score de 80,20 %**. De leur côté, **Mustafa Basthikodi et al. [34]** ont appliqué un **modèle SVM** combiné à des techniques d'extraction de caractéristiques telles que les **motifs binaires locaux (LBP)** et les

histogrammes de gradients orientés (HOG), avec une **réduction de dimensionnalité par ACP (PCA)**. Leur approche a permis d'atteindre une performance notable de **96,03 % de précision** et un **F1-Score de 96 %**.

Par ailleurs, **C. Kishor Kumar Reddy et al. [32]** ont utilisé un modèle fondé sur le **Vision Transformer (ViT)**, avec un **taux de classification et un F1-Score atteignant 98,70 %**. De même, **Rezuana Haque et al. [33]** ont employé le modèle **NeuroNet19**, qui a permis d'obtenir un **taux de classification de 99,30 %** et un **F1-Score de 99,20 %**.

Dans notre travail, nous avons cherché à **améliorer davantage ces résultats** en combinant des **techniques avancées de prétraitement, d'augmentation des données et d'équilibrage des classes**, afin d'adapter au mieux nos modèles aux caractéristiques spécifiques de notre jeu de données. Grâce à ces améliorations, notre modèle basé sur **ResNet50** a atteint un **taux de classification de 99,62 %**, surpassant ainsi plusieurs approches existantes. Ces résultats très favorables confirment l'efficacité de notre méthode dans le contexte de la **classification automatique des tumeurs cérébrales**.

6. Conclusion

Dans ce chapitre, nous avons présenté notre approche proposée pour la classification automatique des tumeurs cérébrales à partir d'images IRM, en exploitant la puissance de l'apprentissage profond. Plusieurs modèles ont été étudiés, notamment ResNet50, EfficientNetB0 et un CNN classique, en tenant compte de différentes configurations : avec ou sans prétraitement, augmentation et équilibrage des données.

Les résultats expérimentaux ont montré que les étapes de prétraitement et d'augmentation ont un impact significatif sur la stabilité et la performance des modèles, en particulier pour les classes les plus difficiles à distinguer. Le modèle ResNet50 s'est distingué par sa capacité de généralisation, atteignant un taux de classification de 99,62 %, ce qui le positionne favorablement par rapport aux travaux récents de l'état de l'art.

Ces résultats confirment l'intérêt des architectures profondes combinées à un traitement rigoureux des données pour améliorer la détection des tumeurs cérébrales et ouvrent la voie à de futures améliorations en vue d'une intégration clinique.

Conclusion général

Ce travail a mis en évidence l'intérêt croissant de l'intelligence artificielle, en particulier de l'apprentissage profond, dans le domaine de l'imagerie médicale appliquée au diagnostic des tumeurs cérébrales. À travers une étude comparative de plusieurs modèles (CNN, EfficientNetB0 et ResNet50), nous avons démontré que l'automatisation de la classification des tumeurs à partir d'images IRM est non seulement possible, mais aussi très prometteuse en termes de précision, de rapidité et de fiabilité. Le modèle ResNet50 s'est avéré le plus performant, atteignant un taux de précision remarquable de 99,62 %, confirmant ainsi sa robustesse dans ce type de tâche.

Notre mémoire s'est articulé autour de trois volets complémentaires : la compréhension médicale des tumeurs et des méthodes de diagnostic actuelles, l'approche algorithmique basée sur les réseaux neuronaux profonds, et enfin l'expérimentation concrète à partir de données réelles. Ce croisement entre domaine médical et intelligence artificielle illustre la richesse d'une approche pluridisciplinaire dans la résolution de problématiques complexes.

Toutefois, des pistes d'amélioration subsistent. Il serait pertinent d'explorer des techniques comme l'apprentissage par transfert ou le réglage fin pour optimiser davantage les performances. L'enrichissement des jeux de données, notamment à travers la constitution de bases locales reflétant mieux le contexte clinique algérien, permettrait également de rendre les modèles plus robustes et adaptés à la réalité du terrain. L'intégration de ces modèles dans des outils cliniques temps réel, l'ajout d'autres modalités médicales (CT scan, données patient) et le développement de systèmes hybrides multimodaux pourraient considérablement enrichir l'aide au diagnostic.

Enfin, la réussite de ce type de solution dépendra fortement d'une collaboration étroite entre ingénieurs et professionnels de la santé, ainsi que de la formation du personnel médical à ces nouvelles technologies. Ce travail n'est donc pas une fin en soi, mais une base solide vers des systèmes intelligents, accessibles et efficaces pour renforcer la médecine de demain.

