

Université Mohamed El Bachir El Ibrahimi de Bordj Bou Arréridj

Faculté des Mathématiques et de l'Informatique

Département d'Informatique



Mémoire

Pour l'obtention du diplôme de

Master en informatique

Spécialité : Technologies de l'information et des communications

THÈME

**Prédiction des tumeurs cérébrales dans les images IRM par
l'apprentissage profond**

Présenté par

MERDJI Saida

REBIAI Soria

Soutenu publiquement Juin 2024

Devant le jury composé de

Président **SAIFI Linda**

Encadrante **BOUTOUHAMI Sara**

Examineur **NOUIOUA Mourad**

2023/2024

Dédicace

Hier fut un rêve, aujourd'hui c'est une réalité. Aucun mot ne pourrait exprimer toute ma gratitude, mon amour, mon respect et ma reconnaissance. Merci Dieu de me permettre de partager cela avec ceux que j'aime.

Je dédie cette thèse de Master :

À mon cher père

Qui m'a soutenu et qui m'a fait confiance toutes ces années. Mon soutien de toujours, mon refuge et mon réconfort.

À ma chère mère

Qui m'a apporté et qui ne cesse pas de me supporter, je lui dis hautement et fortement je t'aime. Ce modeste mémoire, est pour toi une petite part de tout le bonheur que tu mérites

À mes chères sœurs *Chahda, Tahani* et son mari

Avec tout mon amour et ma gratitude. Votre soutien indéfectible, votre encouragement constant et votre compréhension inégalée ont été des piliers essentiels tout au long de ce parcours académique.

À mes frères *Fead, Imad, Ahmed*

Je leur souhaite beaucoup de succès.

À mes chères amies, *Soria, Lamis, Ahlem, Dina, Hadil, Nesrine, Sara, Isra, Aya, Souhila, Bouthaina, Wafa*

Je leur souhaite beaucoup de succès.

À tous les membres de la famille *Merdji et Bouzidi*

- *MERDJI Saïda* -

Dédicace

En tout premier lieu, :

Je remercie mon Dieu, tout puissant, de m'avoir donné la force et le courage pour dépasser toutes les difficultés.

Avec l'expression de ma reconnaissance, je dédie ce modeste travail à ceux qui, quels que soient les termes embrassés, je n'arriverais jamais à leur exprimer mon amour sincère.

A ma chère mère,

A mon cher père,

Qui n'ont jamais cessé, de formuler des prières à mon égard, de me soutenir et de m'épauler pour que je puisse atteindre mes objectifs

A mes frères, Samir-Saadi-Noureddine-Hossem-Abdelkader-Saïfi A mes chères sœurs

Assya, Hanane et son mari,

Pour leur soutiens moral et leurs conseils précieux tout au long de mes études. Pour leurs indéfectibles soutiens et leurs patiences infinies

A mon cher binôme, Saida Merdji

Pour son entente et sa sympathie

A mon fiancé, Issam

Qui m'a aidé et supporté dans les moments difficiles.

A mes chères amies, Nesrine-Meryem- Sara- Ilham- Chayma- Rima

Qui m'ot aidée et supportée dans les moments difficiles.

- REBIA Soria -

Remerciement

Nous tenons avant tout à remercier DIEU de nous accorder la santé, la possibilité et la volonté de commencer et de poursuivre nos études.

Nous tenons tout d'abord à remercier notre encadrante, **Mme BOUTOUHAMI Sara** pour nous avoir donné la chance de mener nos recherches. Nous lui exprimons également notre gratitude pour sa générosité, sa gentillesse, ses connaissances, le temps qu'elle nous a accordé et sa disponibilité qui ont rendu notre tâche beaucoup plus facile.

Nous tenons également à exprimer nos remerciements aux membres du jury qui nous ont fait l'honneur de participer à l'évaluation de ce travail et d'enrichir celui-ci avec leurs propositions, à savoir Dr. SAIFI Linda et Dr. NOUIOUA Mourad.

De plus, nous tenons à remercier nos parents pour leur amour, leurs soins, prières, et leur soutien constants.

• Résumé

Le diagnostic précis des maladies contemporaines repose largement sur le traitement des images médicales. Cette étude présente une approche intéressante pour la détection automatisée des tumeurs cérébrales à partir d'images par résonance magnétique (IRM) en utilisant le modèle d'apprentissage en profondeur ResNet50. Ce modèle, réputé pour sa capacité à extraire des caractéristiques complexes des images, est déployé pour analyser les images IRM du cerveau et identifier de manière précise la présence de tumeurs. Les données utilisées dans cette étude comprennent des images IRM présentant des tumeurs. Nous avons comparé notre approche à d'autres méthodes en utilisant des critères tels que la précision, le rappel et le score F1. Le modèle proposé, ResNet50, a atteint une précision de détection de 98 %, démontrant ainsi son efficacité dans la détection des tumeurs cérébrales à partir d'images IRM. Ces résultats mettent en lumière le potentiel du modèle ResNet50 pour améliorer la détection précoce et précise des tumeurs cérébrales sur les images. IRM.

- **Mots clés : Image IRM, ResNet50, CNN, Apprentissage en profondeur, traitement des images ,cerveau,Tumeurs cérébrales.**

• Abstract

The accurate diagnosis of contemporary diseases heavily relies on the processing of medical images. This study introduces an interesting approach for automated detection of brain tumors from magnetic resonance imaging (MRI) using the deep learning model ResNet50. This model, renowned for its ability to extract complex features from images, is deployed to analyze brain MRI images and accurately identify the presence of tumors. The data used in this study include MRI images containing tumors. We compared our approach to other methods using criteria such as precision, recall, and F1 score. The proposed model, ResNet50, achieved a detection accuracy of 98%, demonstrating its effectiveness in detecting brain tumors from MRI images. These results highlight the potential of the ResNet50 model to improve early and accurate detection of brain tumors in images.

• **Keywords :** MRI, ResNet50, CNN, Deep Learning, Brain Tumors, Accuracy.

• ملخص

يعتمد التشخيص الدقيق للأمراض المعاصرة بشكل كبير على معالجة الصور الطبية. تقدم هذه الدراسة طريقة مبتكرة للكشف الآلي عن أورام المخ من صور الرنين المغناطيسي باستخدام نموذج التعلم العميق *ResNet50*. يُستخدم هذا النموذج المشهور بقدرته على استخراج ميزات معقدة من الصور، لتحليل صور الدماغ وتحديد وجود الأورام بدقة. تتضمن البيانات المستخدمة في هذه الدراسة صوراً تظهر الأورام. قمنا بمقارنة منهجنا بالطرق الأخرى باستخدام معايير مثل الدقة والاستدعاء ودرجة $F1$. حقق النموذج المقترح *ResNet50* دقة كشف تصل إلى 98%، مما يدل على فعاليته في الكشف عن أورام المخ من خلال الصور. تسلسل هذه النتائج الضوء على قدرة النموذج *ResNet50* على تحسين الاكتشاف المبكر والدقيق لأورام المخ في الصور.

• الكلمات المفتاحية: التصوير بالرنين المغناطيسي، شبكة عصبية تلافيفية، التعلم العميق، أورام الدماغ.

Table des matières

Liste des abréviations	9
Liste des figures	13
Liste des tableaux	13
Introduction générale	13
1 La Tumeur Cérébrale et L'imagerie Par Résonance Magnétique (IRM)	16
1.1 Introduction	16
1.2 Le cerveau	17
1.2.1 Qu'est-ce que le cerveau	17
1.2.2 Anatomie de cerveau	17
1.2.2.1 La structure générale du cerveau	17
1.2.2.2 Les différentes parties du cerveau et leurs fonctions	18
1.3 Les tumeurs cérébrales	20
1.3.1 C'est quoi une tumeur cérébrale ?	20
1.3.2 Les types des tumeurs cérébrales	20
1.3.3 Les causes des tumeurs du cerveau	21
1.3.4 Les symptômes et le diagnostic des tumeurs du cerveau	21
1.4 Imagerie médicale	22
1.4.1 Imagier par résonance magnétique IRM	23
1.4.2 Le principe de IRM	23
1.4.3 Les différents types d'IRM	24
1.4.4 Pondération et séquence de images IRM	24
1.5 Conclusion	25

2	Les méthodes de détection des image IRM	26
2.1	Introduction	26
2.2	Qu'est-ce que la détection ?	26
2.3	Les méthodes de détection de tumeur en imagerie IRM	27
2.3.1	Détection manuelle des images	27
2.3.2	Technique semi-automatique de détection des structures cérébrales sur les IRM	27
2.3.3	Approches automatisées pour la détection des structure cérébrales sur les IRM	27
2.4	L'Apprentissage profond (Deep Learning)	28
2.4.1	Histoire de l'apprentissage profond (Deep Learning)	28
2.4.2	Pour quoi l'apprentissage profond ?	29
2.4.3	L'importance de l'apprentissage profond	30
2.4.4	Comment fonctionne l'apprentissage profond	30
2.4.5	Application d'apprentissage profond	31
2.5	Les techniques d'apprentissage profond	32
2.5.1	Les réseaux neuronaux récurrents (RNN - recurrent neural network)	32
2.5.2	Les réseaux adversaires génératifs (GAN)	33
2.5.3	Les réseaux à mémoire à long terme (LSTM - Long short-term memory)	33
2.5.4	Les réseaux neuronaux convolutifs (CNN)	34
2.5.5	L'architecture d'un réseau neuronal convolutif (CNN)	34
2.5.5.1	Couche de Convolution	35
2.5.5.2	Couche d'Activation (ReLU)	35
2.5.5.3	Couches de pooling	35
2.5.5.4	Couche Entièrement Connectée	36
2.6	Fonctionnement des réseaux neuronaux convolutifs (CNN)	37
2.7	Applications des réseaux neuronaux convolutifs (CNN)	37
2.8	La relation entre intelligence artificielle, machine learning et le deep Learning	38
2.9	Analyse comparative des techniques de détection	39
2.10	Conclusion	40
3	Implémentation et résultats	41
3.1	Introduction	41
3.2	Ensembles de données d'entraînement, de validation et de test	41
3.3	Environnement de développement de système	42
3.3.1	Environnement matériel	42
3.3.2	Environnement logiciel	42
3.3.2.1	Le langage de programmation utilisé (Python)	42
3.3.2.2	Les bibliothèques Python	43
3.3.2.3	Kaggle	44

