



## *Mémoire de fin de cycle*

*En vue de l'obtention d'un Master Recherche en Informatique*

*Option : Intelligence Artificielle*

## *Thème*

**Classification de tumeurs cérébrales à partir  
d'images IRM en utilisant le Deep Learning**

*Réalisé par :*

*M<sup>me</sup> GUEMOUNI Anais et M<sup>r</sup> BENABBAS Mohand*

Soutenu le 03/07/2024 devant le jury composé de :

Présidente	<i>M<sup>me</sup> D.ZAMOUCHE</i>	<i>U. A/Mira Bejaia.</i>
Examineur	<i>M<sup>r</sup> K.AKILAL</i>	<i>U. A/Mira Bejaia.</i>
Encadrant	<i>M<sup>me</sup> D.KESSIRA</i>	<i>U. A/Mira Bejaia.</i>

**Année Universitaire : 2023/2024**

# Table des matières

Table des figures	i
Liste des tableaux	ii
Liste des abréviations	iv
Introduction générale	1
<b>1 Définitions et Concepts de Base</b>	<b>3</b>
1.1 Introduction . . . . .	3
1.2 Apprentissage Automatique . . . . .	3
1.2.1 Définition . . . . .	4
1.2.2 Différents types d'apprentissage . . . . .	4
1.2.2.1 Apprentissage Supervisé . . . . .	4
1.2.2.2 Apprentissage Non Supervisé . . . . .	4
1.2.2.3 Apprentissage Par Renforcement . . . . .	4
1.2.2.4 Apprentissage Semi-Supervisé . . . . .	5
1.2.2.5 Apprentissage Profond . . . . .	5
1.3 Apprentissage Profond . . . . .	5
1.3.1 Définition . . . . .	5
1.3.2 Réseaux de Neurones Convolutifs (CNN) . . . . .	5
1.3.2.1 Couches de CNN . . . . .	6
1.3.2.2 Régularisation des CNN . . . . .	7
1.3.2.3 Optimizers des CNN . . . . .	8
1.3.2.4 Domaines d'applications . . . . .	8
1.4 Apprentissage par Transfert . . . . .	9
1.4.1 Définition . . . . .	9
1.4.2 Approches d'apprentissage par transfert . . . . .	10
1.4.2.1 Approches basées sur le modèle . . . . .	10
1.4.2.2 Approches basées sur les caractéristiques . . . . .	10
1.5 Modèles Pré-entraînés pour vision par ordinateur . . . . .	11
1.5.1 Visual Geometry Group (VGG) . . . . .	12
1.5.2 Residual Network (ResNet) . . . . .	12

1.6	Tumeurs Cérébrales . . . . .	13
1.6.1	Définition de Tumeurs Cérébrales . . . . .	13
1.6.2	Grades des tumeurs cérébrales et leurs caractéristiques . . . . .	14
1.6.2.1	Grade I . . . . .	14
1.6.2.2	Grade II . . . . .	14
1.6.2.3	Grade III . . . . .	14
1.6.2.4	Grade IV . . . . .	14
1.6.3	Types de Tumeurs Cérébrales . . . . .	14
1.6.3.1	Tumeurs Gliales . . . . .	14
1.6.3.2	Tumeurs Méningées . . . . .	14
1.6.3.3	Adénomes Hypophysaires . . . . .	15
1.6.4	Système de Classification de Tumeurs Cérébrales selon l’OMS . . . . .	15
1.6.4.1	Classification OMS 2021 . . . . .	15
1.6.4.2	Critères de Diagnostic . . . . .	15
1.6.5	Les mécanismes de progression des tumeurs cérébrales . . . . .	15
1.6.5.1	Multiplication des cellules tumorales . . . . .	15
1.6.5.2	Apparition de kystes . . . . .	15
1.6.5.3	Saignement tumoral . . . . .	16
1.6.5.4	Œdème . . . . .	16
1.6.5.5	Infiltration du tissu cérébral . . . . .	16
1.6.5.6	Compression du cerveau . . . . .	16
1.6.5.7	Irritation du cortex . . . . .	16
1.6.5.8	Hydrocéphalie tumorale . . . . .	16
1.6.5.9	Engagement . . . . .	16
1.6.5.10	Cercle vicieux . . . . .	16
1.6.6	Diagnostics des Tumeurs Cérébrales . . . . .	16
1.6.6.1	Examen clinique et neurologique . . . . .	17
1.6.6.2	Imagerie . . . . .	17
1.6.6.3	Biopsie . . . . .	17
1.6.6.4	Ponction lombaire . . . . .	17
1.6.6.5	Examen anatomo-pathologique . . . . .	17
1.6.6.6	Spectroscopie par résonance magnétique . . . . .	17
1.6.6.7	Classification officielle . . . . .	17
1.6.7	L’importance de la détection et du diagnostic des Tumeurs Cérébrales . . . . .	17
1.6.7.1	Perspectives futures . . . . .	18
1.7	Conclusion . . . . .	19
<b>2</b>	<b>Etat de l’Art</b>	<b>20</b>
2.1	Introduction . . . . .	20
2.2	Travaux connexes . . . . .	20
2.2.1	Revue des méthodes de classification des IRM cérébrales . . . . .	21

2.2.1.1	Article 1 : Brain tumor classification for MR images using transfer learning and fine-tuning . . . . .	21
2.2.1.2	Article 2 : Brain tumor MRI images identification and classification based on the recurrent convolutional neural network . . . . .	22
2.2.1.3	Article 3 : Robust clinical applicable CNN and U-Net based algorithm for MRI classification and Segmentation for brain tumor . . . . .	22
2.2.1.4	Article 4 : Detection and classification of Brain tumors . . . . .	23
2.2.1.5	Article 5 : MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques . . . . .	24
2.2.1.6	Article 6 : An efficient automatic brain tumor classification using optimized hybrid deep neural network . . . . .	25
2.2.1.7	Article 7 : A Framework for Brain Tumor Segmentation and Classification using Deep Learning Algorithm . . . . .	26
2.2.1.8	Article 8 : Brain tumor classification using deep CNN features via transfer learning . . . . .	26
2.2.1.9	Article 9 : Detection and Classification of Brain tumors Using Deep Convolutional Neural Networks . . . . .	27
2.2.1.10	Article 10 : Classification of Brain Tumors Using Convolutional Neural Network over Various SVM Methods . . . . .	28
2.2.2	Tableau récapitulatif . . . . .	29
2.3	Discussion . . . . .	34
2.4	Conclusion . . . . .	34
<b>3</b>	<b>Notre Approche</b>	<b>36</b>
3.1	Introduction . . . . .	36
3.2	Architecture EfficientNetB0 . . . . .	36
3.3	Notre méthodologie . . . . .	37
3.4	Couches proposées . . . . .	38
3.5	Approche proposée (Transfert learning et Fine-tuning) . . . . .	39
3.6	Hyperparamètres et fonction de perte . . . . .	40
3.7	Conclusion . . . . .	41
<b>4</b>	<b>Evaluation des performances</b>	<b>42</b>
4.1	introduction . . . . .	42
4.2	Détails d'implémentation . . . . .	42
4.2.1	Descriptions des datasets . . . . .	43
4.3	Mesures de performances . . . . .	44
4.3.1	Précision (Precision) . . . . .	44
4.3.2	Exactitude (Accuracy) . . . . .	44
4.3.3	Rappel (Recall) . . . . .	44
4.3.4	F1-Score . . . . .	44

4.3.5	Matrice de Confusion . . . . .	45
4.3.6	Fonction de perte . . . . .	45
4.4	Résultats du modèle proposé . . . . .	46
4.5	Validation . . . . .	50
4.5.1	Résultats de l'entraînement des 2 datasets . . . . .	50
4.5.2	Comparaison avec d'autres modèles . . . . .	50
4.5.3	Discussion des résultats de la comparaison . . . . .	51
4.6	Conclusion . . . . .	52

# Table des figures

1.1	Architecture du CNN [35]	7
1.2	VGG-Net Architecture[4]	12
1.3	ResNet Architecture[25]	13
1.4	Tumeurs cérébrales[29]	13
2.1	Approche proposée dans l'article 1 [31]	21
2.2	Approche proposée dans l'article 2 [37]	22
2.3	Approche proposée dans l'article 3 [1]	23
2.4	Approche proposée dans l'article 4 [8]	24
2.5	Approche proposée dans l'article 5 [26]	25
2.6	Approche proposée dans l'article 6 [28]	25
2.7	Approche proposée dans l'article 7 [21]	26
2.8	Approche proposée dans l'article 8 [10]	27
2.9	Approche proposée dans l'article 9 [3]	28
2.10	Approche proposée dans l'article 10 [27]	29
3.1	Architecture EfficientNetB0[36]	37
3.2	Diagramme de la méthode utilisée	38
3.3	Couches proposée	39
3.4	Architecture finale proposée	40
4.1	Dataset a accuracy	46
4.2	Dataset a perte	46
4.3	Matrice de confusion Dataset a	47
4.4	Dataset b accuracy	48
4.5	Dataset b perte	48
4.6	Matrice de confusion Dataset b	49
4.7	ResNet50 perte dataset a	51
4.8	ResNet50 perte dataset b	51
4.9	VGG19 perte dataset a	51
4.10	VGG19 perte dataset b	51

# Liste des tableaux

- 2.1 Tableau récapitulatif selon 7 caractéristiques . . . . . 33
- 4.1 Métriques de performance et perf globale Dataset a . . . . . 47
- 4.2 Métriques de performance et perf globale Dataset b . . . . . 49
- 4.3 Comparaison des résultats des datasets a,b et c . . . . . 50
- 4.4 Tableau des performances des différents modèles sur deux datasets. . . . . 50

# Liste des abréviations

**ANN** : Artificial Neural Network

**ASI** : Artificial Superintelligence

**BM3D** : Block-Matching 3D

**CNN** : Convolutional Neural Network

**FCM** : Fuzzy C-Means

**IRM** : Imagerie par Résonance Magnétique

**IRM-CE** : Imagerie par Résonance Magnétique avec Contraste par Injection

**K-nearest** : Méthode des k plus proches voisins

**KNN** : K-Nearest Neighbors

**LSTM** : Long Short-Term Memory

**LR** : Logistic Regression

**MBC<sub>conv</sub>** : MobileNetV2 Convolutional Block

**MLD** : Machine Learning Développeur

**OMS** : Organisation Mondiale de la Santé

**RCNN** : Region-based Convolutional Neural Networks

**RELU** : Rectified Linear Unit

**ResNet50** : Residual Network with 50 layers

**RF** : Random Forest

**SGD** : Stochastic Gradient Descent



---

**TDM** : Tomodensitométrie ou Scanner

**VGG** : Visual Geometry Group

**Xception** : Extended version of Conception

**YOLO** : You Only Look Once

## *Remerciements*

Ce mémoire de fin de cycle marque le résultat de plusieurs années de travail et d'investigation. Cette réalisation n'aurait pas pu être possible sans le soutien et l'assistance de nombreuses personnes à qui on souhaite exprimer ma plus sincère reconnaissance.

En premier lieu, on tient à exprimer notre gratitude envers notre directeur de recherche, *M<sup>me</sup> KESSIRA Dalila*, pour son encadrement remarquable, ses conseils précieux et son soutien inébranlable tout au long de ce projet. Son expertise, ses compétences et sa disponibilité ont joué un rôle crucial dans la réalisation de cette tâche.

Nous souhaitons également remercier les membres du jury, *M<sup>me</sup> D.ZAMOUCHE*, *M<sup>r</sup> K.AKILAL*, pour leur temps précieux qui nous ont accordé, ainsi que laboratoire LIMED pour la station qui nous en mis en oeuvre.

Nous tenons à exprimer notre profonde gratitude envers nos collègues et amis, pour leurs encouragements et leur soutien tout au long de ces années. Leurs conseils, leur aide et leur amitié ont été d'une grande valeur.

Enfin, on tient à exprimer notre gratitude envers nos familles, pour leur soutien inconditionnel, leur affection et leurs encouragements incessants. Sans leur soutien, cette tâche n'aurait pas pu être réalisée. Nous sommes reconnaissants envers nos parents, nos frères et sœurs pour leur patience et leur grande compréhension.

GUEMOUNI Anais  
BENABBAS Mohand

# Introduction générale

Les tumeurs du cerveau constituent l'une des maladies les plus préoccupantes en raison de leur complexité et de leur influence importante sur le système nerveux central. Il est essentiel de les identifier et de les classer de manière précoce afin d'améliorer les pronostics et la qualité de vie des patients. L'imagerie par résonance magnétique (IRM) est une méthode non invasive fréquemment employée pour le diagnostic et la surveillance des tumeurs cérébrales, car elle permet de réaliser des images détaillées des structures placées dans le cerveau[18].

Malgré les progrès technologiques dans le domaine de l'imagerie médicale, l'analyse des images IRM demeure une tâche complexe et sujette à des variations entre les différents observateurs. Il est crucial de classer de manière précise les tumeurs cérébrales afin de prévoir des traitements adaptés et réduire au minimum les interventions invasives. Toutefois, il peut être difficile de distinguer les divers types de tumeurs en raison de leurs caractéristiques visuelles souvent semblables et de leur variabilité intra-classe.

Le deep learning, en particulier les réseaux de neurones convolutifs (CNN) ont bouleversé le domaine de l'analyse d'images médicales en proposant des performances exceptionnelles dans la détection de motifs complexes. Les méthodes permettent de rendre la classification des images médicales plus automatisée et plus précise. En utilisant le deep learning pour analyser les images IRM des tumeurs cérébrales, il est possible de modifier les pratiques cliniques en offrant des diagnostics plus rapides et plus précis, ce qui permet de réduire la charge de travail des radiologues et d'améliorer les résultats des patients[9].

Dans cette recherche, une approche d'apprentissage par transfert utilisant EfficientNetB0 a été proposée afin d'améliorer la classification des images IRM des tumeurs cérébrales. L'architecture proposée a été comparée à d'autres modèles CNN (VGG19, ResNet50) sur deux datasets (a et b) pour évaluer son efficacité. En moyenne, notre architecture suggérée atteint 95% de précision.

Nous avons élaboré un plan détaillé qui englobe tous les aspects de notre projet, de la phase théorique à la mise en œuvre pratique. Notre travail est divisé en cinq chapitres, organisés comme suit :

**Chapitre 1 (Définitions et Concepts de Base )** : Ce chapitre présente l'intelligence artificielle et les tumeurs cérébrales, ainsi que leur relation pour notre étude.

---

**Chapitre 2 (Etat de l'art)** : Ce chapitre offre une présentation des articles choisis pour notre étude, en présentant une synthèse des études et des contributions pertinentes à notre sujet.

**Chapitre 3 (Notre approche)** : Ce chapitre détaille le modèle et l'architecture choisis pour mener à bien la classification des tumeurs cérébrales. Nous y décrivons les différentes composantes du modèle, les paramètres utilisés, ainsi que les étapes de conception.

**Chapitre 4 ( Evaluation des performances)** : Ce chapitre propose une analyse globale et une comparaison des résultats en fonction des différentes mesures de performance présentées.

# Chapitre 1

## Définitions et Concepts de Base

### 1.1 Introduction

Les tumeurs cérébrales constituent un défi majeur en raison de leur complexité et de leur variété. Il est crucial de diagnostiquer et de classer ces tumeurs de manière adéquate afin de déterminer le traitement adéquat et d'améliorer les chances de survie des patients. Grâce à la rapidité d'évolution des technologies d'imagerie médicale, en particulier l'imagerie par résonance magnétique (IRM), il est maintenant envisageable d'obtenir des images détaillées du cerveau, ce qui permet une meilleure compréhension des anomalies. Toutefois, l'analyse de ces images demeure une tâche complexe qui demande une expertise spécialisée.

C'est dans ce contexte que les méthodes d'apprentissage profond, et en particulier le transfert learning, ont montré un potentiel de grande envergure. Le transfert learning est une technique récente dans l'intelligence artificielle, utilisée dans divers domaines, notamment dans le domaine médical. Il est souvent utilisé avec les réseaux de neurones convolutifs (CNN) pré-entraînés sur de grandes bases de données d'images comme ImageNet [11].

Ce chapitre propose une définition approfondie du transfert learning, en abordant ses aspects les plus importants : l'apprentissage automatique, l'apprentissage profond, l'apprentissage par transfert et les modèles pré-entraînés. Dans la deuxième section, nous définirons les tumeurs cérébrales, en examinant leurs grades, types et d'autres caractéristiques essentielles, afin de fournir une compréhension complète de cette maladie en abordant les principes du transfert learning et en détaillant les caractéristiques de cette maladie.