Les Références

- [1]: International Agency for Research on Cancer. (2024). Algeria : GLOBOCAN 2022 fact sheet. Global Cancer Observatory.
- [2] : Ghomari C., Recueil de Neurologie (GC), 3^e édition, 2022.
- [3] : Brain Tumour Foundation of Canada, “Adénomes hypophysaires,” [En ligne]. Disponible sur: http://braintumour.ca/fr/types_de_tumeurs_cerebrales/adenomes-hypophysaires/. [Consulté le: 13 février 2025].
- [4] : Kenhub, “Hypophyse (glande pituitaire),” [En ligne]. Disponible sur: <https://www.kenhub.com/fr/library/anatomie/hypophyse-glande-pituitaire>. [Consulté le: 13 février 2025].
- [5]: Institut National du Cancer (INCa), Les tumeurs cérébrales : Types de tumeurs, [En ligne]. Disponible sur: <https://www.e-cancer.fr/...> [Consulté le: 26 janvier 2025].
- [6] : Elsan Santé, “Méningiome : définition et traitements,” [En ligne]. Disponible sur: <https://www.elsan.care/...> [Consulté le: 24 janvier 2025].
- [7] : ameli.fr, “Méningiome : définition et causes,” mis à jour le 1 juillet 2024.
- [8] : Hoang-Xuan K., Peyre M., Feuvret L., Les Cancers du cerveau, Fondation ARC, coll. Comprendre et agir, 1^{er} tirage, mai 2015.
- [9] : NCBI, Brain Tumours, dans : Neuro-oncology, [En ligne]. Disponible sur: <https://www.ncbi.nlm.nih.gov/books/NBK441874/>. [Consulté le: 25 janvier 2025].
- [10] : Mayo Clinic, “Glioma – Symptoms & Causes,” [En ligne]. Disponible sur: <https://www.mayoclinic.org/diseases-conditions/glioma/...> [Consulté le: 25 janvier 2025].
- [11] : NYU Langone / StayWell, [En ligne]. Disponible sur: <https://nyulangoneib.staywellsolutionsonline.com>. [Consulté le: 13 février 2025].
- [12] : Mekki A., Saadoun A., Fusion hybride des images médicales par la transformée en bandelette couplé avec le PCNN, Mémoire de Master, Université Abou Bekr Belkaid – Tlemcen, 2015.
- [13] : Chergui Y., Boussaha C., Détection des anomalies par segmentation des images médicales cérébrales, Mémoire, Université Ibn Khaldoun – Tiaret, 2022.
- [14]: Berger M., Prados M. D., “Cerebrospinal Fluid in the Diagnosis of Brain Tumors,” *Clinical Neuro-Oncology*, vol. 8, no. 2, pp. 245–250, 2018.
- [15]: Louis D. N., et al., WHO Classification of Tumors of the Central Nervous System, IARC Press, 2021.
- [16] : Institut National du Cancer (INCa), “Biopsie des tumeurs cérébrales,” [En ligne]. Disponible sur: <https://www.e-cancer.fr/...> [Consulté le: 26 janvier 2025].
- [17]: B. Kokila, M. S. Devadharshini, A. Anitha, and S. A. Sankar, “Brain Tumor Detection and Classification Using Deep Learning Techniques Based on MRI Images,” *Journal of Physics: Conference Series*, vol. 1916, no. 1, Art. no. 012226, May 2021, doi: 10.1088/1742-6596/1916/1/012226.