3.3.2.4	Google Colab	44
3.3.2.5	Letex (Overleaf)	45
3.4	Approche Proposée	45
3.4.1	Collecte des données IRM	46
3.4.2	Prétraitement des données IRM	48
3.4.2.1	Recadrage d'images IRM	48
3.4.2.2	Le redimensionnement des images IRM	49
3.4.3	Augmentation d'image IRM	50
3.4.4	Architecture du modèle proposée pour le diagnostique	51
3.4.4.1	Réseau de neurones à convolution (CNN)	51
3.4.4.2	ResNet50	52
3.4.5	La phase d'évaluation	53
3.4.6	Résultats et discussion	55
3.4.6.1	Comparaison des performances entre le modèle existant et le modèle proposé	56
3.4.7	Prédiction :	57
3.4.7.1	Le fonctionnement de l'application	57
3.5	Conclusion	59
3.6	Conclusion générale	60

Liste des abréviations

IRM	Imagerie par résonance magnétique
IA	Intelligence Artificiel
ML	Machine Learning
DL	Deep Learning
CNN	Réseaux de Neurones Convolutionnels
RNN	Réseau de Neurones Récurrents
GAN	Modèle Génératif Profond
ResNet50	Residual Network with 50 layers
ReLU	Rectified Linear Unit

Table des figures

1.1	Illustration du cerveau[2].	17
1.2	Anatomie du système nerveux central (SNC)[4].	18
1.3	Les deux hémisphères cérébraux	18
1.4	Les 4 lobes de l'hémisphère gauche [1].	19
1.5	Imagerie médicale IRM	22
1.6	l'IRM anatomique [14]	24
2.1	La détection d'une tumeur [17]	26
2.2	La détection d'une tumeur [2]	27
2.3	Comment fonctionne le Deep Learning [24]	31
2.4	Réseaux RNN .[24]	33
2.5	Cellule LSTM.	34
2.6	Les Réseaux de Neurones convolutifs.[30]	34
2.7	Architecture couche de convolution.	35
2.8	Couche de pooling	36
2.9	La relation entre AI,machine learning,deep learning.	38
3.1	Ensemble des données d'entraînement, test et validation [43].	42
3.2	Interface de Kaggle	43
3.3	Interface de Kaggle	44
3.4	Interface de Google Colab	44
3.5	Interface de LATEX	45
3.6	Architecture de méthode proposée	46
3.7	Collecte de données IRM	47
3.8	Recadrage des images IRM	49
3.9	Dataset après le recadrage	49

3.10 Les images IRM redimensionnées	50
3.11 Technique d'augmentation sur l'image originale	51
3.12 Architecture du Modèle ResNet50	53
3.13 Accuracy durant les phases d'entraînement et d'évaluation sur 20 itérations.	55
3.14 Perte d'entraînement, d'évaluation sur 20 itérations	56
3.15 Résultat de notre méthode	57
3.16 La page d'accueil	58
3.17 La page d'accueil	58
3.18 Résultat positif.	59
3.19 Résultat négatif.	59

Liste des tableaux

1.1	Les principales fonctions des 4 lobes de l'hémisphère gauche.	19
1.2	Les principaux symptômes de la tumeur cérébrale	22
1.3	Les types IRM et leurs parties [15].	24
2.1	Applications d'apprentissage profond [25].	32
2.2	Analyse comparative sur la tumeur au cerveau.	40
3.1	Les résultats obtenus par notre approche	56
3.2	La performance de modèle proposée.	57

Introduction générale

L'avènement de l'intelligence artificielle (IA) et l'apprentissage profond a révolutionné de nombreux domaines, y compris celui de la médecine. Parmi les applications les plus prometteuses de l'apprentissage profond en médecine figure la détection des tumeurs cérébrales à partir d'images par résonance magnétique (IRM). Les tumeurs cérébrales sont des affections graves qui nécessitent une détection précoce et précise pour garantir des interventions médicales appropriées. L'imagerie par résonance magnétique (IRM) est une modalité d'imagerie largement utilisée pour diagnostiquer les tumeurs cérébrales en raison de sa haute résolution et de sa capacité à visualiser les tissus mous avec précision.

L'objectif principal de ce projet de recherche est d'utiliser une méthode de détection des tumeurs cérébrales en utilisant l'apprentissage profond. Cette approche repose sur la création de modèles d'intelligence artificielle capables d'analyser de manière précise les images IRM du cerveau afin de détecter la présence de tumeurs. Notre but ultime est de fournir des outils de diagnostic précoce des tumeurs cérébrales, ce qui facilitera grandement le processus de détection et de diagnostic dans les établissements médicaux.

Pour atteindre cet objectif, nous prévoyons d'entraîner nos modèles informatiques sur de vastes ensembles de données d'images cérébrales, comprenant à la fois des images de tumeurs et des images de tissus sains. En utilisant l'apprentissage profond, ces modèles seront capables d'extraire automatiquement les caractéristiques et les motifs distinctifs des tumeurs cérébrales, ce qui leur permettra de les distinguer des tissus sains avec une grande précision. En améliorant la capacité des systèmes informatiques à reconnaître les tumeurs cérébrales, notre travail vise à augmenter les chances de diagnostic précoce et à améliorer les résultats des soins de santé pour les patients atteints de cette maladie grave. En fournissant des outils précis et efficaces pour la détection des tumeurs cérébrales, nous espérons contribuer de manière significative à l'amélioration des pratiques médicales et à la qualité des soins prodigués aux patients.

Ce mémoire est organisé en trois chapitres qui détaillent les différents aspects de notre travail. Chaque chapitre présente une étape spécifique du travail .

Après l'introduction générale nous avons :

Chapiter 1 : La Tumeur Cérébrale et L'imagerie Par Résonance Magnétique (IRM).

Dans ce chapitre, nous examinerons en détail les caractéristiques des tumeurs cérébrales, leur classification et les principaux enjeux liés à leur détection précoce. Nous explorerons également les principes de base de l'imagerie par résonance magnétique (IRM) et son utilisation dans le diagnostic des tumeurs cérébrales.

Chapiter 2 : Les techniques d'apprentissage profond

Ce chapitre se concentrera sur les fondements théoriques de l'apprentissage profond, en mettant l'accent sur les réseaux de neurones convolutionnels (CNN), une architecture largement utilisée pour la vision par ordinateur et l'analyse d'images médicales. Nous explorerons les principes de fonctionnement des CNN, ainsi que les différentes étapes de leur entraînement et de leur utilisation pour la détection des tumeurs cérébrales.

Chapiter 3 : Les méthodes de détection de la tumeur.

Dans ce chapitre, nous décrirons en détail l'implémentation de notre méthode de détection des tumeurs cérébrales par l'apprentissage profond, en utilisant le modèle de détection ResNet50. Nous présenterons également les résultats de nos expériences, en évaluant les performances de notre modèle sur un ensemble de données d'images IRM de tumeurs cérébrales. Nous discuterons des implications cliniques de nos résultats et des pistes d'amélioration pour des travaux futurs.

Nous terminons par une conclusion générale et des perspectives.

Ce mémoire s'efforcera d'apporter une contribution significative à la recherche dans le domaine de la détection des tumeurs cérébrales par l'apprentissage profond, en fournissant une méthodologie rigoureuse, des analyses approfondies et des résultats expérimentaux convaincants.

La Tumeur Cérébrale et L'imagerie Par Résonance Magnétique (IRM)

1.1 Introduction

Le cancer du cerveau est parmi les types de cancer les plus critiques, le patient peut avoir plusieurs symptômes dans le corps en fonction de la localisation du cancer dans le cerveau. La détection précoce du cancer peut donner à la personne une nouvelle chance dans sa vie, afin de suivre un traitement efficace pour la sauver.

Les tumeurs cérébrales sont classées en deux catégories : primaires et secondaires. Les tumeurs primaires ont leur origine dans le cerveau lui-même. Les tumeurs cérébrales peuvent être bénignes ou malignes. Les tumeurs cérébrales métastatiques, en revanche, sont des tumeurs secondaires qui se développent lorsque des cellules cancéreuses d'un autre organe, comme le sein ou le poumon, se propagent jusqu'au cerveau. Les scanners cérébraux par imagerie par résonance magnétique (IRM) sont des méthodes de détection rapide des tumeurs. L'IRM est devenue une méthode d'imagerie médicale de haute qualité largement utilisée. Cependant, la technologie de détection des tumeurs doit être fiable et robuste pour garantir un diagnostic correct.

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

1.2 Le cerveau

1.2.1 Qu'est-ce que le cerveau

Le cerveau est le tissu qui se trouve à l'intérieur du crâne. Il ne s'agit que d'une partie du système nerveux central. Protégé par la boîte crânienne, le cerveau est l'organe qui fait office de chef d'orchestre pour tous les membres et organes du corps humain. Il centralise les informations et renvoie des messages aux différents membres. Il se compose de deux hémisphères reliés : l'hémisphère gauche et l'hémisphère droit, qui contrôlent chacun la partie du corps qui lui est opposée. La main droite sera donc contrôlée par une partie de l'hémisphère gauche.[1]



FIGURE 1.1: Illustration du cerveau[2].

1.2.2 Anatomie de cerveau

1.2.2.1 La structure générale du cerveau

Le cerveau (l'encéphale, plus exactement) a trois parties principales. Ce sont le cervelet, le cerveau et le tronc cérébral.