Ce chapitre vise à fournir une base solide pour comprendre comment ces approches innovantes peuvent transformer le diagnostic et le traitement des tumeurs cérébrales, ouvrant ainsi la voie à des avancées significatives dans le domaine de la médecine oncologique.

### 1.2 Apprentissage Automatique

Dans cette partie, nous allons présenter l'apprentissage automatique et ses différentes catégories.

### 1.2.1 Définition

La branche de l'intelligence artificielle appelée apprentissage automatique (ou machine learning) se focalise sur la création et le développement d'algorithmes qui peuvent analyser, interpréter et traiter des données afin d'apprendre et de prendre des décisions basées sur ces dernières[2].

En apprentissage automatique, on utilise fréquemment des techniques telles que les CNN, les réseaux de neurones récurrents (RNN) et les modèles de transfert learning pour traiter les images. Ces algorithmes offrent la possibilité de concevoir des systèmes qui peuvent effectuer des tâches complexes de traitement d'images avec une grande précision, ce qui facilite des progrès importants dans des secteurs tels que la médecine, la sécurité, l'automatisation industrielle, et bien d'autres encore [2].

De plus, l'utilisation de l'apprentissage automatique offre la possibilité de créer des applications avancées telles que la détection d'objets, la classification, la segmentation, la reconnaissance de formes, l'amélioration et la restauration d'images. Cela soutient de nombreuses avancées technologiques et améliore considérablement les services et les solutions dans différents domaines [2].

### 1.2.2 Différents types d'apprentissage

On peut classer l'apprentissage automatique (Machine Learning) en différents types, chacun ayant des objectifs et des méthodes particulières. Les différents types d'apprentissage automatique sont les suivants :

#### 1.2.2.1 Apprentissage Supervisé

Le type le plus répandu d'apprentissage est l'apprentissage supervisé. Le modèle est entraîné en utilisant des données étiquetées. On subdivise les données en entrées et sorties, et l'algorithme apprend à prédire les sorties en se basant sur les entrées. Ce processus d'apprentissage est employé pour des opérations comme la classification et le repérage[2].

#### 1.2.2.2 Apprentissage Non Supervisé

En utilisant des données non étiquetées, l'apprentissage non supervisé permet de repérer des structures et des modèles dans les données. On l'emploie pour analyser les caractéristiques et repérer les clusters dans les données[2].

#### 1.2.2.3 Apprentissage Par Renforcement

En utilisant des récompenses et des pénalités, l'apprentissage par renforcement vise à former un agent à prendre des décisions. L'apprentissage de cette méthode est employé dans des secteurs tels que la robotique, la théorie des jeux et les véhicules autonomes[2].

#### 1.2.2.4 Apprentissage Semi-Supervisé

L'apprentissage semi-supervisé allie les bénéfices de la supervision et de la non-supervision. L'apprentissage commence par un ensemble limité de données étiquetées, puis l'algorithme est appliqué à un ensemble plus vaste de données non étiquetées[2].

#### 1.2.2.5 Apprentissage Profond

Le deep learning est une forme particulière d'apprentissage supervisé qui repose sur les réseaux neuronaux. On l'emploie pour des fonctions comme la reconnaissance vocale et l'imagerie[2].

### 1.3 Apprentissage Profond

Dans cette section nous allons définir l'apprentissage profond et les réseaux de neurones convolutifs.

#### 1.3.1 Définition

L'apprentissage profond est une discipline avancée de l'intelligence artificielle qui utilise des réseaux de neurones profonds, en particulier les réseaux de neurones convolutifs (CNN), afin d'analyser et d'interpréter de manière hiérarchique et complexe des données visuelles. À la différence des méthodes classiques, l'apprentissage profond permet aux modèles d'acquérir automatiquement des connaissances à partir de données non structurées et de déterminer des représentations abstraites et spécifiques des caractéristiques visuelles[2].

Cette approche se base sur différentes étapes de traitement, chaque étape capturant des niveaux de complexité croissants des éléments visuels, comme les contours, les textures et les figurines. En utilisant des architectures profondes, l'apprentissage profond permet d'acquérir une meilleure précision dans la reconnaissance de motifs et d'objets dans les images, ce qui a fait révolution dans des domaines tels que la reconnaissance d'objets, la classification d'images, la segmentation sémantique, et bien d'autres encore[2].

En résumé, grâce à l'acquisition d'une expertise approfondie dans le traitement d'images, les systèmes informatiques peuvent acquérir une compréhension avancée et une interprétation intelligente des informations visuelles, ce qui ouvre la voie à des applications innovantes dans différents domaines tels que la médecine, l'automobile autonome et la surveillance de qualité.

#### 1.3.2 Réseaux de Neurones Convolutifs (CNN)

Les CNN, ou Réseaux de Neurones Convolutifs, sont des architectures spécialisées de réseaux de neurones profonds qui utilisent des couches convolutionnelles pour extraire et apprendre des caractéristiques visuelles à partir des données.

Dans l'image, chaque couche convolutionnelle utilise des filtres afin de repérer des motifs locaux tels

que les bords, les textures et les formes. En raison de leur capacité à capturer des hiérarchies complexes de caractéristiques visuelles, les CNN sont couramment employés pour des tâches comme la classification d'images, la détection d'objets et la segmentation d'images médicales, ce qui permet une analyse robuste et précise des données visuelles.

Grâce à leur structure en couches, la reconnaissance des caractéristiques évolue progressivement, passant des détails de base aux concepts plus abstraits et contextuels. Cela rend les CNN particulièrement efficaces dans des domaines qui exigent une interprétation sophistiquée des informations visuelles[38].

### 1.3.2.1 Couches de CNN

Les réseaux de neurones convolutifs (CNN) sont constitués de diverses couches qui ont des fonctions particulières dans le traitement des données d'image. Les principales couches que l'on retrouve habituellement dans une architecture classique de CNN sont les suivantes :

#### a. Couche de convolution :

Pour extraire des éléments locaux tels que des bords, des textures et des motifs, une couche de convolution effectue des opérations de convolution sur l'image d'entrée. Des filtres (ou noyaux) sont utilisés pour parcourir l'image d'entrée et effectuer une transformation linéaire à chaque région locale. La matrice de poids partagés de chaque filtre est utilisée pour appliquer des poids à des sous-régions de l'image afin de créer une carte de caractéristiques.

La convolution implique de déplacer ces filtres sur l'image d'entrée et de calculer le rapport scalaire entre les filtres et les différentes sous-régions de l'image. Une nouvelle image, connue sous le nom de carte de caractéristiques, est obtenue, où chaque pixel correspond à une caractéristique locale extraite par le filtre. Il est possible d'utiliser plusieurs filtres dans une seule couche de convolution afin de repérer diverses caractéristiques.[2].

#### b. Couche d'activation :

Après la couche de convolution, une fonction d'activation (telle que ReLU - Unité Lineaire Rectifiée) est appliquée afin d'introduire la non-linéarité dans le modèle.

#### c. Couche de pooling :

L'agrégation de l'information provenant des régions locales permet de réduire la taille de l'image. Le principe de pooling le plus fréquent est le pooling max, qui maintient la valeur maximale de chaque région[2].

#### d. Couche entièrement connectée :

Cette couche transforme les caractéristiques extraites par les couches précédentes de manière linéaire. Il s'agit fréquemment de la couche finale du réseau, qui est employée pour la classification ou la régression[2].

#### e. Fonction de perte :

Le rôle de cette fonction est de symboliser l'erreur ou la sanction que le modèle endure en raison



de ses prédictions par rapport aux étiquettes réelles[2].

La figure 1.1 représente l'architecture du CNN :

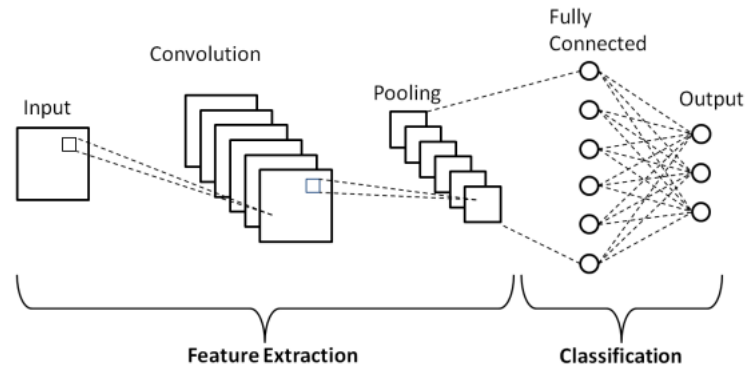


FIGURE 1.1 – Architecture du CNN [35]

### 1.3.2.2 Régularisation des CNN

La régularisation joue un rôle crucial dans la prévention du surapprentissage (overfitting) et dans l'amélioration de la généralisation du modèle. Voici quelques méthodes fréquemment employées afin d'améliorer la régularité des CNN :

#### a. Dropout :

Pendant l'entraînement, le dropout est une méthode de régularisation efficace qui implique de "désactiver" aléatoirement un certain pourcentage de neurones dans une couche. Cela oblige le réseau à ne pas être trop dépendant de certains chemins neuronaux particuliers, ce qui renforce sa capacité à s'adapter à de nouvelles données [38].

#### b. Régularisation L2 (weight decay) :

Cette méthode implique l'ajout d'une pénalité à la fonction de perte qui est proportionnelle à la somme des carrés des poids du modèle. Ceci favorise la réduction des poids, ce qui peut contribuer à éviter le surapprentissage en réduisant la complexité du modèle [38].

#### c. Augmentation de données (data augmentation) :

La méthode d'augmentation de données consiste à modifier artificiellement les données d'entraînement en effectuant des transformations telles que des rotations, des retournements, des zooms, des translations, etc. Cela favorise une augmentation de la taille et de la variété du jeu de données d'entraînement, ce qui permet au modèle de se généraliser d'avantage aux données de test [38].

#### **d. Batch Normalization :**

Même si la batch normalisation est principalement employée pour accélérer la convergence de l'entraînement, elle peut également jouer un rôle de régularisation en stabilisant en normalisant les activations entre les différentes couches du réseau [38].

#### **e. Early Stopping :**

Durant l'entraînement, l'arrêt anticipé est une méthode simple mais efficace qui permet de surveiller la performance du modèle sur un ensemble de validation différent. Quand les résultats sur l'ensemble de validation ne s'améliorent plus, l'entraînement est suspendu afin d'éviter le surapprentissage [38].

### **1.3.2.3 Optimizers des CNN**

Les algorithmes appelés optimiseurs sont employés pour modifier les poids d'un modèle de réseau neuronal pendant l'entraînement, dans le but de réduire la fonction de perte. Les optimiseurs suivants sont fréquemment employés pour les réseaux de neurones convolutifs (CNN) dans le domaine du traitement d'images :

#### **a. Adam (Adaptive Moment Estimation) :**

Adam est une méthode populaire d'optimisation qui allie les bénéfices de l'algorithme de descente de gradient stochastique avec les idées de moment et d'ajustement du taux d'apprentissage. Souvent utilisé pour résoudre les problèmes d'optimisation des réseaux de neurones [13].

#### **b. Batch Gradient Descent :**

Batch GD calcule le gradient de la fonction de perte par rapport à tous les paramètres du modèle sur l'ensemble des données d'entraînement à chaque itération de l'entraînement. Cela implique que le calcul du gradient se fait une seule fois sur toutes les données d'entraînement [13].

### **1.3.2.4 Domaines d'applications**

Les CNN sont couramment employés dans différents secteurs en raison de leur aptitude à traiter de manière efficace les données visuelles et à extraire des caractéristiques importantes à partir d'images. Voici certains domaines d'application majeurs des CNN :

#### **a. Vision par ordinateur :**

Dans le domaine de la vision par ordinateur, les réseaux neuronaux convolutionnels sont employés pour classer les images, ce qui permet d'identifier de manière précise des catégories telles que les animaux et les véhicules. La détection d'objets est également facilitée par leur capacité à localiser

des entités spécifiques dans des scènes visuelles, une fonctionnalité cruciale pour les systèmes de surveillance et de conduite autonome. En outre, les réseaux neuronaux convolutionnels sont utilisés dans la segmentation d'images, ce qui permet de diviser une image en segments ou zones, ce qui est pratique dans le domaine de l'imagerie médicale pour localiser précisément des organes ou détecter des anomalies, ce qui améliore les traitements médicaux et les diagnostics. L'importance grandissante des CNN dans la manipulation et l'analyse avancée des données visuelles est prouvée par ces capacités, qui sont utilisées dans de nombreuses applications critiques et innovantes[7].

### **b. Médecine :**

Les CNN sont employés dans le domaine du diagnostic médical afin d'interpréter des images médicales comme les IRM et les scanners CT, ce qui permet de détecter et de classer de manière précise des conditions médicales complexes telles que les tumeurs et les fractures. En outre, les CNN simplifient la segmentation et l'analyse d'images médicales en extrayant automatiquement des caractéristiques essentielles pour la planification chirurgicale et le suivi des traitements, ce qui améliore la précision des interventions médicales et la gestion des soins aux patients. Ces exemples mettent en évidence la capacité des réseaux neuronaux à apporter une transformation significative à la pratique médicale en tirant parti des progrès technologiques pour réaliser des diagnostics plus précis et des interventions médicales plus performantes[7].

### **c. Industrie du divertissement :**

En analyse d'images et de vidéos, les réseaux de neurones convolutionnels (CNN) offrent la possibilité de classer de manière efficace des volumes considérables de médias visuels en catégories précises, ce qui facilite la gestion et l'organisation des données. En outre, ces réseaux servent à offrir des recommandations sur mesure en se basant sur les préférences et les interactions des utilisateurs avec les contenus visuels, ce qui améliore l'expérience utilisateur sur des plateformes de médias et de divertissement. Grâce à leur aptitude à traiter et à interpréter de manière efficace les informations visuelles, les CNN offrent de nouvelles opportunités pour personnaliser les services numériques et améliorer la satisfaction des clients grâce à une analyse intelligente des médias visuels[7].

## **1.4 Apprentissage par Transfert**

Dans cette partie, nous définissons l'apprentissage automatique et leurs approches d'apprentissage.

### **1.4.1 Définition**

L'apprentissage par transfert consiste à transférer et réutiliser les connaissances acquises par un modèle sur une tâche source afin d'améliorer ses performances sur une tâche cible. Au lieu de construire un modèle à partir de zéro avec une grande quantité de données, l'apprentissage par transfert se base sur un modèle pré-entraîné. Il est possible d'utiliser telles quelles les couches du modèle pré-entraîné ou de les adapter en réinitialisant et en ré-entraînant certaines couches spécifiques afin de s'adapter à

la nouvelle tâche cible [12].

Les caractéristiques extraites par le modèle source, souvent entraîné sur des données massives, permettent d'améliorer l'efficacité et l'exactitude du modèle cible, même avec un ensemble de données d'entraînement restreint. On utilise fréquemment l'apprentissage par transfert dans des domaines tels que la classification d'images médicales, la détection d'objets et d'autres tâches de vision par ordinateur où les données d'entraînement sont souvent rares ou coûteuses à obtenir [12].

Dans notre recherche, nous avons utilisé cette méthode afin d'améliorer notre méthode de classification des images IRM de tumeurs cérébrales.

## 1.4.2 Approches d'apprentissage par transfert

Différentes méthodes de transfert d'apprentissage sont employées afin d'utiliser de manière efficace les connaissances préalablement acquises à partir de modèles pré-entraînés. Voici les deux bases d'approches fréquemment utilisées :

### 1.4.2.1 Approches basées sur le modèle

Les stratégies utilisées dans les approches basées sur le modèle permettent d'ajuster des modèles pré-entraînés à de nouvelles tâches spécifiques. Voici certaines de ces méthodes :

#### a. Fine-tuning (affinage) :

Le fine-tuning implique d'adapter les poids d'un modèle pré-entraîné à de nouvelles données spécifiques à la tâche cible. Il est fréquent de réinitialiser et de réentraîner les couches supérieures du modèle avec un taux d'apprentissage plus élevé, tandis que les couches inférieures, qui enregistrent des caractéristiques plus générales et abstraites, sont souvent conservées sans modifications significatives [12].

#### b. Parameter Shaving (Feature Shaving) :

L'optimisation par paramètres, aussi appelée Feature Shaving ou Weight Shaving, est une méthode d'apprentissage par transfert qui permet d'adapter un modèle pré-entraîné à une nouvelle tâche en diminuant le nombre de paramètres modifiés. L'objectif de cette méthode est de préserver et de réutiliser de manière efficace les connaissances acquises par le modèle source tout en ajustant spécifiquement les paramètres essentiels requis pour la nouvelle tâche [12].