- [18]: A. S. Musallam, A. S. Sherif, and M. K. Hussein, “A New Convolutional Neural Network Architecture for Automatic Detection of Brain Tumors in Magnetic Resonance Imaging Images,” *IEEE Access*, vol. 10, pp. 2775–2785, 2022.
- [19]: N. Noreen, S. Ahmed, and Z. Ali, “A Deep Analysis of Brain Tumor Detection from MR Images Using Deep Learning Networks,” *Algorithms*, vol. 16, no. 4, Art. no. 176, 2023.
- [20]: M. Aamir, Z. Rahman, Z. A. Dayo, et al., “A Deep Learning Approach for Brain Tumor Classification Using MRI Images,” *Computers & Electrical Engineering*, vol. 101, Art. no. 108105, 2022.
- [21]: S. Saeedi, H. M. El-Samie, A. M. El-Rabaie, and M. A. Mohamed, “MRI-based Brain Tumor Detection Using Convolutional Deep Learning and Selected Machine Learning Techniques,” *Sensors*, vol. 23, no. 13, Art. no. 6930, 2023.
- [22]: Z. Jia and D. Chen, “FAHS-SVM: Wavelet Segmentation with ELM-SVM Classification for Brain Tumor Detection,” *Expert Systems with Applications*, vol. 167, Art. no. 114123, 2021.
- [23]: P. G. Brindha and K. N. Vigneshwaran, “Improved Classification of Brain Tumors in MRI Using Patterned-GridMask,” *IEEE Transactions on Medical Imaging*, vol. 41, no. 9, pp. 2501–2510, 2022.
- [24]: M. Rahman, “Optimizing MRI-Based Brain Tumor Classification Using AI,” *Pattern Recognition*, vol. 130, Art. no. 108105, 2022.
- [25]: R. Preetha, A. Pulli, and S. Raj, “Automated Brain Tumor Detection from MRI Using Fine-Tuned EfficientNet,” *Computers in Biology and Medicine*, vol. 144, Art. no. 105345, 2022.
- [26]: A. Anaya-Isaza, L. Lopez, and M. Espinosa, “Cross-Transformer with InceptionResNetV2 for Brain Tumor Detection,” *Pattern Recognition*, vol. 130, Art. no. 108739, 2022.
- [27]: S. Ratha, N. Kumar, and P. Ram, “ResNet-50 Based Model for Brain Tumor Detection in MRI Scans,” *Computerized Medical Imaging and Graphics*, vol. 92, pp. 101–110, 2021.
- [28]: M. S. Mithun and S. Joseph Jawhar, “YOLO NAS and U-Net Hybrid for Brain Tumor Detection from MRI,” *Diagnostics*, vol. 13, no. 3, Art. no. 2094, 2023.
- [29]: J.-H. Lee, J.-W. Chae, and H.-C. Cho, “Patterned-GridMask Augmentation in CADx for Brain Tumor Classification,” *IEEE Transactions on Medical Imaging*, vol. 41, no. 10, pp. 2800–2810, 2022.
- [30]: M. N. Islam, A. Mahmud, and S. Hossain, “Ensemble CNN-LSTM for Brain Tumor Detection in MRI,” *Computer Methods and Programs in Biomedicine*, vol. 214, Art. no. 106599, 2022.
- [31]: B. Kukadiya, “CNN Ensemble and Xception Model for Brain Tumor Identification Using Brain MRI,” *Heliyon*, vol. 8, no. 5, Art. no. e11111, 2022.
- [32]: C. K. Reddy, S. Kumar, and P. Rani, “Fine-Tuned Vision Transformer (FTVT-116) for Brain Tumor Classification,” *Computational Intelligence and Neuroscience*, vol. 2023, Art. ID 9803247, 2023.

- [33]: R. Haque, A. Gomez-Guzman, M. L. Hasan, and A. F. Mollah, “NeuroNet19: Explainable Deep Neural Network Model for Brain Tumor Classification,” *Frontiers in Neuroscience*, vol. 17, Art. no. 11234, 2023.
- [34]: M. Basthikodi, S. D. Kumar, and A. A. Bhosale, “Multiclass Brain Tumor Diagnosis Using SVM and Feature Extraction Techniques,” *Biomedical Engineering Letters*, vol. 13, no. 3, pp. 275–283, 2023.
- [35]: M. J. Adam, P. Singh, and R. Shah, “MobileNetV2-SVM Hybrid for Brain Tumor Classification,” *IEEE Reviews in Biomedical Engineering*, vol. 16, pp. 234–245, 2023.
- [36] : NetApp, “What is Artificial Intelligence?”, [En ligne]. Disponible sur: <https://www.netapp.com/fr/artificial-intelligence/what-is-artificial-intelligence/>. [Consulté le: 17 février 2025].
- [37] : ELAOUABER Z. A., Système d'aide au diagnostic pour la détection automatique du Glaucome et de la rétinopathie diabétique, Thèse de Doctorat, Université de Tlemcen-Abou Bekr Belkaid, 2021.
- [38] : Terkmane Y., Classification des tumeurs cérébrales, Mémoire, Université Yahia Fares de Médéa, 2022.
- [39]: Dutta S., “Mastering Hyperparameters: Learning Rate, Batch Size, and More,” *Medium*, [En ligne].
- [40]: Amazon Web Services, “Hyperparameters for Optimizing the Learning Process of Your Text Generation Models,” *Amazon SageMaker*, 2024.
- [41]: AWS, “Transfer Learning,” [En ligne]. Disponible sur: <https://aws.amazon.com/fr/what-is/transfer-learning/>. [Consulté le: 25 février 2025].
- [42] : Innovatiana, “Discover ResNet-50,” [En ligne]. Disponible sur: <https://www.innovatiana.com/post/discover-resnet-50>. [Consulté le: 25 février 2025].
- [43] : Keras, “EfficientNet Applications API,” [En ligne]. Disponible sur: <https://keras.io/api/applications/efficientnet/>. [Consulté le: 25 février 2025].
- [44] : Merdoud K., Bousbaine K., Détection de maladies par traitement d’image, Université de Bouira, 2018.
- [45]: EITCA, “Deep Learning with Python, TensorFlow and Keras,” [En ligne]. Disponible sur: <https://fr.eitca.org/...> [Consulté le: 18 avril 2025].
- [46] : Kaggle, “Brain Tumor MRI Scans Dataset,” [En ligne]. Disponible sur: <https://www.kaggle.com/datasets/rm1000/brain-tumor-mri-scans>.