- **1.Le cerveau** est la plus grande partie du cerveau, et est composé des hémisphères gauches et droit. Il repose sur le cervelet et le tronc cérébral. De nombreuses fonctions essentielles de votre corps dépendent du cerveau. Par exemple, il contrôle le toucher, la vue, l'ouïe, le langage et la motricité fine. Vous avez également besoin de votre cerveau pour interpréter les émotions, résoudre les problèmes et apprendre [3].
- **2. Le cervelet** aide à affiner vos mouvements musculaires. Par exemple, il aide à contrôler l'équilibre, la posture et l'apprentissage moteur[3].
- **3.Le tronc cérébral** relie la base du cerveau à la moelle épinière. Il aide à coordonner la communication du cerveau avec le reste du corps. Le tronc cérébral aide également à coordonner les actions involontaires comme la respiration et le rythme cardiaque [4].

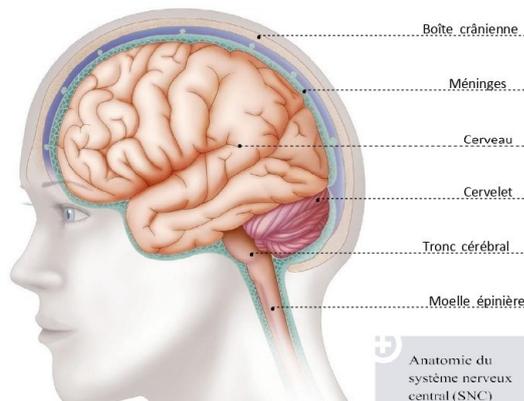


FIGURE 1.2: Anatomie du système nerveux central (SNC)[4].

1.2.2.2 Les différentes parties du cerveau et leurs fonctions

Le cerveau est très organisé. Il se compose de plusieurs parties dont chacune joue un rôle spécifique et se complète.

- **Hémisphères cérébraux** constituent la plus grande partie du cerveau. Il comporte deux parties : l'hémisphère droit et l'hémisphère gauche. On parle souvent de cerveau droit et de cerveau gauche. Les hémisphères contrôlent toutes nos fonctions mentales supérieures : mouvement volontaire, pensée, apprentissage, mémoire, etc [6].

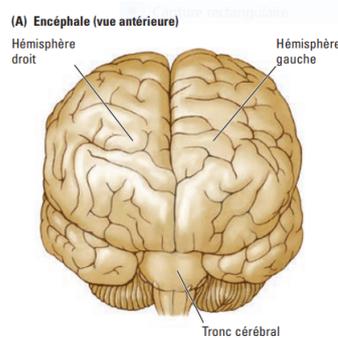


FIGURE 1.3: Les deux hémisphères cérébraux .

Chaque hémisphère lui-même est divisé en quatre régions, appelées lobes, dans lesquelles sont gérées ces différentes fonctions : lobes frontal, pariétal, temporal et occipital.

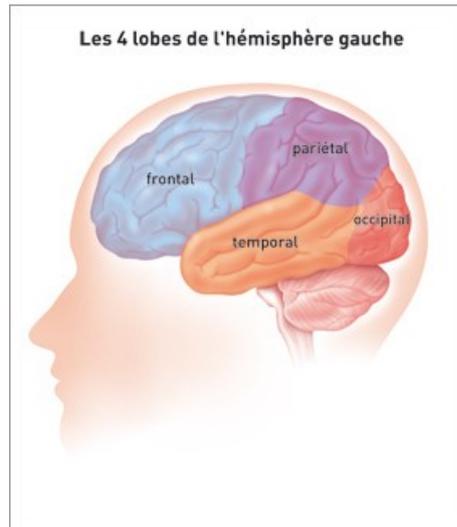


FIGURE 1.4: Les 4 lobes de l'hémisphère gauche [1].

Les principales fonctions de chaque lobe sont présentées dans Le tableau ci-dessous.

Les lobes	Principale fonction
Lobe frontal	Parole et langage, raisonnement, mémoire, prise de décision, personnalité, jugement, mouvement. Le lobe frontal droit contrôle les mouvements du côté gauche du corps et, inversement, le lobe frontal gauche contrôle les mouvements du côté droit du corps [5].
Lobe pariétal	Lecture, position spatiale, sensibilité. Ici, le lobe pariétal droit gère également la sensibilité du côté gauche du corps et vice versa [5].
Lobe occipital	Vision [1].
Lobe temporal	Langage, mémoire, émotion [1].

TABLE 1.1: Les principales fonctions des 4 lobes de l'hémisphère gauche.

- **Tronc cérébral** relie les hémisphères cérébraux et la moelle épinière. Il contrôle des fonctions importantes du corps, telles que la fréquence cardiaque, la respiration et la tension artérielle. Les mouvements oculaires et les mouvements du visage et la déglutition [6].
- **Cervelet** est situé à l'arrière du tronc cérébral, sous le lobe occipital. Cela nous permet d'avoir des réflexes, de coordonner nos mouvements et de maintenir l'équilibre [6].
- **Glande pituitaire et hypothalamus** L'hypophyse et l'hypothalamus sont des structures neuronales situées à la base du cerveau, au centre du crâne.

1.3 Les tumeurs cérébrales

1.3.1 C'est quoi une tumeur cérébrale ?

La tumeur est une croissance cellulaire dans le cerveau, qui peut être de nature bénigne (non cancéreuse) ou maligne (cancéreuse) [7].

Les tumeurs cérébrales peuvent effectivement se développer à tout âge, mais certaines sont plus courantes chez les personnes âgées. Le glioblastome, en particulier, est l'une des tumeurs cérébrales les plus graves et les plus fréquentes chez les personnes âgées, en raison du vieillissement de la population.

Les tumeurs cérébrales, cancéreuses ou non, peuvent causer de graves problèmes en raison du fait que le crâne est rigide, ne laissant pas de place pour la croissance de la tumeur. En outre, si une tumeur se développe à proximité des parties du cerveau qui contrôlent les fonctions vitales, elle peut causer des problèmes, comme une faiblesse, des difficultés à marcher, une perte d'équilibre, une perte partielle ou complète de la vision, des inconvenances de la compréhension ou de l'utilisation du langage, ainsi que des problèmes de mémoire [7].

1.3.2 Les types des tumeurs cérébrales

Les tumeurs cérébrales sont de gros agrégats de cellules agrégats qui se propagent rapidement et de manière incontrôlable dans tout le cerveau. Ils sont de deux sortes :

- Les tumeurs primitives proviennent du cerveau. On distingue Les tumeurs bénignes qui constituent deux tiers des instances de tumeurs primitives, sont caractérisées par des cellules non cancéreuses et les tumeurs malignes tumeurs sont constituées de cellules cancéreuses. Qu'elles soient bénignes ou malignes, les tumeurs primitives peuvent provoquer des symptômes graves surtout si elles sont localisées dans des zones fonctionnelles clés du cerveau. Les principales tumeurs cérébrales primitives sont [8] :

- ▶ **Les gliomes** : qui sont les tumeurs primitives du cerveau les plus fréquentes. Les gliomes regroupent un ensemble de tumeurs infiltrantes origines au sein du cerveau à partir des gliales (astrocytes ou oligodendrocytes). Les gliomes sont systématiquement les tumeurs malignes dont le pronostic est réservé, et les glioblastomes représentent la majorité des tumeurs malignes.

Les gliomes sont classés selon leur degré de sévérité : les gliomes de grade I sont bénins, les gliomes de grade II correspondant à des tumeurs de croissance lente, les gliomes de grade III et les gliomes de grade IV sont systématiques [9].

- ▶ **Les méningiomes** : environ 30 tumeurs cérébrales primitives sont des méningiomes, ces tumeurs qui prolifèrent à partir des cellules méninges sur la surface du cerveau.

Ils sont plus fréquents chez les femmes. Dans la grande majorité des cas.

- ▶ **Les lymphomes primitifs du système nerveux central :** ou bien les tumeurs infiltrantes qui émergent dans le cerveau à partir de certaines cellules singulières appelées lymphocytes et qui jouent un rôle dans l'immunité sont connues comme les lymphomes primitifs du système nerveux central. Ils Touchent principalement les personnes âgées ou immunodéprimées .Des tumeurs cérébrales plus rares surviennent, telles que les gangliogliomes, les épendymomes, les neurocytomes, les pinéalomes, les germinomes, les craniopharyngiomes, les hémangiopéricytomes et les hémangioblastomes. Ces les tumeurs peuvent affecter de nombreux tissus ou types de cellules du système nerveux centraltypes et du système nerveux central et peuvent être bénignes ou malignes .
- ▶ **Les tumeurs médulloblastomes :** appelées tumeurs malignes se développent dans le cervelet . Les victimes sont des enfants.
- ▶ **Les tumeurs secondaires :** sont les métastases d'une tumeur maligne sous-jacente. Provenant d'une tumeur originelle située à l'extérieur du cerveau migrent dans le tissu cérébral par la circulation sanguine . Celles de la prostate, de la peau, des reins ou du sein – sont fréquemment liées à la croissance de métastases cérébrales .

1.3.3 Les causes des tumeurs du cerveau

Les causes des tumeurs cérébrales ne sont pas bien comprises. Nous ne les connaissons pas. Nous ne savons pas pourquoi, à un moment donné, les cellules se développent de manière incontrôlée et forment une tumeur.

De nombreuses études scientifiques ont été et sont en cours, tentent d'identifier les facteurs favorisant l'émergence de tumeurs cérébrale. Ces facteurs sont appelés facteurs de risque des tumeurs cérébrales. On distingue Trois types de facteurs de risque sont étudiés. Ils sont environnementaux, génétiques et viraux.

À eux seuls, les facteurs de risque n'expliquent pas pourquoi les tumeurs se développent. Ils n'expliquent pas non plus l'évolution des tumeurs. En fait, le même risque l'un développe une tumeur et l'autre non. À l'inverse, une tumeur peut se développer même en l'absence de facteurs de risque. Les tumeurs peuvent se développer même en l'absence de facteurs de risque [10].

1.3.4 Les symptômes et le diagnostic des tumeurs du cerveau

Les symptômes d'une tumeur au cerveau peuvent varier en fonction de la localisation de la tumeur. Sont très variables et n'apparaissent pas systématiquement. Ils dépendent du volume de la tumeur, de la vitesse à laquelle elle se développe et surtout de son emplacement.