### 1.4.2.2 Approches basées sur les caractéristiques

L'objectif des approches basées sur les caractéristiques est d'optimiser l'utilisation des représentations acquises par un modèle pré-entraîné afin d'améliorer les performances d'un modèle cible sur une nouvelle tâche. Voici certaines méthodes principales :

**a. Extraction de features :**

On utilise cette méthode en utilisant les couches convolutionnelles d'un modèle pré-entraîné afin d'extraire des caractéristiques pertinentes des images d'entrée. Ensuite, ces caractéristiques sont exploitées comme données pour un nouveau modèle spécifique à la tâche, comme un classificateur ou un détecteur d'objets. Ceci donne l'opportunité de bénéficier des représentations visuelles générales et abstraites acquises grâce au modèle source [12].

**b. Réglage fin des couches supérieures :**

Dans cette méthode, on réinitialise et réentraîne les couches supérieures d'un modèle pré-entraîné avec un taux d'apprentissage faible afin de s'adapter spécifiquement aux caractéristiques de la nouvelle tâche. Les couches basses, qui représentent des éléments visuels de bas niveau, sont généralement maintenues sans modifications significatives, ce qui permet de préserver les connaissances générales acquises par le modèle source [12].

**c. Adaptation de domaines :**

L'adaptation de domaines est employée lorsqu'il y a une différence significative dans les distributions de données entre le domaine source (sur lequel le modèle est pré-entraîné) et le domaine cible. Il est possible d'employer des méthodes telles que le fine-tuning adaptatif ou l'ajustement des poids des couches afin d'aligner les caractéristiques acquises avec les nouvelles données cibles, ce qui améliore la généralisation du modèle [12].

## 1.5 Modèles Pré-entraînés pour vision par ordinateur

En apprentissage automatique, l'adaptation de domaines est une méthode employée lorsque les données sur lesquelles un modèle a été initialement entraîné (domaine source) diffèrent des nouvelles données sur lesquelles il doit être appliqué (domaine cible). Cette disparité peut diminuer l'efficacité du modèle face aux nouvelles données. Afin de résoudre cette difficulté, différentes approches peuvent être employées. La méthode la plus répandue est le "fine-tuning". Grâce à ces méthodes, on renforce la capacité du modèle à généraliser, c'est-à-dire à fonctionner correctement sur de nouvelles données qu'il n'a pas vues plus tôt. En combinant les caractéristiques acquises avec celles des nouvelles données, le modèle prend de l'adaptation et devient plus efficace dans le contexte. Voici quelques-uns des modèles pré-entraînés les plus couramment employés.

### 1.5.1 Visual Geometry Group (VGG)

Le Visual Geometry Group (VGG) est une architecture de réseau de neurones convolutifs (CNN) créée par le groupe de recherche de l'Université d'Oxford. Simonyan et Zisserman ont introduit cette architecture pour la première fois en 2014 dans leur article intitulé "Very Deep Convolutional Networks for Large-Scale Image Recognition" [30].

L'architecture uniforme de VGG se caractérise par la présence de couches convolutives de taille 3x3 avec un stride (pas) de 1, tandis que les couches de pooling sont de taille 2x2 avec un stride de 2. Cela facilite la compréhension et la répétition du réseau. On en trouve plusieurs versions, comme VGG16 et VGG19, qui se caractérisent par le nombre de couches. Il y a 16 couches dans VGG16 (13 convolutives et 3 entièrement connectées), tandis que 19 couches dans VGG19 (16 convolutives et 3 entièrement connectées)[33].

La figure 1.2 ci-dessous représente une architecture du modèle VGG.

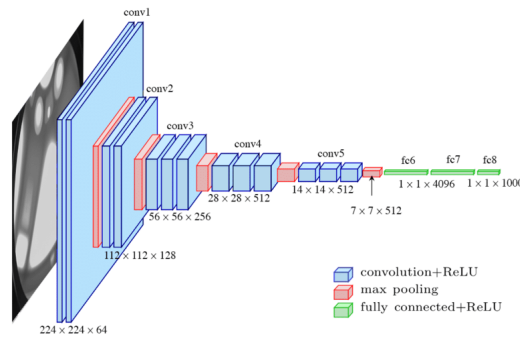


FIGURE 1.2 – VGG-Net Architecture[4]

### 1.5.2 Residual Network (ResNet)

Réseau Résiduel (Residual Network), également connu sous le nom de ResNet, est une structure de réseau de neurones convolutifs (CNN) introduite par Kaiming He et al. (2015) dans leur étude intitulée "Deep Residual Learning for Image Recognition" [17].

Au début de ResNet, une image d'entrée de taille fixe est utilisée, généralement de taille 224x224 pixels pour les modèles entraînés sur ImageNet. Après cela, une première couche de convolution avec un filtre de grande taille (7x7) et un stride de 2 est mise en place, suivie d'une couche de normalisation et d'une fonction d'activation ReLU. Une couche de pooling max (3x3) est ensuite ajoutée avec un stride de 2 afin de diminuer la taille de l'image [33].

Les unités de base de ResNet sont les blocs résiduels. Chaque bloc est composé de différentes couches de convolution avec des filtres de petite taille (3x3) et des connexions directes qui ajoutent l'entrée du bloc à sa sortie. Il y a deux catégories de blocs résiduels : les blocs simples, employés dans ResNet-18 et ResNet-34, qui contiennent deux couches de convolution, et les blocs bottleneck, employés dans ResNet-50, ResNet-101 et ResNet-152, qui contiennent trois couches de convolution (1x1, 3x3, 1x1) [33].

La figure 1.3 ci-dessous représente une architecture du modèle ResNet.




FIGURE 1.3 – ResNet Architecture[25]

## 1.6 Tumeurs Cérébrales

Cette section vous offre toutes les informations nécessaires pour définir les tumeurs cérébrales de manière précise et accessible.

### 1.6.1 Définition de Tumeurs Cérébrales

Les tumeurs du cerveau sont toutes les tumeurs, qu'elles soient bénignes ou malignes, qui se forment dans le parenchyme cérébral. Il est possible qu'elles proviennent du cerveau lui-même ou qu'elles l'aient envahi après s'être développées dans une autre partie de l'humain (métastase). Il peut y avoir des douleurs, des modifications de la personnalité, une fatigue, des sensations inhabituelles, une perte d'équilibre, des problèmes de concentration, des convulsions et un trouble de la coordination. Les examens d'imagerie peuvent repérer des tumeurs cérébrales, mais il est souvent indispensable de réaliser une biopsie de la tumeur pour confirmer cette détection [22]. Il peut s'agir d'une opération, d'une radiothérapie, d'une chimiothérapie ou d'une combinaison de ces traitements. Le développement des tumeurs cérébrales bénignes est lent et peut être très volumineux avant de donner des symptômes, tandis que le développement des tumeurs cancéreuses est généralement rapide. Des tumeurs bénignes peuvent se transformer en tumeurs malignes [22]. La figure ci-dessous 1.4 présente un ensemble d'images IRM cérébrales.




FIGURE 1.4 – Tumeurs cérébrales[29]

## 1.6.2 Grades des tumeurs cérébrales et leurs caractéristiques

On classe les tumeurs cérébrales selon leur niveau d'agressivité et leur comportement. Les types de tumeurs cérébrales sont les suivants :

### 1.6.2.1 Grade I

Les tumeurs qui n'ont pas de cancer, les moins agressives. Les exemples incluent l'astrocytome pilocytique et l'oligodendrogliome[22].

### 1.6.2.2 Grade II

Tumeurs de petite taille, bien différenciées, qui se développent lentement et ont moins de chances de se propager. Par exemple : astrocytome diffus, oligodendrogliome[22].

### 1.6.2.3 Grade III

Une tumeur de haut grade, peu différenciée ou indifférenciée, qui s'élargit plus rapidement et a une plus grande probabilité de se propager. Illustrations : astrocytome anaplasique, oligodendrogliome anaplasique[22].

### 1.6.2.4 Grade IV

Les tumeurs les plus agressives, très rapidement développées et présentant un risque élevé de récurrence. Comme par exemple : le glioblastome multiforme et de l'épendymome anaplasique[22].

## 1.6.3 Types de Tumeurs Cérébrales

Il existe différentes catégories de tumeurs cérébrales en fonction de leur origine cellulaire et de leur niveau de malignité.

### 1.6.3.1 Tumeurs Gliales

Les tumeurs de type glial sont les plus courantes et se forment à partir des cellules gliales du cerveau. On retrouve parmi elles les astrocytomes, les oligodendrogliomes et les glioblastomes. Les astrocytomes se forment à partir des astrocytes et peuvent être classés de I à IV en fonction de leur potentiel malignement. Les oligodendrogliomes sont produits par les oligodendrocytes et sont habituellement de grade II ou III. Les glioblastomes sont des type IV d'astrocytomes, les plus agressifs et les plus courants des gliomes[22].

### 1.6.3.2 Tumeurs Méningées

Les méningiomes se forment à partir des cellules des méninges, des membranes qui entourent le cerveau et la paroi épinière. La majorité des cas sont bénins (grade I), mais certains peuvent être atypiques (grade II) ou anaplasiques (grade III)[22].



### 1.6.3.3 Adénomes Hypophysaires

Une tumeur bénigne de l'hypophyse, une petite glande située à la base du cerveau, est l'adénome hypophysaire. La fonction de l'hypophyse, souvent désignée comme la "glande maîtresse", est essentielle pour la régulation de nombreuses fonctions hormonales du corps. Cette régulation peut être perturbée par les adénomes hypophysaires, ce qui peut entraîner différents symptômes en fonction des hormones touchées[22].

## 1.6.4 Système de Classification de Tumeurs Cérébrales selon l'OMS

Les tumeurs cérébrales sont classées par l'Organisation mondiale de la santé (OMS), qui est une référence mondiale pour les médecins et les chercheurs en neuro-oncologie. Cette typologie est régulièrement actualisée afin d'intégrer les dernières avancées en biologie moléculaire et en histopathologie.

### 1.6.4.1 Classification OMS 2021

En 2021, l'OMS a publié la classification des tumeurs du système nerveux central, ce qui constitue une importante mise à jour par rapport à la classification précédente. Cette version intègre de nouvelles catégories et sous-catégories de tumeurs, ainsi que des critères de diagnostic histomoléculaire et de grading améliorés, en particulier pour les gliomes diffus[22].

### 1.6.4.2 Critères de Diagnostic

Les analyses histologiques et moléculaires sont incluses dans les critères de diagnostic de la classification OMS 2021. Les analyses histologiques permettent d'analyser les cellules tumorales au microscope afin de déterminer leur nature et leur niveau. Les analyses moléculaires permettent d'étudier les anomalies génétiques et épigénétiques des cellules tumorales afin d'évaluer leur comportement et leur pronostic[22].

## 1.6.5 Les mécanismes de progression des tumeurs cérébrales

Les principaux mécanismes de développement des tumeurs cérébrales sont résumés ci-dessous, avec les sources correspondantes :

### 1.6.5.1 Multiplication des cellules tumorales

Les cellules tumorales prolifèrent sans régulation, ce qui conduit à une augmentation du volume tumoral[15].

### 1.6.5.2 Apparition de kystes

Les cellules tumorales ont la capacité de créer des kystes, ce qui peut accroître la taille des tumeurs[15].

### 1.6.5.3 Saignement tumoral

Les cellules tumorales peuvent s'effondrer et provoquer des saignements, ce qui peut accroître la taille des tumeurs[15].

### 1.6.5.4 Œdème

Les cellules tumorales ont la capacité de sécréter des substances qui provoquent une inflammation et un gonflement, ce qui peut entraîner une augmentation du volume tumoral[15].

### 1.6.5.5 Infiltration du tissu cérébral

Les tumeurs peuvent pénétrer dans le cerveau, ce qui peut causer une diminution de la fonction cérébrale[15].

### 1.6.5.6 Compression du cerveau

En raison de l'augmentation du volume tumoral, il est possible que le cerveau soit comprimé, ce qui peut entraîner des symptômes tels que des douleurs, des altérations de la fonction cognitive, des problèmes causés par la pression sur des structures spécifiques situées dans ou près du cerveau[15].

### 1.6.5.7 Irritation du cortex

Le cortex peut être irrité par les cellules tumorales, ce qui peut provoquer des crises d'épilepsie[15].

### 1.6.5.8 Hydrocéphalie tumorale

Il est possible que les cellules tumorales entravent la circulation du liquide cérébro-spinal, ce qui peut provoquer une hydrocéphalie tumorale[15].

### 1.6.5.9 Engagement

L'augmentation du volume tumoral peut engendrer une variation de pression, ce qui peut entraîner une hernie de tissu cérébral à travers un orifice du dièdre falco-tentorial ou le foramen magnum[15].

### 1.6.5.10 Cercle vicieux

Les divers processus de développement tumoral peuvent s'aggraver mutuellement, engendrant un cercle vicieux qui peut conduire à une aggravation rapide de la tumeur[15].

## 1.6.6 Diagnostics des Tumeurs Cérébrales

Les différentes étapes des diagnostics des tumeurs cérébrales sont les suivantes :

### **1.6.6.1 Examen clinique et neurologique**

Une évaluation clinique et neurologique approfondie est effectuée par le médecin traitant ou un spécialiste du cerveau afin de détecter les signes et les symptômes de la tumeur[22].

### **1.6.6.2 Imagerie**

L'IRM représente la méthode la plus efficace pour détecter les tumeurs cérébrales. La tomodesitométrie (TDM) présente des avantages. Ces examens permettent de déterminer de manière très précise la taille de la tumeur et son emplacement précis[22].

### **1.6.6.3 Biopsie**

On peut effectuer une biopsie afin de confirmer le diagnostic. La méthode implique l'insertion d'une aiguille fine dans le cerveau afin de prélever un échantillon de tissu tumoral[22].

### **1.6.6.4 Ponction lombaire**

Il est possible d'effectuer une ponction lombaire afin d'affiner le diagnostic. Elle implique l'insertion d'une aiguille fine dans le bas de la colonne vertébrale afin de prélever un échantillon du liquide cébrospinal[22].

### **1.6.6.5 Examen anatomo-pathologique**

Le diagnostic anatomo-pathologique est effectué afin d'étudier l'échantillon prélevé lors de la biopsie ou de la ponction lombaire. Cela permet d'identifier la nature de la tumeur ainsi que ses propriétés[22].

### **1.6.6.6 Spectroscopie par résonance magnétique**

L'activité des cellules cérébrales est évaluée par spectroscopie par résonance magnétique, qui permet d'identifier des molécules liées à leur métabolisme. Cela peut permettre de déterminer les caractéristiques d'une tumeur sans nécessiter une biopsie[22].

### **1.6.6.7 Classification officielle**

L'Organisation mondiale de la santé (OMS) utilise la classification officielle des tumeurs cérébrales pour identifier les tumeurs cérébrales. Elle établit une classification des tumeurs en fonction de leur origine cellulaire et de leur comportement, allant des tumeurs moins agressives (non malignes) aux tumeurs les plus agressives [22].

## **1.6.7 L'importance de la détection et du diagnostic des Tumeurs Cérébrales**

Le diagnostic précoce des tumeurs cérébrales est essentiel pour le pronostic et la prise en charge des patients. Effectivement, plus la tumeur est repérée à un stade précoce, plus les traitements disponibles

sont nombreux et efficaces. La détection des tumeurs cérébrales est essentielle grâce aux examens d'imagerie, comme l'IRM et le scanner. Ils donnent la possibilité d'observer la zone cérébrale touchée, la taille de la lésion et de comprendre la nature de la tumeur. Pour autant, le diagnostic de certitude est basé sur l'examen anatomopathologique d'un échantillon prélevé par biopsie. Ce test permet d'identifier le genre de tumeur, son stade et ses propriétés moléculaires, des données cruciales pour guider le traitement. Les signes des tumeurs cérébrales peuvent être inhabituels, comme les maux de tête, les crises d'épilepsie et les problèmes fonctionnels. Cependant, leur persistance ou leur caractère inhabituel doivent susciter l'attention et inciter le patient à consulter un médecin. On effectue ensuite un examen clinique et neurologique complet afin d'évaluer les répercussions de la tumeur et de guider les examens supplémentaires. En somme, il est essentiel de détecter et de diagnostiquer précocement les tumeurs cérébrales afin de proposer aux patients les techniques de traitement les plus efficaces et d'améliorer leur pronostic. Les tests d'imagerie et l'examen anatomopathologique jouent un rôle essentiel dans le processus de diagnostic [22].

#### **1.6.7.1 Perspectives futures**

Les perspectives à venir pour détecter les tumeurs du cerveau sont les suivantes :

##### **a. Amélioration de la précision**

L'emploi de l'apprentissage profond peut augmenter la précision du diagnostic des tumeurs cérébrales, ce qui peut conduire à des traitements plus efficaces et à des résultats améliorés pour les patients[22].