L'apparition des symptômes peut être soudaine ou très progressive, en fonction de la rapidité de développement de la tumeur. Certaines tumeurs signifie généralement qu'elle se développe lentement. Ya Trois types de symptômes sont possibles .Ce tableau illustre les de symptômes de chaque type [11].

Type de symptômes	Les symptômes
Des maux de tête	<ul style="list-style-type: none">• à un gonflement du cerveau œdème cérébrale.• à une compression du cerveau par la tumeur.• à une mauvaise circulation du liquide céphalo-rachidien.
Des crises d'épilepsie	<ul style="list-style-type: none">• pertes de conscience s'accompagnant de chute, de perte d'urine, de morsure de la langue ou de convulsions.• mouvements soudains et involontaires des bras et des jambes.• raideur des muscles.
Des troubles fonctionnels	<ul style="list-style-type: none">• des troubles de la vision, des modifications de la personnalité.• des difficultés à coordonner ses mouvements.• une faiblesse, des sensations anormales, une perte d'équilibre.

TABLE 1.2: Les principaux symptômes de la tumeur cérébrale

1.4 Imagerie médicale

L'imagerie médicale est un domaine de la médecine qui englobe différentes techniques permettant de visualiser l'intérieur du corps humain afin de diagnostiquer, de surveiller et de traiter les maladies. Ces techniques comprennent la radiographie, l'échographie, la tomodensitométrie (scanner), l'IRM, la scintigraphie, la mammographie, entre autres. Elles sont utilisées pour examiner divers organes et tissus, tels que les os, les organes internes, le cerveau, les seins, etc. L'IRM, par exemple, utilise un champ magnétique puissant et des ondes radio pour produire des images détaillées en 3D des tissus mous et des os à l'intérieur du corps. Ces techniques jouent un rôle crucial dans le diagnostic précoce et la prise en charge des maladies [12].



FIGURE 1.5: Imagerie médicale IRM

1.4.1 Imagier par résonance magnétique IRM

L'imagerie par résonance magnétique (IRM) est une technique d'imagerie médicale qui utilise de puissants champs magnétiques et des ondes radio pour produire des images 3D détaillées des tissus mous et des os du corps. Ce test est utilisé pour examiner diverses parties du corps, telles que le cerveau, le foie, les poumons et le pancréas. L'IRM est sans danger pour les radiations car elle n'utilise pas de rayons X et est généralement très sûre. Cependant, certaines conditions médicales et certains appareils, tels que les stimulateurs cardiaques, les neurostimulantes et certains implants, peuvent constituer des contre-indications à l'IRM. Avant de réaliser ce test, il est important d'informer votre médecin de tout appareil implanté dans votre corps afin de déterminer si une IRM est appropriée. L'IRM permet d'obtenir des images en 3D d'une précision inégalable, en particulier lorsqu'elle est associée à un produit de contraste, et elle est prescrite par le médecin dans le cadre d'indications précises, à certaines phases du diagnostic, du traitement ou du suivi

1.4.2 Le principe de IRM

Un appareil IRM est un grand appareil cylindrique (en forme de tube) qui crée un champ magnétique puissant autour du patient et envoie des impulsions d'ondes radio depuis le scanner. Certains appareils IRM ressemblent à des tunnels étroits, tandis que d'autres sont plus ouverts.

Le puissant champ magnétique créé par l'appareil IRM amène les atomes de votre corps à s'aligner dans la même direction, puis des ondes radio sont envoyées par l'appareil IRM et déplacent ces atomes hors de leur emplacement d'origine.

Lorsque les ondes radio sont désactivées, les atomes reviennent à leur position d'origine et envoient des signaux radio. Ces signaux sont reçus par l'ordinateur et convertis en une image de la partie du corps examinée. Cette image apparaît sur l'écran d'affichage. L'IRM peut être utilisée à la place de la tomodensitométrie (TDM) lors de l'étude d'organes ou de tissus mous, l'IRM est plus efficace pour faire la différence entre les types de tissus mous et entre les tissus mous normaux et anormaux.

Les utilisations modernes de l'IRM ont contribué au développement d'une technologie d'IRM supplémentaire. L'angiographie par résonance magnétique (ARM) est une procédure utilisée pour évaluer le flux sanguin dans les artères. L'ARM peut également être utilisée pour détecter les anévrismes cérébraux et les anomalies des vaisseaux sanguins.

En fin de compte, l'imagerie par résonance magnétique fonctionnelle (IRMf) du cerveau peut être utilisée pour déterminer l'emplacement spécifique du cerveau où une fonction particulière se produit, comme la parole ou la mémoire, ainsi que les zones générales du cerveau dans lesquelles ces fonctions connues se produisent, mais la localisation exacte peut varier d'une personne à l'autre, selon les cas di-

verses pathologies [13].

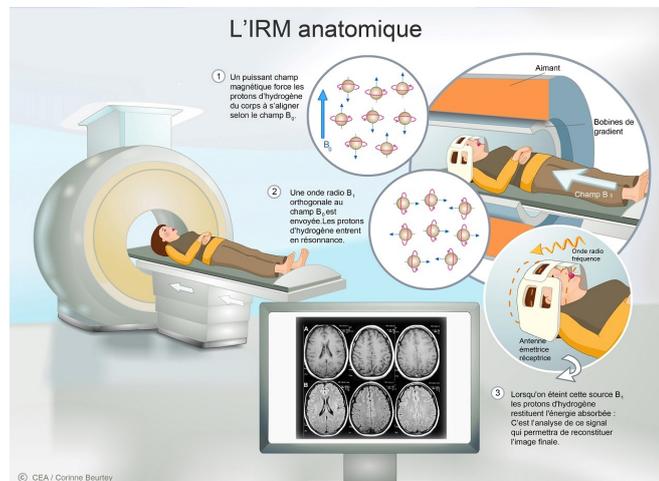


FIGURE 1.6: l'IRM anatomique [14]

1.4.3 Les différents types d'IRM

Tous les organes ont été explorés par IRM, mais l'analyse doit inclure une certaine partie du corps pour une analyse précise. Voici les contrôles les plus couramment effectués :

Type IRM	Les parties cibles
IRM osseuse et articulaire	Colonne vertébrale (côlon vertébral), os et articulations (épaules, genoux, chevilles, poignets, pieds et tronc), tissus mous et muscles
IRM de neurologie	Cerveau, moelle épinière, orbite
IRM abdominale et digestive	Foie, Supplémentation en Fer (Hémochromatose), Reins, IRM Interne
IRM mammaire	Mammaire
IRM cutanée	Utérus, ovaires, trompes de Fallope, vessie, prostate

TABLE 1.3: Les types IRM et leurs parties [15].

1.4.4 Pondération et séquence de images IRM

Les résultats de la recherche n'apportent pas de réponse directe à la question de la pondération et du séquençage des images IRM. Cependant, ils fournissent du contexte et des informations connexes qui peuvent être utilisées pour déduire une réponse.

Les résultats de la recherche montrent que « procession » est un terme utilisé dans divers contextes, notamment les processus religieux, le cinéma et la photographie, ainsi que les événements culturels. Cela suggère que le terme « cortège » peut faire référence à une séquence d'événements ou d'images, ce qui pourrait être pertinent pour la question de la séquence d'images IRM.

Dans le contexte des images IRM, la séquence d'images est importante pour interpréter avec précision les données. La pondération des images, quant à elle, fait référence au processus d'ajustement de l'intensité du signal des images pour améliorer le contraste et améliorer la précision du diagnostic.

Par conséquent, dans le contexte des images IRM, la pondération et la séquence des images sont toutes deux importantes pour une interprétation et un diagnostic précis. La pondération des images peut contribuer à améliorer le contraste et à améliorer la précision du diagnostic, tandis que la séquence des images peut contribuer à fournir un contexte et à faciliter l'interprétation des données.

1.5 Conclusion

Dans ce chapitre, nous avons présenté tout ce qui concerne les tumeurs cérébrales, les notions essentielles liées à l'anatomie du cerveau et les principales régions cérébrales qui ont une importance dans l'examen et le diagnostic clinique. Nous avons présenté également les principes d'acquisition des images médicales. Nous avons remarqué que l'imagerie à Résonance Magnétique est une technique d'imagerie médicale très utile pour l'observation du cerveau. Car c'est la méthode d'imagerie qui, dans la plupart des cas, donne les informations les plus riches (la résolution spatiale habituelle est de l'ordre du Millimètre).

Les méthodes de détection des image IRM

2.1 Introduction

La détection automatique des structures cérébrales est un domaine de recherche crucial en neurologie, visant à identifier et localiser automatiquement des structures spécifiques du cerveau sur des images médicales, telles que des tumeurs, des plissements corticaux ou d'autres anomalies. Il existe plusieurs méthodes de détection de tumeurs cérébrales, notamment l'utilisation de Deep learning pour identifier automatiquement six tumeurs cérébrales courantes sur des images IRM.

Ces méthodes peuvent aider à l'analyse et au diagnostic des tumeurs cérébrales en fournissant des informations précises et détaillées sur la taille, la forme et la localisation de la tumeur.

2.2 Qu'est-ce que la détection ?

La détection des tumeurs cérébrales d'images IRM est un processus qui vise à identifier et localiser les tumeurs cérébrales dans les images médicales obtenues par imagerie par résonance magnétique (IRM). Cette méthode est utilisée pour aider au diagnostic et au traitement des patients atteints de tumeurs cérébrales. Plusieurs techniques de détection ont été proposées, telles que l'utilisation de modèles de deep learning pour identifier automatiquement six tumeurs cérébrales courantes par IRM. Ces techniques permettent d'améliorer la précision de la détection et de faciliter le diagnostic des tumeurs cérébrales, offrant ainsi de meilleures chances de traitement et de suivi des patients.[16]

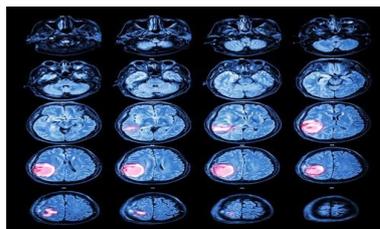


FIGURE 2.1: La détection d'une tumeur [17]

2.3 Les méthodes de détection de tumeur en imagerie IRM

Les techniques de détection de tumeur en imagerie par résonance magnétique (IRM) peuvent être classées en trois catégories

2.3.1 Détection manuelle des images

Cette technique implique que les médecins radiologues examinent visuellement les images IRM et identifient manuellement les structures ou les anomalies présentes. Cette méthode implique une analyse visuelle minutieuse des images IRM par des professionnels de la santé qualifiés pour repérer des signes de pathologies telles que des tumeurs, des lésions ou d'autres anomalies. La détection manuelle des images IRM repose sur l'expertise et l'expérience des radiologues pour interpréter les images et poser un diagnostic précis. [18]



FIGURE 2.2: La détection d'une tumeur [2]

2.3.2 Technique semi-automatique de détection des structures cérébrales sur les IRM

La technique semi-automatique de détection des structures cérébrales sur les IRM consiste à utiliser des algorithmes et des outils informatiques pour assister les radiologues dans l'identification et la détection des structures cérébrales sur les images IRM. Cette approche combine l'intervention humaine avec des méthodes automatisées pour faciliter le processus de détection des lésions ou des anomalies cérébrales. En utilisant des techniques semi-automatiques, les radiologues peuvent bénéficier d'une assistance précieuse pour repérer et analyser les structures cérébrales avec une plus grande efficacité et précision [19].

2.3.3 Approches automatisées pour la détection des structure cérébrales sur les IRM

Ces approches utilisent des algorithmes et des outils informatiques pour analyser et identifier automatiquement les différentes structures cérébrales à partir des images IRM. Ces approches permettent de détecter, de mesurer et d'analyser les différentes régions du cerveau de manière automatisée, sans nécessiter une intervention humaine directe. Elles sont conçues pour assister les professionnels de la santé

dans le diagnostic précoce, la surveillance et le traitement des pathologies cérébrales en fournissant des informations précises et rapides sur les structures cérébrales.

Les approches automatisées pour la détection des structures cérébrales sur les IRM impliquent l'utilisation de l'apprentissage profond. L'apprentissage profond, une sous-catégorie du machine learning, est particulièrement adapté à cette tâche car il peut extraire des caractéristiques complexes et hiérarchiques à partir des données d'IRM pour identifier et localiser différentes structures cérébrales avec une précision élevée. Ces méthodes utilisent des algorithmes et des outils informatiques, notamment des réseaux de neurones convolutionnels (CNN) pour analyser les images IRM et détecter automatiquement les régions d'intérêt, telles que les régions du cerveau, les tumeurs ou les lésions. Ces approches automatisées permettent d'interpréter et de diagnostiquer les images IRM de manière plus efficace et précise sans nécessiter d'intervention humaine directe.

Ainsi, les approches automatisées basées sur l'apprentissage profond constituent une avancée majeure pour la détection et l'analyse des structures cérébrales sur les images IRM, offrant des solutions efficaces et précises pour le dépistage précoce, le diagnostic et le suivi des pathologies cérébrales [18].

2.4 L'Apprentissage profond (Deep Learning)

L'apprentissage profond Également connu sous sa dénomination anglaise « Deep Learning » ou « DL », est une technique d'intelligence artificielle qui permet aux machines d'apprendre à partir de données complexes et non structurées. Il s'agit d'un sous-domaine de l'intelligence artificielle qui utilise des réseaux neuronaux artificiels profonds pour déterminer des règles plus complexes, à savoir une technique d'entraînement de machines visant à imiter la manière dont les neurones du cerveau humain traitent et apprennent des informations. On peut parler de réseau de neurones artificiels.

Cette technique d'apprentissage automatique est largement utilisée dans divers domaines tels que la reconnaissance d'image, la traduction automatique, les voitures autonomes, le diagnostic médical, les recommandations personnalisées, la modération automatique des réseaux sociaux, la prédiction financière et le trading automatisé, l'identification de pièces défectueuses, la détection de malwares ou de fraudes, les chatbots, l'exploration spatiale, les robots intelligents, et bien d'autres.

Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données (« big data »).[20]

2.4.1 Histoire de l'apprentissage profond (Deep Learning)

L'histoire de l'apprentissage profond (deep learning) remonte aux années 1940, mais son développement significatif a eu lieu plus tard, à mesure que les avancées technologiques et les progrès en informatique ont permis d'exploiter son plein potentiel. Voici un aperçu de son évolution :

-Dans les années 1940-1960, McCulloch et Pitts ont jeté les bases de l'apprentissage profond avec leur modèle de neurone formel en 1943. Plus tard, en 1958, Frank Rosenblatt a créé le perceptron, un précurseur

des réseaux de neurones, mais il était limité dans sa capacité à traiter des problèmes complexes en raison de sa structure à une seule couche.

Ère de l'IA symbolique (années 1960-1980) : Pendant cette période, l'intelligence artificielle (IA) était dominée par des méthodes symboliques et des systèmes experts. Les réseaux de neurones ont été largement délaissés en raison de leur manque de succès dans la résolution de problèmes complexes et de l'absence de puissance de calcul nécessaire pour les entraîner sur de grandes quantités de données

- L'ère de l'IA symbolique (années 1960-1980) : Durant cette période, l'intelligence artificielle (IA) était dominée par des approches symboliques et des systèmes experts, reléguant les réseaux de neurones au second plan.

-L'hiver du : 1980-2000 Malgré ces avancées, le deep learning connaît une période de désintérêt pendant plusieurs années, faute de puissance de calcul suffisante pour entraîner des réseaux de neurones profonds

- Dans les années 2000 jusqu'à aujourd'hui, l'apprentissage profond a connu une résurgence fulgurante, portée par des avancées significatives dans la puissance de calcul et l'accès à d'énormes ensembles de données. Cette renaissance a été alimentée par des algorithmes d'apprentissage améliorés, notamment les réseaux de neurones convolutifs (CNN) et les réseaux de neurones récurrents (RNN). Ces algorithmes ont démontré des performances remarquables dans divers domaines, tels que la vision par ordinateur, le traitement du langage naturel, la reconnaissance vocale, et bien plus encore [21].

2.4.2 Pour quoi l'apprentissage profond ?

La capacité remarquable de l'apprentissage profond (deep-learning) à déduire une signification des données complexes ou imprécises permet d'extraire des modèles et de repérer les tendances trop complexes pour être détectées par l'homme ou les techniques informatiques. Il est possible de considérer un réseau de neurones qualifiés comme un "expert" dans la catégorie des informations qu'il a été assigné à analyser. Cet expert peut donc être employé afin de proposer de nouvelles prévisions des situations d'intérêt et de réponse.[22]

Les autres bénéfices comprennent

► **L'enregistrement des données sur l'ensemble du réseau :**

Les informations comme dans la programmation traditionnelle sont stockées sur l'ensemble du réseau plutôt que sur une base de données.

► **Aptitude à faire face à des connaissances incomplètes :**

Une fois formées, les données peuvent donner une conclusion même avec des informations incomplètes.

► **Être capable de supporter les pannes :**

La défaillance d'une ou plusieurs cellules.

► **Assurer la capacité d'apprentissage :**

Il est essentiel de définir les exemples et de les enseigner au réseau en fonction de la sortie souhaitée

en présentant ces exemples au réseau. La réussite du réseau est directement aux instances choisies et si l'événement ne peut pas être représenté dans tous ses aspects, il est possible que le réseau génère une fausse sortie.

► **Aptitude à enseigner aux machines :**

Les réseaux En analysant les événements similaires, les réseaux de neurones artificiels apprennent et prennent des décisions.

► **Capacité de traitement simultané :**

Les réseaux de neurones artificiels possèdent une puissance numérique capable de réaliser plusieurs tâches simultanément. [22]

2.4.3 L'importance de l'apprentissage profond

L'importance de l'apprentissage profond réside dans sa capacité à révolutionner de nombreux domaines en permettant aux machines d'apprendre à partir de données complexes et non structurées. Cette technologie est essentielle pour plusieurs raisons :

► **Innovation Technologique**

Permettant le développement de produits et de services avancés dans des domaines tels que la reconnaissance d'objets, la reconnaissance vocale, la vision par ordinateur, et bien d'autres encore, est à la pointe de l'innovation technologique.

► **Solutions aux Problématiques Mondiales**

L'apprentissage profond peut accélérer la mise au point de solutions en réponse aux problématiques mondiales telles que le changement climatique, la sécurité alimentaire, la santé, et bien d'autres, en optimisant les processus, améliorant l'efficacité et stimulant l'innovation.

► **Avancées Scientifiques**

L'apprentissage profond permet de réaliser des avancées significatives dans des domaines variés tels que la médecine, la recherche biologique, l'analyse d'images médicales, la détection de maladies, et bien d'autres, contribuant ainsi à l'amélioration de la qualité de vie et à la progression de la science.

L'apprentissage profond est un pilier de l'intelligence artificielle qui ouvre de nouvelles perspectives technologiques, sociales et scientifiques, offrant des solutions innovantes et des avancées majeures dans de nombreux domaines pour répondre aux défis actuels et futurs de notre société.

2.4.4 Comment fonctionne l'apprentissage profond

Le deep learning se base sur un réseau de neurones artificiels imitant le cerveau humain. Cette structure est disposée en plusieurs couches, interconnectées entre elles.

La première couche correspond aux neurones d'entrée et la dernière transmet les résultats de sortie. Entre les deux se trouvent plusieurs couches intermédiaires par lesquelles l'information est traitée. Cette

architecture est propre au deep learning et permet que chaque couche analyse de manière plus précise les données d'entrée.