##### **b. Réduction des délais**

L'utilisation du deep learning permet de diminuer le temps requis pour établir un diagnostic, ce qui est essentiel pour les maladies nécessitant une intervention rapide[22].

##### **c. Traitement personnalisé**

La possibilité d'identifier précisément les tumeurs permet d'obtenir des traitements plus précis et donc potentiellement plus efficaces[22].

##### **d. Intégration de l'IA dans la neurochirurgie**

En incorporant l'intelligence artificielle dans la neurochirurgie, il est possible d'optimiser la planification des interventions et la prise en charge des patients[22].

##### **e. Avancement de la recherche**

La poursuite de l'étude des tumeurs cérébrales peut conduire à des progrès importants dans la compréhension et le traitement de ces affections[22].

## 1.7 Conclusion

La mise en œuvre du transfert learning en collaboration avec les réseaux de neurones convolutifs (CNN) dans la classification des tumeurs cérébrales marque une nouvelle convergence entre l'intelligence artificielle et la neurologie. En personnalisant ces modèles pré-entraînés en fonction de caractéristiques particulières des tumeurs cérébrales, telles que leur forme, leur texture et leur localisation. Le transfert learning permet de relever les défis classiques liés à la nécessité de données massives et annotées spécifiquement. La coopération entre le transfert learning et les CNN améliore la précision et la rapidité du diagnostic, qui sont indispensables dans le traitement des patients souffrant de tumeurs cérébrales.

Dans ce chapitre, nous avons examiné différentes technologies importantes en ce qui concerne la rapidité et l'efficacité du diagnostic, ce qui est essentiel dans le contexte clinique des tumeurs cérébrales où chaque seconde est importante. Néanmoins, malgré les avancées accomplies, des difficultés demeurent, notamment en ce qui concerne la validation clinique et l'interopérabilité des modèles dans divers milieux hospitaliers. Cependant, bien que présentant des bénéfices évidents, l'utilisation du transfert learning dans le domaine clinique des tumeurs cérébrales requiert une validation approfondie afin de garantir la fiabilité et la généralisabilité des résultats effectués.

En résumé, l'association du transfert learning et des CNN dans l'étude des tumeurs cérébrales permet d'accéder à une médecine de précision plus adaptée et efficace. L'avenir de ces technologies repose sur leur aptitude à se transformer en fonction des besoins cliniques et à être intégrées de manière transparente dans les pratiques médicales quotidiennes, afin d'améliorer la prise en charge des patients et d'optimiser les traitements.

# Chapitre 2

## Etat de l'Art

### 2.1 Introduction

Dans ce chapitre, nous nous concentrerons sur l'utilisation de l'intelligence artificielle dans le domaine de la neurochirurgie, en particulier sur l'utilisation des réseaux de neurones convolutifs (CNN) pour la détection des tumeurs cérébrales.

Nous traiterons de cette question en analysant attentivement plusieurs articles pertinents qui ont apporté une contribution importante à ce domaine. Leurs méthodologies, leurs approches, et les résultats obtenus seront exposés. Nous donnons ainsi l'occasion d'explorer les progrès récents et les difficultés liées à l'utilisation des CNN pour la classification des tumeurs céphaliques.

Nous pourrions comprendre les diverses techniques et architectures de CNN employées, les ensembles de données utilisés pour l'entraînement et la validation, ainsi que les résultats obtenus par ces modèles en nous appuyant sur ces travaux de recherche. En outre, nous soulignerons les possibles limites dans ce domaine, en nous basant sur les contributions et les recommandations retrouvées dans la littérature. Le but de ce chapitre d'état de l'art est de présenter une analyse détaillée de l'utilisation des CNN dans la classification d'IRM des tumeurs du cerveau. En analysant diverses méthodes et les résultats obtenus, Nous souhaitons apporter notre contribution à l'enrichissement des connaissances et à l'évolution de l'IA dans le domaine de la neurochirurgie avec pour objectif d'accroître le taux de classement des images IRM et de rassurer les patients.

### 2.2 Travaux connexes

La classification des tumeurs cérébrales a été l'objet de nombreuses études qui ont utilisé des modèles du deep learning et des images par IRM. Ces articles se focalisent surtout sur la classification et le diagnostic des tumeurs cérébrales. Ces articles font appel à l'apprentissage profond, pour l'analyse d'images par IRM du cerveau, ce qui correspond à l'objectif de notre étude.

## 2.2.1 Revues des méthodes de classification des IRM cérébrales

Dans cette section, nous présentons des travaux constituant notre état de l'art de l'utilisation de l'apprentissage par transfert pour la classification des tumeurs cérébrales.

### 2.2.1.1 Article 1 : Brain tumor classification for MR images using transfer learning and fine-tuning

Ce travail de Zar Nawab et al [31] propose une nouvelle approche pour la classification des images de tumeurs cérébrales basées sur l'apprentissage par transfert et le réglage fin, tout en appliquant l'apprentissage profond et d'entraîner le CNN à partir de zéro sur un petit ensemble de données. Pour cela, ils ont utilisé l'ensemble de données IRM-CE [34] avec une classification bidimensionnelles basée sur des grands écarts entre les coupes.

Ensuite, ils ont fourni des images RM directement au CNN en appliquant le noyau convolutif à l'intensité du pixel dans l'image, et une normalisation de l'intensité pour les pré traiter.

Les auteurs ont commencé l'entraînement avec le modèle VGG19 à partir de la première couche d'entrée jusqu'à la couche de classification finale selon le principe de retropropagation, la sortie est calculée avec la fonction RELU non linéaire.

Pour l'apprentissage par transfert et le réglage fin du CNN, ils ont mis à jour les poids des couches de ce dernier après chaque itération. Puis, ils ont affiné le VGG19 sur l'ensemble des données et ils ont appliqués un réglage fin par les deux derniers blocs du CNN en fixant le biais à zéro.

Ils ont testé l'approche proposé en divisant au hasard les données d'IRM-CE de 233 patients en cinq sous ensembles de taille approximativement égale et ils ont veillé à ce qu'il n'y ait pas de chevauchement et à ce que les différents types de tumeurs soient représentés de manière égale dans les cinq sous ensembles.

Après l'expérience, ils ont trouvé que cette approche proposée a atteint son maximum de précision de 94,82%, et il y avait une cohérence entre la précision et la perte.

En conclusion, cette approche peut être utilisée pour développer un système de classification pour d'autres images IRM d'organes du corps et d'autres domaines d'imagerie médicales tels que les radiographies et la photographies.




FIGURE 2.1 – Approche proposée dans l'article 1 [31]

### 2.2.1.2 Article 2 : Brain tumor MRI images identification and classification based on the recurrent convolutional neural network

Dans cet article [37] R.Vankdothu et M.Abdul Hameed ont proposé une nouvelle méthode pour l'identification et la classification des tumeurs cérébrales. Cette méthode est divisée en quatre étapes importantes qui sont le pré-traitement des images IRM, la segmentation, l'extraction des caractéristiques et la classification.

D'abord, ils ont utilisé un filtre adaptatif ou un filtre médiane pour le pré-traitement des images afin d'éliminer les bruits. Ensuite, pour la segmentation la méthode de K-means clustering est appliquée pour identifier la tumeur, et une matrice co-occurrence de niveaux de gris pour l'extraction des caractéristiques. Enfin, ils ont classifié le dataset en quatre types : "gliomas", "meningiomas", "no-pituitary" et "no-tumor" avec l'algorithme RCNN.

En conclusion, une expérience été faite sur un dataset dans Kaggle [5]. Le RCNN a donné un taux de validité de 95%.

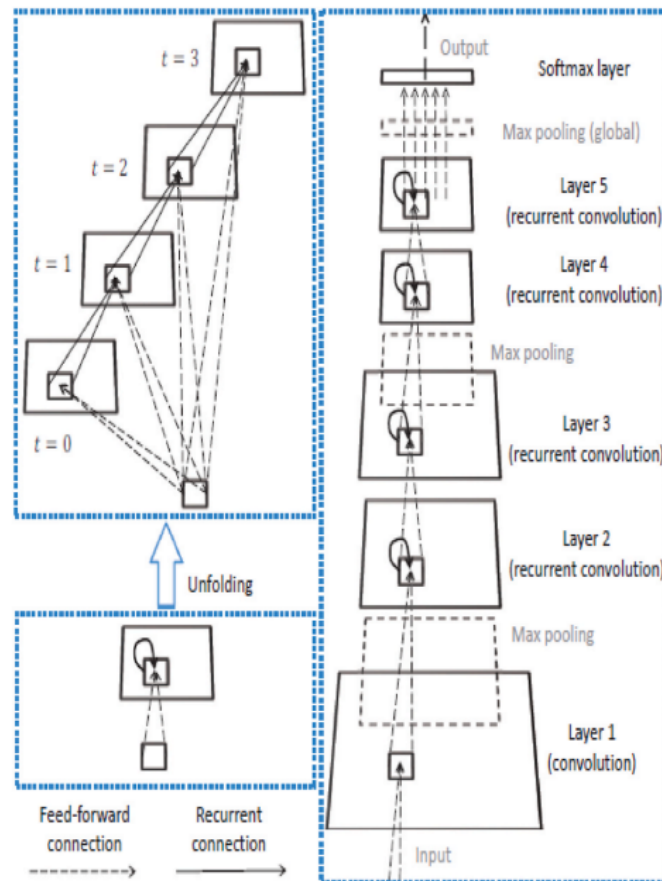


FIGURE 2.2 – Approche proposée dans l'article 2 [37]

### 2.2.1.3 Article 3 : Robust clinical applicable CNN and U-Net based algorithm for MRI classification and Segmentation for brain tumor

Cet article [1] de A.Akter et al propose une approche de fusion de datasets, où leur travail a été appliqué sur six datasets : quatre datasets individuels et deux datasets fusionnés. La fusion a été mise



en place de la manière suivante : pour les quatre datasets individuels (a,b,c,d), ils ont fusionné 'a' et 'b' pour avoir le premier dataset fusionné et 'c' et 'd' pour avoir le deuxième.

D'abord, ils ont effectué un pré-traitement d'images qui consiste à redimensionner l'image, la transformer en niveaux de gris...etc

Puis vient la segmentation où le premier dataset a été segmenté manuellement et pour le reste ils ont utilisé U-Net, fine-tuning et training pour générer les masques des tumeurs dans l'IRM. Ils ont utilisé des méthodes pré-entraînées sur d'autres datasets (VGG16, VGG19, ResNet152V2...) qui offrent de très bons résultats.

La classification d'image a été effectuée sur quatre types : "gliomas", "meningiomas", "non-pituitary" et "cerveau clean".

Finalement, le CNN proposé dans la classification a fourni des résultats de 98% de réussite sur les datasets fusionnées et 97% sur les datasets individuels.

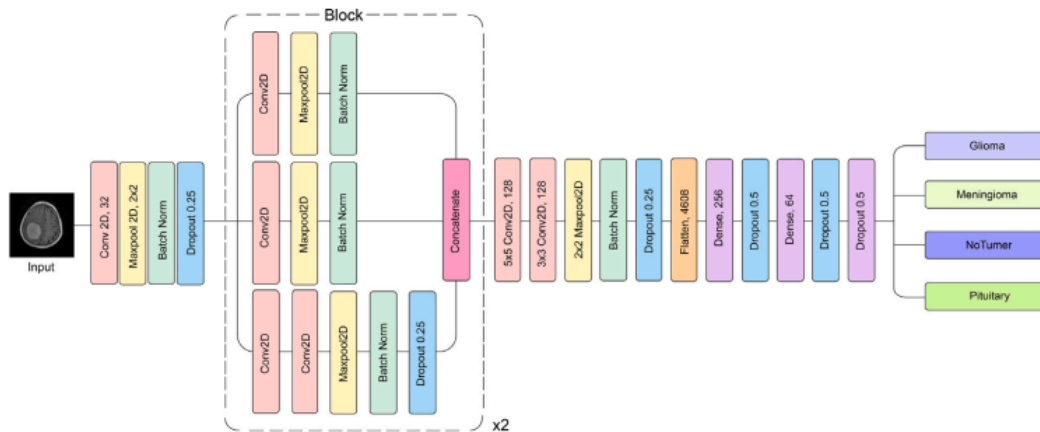


FIGURE 2.3 – Approche proposée dans l'article 3 [1]

#### 2.2.1.4 Article 4 : Detection and classification of Brain tumors

Dans cet article [8] Nikita V. Chavan et al ont divisé le travail en deux parties, la partie pré-traitement et la partie test.

Tout d'abord, ils ont utilisé un pré-traitement d'images avec le filtre gaussien, puis ils ont effectué l'histogramme d'égalisation pour le renforcement afin de d'éclaircir les images sombres. Pour la segmentation, la méthode binarisation est utilisé pour transformer l'image en noir et blanc selon une certaine intensité de pixels fixés. Puis vient l'étape de l'extraction des caractéristiques qui s'est effectué avec la matrice de co-occurrence de niveaux de gris.

Ensuite, le KNN est utilisé pour la classification, où les tumeurs ont été classifiées en deux types : "Normal" et "Anormal".

Finalement, ils ont testé leurs approche et la classification avec KNN a monté 96% de réussite.

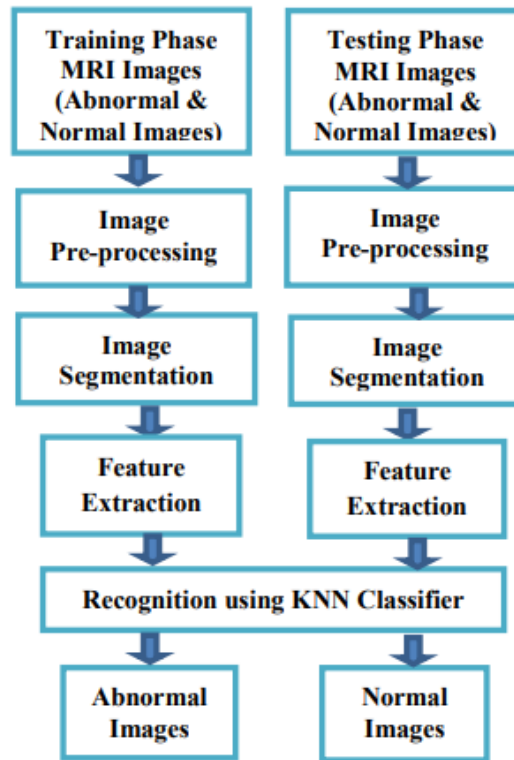


FIGURE 2.4 – Approche proposée dans l'article 4 [8]

### 2.2.1.5 Article 5 : MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques

Dans cet article [26] S.Saedi et al proposent une comparaison entre le CNN 2D et l'auto-encodeur en utilisant les techniques suivantes de machine learning : SVM, KNN, RF, SGD, LR et MLD. Ils ont commencé par un pré-traitement et une augmentation d'algorithmes sur les IRM afin de redimensionner les images d'entrées en 80x80 pixels.

Ensuite, ils ont utilisé un CNN qui contient des couches de convolution qui fonctionnent avec le filtre Kernel, des couches de maxPooling, une couche flatten, deux couches de densité et deux couches entièrement connectées.

Puis, les auteurs ont proposé un auto-encodeur qui comprend des couches de convolution de 32 à 128 filtres dans les parties encodage et décodage où ils ont appliqué un maxpooling. À chaque fin d'une opération (encodage et décodage) ils utilisent les couches de densité et les couches entièrement connectées.

Enfin, ils ont testé un dataset de 3264 [5] d'images IRM des trois types de tumeurs et les résultats ont démontré que le CNN 2D a un meilleur taux de validation que l'auto-encodeur.

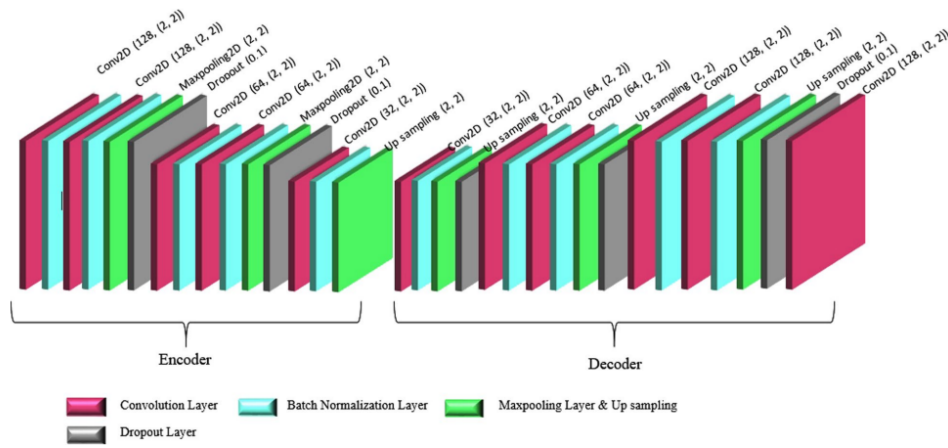


FIGURE 2.5 – Approche proposée dans l'article 5 [26]

### 2.2.1.6 Article 6 : An efficient automatic brain tumor classification using optimized hybrid deep neural network

Dans cet article [28], S. Shanthi et al ont proposé un réseau neuronal profond hybride optimisé (OHDNN) pour les tumeurs cérébrales. Cette technique englobe deux phases : le pré-traitement et la classification des images IRM.