Ainsi, plus le réseau de neurones artificiels est profond et donc contient plusieurs couches, plus le système peut effectuer des tâches complexes. Il est capable de déterminer par lui-même une représentation de ce qu'il reçoit, que ce soit une image ou un texte.

À chaque information intégrée, les connexions entre neurones s'étendent et se modifient. C'est pour cela qu'un système utilisant l'apprentissage profond a la capacité d'apprendre de nouvelles choses en autonomie. Il améliore également de lui-même ses prévisions et ses prises de décision, sans qu'aucune intervention humaine ne soit requise. Il a donc pour particularité d'apprendre de ses propres erreurs.

Les performances des systèmes de deep learning sont bien supérieures à celles des systèmes de machine learning classiques pour de nombreuses tâches telles que la vision informatique, la reconnaissance vocale, la traduction automatique et la robotique. En plus de cela, la mise en place de systèmes de deep learning est également beaucoup plus simple. Bien que la reconnaissance des caractéristiques se déroule de manière autonome, il est nécessaire d'activer des milliers d'hyperparamètres (ou boutons) afin d'obtenir une efficacité optimale d'un modèle de deep learning.[23]

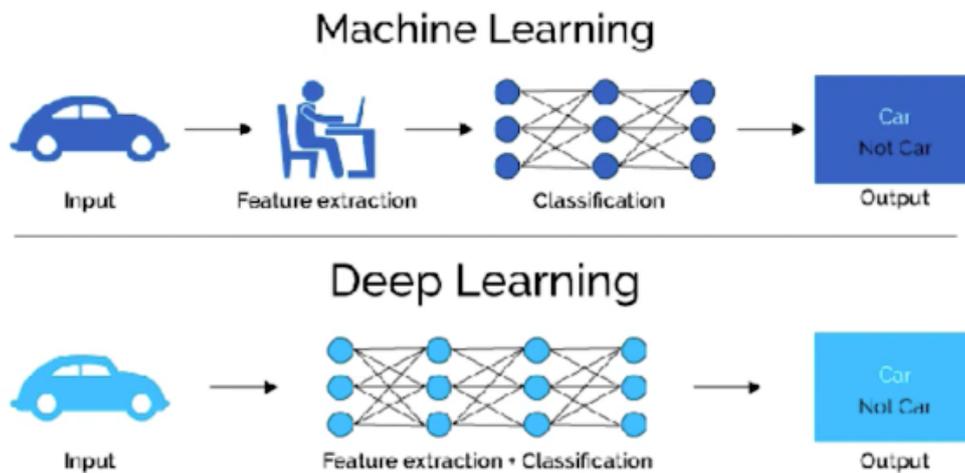


FIGURE 2.3: Comment fonctionne le Deep Learning [24] .

2.4.5 Application d'apprentissage profond

L'apprentissage profond s'applique à divers secteurs notamment :

Domaine d'application	Application
Reconnaissance Faciale	Basée sur l'utilisation de l'apprentissage profond, avec des systèmes tels que FaceNet de Google, qui offrent un taux d'identification élevé. La technologie est utilisée dans les domaines de la sécurité, de la biométrie et de la médecine.
Prédiction	Les méthodes d'apprentissage profond sont employées afin de prévoir l'avenir dans différents secteurs tels que les investissements, les accidents, les maladies, etc. C'est ce qui a donné naissance à la « gouvernamentalité algorithmique » où des machines entraînées par l'apprentissage profond prennent des décisions en se basant sur de grandes quantités d'information.
La reconnaissance de la parole	Améliorée grâce à l'utilisation de l'apprentissage profond dans des systèmes tels que Siri, ce qui facilite les interactions entre les individus et les machines.
La télédétection	Le terme utilisé pour désigner l'utilisation de méthodes d'apprentissage automatique pour prédire ou classer dans le domaine des télécommunications. Ces méthodes servent à étudier des informations issues de différentes sources comme les réseaux de télécommunications, les systèmes de communication sans fil, les données de trafic Internet, etc.
Voiture Autonome	Dans le domaine des véhicules autonomes, l'apprentissage profond est crucial pour la reconnaissance d'obstacles, de véhicules et de panneaux de signalisation, ce qui assure la sécurité et à la navigation des véhicules sans conducteur.

TABLE 2.1: Applications d'apprentissage profond [25].

2.5 Les techniques d'apprentissage profond

Les techniques d'apprentissage profond existantes comprennent différents types de réseaux neuronaux profonds dont les structures sont spécifiquement conçues pour répondre à diverses tâches.

2.5.1 Les réseaux neuronaux récurrents (RNN - recurrent neural network)

Les réseaux neuronaux récurrents (RNN-recurrent neural network) sont des modèles d'apprentissage automatique puissants qui permettent de traiter des données séquentielles ou des séries temporelles. Ils se distinguent des réseaux de neurones traditionnels par leur capacité à conserver une "mémoire" des informations précédemment traitées, ce qui leur permet de reconnaître des motifs et des séquences dans les données. Les RNN sont largement utilisés dans des applications telles que la traduction linguistique, le traitement du langage naturel, la reconnaissance vocale et le sous-titrage d'images, et sont incorporés dans des technologies populaires comme Siri, la recherche vocale et Google Translate.[26]

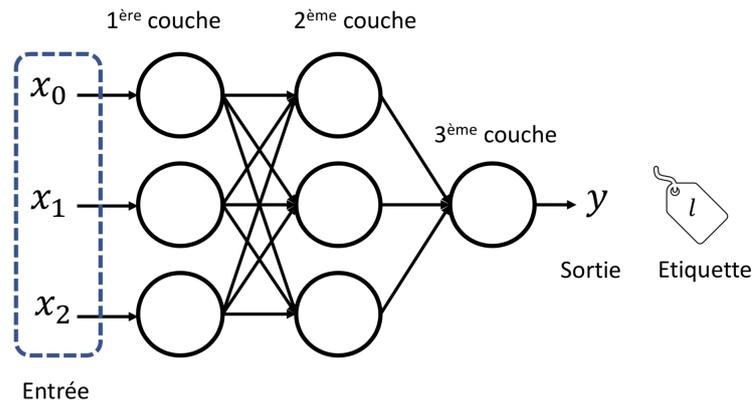


FIGURE 2.4: Réseaux RNN .[24]

2.5.2 Les réseaux adversaires génératifs (GAN)

Les réseaux adversaires génératifs (GAN) sont une technique d'intelligence artificielle qui permet de créer de nouvelles instances d'un objet. Ils reposent sur la mise en compétition de deux réseaux de neurones, le générateur et le discriminateur. Le générateur est un réseau de neurones convolutif qui crée de nouvelles instances, tandis que le discriminateur est un réseau de neurones déconvolutif qui détermine l'authenticité de l'objet ou s'il fait partie de l'ensemble d'apprentissage initial[27].

Les GAN ont pour objectif de produire des outputs sans que l'on puisse déterminer s'ils sont faux, tandis que le discriminateur doit identifier les faux. Au fil du processus, le générateur produit des outputs de meilleure qualité tandis que le discriminateur détecte de mieux en mieux les faux[27].

Les GAN sont utilisés dans de nombreux domaines, tels que la génération d'images et de vidéos de haute qualité, la colorisation d'images en noir et blanc, la détection et la correction d'anomalies, la création d'œuvres d'art, la synthèse de voix, et même dans le domaine de la médecine pour générer des images médicales synthétiques pour l'entraînement de réseaux de neurones.

2.5.3 Les réseaux à mémoire à long terme (LSTM - Long short-term memory)

Sont une classe unique de réseaux neuronaux récurrents (RNN) qui sont conçus pour reconnaître les dépendances à long terme dans les données séquentielles. Ils ont été introduits pour la première fois par Hochreiter Schmidhuber en 1997 et sont largement utilisés dans de nombreuses applications en raison de leur capacité à capturer des dépendances à long terme sans souffrir de gradients qui disparaissent. Les LSTM sont particulièrement efficaces pour des tâches telles que la reconnaissance vocale, la modélisation du langage et la prévision de séries chronologiques.

Dans l'exemple mentionné ci-dessus, il est souligné que les LSTM peuvent être utilisés pour la détection des fraudes, car ils excellent dans l'identification des dépendances à long terme dans les séquences. Cette capacité des LSTM à capturer des dépendances complexes et à long terme en fait un outil puissant pour des applications telles que la détection de fraudes, où la détection de schémas et de comportements

anormaux sur de longues périodes est cruciale.

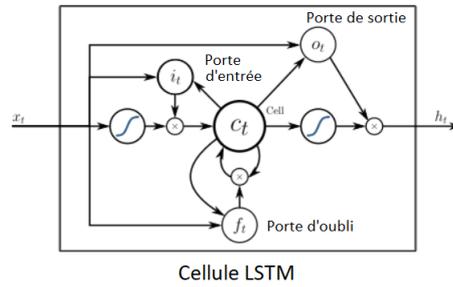


FIGURE 2.5: Cellule LSTM.

2.5.4 Les réseaux neuronaux convolutifs (CNN)

Le réseau de neurones convolutifs, ou CNN est un type spécialisé de modèle de réseau de neurones conçu pour travailler avec des données d’images bidimensionnelles, bien qu’ils puissent être utilisés avec des données unidimensionnelles et tridimensionnelles. Ces réseaux sont capables d’apprendre à extraire des caractéristiques locales, c’est-à-dire des structures qui se répètent à travers l’image.