En premier temps, ils ont pré-traité les images IRM de tumeurs cérébrales afin d'améliorer leurs qualités et d'éliminer les bruits, puis ils ont utilisé un filtre gaussien pour réduire l'erreur.

Ensuite, ils ont soumis les images IRM à l'étape de classification en utilisant l'OHDNN pour l'identification des tumeurs cérébrales et une technique hybride entre le CNN et le LSTM où les paramètres de poids de LSTM ont été choisis de manière optimale en utilisant la technique ARO afin d'augmenter le taux de classification. Pour l'examen expérimental, ils ont utilisé 1000 images IRM du cerveau de taille (512x512) collectées dans différentes cliniques de Karnataka. Parmi ces images, 600 ont été utilisées pour le processus de traitement et 400 restantes pour le processus de test. Les résultats du test sur 80 époques ont montré que la perte est de 0,025% et la précision est de 97,5%.

En conclusion, ils ont montré que cette approche basée sur le CNN-LSTM donne 3,17% de mieux par rapport à la classification des tumeurs basée sur le CNN, 8,3% de mieux que celle du SVM et 10,4% de mieux que celle des ANN.

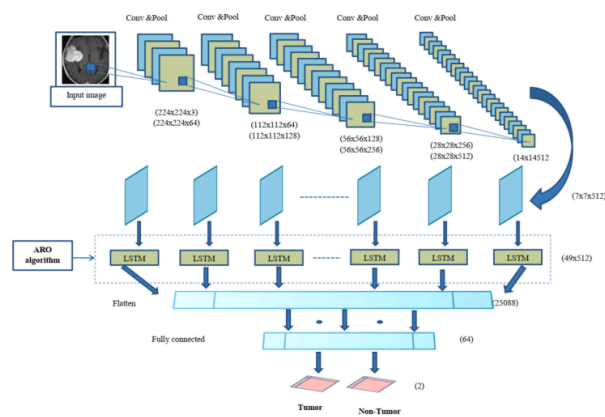


FIGURE 2.6 – Approche proposée dans l'article 6 [28]

### 2.2.1.7 Article 7 : A Framework for Brain Tumor Segmentation and Classification using Deep Learning Algorithm

Cet article [21] de Sunita M. Kulkarni et al propose une méthode de détection des tumeurs cérébrales et de classification où les données ont été classifiées avec ou sans tumeur.

Les auteurs ont commencé par le pré-traitement et la normalisation pour que l'intensité sera situé dans une plage de valeurs des pixels entre 0 et 1.

Ensuite, ils ont découpé les images du crâne qui est une procédure nécessaire pour examiner les images biomédicales, ce qui permettra une analyse efficace des tumeurs cérébrales. Ce découpage permet d'éliminer les parties non cérébrales comme la peau, la graisse et le crâne. Dans l'étape suivante vient le traitement morphologique avec un petit masque de 3x3 ou de 5x5 qui a été effectué par le processus d'orision et de dilatation sur l'image binaire afin d'obtenir une image appropriée et des lacunes comblées au sein de l'objet détecté.

Pour l'entraînement des données, ils ont utilisé GoogleNet qui applique un pooling et un Continual Learning en parallèle, ce qui donne lieu à une amélioration de la profondeur de réseau et une performance plus élevée.

Enfin, ils ont classifié les images IRM [23] en tumeurs (maligne et bénigne) à l'aide d'algorithmes d'apprentissage par transfert AlexNet basé sur le CNN. Cette méthode proposée a atteint une précision de 93,75% , un rappel de 1 et une mesure F1-Score de 96,77%.




FIGURE 2.7 – Approche proposée dans l'article 7 [21]

### 2.2.1.8 Article 8 : Brain tumor classification using deep CNN features via transfer learning

Dans cet article [10] S.Deepak et P.M.Ameer porte sur une difficulté de classement en trois classes afin de distinguer les gliomes, les méningiomes et les tumeurs hypophysaires.

L'algorithme proposé utilise le réseau GoogLeNet modifié et affiné pour apprendre les caractéristiques des images IRM du cerveau contenant des tumeurs afin d'avoir une classification via un apprentissage par transfert.

Le modèle appris par le transfert comprends une couche de classification softmax qui classe les images en trois catégories de tumeurs citées auparavant. Le modèle prédit produit des étiquettes de classes

pour les données de test. Par la suite, ils ont utilisé KNN pour avoir une meilleure comparaison. Ils ont testés les caractéristiques CNN sur deux classificateurs autres que le classificateur softmax (SVM et K-nearest neighbours) sur une collection de données de 3064 images IRM cérébrales de taille 512x512 de 233 patients, qui ont été pré-entraînées et normalisées en valeurs d'intensité avec la technique min-max entre 0 et 1.

L'ensemble de données a été divisé en cinq sous-ensembles disjoints de taille approximativement égales. Cette division de l'ensemble de données assure que les données d'un patient particulier ne seront pas présentes dans l'ensemble de test et dans l'ensemble d'apprentissage simultanément.

Ils ont obtenus comme résultats de test, une précision de  $92,3 \pm 0,7\%$  de la classification du modèle appris par le transfert profond, une précision de  $97,8 \pm 0,2\%$  pour SVM et une précision de  $98,0 \pm 0,4\%$  pour le KNN.




Fig. 1. Transfer learning setting.




FIGURE 2.8 – Approche proposée dans l'article 8 [10]

### 2.2.1.9 Article 9 : Detection and Classification of Brain tumors Using Deep Convolutional Neural Networks

Cet article [3] de Ranit Sen et al a pour objectif de différencier les pixels anormaux et de les classer par ordre de priorité afin d'avoir une meilleur classification des images IRM.

Pour cette étude, ils ont implémentés des architectures des CNN telles que EfficientNetB0, ResNet50, Xception, MobileNetV2 et VGG16 en utilisant l'apprentissage par transfert pour détecter les quarte classes des tumeurs cérébrales (gliomes, méningiomes, tumeurs hypophysaires et pas de tumeurs).

Ils ont commencé par un pré-traitement des images IRM en appliquant une correction du biais et en maximisant la qualité de ces dernières afin d'avoir une meilleur segmentation. Le filtre de flou gaussien, le débruitage BM3D, le lissage de variation to-tale, l'augmentation des données ont également été utilisés.

Les auteurs ont utilisé le CNN affiné pour détecter avec précision les bordures d'images. Ils l'ont modifié en ajoutant des couches entièrement connectées (FC) et en remplaçant les couches danses par une moyenne globale, une couche d'exclusion et une couche d'abandon. Le taux d'apprentissage initiale a été fixé à 0,003 et la taille de chaque lot à 32.

Ils ont entraîné le modèle pendant 12 époques sur 3264 images IRM de dimension 150x150. EfficientNetB0 a donné le meilleur résultats (97,61%) comparant aux quatre autres architectures qui ont donné aussi de bons résultats (96%).




FIGURE 2.9 – Approche proposée dans l'article 9 [3]

### 2.2.1.10 Article 10 : Classification of Brain Tumors Using Convolutional Neural Network over Various SVM Methods

Ce travail [27] de V.R.Sajja et H.K.Kalluri utilise une architecture CNN hybride qui se compose de trois couches de convolutions et trois couches de max-pooling pour avoir une meilleur classification des images IRM des tumeurs cérébrales.

Les images RVB ou en niveaux de gris sera donnée en entrée à la premiere couche convolutive (en appliquant la fonction RELU) qui produira la sortie en calculant le produit croisé entre les poids et les régions.

Le nombre requis de classes de sorties est calculé à partir des scores des classes de la couche entièrement connectée. Ils ont utilisé 577 images de l'ensemble de données BRATS [20-22] afin de tester l'architecture proposée. Ils ont opté pour une comparaison entre CNN et FCM+SVM puis avec K-means+SVM.

Les resultats montrent que CNN donne une meilleur classification (96,15%) par rappaort à FCM+SVM (94,5%) et K-means+SVM (92,3%).

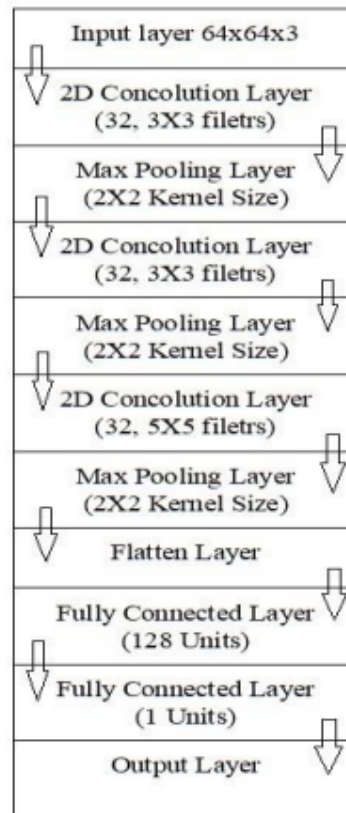


FIGURE 2.10 – Approche proposée dans l'article 10 [27]

### 2.2.2 Tableau récapitulatif

Nous procéderons à un récapitulatif des approches mentionnées ci-dessus sur la base des six facteurs suivants dans le tableau ci-dessous :

- Titre : désigne le titre de l'article aussi bien que les auteurs.
- Dataset : identifie les ensembles de données utilisés pour mettre en œuvre l'approche proposée .
- Classes de sortie : décrit les différents types de tumeurs sur lesquels ils ont opté après avoir effectué la classification.
- Approches : décrit comment chaque article est abordé.
- Résultats : les résultats obtenus par chaque méthode.
- Avantages : les avantages de l'approche adoptée.
- Inconvénients : Les inconvénients de l'approche adoptée.

Articles	Dataset	Approches	Classes de sortie	Résultats	Avantages	Inconvénients
<b>Articles 1 [31]</b>	Les données d'IRM-CE de 233 patients comprenant [34]	<ul style="list-style-type: none"> <li>• Une architecture CNN</li> <li>• La fonction d'activation ReLU non linéaire</li> <li>• Réglage de fin</li> <li>• Le réglage de rétropropagation.</li> </ul>	Normale ou Anormale	94,82% de précision	<ul style="list-style-type: none"> <li>• précision élevée</li> <li>• pré-traitement minim</li> </ul>	<ul style="list-style-type: none"> <li>• La précision est discutable (dataset minim)</li> <li>• Le nombre de classes est petit</li> </ul>
<b>Article 2 [37]</b>	Dataset dans Kaggle (3264 images IRM de 233 patients) [5]	<ul style="list-style-type: none"> <li>• Un pré-traitement,</li> <li>• K-means clustering,</li> <li>• matrice co-occurrence</li> <li>• L'algorithme RCNN</li> </ul>	gliomas, meningiomas, non-tumors, et pituitary tumors.	95% de précision	<ul style="list-style-type: none"> <li>• RCNN offre un grand taux de sensibilité par rapport à U-Net,</li> <li>• RCNN améliore la qualité de l'image</li> </ul>	<ul style="list-style-type: none"> <li>• RCNN prend beaucoup de temps,</li> <li>• Un grand espace mémoire</li> </ul>
<b>Article 3 [1]</b>	<ul style="list-style-type: none"> <li>• (ensemble de données 'a' (cheng,2017), dataset 'b' (Bhuvaji,2020), dataset 'c' (Pradeep,2021), dataset 'd' (Sherif,2020))</li> <li>• (Merged dataset1 et Merged dataset2)</li> </ul>	<ul style="list-style-type: none"> <li>• Rédimensionnement d'image,</li> <li>• transformation de niveaux de gris,</li> <li>• segmentation manuelle et U-Net,</li> <li>• un training, (VGG16, VGG19, ResNet152V2, EfficientNetB0, EfficientNetB7),</li> <li>• fonction Softmax,</li> <li>• CNN</li> </ul>	gliomas, meningiomas, non-pituitary et clean	<ul style="list-style-type: none"> <li>• 98% de réussite sur les dataset fusionnés,</li> <li>• 97% sur ceux individuels</li> </ul>	<ul style="list-style-type: none"> <li>• Résultats uniformes,</li> <li>• Les dataset fusionnés donnent des résultats plus élevés</li> </ul>	<ul style="list-style-type: none"> <li>• La classification des dataset fusionnés est complexe</li> </ul>



Articles	Dataset	Approches	Classes de sortie	Résultats	Avantages	Inconvénients
<b>Article 4 [8]</b>	Images de l'OMS (organisation mondiale de la santé) et WBA (World Brain Atlas)	<ul style="list-style-type: none"> <li>• Un pré-traitement, filtre gaussien,</li> <li>• un histogramme d'égalisation,</li> <li>• une segmentation (binarization),</li> <li>• matrice de co-occurrence,</li> <li>• KNN</li> </ul>	Normale et Anormale	96% de précision	Une précision élevée	<ul style="list-style-type: none"> <li>• Nécessité d'un temps de calcul très grand,</li> <li>• sensibilité aux bruits.</li> </ul>
<b>Article 5 [26]</b>	3264 images IRM [5]	<ul style="list-style-type: none"> <li>• Un pretraitement,</li> <li>• augmentation d'algorithmes,</li> <li>• CNN, filtre Kernel,</li> <li>• couches pooling,</li> <li>• couche flatten,</li> <li>• 2 couches de densité,</li> <li>• 2 couches entièrement connectées,</li> <li>• un auto-encodeur</li> </ul>	glioma, meningioma, pituitary gland tumors	<ul style="list-style-type: none"> <li>• 96,47% de validation (CNN 2D),</li> <li>• 95,63% de validation (l'auto-encodeur)</li> </ul>	<ul style="list-style-type: none"> <li>• des bonnes performances optimal sans latence, complexité minimale (CNN)</li> </ul>	<ul style="list-style-type: none"> <li>• consommation extrême de mémoire</li> </ul>
<b>Article 6 [28]</b>	1000 images IRM (512x512)	<ul style="list-style-type: none"> <li>• Un pré-traitement,</li> <li>• un filtre gaussien,</li> <li>• OHDNN,</li> <li>• technique hybride entre CNN et LSTM</li> </ul>	Normal ou Tumor	<ul style="list-style-type: none"> <li>• 97,5% de précision (sur 80 epoques),</li> <li>• 0,025% de perte</li> </ul>	<ul style="list-style-type: none"> <li>• une classification automatique (schéma hybride CNN-LSTM),</li> <li>• une efficacité de classification</li> </ul>	<ul style="list-style-type: none"> <li>• L'efficacité du schéma hybride CNN-LSTM peut dépendre de la qualité des images utilisées.</li> </ul>

Articles	Dataset	Approches	Classes de sortie	Résultats	Avantages	Inconvénients
<b>Article 7 [21]</b>	154 IRM tumorales et 91 IRM non-tumorales [23]	<ul style="list-style-type: none"> <li>• Un pré-traitement, une normalisation, • méthode du découpage de crâne, • un traitement morphologique, • GoogleNet, • un pooling, • CL en parallèle</li> </ul>	malignes et bénignes	<ul style="list-style-type: none"> <li>• 93,75% de précision</li> </ul>	<ul style="list-style-type: none"> <li>• une détection et une classification avancée, • un pré-traitement efficace, • Amélioration de performance du modèle avec l'apprentissage par transfert AlexNet</li> </ul>	<ul style="list-style-type: none"> <li>• Un problème de détection de frontières comme tous les CNN, • Une complexité de la mise en oeuvre.</li> </ul>
<b>Article 8 [10]</b>	brain tumor dataset [figshare'brain_tumor]	<ul style="list-style-type: none"> <li>• GoogLeNet, • un apprentissage par transfert, • softmax, • CNN, • SVM, • K-nearest neighbours</li> </ul>	les gliomes, les méningiomes et les tumeurs hypophysaires	<ul style="list-style-type: none"> <li>• 92,3 ± 0,7% du transfert profond, • 97,8 ± 0,2% pour SVM, • 98,0 ± 0,4% pour KNN</li> </ul>	<ul style="list-style-type: none"> <li>• Une meilleure performance de SVM et KNN</li> </ul>	<ul style="list-style-type: none"> <li>• La masse de données prise est déséquilibrée.</li> </ul>

Articles	Dataset	Approches	Classes de sortie	Résultats	Avantages	Inconvénients
<b>Article 9 [3]</b>	3264 Images IRM 2D	<ul style="list-style-type: none"> <li>• Correction du biais</li> <li>• un apprentissage par transfert</li> <li>• filtre de flou gaussien</li> <li>• BM3D</li> <li>• lissage total</li> <li>• CNN</li> <li>• EfficientNetB0</li> <li>• ResNet50</li> <li>• Xception</li> <li>• MobileNetV2</li> <li>• VGG16</li> </ul>	les gliomes, les méningiomes, les tumeurs hypophysaires et no-tumor	<ul style="list-style-type: none"> <li>• 97,61% de EfficientNetB0</li> <li>• 96% (ResNet50, Xception, MobileNetV2, VGG16)</li> </ul>	Une bonne précision de EfficientNetB0	Une perte d'information lorsque on va plus en profondeur.
<b>Article 10 [27]</b>	577 IRM de BRATS [20-22]	<ul style="list-style-type: none"> <li>• 3 couches de convolution</li> <li>• 3 couches de max-pooling</li> <li>• CNN</li> <li>• SVM</li> <li>• FCM</li> <li>• K-means</li> </ul>	tumor et no-tumor	<ul style="list-style-type: none"> <li>• 96,15% pour CNN</li> <li>• 94,5% pour FCM+SVM</li> <li>• 92,5% pour K-means+SVM</li> </ul>	<ul style="list-style-type: none"> <li>• Un bon entraînement de données</li> <li>• CNN produit de meilleurs résultats par rapport à SVM</li> </ul>	Une complexité temporelle lorsque le dataset est grand.

TABLE 2.1 – Tableau récapitulatif selon 7 caractéristiques

## 2.3 Discussion

Les travaux de recherche présentés dans les articles mentionnés précédemment concernant la classification des tumeurs cérébrales mettent en évidence différentes méthodes qui utilisent des réseaux de neurones convolutionnels (CNN) et l'apprentissage par transfert, chacune avec ses propres techniques de pré-traitement, de segmentation et d'extraction de caractéristiques. À titre d'exemple, l'emploi du modèle VGG19 et de GoogleNet dans des configurations de transfert d'apprentissage a démontré des précisions allant jusqu'à 98%. Les résultats obtenus avec d'autres techniques telles que RCNN, U-Net, EfficientNetB0 et des modèles hybrides combinant CNN et LSTM, FCM et SVM, K-means et SVM ont également été prometteurs, avec des précisions allant de 94,82% à 97,5%. Malgré ces progrès, le problème de la classification des tumeurs cérébrales demeure insoluble. La précision de la classification, la diversité des datasets, la complexité des modèles et la nécessité d'une segmentation précise sont des défis majeurs.

Le transfert learning est particulièrement bénéfique pour optimiser les performances avec des données restreintes, car il permet de tirer parti des connaissances acquises par des modèles pré-entraînés sur de vastes ensembles de données. Cela diminue la nécessité d'obtenir des quantités considérables de données marginées, souvent difficiles à obtenir dans le secteur médical. Il est donc crucial de concevoir de nouvelles méthodes ou de les améliorer afin de surmonter ces contraintes.

Ces progrès sont indispensables afin de proposer des solutions cliniquement fiables et précises pour le diagnostic et le traitement des tumeurs cérébrales. Cela aidera les cliniciens à prendre des décisions cruciales de manière plus efficace, ce qui améliorera les résultats pour les patients.

Après avoir pris en compte tous ces éléments, nous avons décidé d'utiliser un modèle EfficientNetB0 afin de gérer notre problématique et extraire les propriétés. Ce modèle est couramment employé et ont prouvé leur efficacité dans le domaine de la vision par ordinateur, en particulier pour la classification d'images IRM. Nous souhaitons obtenir des résultats précis et fiables dans notre étude de classification d'images d'IRM en utilisant ce modèle.

## 2.4 Conclusion

L'analyse de la classification des tumeurs cérébrales actuelle met en évidence une diversité d'approches novatrices, principalement axées sur l'utilisation des réseaux de neurones convolutionnels (CNN) et des techniques d'apprentissage par transfert. Les résultats des recherches démontrent des progrès notables en matière de précision et de solidité des modèles, avec des taux de succès souvent supérieurs à 94%. Néanmoins, malgré ces progrès significatifs, la classification des tumeurs cérébrales demeure un défi pour diverses raisons, notamment la complexité des différentes formes de tumeurs, la similarité des caractéristiques radiologiques entre les différentes formes de tumeurs, la diversité des manifestations cliniques et l'importance primordiale d'une détection précoce pour améliorer les résultats cliniques.

Il est essentiel que la recherche dans ce domaine se focalise sur l'élaboration de nouvelles méthodes

afin d'améliorer la précision, la généralisation et la simplification des modèles. Cela englobe l'étude de nouvelles structures de réseaux, l'incorporation de méthodes de classification avancées et la combinaison de différentes approches afin d'atteindre des performances optimales. Grâce à ces initiatives, des outils de classification plus précis et fiables seront disponibles, ce qui permettra d'améliorer les soins prodigués aux patients souffrant de tumeurs cérébrales.

# Chapitre 3

## Notre Approche

### 3.1 Introduction

Dans ce chapitre, nous allons présenter l'approche proposée avec explications de ses différentes étapes. Tout d'abord nous allons présenter le modèle que nous avons choisi pour le transfert learning, ensuite nous allons expliquer toutes les étapes de notre approche en détails, puis nous allons présenter les couches que nous avons ajoutés au modèle de base et justifier pourquoi nous les avons choisi, après ça nous passons à la manière dont nous avons entraîné le modèle c'est-à-dire le transfert learning et le fine-tuning, et en dernier lieu nous allons faire un tour sur les hyperparamètres que nous avons choisis.

### 3.2 Architecture EfficientNetB0

EfficientNetB0[28] est un modèle de réseau de neurones convolutif (CNN), il a été proposé pour la première fois par Google AI en 2019.

Le modèle a été introduit dans l'article de recherche intitulé "EfficientNet : Rethinking Model Scaling for Convolutional Neural Networks"[32], publié par Mingxing Tan et Quoc V.Le, visant à optimiser la classification d'images en maximisant l'efficacité et la précision grâce à une technique innovante de redimensionnement, appelée "compound scaling". Cette technique ajuste simultanément et de manière équilibrée la profondeur, la largeur et la résolution d'images, ce qui permet d'atteindre une performance optimale sans augmenter excessivement la complexité du modèle.

EfficientNetB0 est construit à partir de blocs MBConv (Mobile Inverted Bottleneck Convolution), favorisant une réduction significative des paramètres et une amélioration de l'efficacité computationnelle. Ce modèle, avec environ 5,3 millions de paramètres, atteint une précision supérieure à 77% sur le benchmark ImageNet[11], se distinguant par son excellent compromis entre performance et coût computationnel.

Conçu pour être léger et rapide, EfficientNetB0 est particulièrement adapté aux environnements aux ressources limitées, comme les appareils mobiles ou les systèmes embarqués. La famille des modèles EfficientNet, comprenant plusieurs versions allant de B0 à B7, permet aux utilisateurs de choisir un

modèle en fonction de leurs besoins spécifiques en termes de précision et de contraintes de calcul.

De plus, EfficientNetB0 est facilement intégrable dans divers programmes de traitement d'images via des bibliothèques populaires comme TensorFlow et Keras, facilitant son utilisation dans les applications pratiques. La figure 3.1 montre comment l'architecture d'EfficientNetB0 est faite et montre la distribution de ses blocs de convolution.




FIGURE 3.1 – Architecture EfficientNetB0[36]

### 3.3 Notre méthodologie

Le modèle proposé avec ses différentes couches va être discuté en détails dans cette section. La figure 3.2 présente les différentes étapes suivies.

- **Premièrement**, nous allons lire les images des datasets une par une et les mettre dans la classe à laquelle elle appartient, grâce à la bibliothèque "cv2" cette opération est réalisable, il suffit juste de montrer le chemin du dataset.
- **Ensuite**, après chaque image lue, nous allons directement effectuer un redimensionnement de l'image en 224x224x3 pour qu'elle soit adapté au format demandé par EfficientNetB0, c'est la condition mise par le modèle pour procéder à l'entraînement. Cette opération est aussi réalisable grâce à la bibliothèque "cv2".
- **Deuxièmement**, L'étape de la division des données lues en données d'entraînement et données de validation vient juste après, en effet, nous allons diviser les données en 80% pour l'entraînement et 20% pour la validation.
- **Troisièmement**, nous allons importer le modèle EfficientNetB0 à partir de la bibliothèque Keras de TensorFlow et le configurer pour qu'il s'adapte de manière optimale à notre tâche spécifique. En tirant parti de l'architecture avancée d'EfficientNetB0, nous pouvons exploiter ses paramètres pré-entraînés et les ajuster pour maximiser les performances sur notre ensemble de données. Voici une explication détaillée de ce processus.
- **En dernier lieu**, Nous avons maintenant terminé les étapes de prétraitement et de configuration du modèle EfficientNetB0. Il ne nous reste plus qu'à régler les hyperparamètres, tels que le taux d'apprentissage, la taille des lots, et le nombre d'époques, puis à procéder à l'entraînement du modèle avec les nouvelles couches ajoutées sur nos ensembles de données. Une fois entraîné, le modèle sera capable de classifier chaque image de nos 2 datasets.

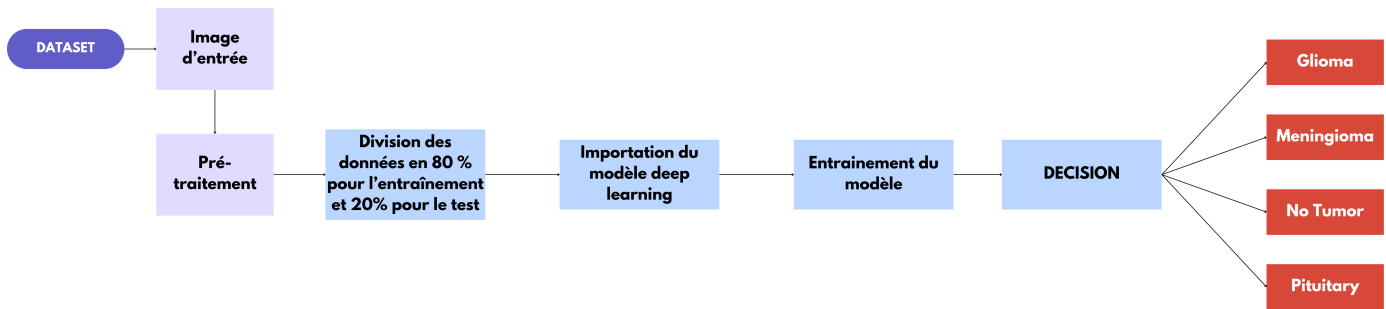


FIGURE 3.2 – Diagramme de la méthode utilisée

### 3.4 Couches proposées

Après avoir importé EfficientNetB0, nous avons décidé de lui rajouter des couches. Ces couches sont choisit après mainte combinaisons de couches. La figure 3.3 montre la structure des couches ajoutées au modèle de base. Nous allons présenter ces couches ajoutées et justifier pourquoi nous les avons choisit :

#### 1ère couche : Flatten

Cette couche permet d’aplatir les données extraites du modèles et les transformer en une seule liste de données pouvant être traitées facilement. En effet, lorsque nous utilions le transfert learning, nous nous devons d’ajouter cette couche pour ensuite pouvoir en rajouter d’autres, autrement, le processus de la classification ne sera pas réalisable car les données sorties du modèle sont massives et sous forme de matrices, ces matrices ne sont pas compatibles avec les couches Dense.

#### 2ème couche : 1ère couche Dense

Les couches Dense permettent d’affecter à chaque caractéristique extraite par le CNN une probabilité, ceci aide à définir la classification finale de l’image. Nous avons choisi 2048 neurones pour une bien meilleure affectation de probabilités car nous avons un grand nombre d’images, nous pouvons rajouter plus de neurones mais ceci entraînera un sur-apprentissage et une non généralisation des données, il est mieux de réduire au maximum les neurones des couches Dense et de les partager sur plusieurs couches ce que nous avons fait. La fonction d’activation choisie est ‘relu’, son rôle c’est de garder que les valeurs positives extraites du modèle en d’autres termes elle permet de garder que les caractéristiques les plus pertinentes.

#### 3ème couche : 2ème couche Dense

Cette couche Dense avec 512 neurones permet de plus ou moins aider la couche d’avant à bien affecter les probabilités, puisque elles ont la même fonction d’activation qui est ‘relu’, c’est une sorte de deuxième couche intermédiaire qui couvrent les erreurs de la couche précédente.

#### 4ème couche : Dropout

La couche Dropout permet de désactiver quelques neurones (selon le pourcentage mis dans les paramètres de la couches, nous avons mis 0.5 ce qui est 50% des neurones). Cette opération permet aux couches dense de traiter les images avec des neurones en moins pour éviter le sur-apprentissage et bien



généraliser sur les données, elle a un grand rôle dans la cohérence des résultats.

### 5ème couche : 3ème couche Dense

Cette couche Dense a la fonction "softmax" comme fonction d'activation, cette fonction permet de choisir le maximum des probabilités affecté par les couches Dense précédentes aux caractéristiques et avec ça, donner le résultat de la classification. Généralement, cette couche possède comme nombre de neurones le nombre de classes de sorties de la classification finale, ici nous avons 4 classes de sortie.

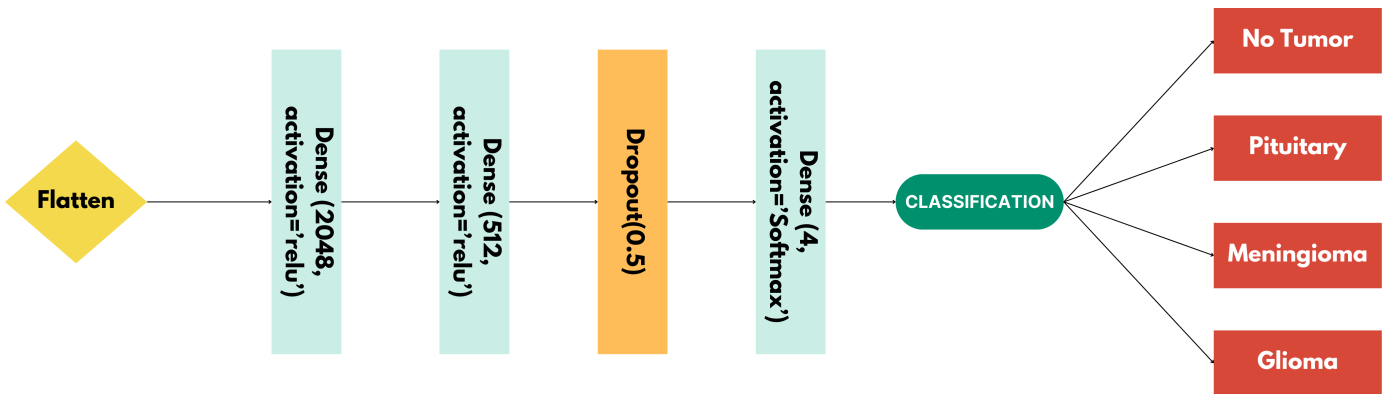


FIGURE 3.3 – Couches proposée

## 3.5 Approche proposée (Transfert learning et Fine-tuning)

Cette section démontre comment nous avons défini et entraîné le modèle.

Premièrement, nous l'avons importé depuis la bibliothèque keras, nous avons choisit ce modèle parcequ'il a déjà été entraîné sur ImageNet[11] qui est un dataset avec plus de 1000 classes de classification et presque 14 millions images dedans et a démontré une précision de plus de 77%. Ceci lui a permit d'obtenir des poids adaptés à la détection des formes, des countours et autres éléments essentiels pour la classification des images.

Mais la structure de base d'EfficientNetB0 ne peut pas être entraîné sur nos 2 datasets, et c'est ici qu'intervient le fine-tuning.

Le fine-tuning est une technique de machine learning consistant à ajuster un modèle préalablement entraîné sur un ensemble de données de base à une nouvelle tâche spécifique en utilisant un ensemble de données plus restreint et spécifique à cette tâche. Elle fonctionne en gélant les couches du modèle à faire des mise à jour des paramètres, ce qui permettra de garder les connaissance acquise de ses expériences précédentes et en profiter pour résoudre notre problème.