Les CNN sont largement utilisés dans la reconnaissance d’images, le traitement audio, la détection de mots-clés, la détection d’objets, la conduite autonome, la génération de données synthétiques, et bien d’autres domaines. Ils sont particulièrement adaptés aux données complexes, telles que les images, et peuvent être utilisés avec des signaux ou des séries temporelles si elles sont prétraitées de manière appropriée.[30]

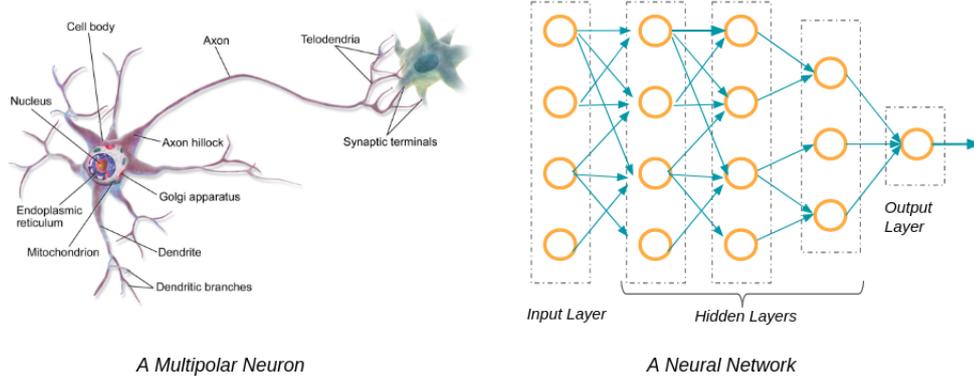


FIGURE 2.6: Les Réseaux de Neurones convolutifs.[30]

2.5.5 L’architecture d’un réseau neuronal convolutif (CNN)

L’architecture d’un réseau neuronal convolutif (CNN) comprend plusieurs couches interconnectées qui permettent au réseau d’apprendre à reconnaître des motifs et des caractéristiques dans les données. Voici les composants principaux de l’architecture d’un CNN

2.5.5.1 Couche de Convolution

La première couche des réseaux de neurones convolutifs est la couche de convolution, qui est toujours au moins la première couche. Les filtres sont utilisés pour créer les couches de convolution. Les filtres sont des planches de valeurs connues sous le nom de feature maps. Chaque couche de convolution intègre une image et génère une carte des caractéristiques. On obtient chaque carte des caractéristiques en appliquant le filtre à l'image. Par conséquent, la couche de convolution reçoit plusieurs images en entrée et effectue le calcul de la convolution de chacune d'entre elles en utilisant chaque filtre. Les filtres sont précisément adaptés aux caractéristiques que l'on désire voir dans les images.[32]

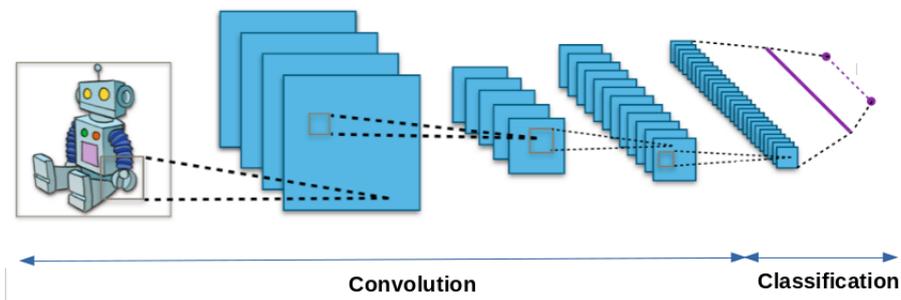


FIGURE 2.7: Architecture couche de convolution.

2.5.5.2 Couche d'Activation (ReLU)

Après la convolution, une fonction d'activation non linéaire, généralement ReLU (Rectified Linear Unit), est appliquée pour introduire de la non-linéarité dans le réseau et améliorer sa capacité à apprendre des modèles complexes.

Cette fonction d'activation transforme les valeurs négatives en zéro et conserve les valeurs positives, introduisant ainsi de la non-linéarité dans le réseau. En utilisant la fonction ReLU, les réseaux neuronaux peuvent apprendre de manière plus efficace et capturer des modèles complexes dans les données. La fonction ReLU est largement préférée pour sa simplicité de calcul et sa capacité à éviter le problème de disparition du gradient.

2.5.5.3 Couches de pooling

L'utilisation des couches de pooling, aussi connues sous le nom de couches de sous-échantillonnage, permet de diminuer la dimensionnalité, c'est-à-dire de diminuer le nombre de paramètres d'entrée. Comme pour la couche de convolution, la méthode de pooling applique un filtre à l'ensemble de l'entrée, mais son poids est inexistant. Plutôt que cela, le noyau exerce une fonction d'agrégation sur les valeurs du champ réceptif, ce qui entraîne la complémentation de la matrice de sortie. Il y a deux catégories principales de pooling.[32]

- **Max pooling** : à mesure que le filtre se déplace sur l'entrée, il sélectionne le pixel ayant la valeur maximale pour l'envoyer à la matrice de sortie.

- **Average pooling** : à mesure que le filtre se déplace sur l'entrée, il calcule la valeur moyenne dans le champ réceptif pour l'envoyer à la matrice de sortie.

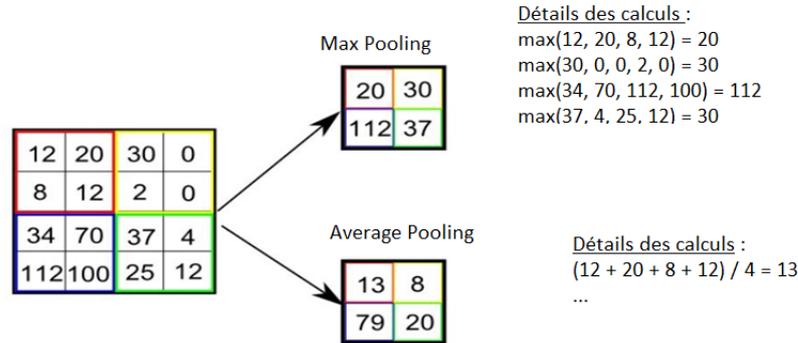


FIGURE 2.8: Couche de pooling .

2.5.5.4 Couche Entièrement Connectée

La couche entièrement connectée (fully connected layer ou FC layer) est un type de couche utilisée dans les réseaux de neurones convolutifs (CNN) et les réseaux de neurones artificiels en général. Voici les principales caractéristiques des couches entièrement connectées :

- Dans une couche entièrement connectée, chaque neurone de la couche est relié à tous les neurones de la couche précédente. Cela permet d'établir des relations complexes entre les caractéristiques extraites par les couches précédentes.
- Les couches entièrement connectées sont généralement placées à la fin d'un CNN, après les couches de convolution et de pooling. Elles permettent d'effectuer la classification finale en combinant les caractéristiques extraites.
- Le calcul dans une couche entièrement connectée revient à multiplier le vecteur d'entrée par une matrice de poids, puis à appliquer une fonction d'activation comme la sigmoïde ou le softmax. Les poids sont appris par rétropropagation du gradient lors de la phase d'entraînement.
- Plusieurs couches entièrement connectées peuvent être empilées les unes après les autres. Cela permet au réseau d'apprendre des combinaisons de plus en plus complexes de caractéristiques pour améliorer la prise de décision.
- La dernière couche entièrement connectée est souvent reliée à la couche de sortie du réseau, qui fournit les prédictions finales sous forme de probabilités pour chaque classe.

En résumé, les couches entièrement connectées jouent un rôle essentiel dans les CNN en permettant d'agréger les caractéristiques extraites par les couches précédentes pour effectuer la classification finale de manière efficace.

2.6 Fonctionnement des réseaux neuronaux convolutifs (CNN)

Un réseau neuronal convolutif fonctionne en appliquant des filtres convolutifs à une image pour détecter des caractéristiques spécifiques. Les filtres sont appliqués à chaque image du jeu d'apprentissage avec différentes résolutions, puis la sortie de chaque image convoluée est utilisée comme entrée de la couche suivante. Au début, ces filtres peuvent concerner des caractéristiques très simples, comme la luminosité et les contours, puis se complexifier jusqu'à représenter des caractéristiques uniques propres à l'objet.

2.7 Applications des réseaux neuronaux convolutifs (CNN)

Les réseaux neuronaux convolutifs (CNN) ont de nombreuses applications dans divers domaines, en particulier dans le traitement des images et des signaux. Voici quelques exemples clés d'applications des CNN :

► **Reconnaissance d'images et de vidéos**

Les CNN sont très performants pour la reconnaissance et la classification d'images. Ils sont utilisés pour identifier des objets, des personnes, des écritures, des scènes et des activités dans des images et des vidéos[33].

► **Détection d'objets**

Les CNN permettent de détecter et de localiser des objets spécifiques dans des images. Cela est crucial pour la conduite autonome, où les CNN identifient les panneaux, les piétons, les autres véhicules, etc.

► **Diagnostic médical**

En imagerie médicale, les CNN aident au diagnostic en identifiant des anomalies comme des tumeurs sur des IRM, des radiographies ou des scanners. Ils peuvent aussi analyser des rapports pathologiques.

► **Génération d'images [33]**

Grâce aux réseaux antagonistes génératifs (GANs), qui combinent des CNN, il est possible de générer de nouvelles images réalistes, par exemple pour créer des jeux de données synthétiques.

► **Traitement audio**

Les CNN peuvent être utilisés pour la détection de mots-clés dans l'audio, par exemple pour activer des assistants vocaux. Ils apprennent à reconnaître précisément les mots cibles malgré le bruit.

Les CNN sont très polyvalents et trouvent des applications dans de nombreux domaines où il s'agit d'analyser et de comprendre des données visuelles ou audio, que ce soit pour de la classification, de la détection, de la génération ou de la reconnaissance.

2.8 La relation entre intelligence artificielle, machine learning et le deep Learning

► Intelligence Artificielle (IA)

L'intelligence artificielle est un concept générique qui représente un ensemble de techniques visant à imiter l'intelligence humaine. L'IA englobe de nombreux domaines comme la reconnaissance vocale, la vision par ordinateur, le traitement du langage naturel.

► Machine Learning (ML)

Le machine learning est une branche de l'intelligence artificielle. Il permet aux systèmes informatiques d'effectuer des tâches sans instructions explicites, en se basant sur des algorithmes et modèles statistiques. Le ML analyse de grands volumes de données pour en extraire des informations pertinentes et prendre des décisions éclairées

► Deep Learning (DL)

Le deep learning est un sous-domaine du machine learning. Il s'agit d'un type d'IA qui utilise des réseaux de neurones artificiels pour mimer le fonctionnement du cerveau humain. Le DL nécessite de très grandes quantités de données d'entraînement mais apprend de manière autonome, sans intervention humaine. Il est particulièrement performant pour des tâches complexes comme la reconnaissance d'images, la conduite autonome, etc.