Cette approche permet de tirer parti des connaissances générales acquises par le modèle de base tout en l'adaptant aux particularités du nouveau contexte, améliorant ainsi les performances et l'ef-

efficacité du modèle pour la tâche cible sans nécessiter un réentraînement complet à partir de zéro.

En résumé, nous importons le modèle de base qu'est EfficientNetB0, nous faisons notre fine-tuning pour en tirer le maximum de ses connaissances acquises à travers d'autres expériences, ensuite nous lui ajoutons les couches que nous avons présenté lors de la section précédente, après ça, nous ajustons nos hyperparamètres en fonction de la taille de nos données, et en dernier lieu il nous reste qu'à entraîner le modèle sur nos 2 datasets et observer les résultats de la classification. La figure 3.4 représente l'architecture finale proposée du modèle.

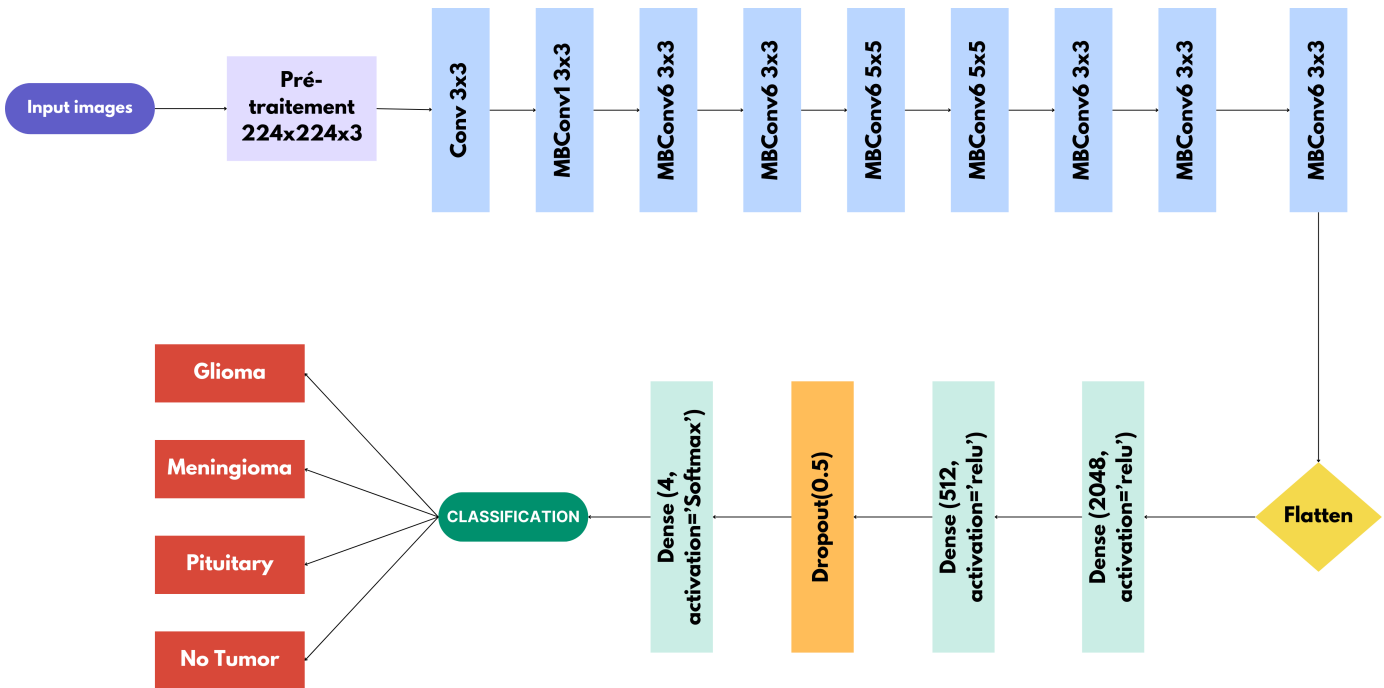


FIGURE 3.4 – Architecture finale proposée

### 3.6 Hyperparamètres et fonction de perte

Lors de l'entraînement d'un modèle de deep learning pour une tâche de classification, la performance ne se base pas uniquement sur la précision mais aussi sur la fonction de perte. Il est courant d'utiliser la fonction de perte categorical cross-entropy, la "categorical cross-entropy" (ou entropie croisée catégorielle en français) est une fonction de perte couramment utilisée dans les problèmes de classification multiclasse en apprentissage automatique et en réseaux de neurones. Elle mesure la performance d'un modèle de classification dont la sortie est une probabilité entre 0 et 1. La categorical cross-entropy quantifie la différence entre deux distributions de probabilité : la distribution prédite par le modèle et la distribution réelle des classes[6]. Elle est définie comme suit :

$$CategoricalCross - Entropy = - \sum_i y_i \log(p_i)$$

où  $y_i$  est la valeur binaire indiquant si la classe  $i$  est la classe correcte et  $p_i$  est la probabilité prédite pour la classe  $i$ .

Pour optimiser les poids du modèle, nous avons utilisé l'optimizer Adam, qui permet un réglage adaptatif des taux d'apprentissage, conduisant à une convergence rapide et stable[20].

Pendant l'entraînement, nous avons configuré un batch size de 64, le batch\_size c'est le nombre d'images que le modèle traite sur une itération avant de mettre à jour les poids du modèle. De plus, nous avons appliqué un validation split de 0.2, réservant ainsi 20% des données d'entraînement pour évaluer les performances du modèle sur des données non vues et prévenir le surapprentissage. Le modèle a été entraîné sur 50 itérations.

La table suivante résume les paramètres utilisés :

No	Hyperparamètre	Valeur
1	Optimizer	Adam
2	Batch size	64
3	Itérations	50
4	Validation split	0.2
5	Fonction de perte	Categorical cross-entropy

En réglant soigneusement les hyperparamètres et en procédant à l'entraînement du modèle avec une attention particulière à la fonction de perte et à l'évaluation sur des données de validation, nous avons optimisé les performances de notre modèle EfficientNetB0 pour la tâche spécifique de classification d'images. Cela permet au modèle de classifier chaque image de notre dataset avec une précision et une robustesse accrues, en exploitant pleinement ses paramètres pré-entraînés et les ajustements spécifiques que nous avons apportés.

## 3.7 Conclusion

En conclusion, ce chapitre a détaillé l'approche utilisée pour mener à bien cette recherche. Nous avons présenté le modèle choisi et avons expliqué pourquoi il a été choisi, nous avons bien détaillé notre approche, nous avons expliqué comment on a adapté le modèle à notre problématique, nous avons présenté les couches ajoutées et expliqué pourquoi nous les avons ajoutés, et enfin nous avons indiqué les hyperparamètres et la fonction de perte utilisés. Ainsi, l'approche décrite dans ce chapitre constitue la colonne vertébrale de notre recherche.

# Chapitre 4

## Evaluation des performances

### 4.1 introduction

Dans ce chapitre, nous allons discuter les résultats générés de l'entraînement et de notre approche sur les 2 datasets pris du site publique Kaggle[19]. Nous allons commencer par expliquer les détails de l'implémentation, ensuite nous allons décrire les deux datasets utilisés et allons expliquer la manière dont nous avons procédé à la division de leurs données, après ça nous allons présenter les mesures de performances pris en considération pour observer les résultats de l'entraînement, ensuite nous allons montrer les résultats obtenus par notre approche pour chaque dataset, et en dernier lieu nous allons valider notre travail en le comparant à 2 autres modèles DL.

### 4.2 Détails d'implémentation

Dans cette section nous allons présenter les détails de notre implémentation. Nous nous avons inspiré de l'article intitulé "Robust clinical applicable CNN and U-Net based algorithm for MRI classification and segmentation for brain tumor" [1], dans cet article ils ont utilisé 4 datasets au total, nous à notre tour avons entraîné notre architecture sur 2 datasets.

Nous avons appliqué notre approche à chacun des 2 datasets (a et b). Un pré-entraînement a été effectué aux données des 2 datasets chacun à leur tour, ce dernier consiste à lire l'image avec la bibliothèque "opencv", grâce à la commande "cv2.imread", direct après que l'image est lue nous allons effectuer un redimensionnement de l'image en 224x224x3 avec la commande "cv2.resize".

Après lecture et redimensionnement, les images seront mises dans deux listes provisoires, la première contient l'image et la deuxième contient le label auquel appartient l'image.

Après avoir lu et redimensionné les images, nous nous devons de les partager en données d'entraînement et données de validation. Nous avons importé de la bibliothèque "sklearn" la méthode "train\_test\_split". nous avons pu diviser les données lues en 2 listes x\_train et x\_test, x\_train contient 80% des données et x\_test contient 20%, y\_train et y\_test sont deux listes qui contiennent les labels des images de x\_train et x\_test.

Pour une bonne exécution nous avons utilisé comme hyperparamètres : L'optimizer Adam pour ajuster le taux d'apprentissage, un batch size de 64 et une fonction de perte qui est categorical cross-entropy. La fonction de la classification finale est softmax, cette fonction choisit le maximum des probabilités affectées par les couches Dense intermédiaires et donne la décision finale sur l'image. Après pré-traitement des données, nous les avons chargés sur deux tableaux `x_train`, `y_train`, de sorte que `x_train` contient les images et `y_train` contient les labels à laquelle l'image de `x_train` appartient, après ça, grâce à la bibliothèque `sklearn`, nous avons importé la méthode `train_test_split` qui a comme rôle de diviser les données en données d'entraînement et données de test. Nous avons divisé les données en 80% données d'entraînement et 20% données de tests pour éviter des dominations de classes. Puis vient le transfert learning et le fine-tuning, et reste qu'à compiler le modèle et l'exécuter. Nous avons entraîné le modèle sur 50 itérations.

### 4.2.1 Descriptions des datasets

Nous allons présenter les 2 datasets utilisés sur notre modèle :

#### Dataset a [24] :

Le dataset contient 7023 images, réparti en deux classes majeures Training et Testing qui définissent les données d'entraînement et les données de test (validation), les données sont de 5712 images pour l'entraînement et 1311 pour le test. Réparti sur 4 sous classes chacune, glioma, meningioma, pituitary et no tumor. Pour le training, nous avons 1321 images pour glioma, 1339 images pour meningioma, 1595 no tumor et 1457 pour pituitary. Pour le testing, nous avons 300 images pour glioma, 306 pour meningioma, 405 pour no tumor, et 300 pour pituitary. Ce dataset est publiquement disponible sur kaggle [19]. Les images n'ont pas forcément la même dimension, cette dernière peut varier d'une image à l'autre pour plusieurs raisons.

#### Dataset b [14] :

Le dataset contient 3264 images, il a la même structure que le dataset a, les données sont de 2870 images pour l'entraînement et 394 pour le test. Réparti sur 4 sous classes chacune, glioma, meningioma, pituitary et no tumor. Pour le training, nous avons 826 images pour glioma, 822 images pour meningioma, 395 no tumor et 827 pour pituitary. Pour le testing, nous avons 100 images pour glioma, 115 pour meningioma, 105 pour no tumor, et 74 pour pituitary. Ce dataset est aussi publiquement disponible sur kaggle. Les images n'ont pas forcément la même dimension, cette dernière peut varier d'une image à l'autre pour plusieurs raisons.

## 4.3 Mesures de performances

### 4.3.1 Précision (Precision)

La précision[16] est une mesure de la qualité des prédictions positives faites par le modèle. Elle est définie comme le ratio des vrais positifs (TP) sur la somme des vrais positifs et des faux positifs (FP). En d'autres termes, la précision indique la proportion des prédictions positives qui étaient correctes. Une haute précision signifie qu'il y a peu de faux positifs. Elle est particulièrement utile lorsque le coût des faux positifs est élevé.

$$Précision = \frac{TP}{TP + FP} \quad (4.1)$$

### 4.3.2 Exactitude (Accuracy)

L'exactitude[16], ou taux de précision globale, est la proportion de prédictions correctes (vrais positifs plus vrais négatifs) sur l'ensemble des prédictions. Elle donne une idée générale de la performance du modèle sur toutes les classes combinées. L'exactitude peut être trompeuse dans des ensembles de données déséquilibrés, où une classe peut dominer.

$$Exactitude = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.2)$$

### 4.3.3 Rappel (Recall)

Le rappel[16], aussi appelé sensibilité ou taux de vrais positifs, mesure la capacité du modèle à identifier correctement toutes les instances positives. Il est défini comme le ratio des vrais positifs (TP) sur la somme des vrais positifs et des faux négatifs (FN). Le rappel est crucial lorsque le coût des faux négatifs est élevé.

$$Rappel = \frac{TP}{TP + FN} \quad (4.3)$$

### 4.3.4 F1-Score

Le F1-Score[16] est la moyenne harmonique de la précision et du rappel. Il combine les deux métriques pour fournir un équilibre, surtout utile lorsque vous avez besoin d'une mesure unique pour évaluer la performance du modèle. Le F1-Score est particulièrement utile lorsque vous avez une distribution inégale des classes.

$$F1Score = 2 \times \frac{Précision \times Rappel}{Précision + Rappel} \quad (4.4)$$

### 4.3.5 Matrice de Confusion

La matrice de confusion est un tableau qui permet de visualiser les performances du modèle en termes de prédictions correctes et incorrectes pour chaque classe. Pour une classification multi-classes, chaque classe est représentée à la fois comme une ligne et une colonne, où les lignes représentent les véritables classes et les colonnes représentent les prédictions.

### 4.3.6 Fonction de perte

La fonction de perte utilisée dans cette approche est la "categorical-crossentropy" comme mentionné dans le chapitre précédent, elle est définie comme suit :

$$CategoricalCross - Entropy = - \sum_i y_i \log(p_i)$$

## 4.4 Résultats du modèle proposé

Dans cette section nous allons avoir un aperçu sur les résultats de chaque dataset entraîné sur notre modèle selon les mesures de performances indiquées ci-dessus.

### Dataset a :

Pour ce dataset nous avons divisé les images en 5618 images d'entraînement et 1405 images de test. Nous pouvons apercevoir un taux d'accuracy élevé et une généralisation sur les données. La figure 4.1 montre l'accuracy du dataset a :



FIGURE 4.1 – Dataset a accuracy

Nous pouvons aussi apercevoir une taux de perte très bas par rapport au nombre d'images que contient le dataset. La figure 4.2 montre bien ceci.




FIGURE 4.2 – Dataset a perte



Voici la matrice de confusion pour ce dataset :




FIGURE 4.3 – Matrice de confusion Dataset a

Maintenant voici les résultats avec les mesures de performances :

Classes	Accuracy	Précision	Rappel	F1-Score
Gioma	0,96	0,86	0,99	0,92
Meningioma	0,95	0,94	0,86	0,89
Non Tumeur	0,99	0,98	0,98	0,98
Pituitary	0,98	0,98	0,95	0,96
Global	0,97	0,94	0,94	0,93

TABLE 4.1 – Métriques de performance et perf globale Dataset a

## Dataset b :

Pour ce dataset nous avons divisé les images en 2611 images d'entraînement et 652 images de test. Nous pouvons apercevoir aussi un taux d'accuracy élevé et une généralisation sur les données bien plus bonne que le dataset a. La figure 4.4 montre l'accuracy du dataset b :




FIGURE 4.4 – Dataset b accuracy

Pour ce dataset, le taux de perte de données de validation est très bas comme le montre la figure 4.5




FIGURE 4.5 – Dataset b perte

Voici la matrice de confusion pour ce dataset :




FIGURE 4.6 – Matrice de confusion Dataset b

Maintenant voici les résultats avec les mesures de performances :

Classes	Accuracy	Précision	Rappel	F1-Score
Glioma	0,94	0,84	0,97	0,90
Meningioma	0,92	0,93	0,82	0,87
Non Tumeur	0,98	0,93	0,95	0,93
Pituitary	0,98	0,97	0,95	0,95
Global	0,95	0,91	0,92	0,91

TABLE 4.2 – Métriques de performance et perf globale Dataset b

## 4.5 Validation

### 4.5.1 Résultats de l'entraînement des 2 datasets

Dans cette section nous allons montrer les résultats engendrés par l'entraînement de notre approche sur les 2 datasets, les mesures de performances sont celles mentionnées dans ce chapitre :

Dataset	Accuracy	Précision	Rappel	F1-Score
a	0,97	0,94	0,94	0,93
b	0,95	0,91	0,92	0,91

TABLE 4.3 – Comparaison des résultats des datasets a,b et c

### 4.5.2 Comparaison avec d'autres modèles

Ici, nous allons discuter les résultats des autres approches sur nos 2 datasets, les approches testées en plus de celle proposée sont VGG 19 et ResNet50, tous deux ont montré des résultats incohérent par rapport à notre architecture selon les métriques de performances mentionnées dans ce chapitre, nous avons utilisé le même pré-traitement des données, les mêmes hyperparamètres, le même optimiseur et la même fonction de perte. Le batch\_size lors de l'entraînement de ces 2 approches est de 32 (par défaut) et la validation split est de 0.1 ( ce qui est généralement utilisé) . Voici un aperçu des résultats sur ces deux approches et la nôtre :

Approche	Dataset	Métriques de Performance			
		Acc	Pré	Rap	F1
Notre approche	Dataset a	0,97	0,94	0,94	0,93
	Dataset b	<b>0,95</b>	0,91	0,92	0,91
VGG 19	Dataset a	<b>0,98</b>	0,95	0,95	0,95
	Dataset b	0,94	<b>0,93</b>	<b>0,93</b>	<b>0,93</b>
ResNet50	Dataset a	0,96	<b>0,96</b>	<b>0,96</b>	<b>0,96</b>
	Dataset b	0,91	0,92	0,91	0,91

TABLE 4.4 – Tableau des performances des différents modèles sur deux datasets.




FIGURE 4.7 – ResNet50 perte dataset a




FIGURE 4.8 – ResNet50 perte dataset b




FIGURE 4.9 – VGG19 perte dataset a




FIGURE 4.10 – VGG19 perte dataset b

### 4.5.3 Discussion des résultats de la comparaison

Si nous nous fions à la table 4.4, nous allons remarquer qu’au niveau du dataset a, les deux autres approches ont un bien meilleur résultat, mais faut regarder les graphes de perte de notre approches et des deux autres approches. Dans la table 4.4 ”Acc” veut dire accuracy, ”Pré” veut dire précision, ”Rap” veut dire rappel et ”F1” veut dire F1-Score.

Les figures 4.7 et 4.8 montrent les graphes de la fonction de perte lors de l’entraînement du modèle ResNet50 sur nos deux datasets. Nous pouvons remarques que le taux de perte des données de la validation est dramatiquement elevé par rapport à ce que les figures 4.2 et 4.5 qui sont les graphe de la fonction de perte lors de l’entraînement de notre approche démontrent, et lorsque nous avons pour une approche un taux de perte d’apprentissage élevé et des bonnes performances d’exacitude, de précision, de rappel et de f1-score, ceci veut dire que les résultats obtenu à partir de cette approche sont atteints de sur-apprentissage des données ce qui démontre une incohérence avec les résultats mentionnés dans la table 4.4.

Même cas pour VGG19, les figures 4.9 et 4.10 démontrent elles aussi un taux de perte de données de validation très élevés en comparaison avec le nôtre, ce qui démontre aussi à son tour un certain taux de sur-apprentissage et en conclusion une incohérence avec les résultats montré dans la table de comparaison 4.4

D’après les figures 4.1,4.4,4.2,4.5 et les tables 4.2,4.1, nous pouvons conclure que notre approche peut-être validée puisque nous avons su montrer de bons résultats (en moyenne 96% d’exacitude sur les deux datasets) tout en évitant le sur-apprentissage.

## 4.6 Conclusion

D'après les résultats démontrés par l'entraînement de nos 2 datasets, nous pouvons constater que ce sont des résultats cohérents et qui démontrent l'absence de sur-apprentissage et la bonne généralisation sur les données, nous pouvons donc conclure que le modèle proposé peut être efficace pour améliorer le processus de la classification des tumeurs cérébrales et peut économiser du temps aux médecins.

# Conclusion Générale et perspectives

L'objectif de ce mémoire de fin de cycle était de mettre en pratique les méthodes de deep learning, en particulier l'algorithme EfficientNetB0, pour classer les images IRM de tumeurs cérébrales. Le but principal de cette étude consistait à créer un modèle qui puisse distinguer avec précision les diverses formes de tumeurs cérébrales, en tirant parti de la puissance et de la souplesse des réseaux de neurones profonds.

Pendant cette étude, nous avons débuté par une analyse approfondie de la littérature concernant les tumeurs cérébrales, les méthodes d'imagerie médicale et les techniques de classification basées sur le deep learning. Grâce à cette étape initiale, nous avons pu approfondir notre compréhension des défis et des opportunités offertes par l'utilisation de ces technologies dans le secteur médical.

Par la suite, nous avons exposé en détail la procédure de prétraitement des images IRM, une étape essentielle pour assurer la qualité et la pertinence des données d'entrée. L'algorithme EfficientNetB0 a été sélectionné en raison de ses résultats renommés en matière de précision et d'efficacité computationnelle. Ce modèle a été mis en place et entraîné sur un ensemble de données IRM, en modifiant les hyperparamètres afin d'améliorer ses performances.

Le modèle EfficientNetB0 a démontré sa capacité à classer avec une grande précision les images IRM de tumeurs cérébrales, dépassant ainsi plusieurs autres architectures de réseaux de neurones testées. La performance de EfficientNetB0 est principalement attribuable à sa capacité à concilier la complexité du modèle et la taille des images, ce qui permet une extraction plus efficace des caractéristiques pertinentes pour la classification.

Pour résumer, ce mémoire met en évidence la possibilité d'utiliser l'algorithme EfficientNetB0 pour classer les images IRM de tumeurs cérébrales, non seulement réalisable, mais aussi extrêmement efficace. Ce travail offre des possibilités d'applications cliniques, où de tels modèles pourraient aider les radiologues à diagnostiquer rapidement et précisément les tumeurs cérébrales, ce qui pourrait améliorer la prise en charge des patients.

Toutefois, il est possible d'envisager plusieurs axes d'amélioration pour des recherches à venir. À titre d'exemple, une augmentation de la taille du jeu de données, l'incorporation de méthodes de segmentation pour isoler les tumeurs avant la classification, ainsi que l'exploration d'autres architectures de réseaux de neurones pourraient encore améliorer les performances du modèle.

En résumé, cette étude représente une étape cruciale vers l'intégration du deep learning dans le domaine de la neuroradiologie, et nous espérons que les résultats obtenus inciteront d'autres chercheurs à continuer dans cette voie prometteuse.

# Bibliographie

- [1] Atika AKTER et al. « Robust clinical applicable CNN and U-Net based algorithm for MRI classification and segmentation for brain tumor ». In : *Expert Systems with Applications* 238 (2024), p. 122347.
- [2] Ethem ALPAYDIN. *Introduction to Machine Learning*. 4th. Consulté le 27 juin 2024. MIT Press, 2020. URL : <https://mitpress.mit.edu/9780262043793/introduction-to-machine-learning/>.
- [3] Gopinath BALAJI, Ranit SEN et Harsh KIRTY. *Detection and classification of brain tumors using deep convolutional neural networks*. 2022.
- [4] Siddhesh BHOBE. « VGG-Net Architecture Explained ». In : *Medium* (2019). Consulté le 23 juin 2024. URL : <https://medium.com/@siddheshb008/vgg-net-architecture-explained-71179310050f>.
- [5] Sartaj BHUVAJI. *Brain Tumor Classification MRI*. Accessed : 2024-07-16. ongoing. URL : <https://www.kaggle.com/sartajbhuvaji/brain-tumor-classification-mri>.
- [6] Christopher M BISHOP. « Pattern Recognition and Machine Learning ». In : (2006).
- [7] Klemens BURG, Herbert HAF et Friedrich WILLE. *Höhere Mathematik für Ingenieure 3. Gewöhnliche Differentialgleichungen, Distributionen, Integraltransformationen*. 5<sup>e</sup> éd. 84 Questions. 2020. ISBN : 9783519329572.
- [8] Nikita V CHAVAN, BD JADHAV et PM PATIL. « Detection and classification of brain tumors ». In : *International Journal of Computer Applications* 112.8 (2015).
- [9] CNIL. *Définition de l'apprentissage automatique*. Accessed : 2024-06-23. 2024. URL : <https://www.cnil.fr/fr/definition/apprentissage-automatique>.
- [10] S DEEPAK et PM AMEER. « Brain tumor classification using deep CNN features via transfer learning ». In : *Computers in Biology and Medicine* 111 (2019), p. 103345.
- [11] Jia DENG et al. « ImageNet : A Large-Scale Hierarchical Image Database ». In : (2009). Accessed : 2024-06-15. URL : <http://www.image-net.org>.
- [12] Nassima DIF. « L'apprentissage profond pour le traitement des images ». Thèse de doct. Déc. 2020.
- [13] Mahir DJEMAA. « Classification des images par CNN ». In : (2023).
- [14] PRATHAM GROVER. *Brain Tumor Classification*. Accessed : 2024-06-15. 2023. URL : <https://www.kaggle.com/datasets/prathamgrover/brain-tumor-classification>.



- [15] Joris GUYON. « Nouveaux mécanismes du développement des tumeurs cérébrales ». Thèse de doct. Université de Bordeaux, 2021.
- [16] Djallel HAMOUDA. « Un système de détection d'intrusion pour la cybersécurité ». In : (2020).
- [17] Kaiming HE et al. « Deep residual learning for image recognition ». In : (2016), p. 770-778.
- [18] IBM. *Qu'est-ce que l'apprentissage automatique ?* Accessed : 2024-06-23. 2024. URL : <https://www.ibm.com/fr-fr/topics/machine-learning>.
- [19] KAGGLE. *Kaggle : Your Home for Data Science*. Accessed : 2024-06-15. 2024. URL : <https://www.kaggle.com>.
- [20] Diederik P KINGMA et Jimmy BA. « Adam : A method for stochastic optimization ». In : *arXiv preprint arXiv :1412.6980* (2014).
- [21] Sunita M KULKARNI et G SUNDARI. « A framework for brain tumor segmentation and classification using deep learning algorithm ». In : *International Journal of Advanced Computer Science and Applications* 11.8 (2020).
- [22] JF LE BAS et al. « IRM de perfusion des tumeurs cérébrales ». In : *Journal de radiologie* 87.6 ().
- [23] Ellyana LINDEN. *GoogleNet Implementation*. Accessed : 2024-07-16. ongoing. URL : <https://www.kaggle.com/code/ellyanalinden/googlenet>.
- [24] MASOUD NICKPARVAR. *Brain Tumor MRI Dataset*. Accessed : 2024-06-15. 2021. URL : <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>.
- [25] François ROUSSEAU, Lucas DRUMETZ et Ronan FABLET. « Residual Networks as Flows of Diffeomorphisms ». In : *Journal of Mathematical Imaging and Vision* 62 (avr. 2020). DOI : 10.1007/s10851-019-00890-3.
- [26] Soheila SAEEDI et al. « MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques ». In : *BMC Medical Informatics and Decision Making* 23.1 (2023), p. 16.
- [27] Venkata Rama Krishna SAJJA et Hemantha Kumar KALLURI. « Classification of Brain Tumors Using Convolutional Neural Network over Various SVM Methods. » In : *Ingénierie des Systèmes d'Inf.* 25.4 (2020), p. 489-495.
- [28] S SHANTHI et al. « An efficient automatic brain tumor classification using optimized hybrid deep neural network ». In : *International Journal of Intelligent Networks* 3 (2022), p. 188-196.
- [29] Dr. B. SILI. *Un nouvel espoir pour les tumeurs cérébrales inopérables*. Accessed : 2024-06-23. 2023. URL : <https://www.drbsili.com/blog/un-nouvel-espoir-pour-les-tumeurs-cerebrales-inoperables>.
- [30] Karen SIMONYAN et Andrew ZISSERMAN. « Very deep convolutional networks for large-scale image recognition ». In : *arXiv preprint arXiv :1409.1556* (2014).
- [31] Zar Nawab Khan SWATI et al. « Brain tumor classification for MR images using transfer learning and fine-tuning ». In : *Computerized Medical Imaging and Graphics* 75 (2019), p. 34-46.

- [32] Mingxing TAN et Quoc V. LE. « EfficientNet : Rethinking Model Scaling for Convolutional Neural Networks ». In : *Proceedings of the 36th International Conference on Machine Learning (ICML)*. 2019. URL : <http://proceedings.mlr.press/v97/tan19a.html>.
- [33] Jiraporn THOMKAEW et Sarun INTAKOSUM. « Improvement classification approach in tomato leaf disease using modified visual geometry group (vgg)-inceptionv3 ». In : *International Journal of Advanced Computer Science and Applications* 13.12 (2022).
- [34] UNKNOWN. *IRM-CE Dataset with Bidimensional Classification Based on Large Differences Between Slices*. Accessed : 2024-07-16. 2019. URL : [https://www.example.com/IRMCE\\_dataset](https://www.example.com/IRMCE_dataset).
- [35] UNKNOWN. *Schematic diagram of a basic convolutional neural network (CNN) architecture*. Accessed : 2024-07-16. 2019. URL : <https://www.researchgate.net/publication/336805909/figure/fig1/AS:817888827023360@1572011300751/Schematic-diagram-of-a-basic-convolutional-neural-network-CNN-architecture-26.ppm>.
- [36] UNKNOWN. *A compact CNN model for automated detection of COVID-19 using thorax x-ray images*. [https://www.researchgate.net/figure/Architecture-of-EfficientNetB0\\_fig3\\_368704765](https://www.researchgate.net/figure/Architecture-of-EfficientNetB0_fig3_368704765). Accessed : 11 Jul, 2024.
- [37] Ramdas VANKDOTHU et Mohd Abdul HAMEED. « Brain tumor MRI images identification and classification based on the recurrent convolutional neural network ». In : *Measurement : Sensors* 24 (2022), p. 100412.
- [38] Mohammed Wassim ZEGHDAOUI. « Contribution à l'étude des réseaux de neurones profonds pour l'analyse d'images en imagerie médicale ». Consulté le 28 juin 2024. Thèse de doct. Université de Technologie de Compiègne, 2023. URL : [https://theses.hal.science/tel-03968442v1/file/these\\_internet\\_zeghdaoui\\_mw.pdf](https://theses.hal.science/tel-03968442v1/file/these_internet_zeghdaoui_mw.pdf).

## *Abstract*

The medical field faces a significant challenge due to the complexity and serious health consequences of brain tumors. These tumors are often diagnosed using magnetic resonance imaging (MRI), which provides detailed and non-invasive images of the brain. However, precise analysis of MRI images often requires extensive expertise. In this study, we investigate how Deep Learning can be utilized to automatically classify brain tumors from MRI images. Convolutional Neural Networks (CNNs) have demonstrated strong capabilities in extracting relevant features from complex medical images through Deep Learning. Several CNN architectures were trained and evaluated using an annotated database of MRI images. According to experimental results, our method shows promising outcomes in brain tumor classification. We compared our results with traditional methods and discussed the potential benefits of Deep Learning in terms of diagnostic accuracy and data processing speed. Furthermore, advanced techniques such as transfer learning were explored to enhance the model's performance on large datasets. In summary, this study contributes to the advancement of medical image analysis methods by employing modern Deep Learning approaches. The findings suggest that integrating these techniques into clinical practice could potentially improve the accuracy and efficiency of diagnosing brain tumors from MRI images.

**Key words :** Deep Learning, Convolutional Neural Networks (CNNs), MRI images, Brain tumor classification, Feature extraction, Transfer learning, Model performance, Diagnostic accuracy, Data processing speed, Annotated database.

## *Résumé*

Le domaine médical fait face à un défi majeur avec les tumeurs cérébrales, en raison de leur complexité et de leurs conséquences graves. Diagnostiquées souvent par IRM, ces images détaillées du cerveau nécessitent une analyse précise demandant une grande expertise. Cette étude explore l'utilisation du Deep Learning pour classifier automatiquement les tumeurs cérébrales à partir d'images IRM. Les réseaux neuronaux convolutionnels (CNN) montrent une forte capacité à extraire des caractéristiques pertinentes d'images médicales complexes. Plusieurs architectures CNN ont été entraînées et évaluées sur une base de données annotée d'IRM. Nos résultats expérimentaux montrent des résultats prometteurs en classification des tumeurs cérébrales. Comparés aux méthodes classiques, les bénéfices du Deep Learning se manifestent par une meilleure précision diagnostique et une rapidité de traitement accrue. Des techniques avancées comme le transfert d'apprentissage ont également été étudiées pour améliorer les performances sur de grands ensembles de données. En résumé, cette étude contribue à l'évolution des méthodes d'analyse d'images médicales par Deep Learning. Les résultats suggèrent que l'intégration de ces techniques dans la pratique clinique pourrait améliorer la précision et l'efficacité du diagnostic des tumeurs cérébrales à partir d'IRM.

**Mots clés :** Deep Learning, Réseaux neuronaux convolutionnels (CNN), Classification automatique, Extraction de caractéristiques, Transfert d'apprentissage, Modèles CNN, Entraînement de réseaux, Base de données annotée, Précision diagnostique, Traitement des données