Le domaine de l'intelligence artificielle (IA) comprend des algorithmes plus ou moins avancés sophistiqués qui imitent actions humaines. Le machine learning (ML) est une branche de l'intelligence artificielle qui cherche à permettre aux machines d'acquérir automatiquement des connaissances à partir de données en utilisant des modèles mathématiques. L'apprentissage profond (DL) est une branche du machine learning qui exploite des réseaux de neurones artificiels profonds afin de déterminer des règles plus complexes. [31]

Deep Learning et Machine Learning sont donc des notions relatives à l'intelligence artificielle, qui participent grandement à sa performance. [31]

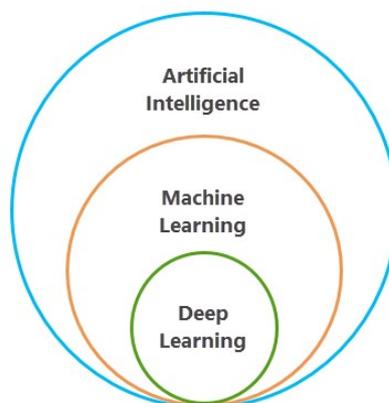


FIGURE 2.9: La relation entre AI,machine learning,deep learning.

2.9 Analyse comparative des techniques de détection

Les chercheurs ont exploré diverses techniques et algorithmes pour aborder la tâche complexe de la détection des tumeurs cérébrales, cherchant à atteindre des niveaux élevés de précision et de performance. Parmi les méthodes largement utilisées dans ce domaine figure Les approches automatisées de détection .

Cette approche automatisées de détection a démontré des résultats prometteurs dans de nombreuses applications, notamment dans la diagnostique précise des tumeurs. En exploitant les capacités des réseaux de neurones convolutifs (CNN) et des algorithmes sophistiqués et d'autres techniques avancées d'apprentissage profond, peuvent fournir des informations précieuses pour la prise de décision clinique en identifiant avec précision les tumeurs sur les images IRM.

Les réseaux de neurones peuvent détecter les lésions cérébrales à partir de l'analyse de milliers d'images IRM, ce qui permet d'améliorer considérablement la précision de la détection et de réduire le temps nécessaire pour effectuer un diagnostic.

- Dans une recherche dirigée par Sneha Grampurohit en 2020, une analyse de 253 images IRM a été réalisée. Ils ont mis en œuvre une méthode de détection basée sur VGG-16. Les résultats obtenus ont révélé une précision de prédiction de 96%, soulignant ainsi l'efficacité de cette approche pour identifier avec précision les tumeurs cérébrales à partir d'images IRM.
- Dans une étude menée par Kange en 2020, un ensemble de données comprenant 3000 images IRM a été utilisé. Ils ont appliqué une méthode basée sur ResNeXt-101. Les résultats obtenus ont montré une précision de 96.13%, ce qui témoigne de l'efficacité de cette approche pour détecter avec précision les tumeurs cérébrales à partir d'images IRM.

Une synthèse des travaux de plusieurs chercheurs ainsi que leur approche de détection de tumeurs dans le tableau ci-dessous :

Auteurs	Méthodes	Dataset	Evaluation
Tariq Sadad et al (2021) [34].	Unet et ResNet50	Dataset Figshare	Accuracy=95 %
Khawaldeh et al (2018) .	AlexNet CNN	Cancer Imaging Archive (TCIA)	Accracy=91%
Toğaçar M. and et.al [35] .	BrainMRNet CNN	MRI Image dataset	Accuracy=96.05%
Abdul Hannan Khan et al(2022) [36].	HDL2BT et CNN	image fragments	Accuracy=92.13%
Mawaddah Hara-hap et al (2022) [37].	ResNet50 et DenseNet121	Images tumor data base	Accuracy=93.23 %
Priyanka Modiya and et.al (2022) [38].	EfficientNet-B7 ET PCA	BT-large-1c	Accuracy=80%
Sneha Grampuro-hit Et al (2020) [39] .	VGG-16	253 IRM images	Accuracy=96
Xizhi Wu and et.al (2020) [40].	Xception	Intel Image Classification dataset	Accuracy=91.20%
Kang et al(2020)[41].	ResNeXt-101	3000 MRI	Accuracy=96.13 %
Sobhangi Sarkar and et. al (2020) [42] .	2D CNN	MRI dataset	Accuracy=91.3 %

TABLE 2.2: Analyse comparative sur la tumeur au cerveau.

2.10 Conclusion

Dans ce chapitre nous avons détaillé et présenté un état de l'art sur les méthodes de la détection des images IRM pour identifier des tumeurs cérébrale et ses différentes approches basée sur les réseaux convolutifs (CNN). Ces approches permettent une détection automatisée et précise des structures pathologiques, offrant un potentiel considérable pour améliorer les diagnostics et les traitements en médecine.

Dans le prochain chapitre, nous allons présenté de notre approche proposée. Nous allons expliqué les outils et la méthode utilisée et montrerons l'ensemble de données utilisées ainsi que les résultats et l'évaluation. .

3.1 Introduction

Avec l'évolution des techniques d'apprentissage en profondeur et l'émergence d'architectures plus complexes, il devient de plus en plus difficile de former ces modèles avec les ensembles de données limités disponibles dans le domaine médical. La taille réduite des données, leur variabilité et l'absence de détection précise posent des défis majeurs.

Ce dernier chapitre est consacré à l'implémentation de système proposé dans le chapitre précédent, 'la prédiction des tumeurs cérébrales en utilisant le CNN', et à leur évaluation selon différents critères proposés, afin d'améliorer les performances du modèle que ce soit en temps ou en efficacité. Pour atteindre cet objectif, nous présentons un modèle d'apprentissage profond basé sur ResNet50.

3.2 Ensembles de données d'entraînement, de validation et de test

Dans la détection des tumeurs, la répartition des données en ensembles de formation, de validation et de test est cruciale pour développer et évaluer des modèles fiables et efficaces. Ces groupes sont couramment utilisés dans ce contexte :

- **Ensemble d'entraînement** : cet ensemble est utilisé pour entraîner le modèle à détecter les tumeurs à partir des données disponibles. Les caractéristiques des tumeurs et des tissus sains sont apprises par le modèle au cours de cette étape.
- **Ensemble de validation** : une fois le modèle entraîné, l'ensemble de validation est utilisé pour régler les hyperparamètres du modèle et évaluer ses performances. Cela vous permet de choisir le modèle le plus efficace et d'optimiser ses paramètres.
- **Ensemble de teste** : l'ensemble de tests est utilisé pour évaluer objectivement les performances finales du modèle sélectionné. Cet ensemble de données n'a pas été utilisé pendant la formation ou

la validation, garantissant ainsi une évaluation impartiale de la capacité du modèle à détecter les tumeurs.

En partitionnant les données de manière appropriée et en utilisant ces combinaisons de manière séquentielle, il est possible de développer des modèles de détection de tumeurs précis et fiables, tout en garantissant leur généralisabilité à de nouvelles données [43].

Typiquement, les données sont divisées de la façon suivante :

- 70% pour l'ensemble d'entraînement .
- 20 % pour l'ensemble de validation.
- 10 % pour l'ensemble de test.

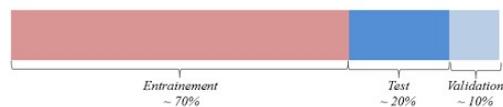


FIGURE 3.1: Ensemble des données d'entraînement, test et validation [43].

3.3 Environnement de développement de système

3.3.1 Environnement matériel

Notre travail est réalisé sur un PC dont la configuration est :

- **PC portable** : DESKTOP-IJ1H6CP , (RAM) :8.00Go.
- **Microprocesseur** : Intel(R) Core(TM) i5-6200U CPU @ 2.30GHz 2.40 GHz
- **Disque dur** : 239 Go.
- **Type du système** : Système d'exploitation 64 bits, processeur x64
- **Edition** : Windows 10 Professionnel

3.3.2 Environnement logiciel

Voici une liste de différentes plateformes et outils utilisés pour l'implémentation de notre système :

3.3.2.1 Le langage de programmation utilisé (Python)

Python est le langage de programmation open source le plus employé par les informaticiens. Ce langage s'est propulsé en tête de la gestion d'infrastructure, d'analyse de données ou dans le domaine du développement de logiciels. En effet, parmi ses qualités, Python permet notamment aux développeurs de se concentrer sur ce qu'ils font plutôt que sur la manière dont ils le font. Il a libéré les développeurs des contraintes de formes qui occupaient leur temps avec les langages plus anciens. Ainsi, développer du code avec Python est plus rapide qu'avec d'autres langages.

Il reste aussi accessible pour les débutants, à condition de lui consacrer un peu de temps pour la prise en main. De nombreux tutoriels sont d'ailleurs disponibles pour l'étudier sur des sites Internet spécialisés ou sur des comptes Youtube. Sur les forums d'informatique, il est toujours possible de trouver des réponses à ses questions, puisque beaucoup de professionnels l'utilisent.[44]



FIGURE 3.2: Interface de Kaggle

3.3.2.2 Les bibliothèques Python

- **TensorFlow** : est un framework de Machine Learning créé par Google et disponible en open source. Il s'agit d'une bibliothèque Open Source de calcul numérique et de Machine Learning compatible avec le langage Python. Elle simplifie le processus d'acquisition de données, d'entraînement des modèles de Machine Learning, de génération de prédictions et de raffinement des résultats futurs. TensorFlow regroupe des modèles et des algorithmes de Machine Learning et de Deep Learning. Le langage Python offre une API front-end pratique et confortable pour créer des applications à l'aide de ce framework. Il est possible de se servir de ce framework pour entraîner et exécuter des réseaux de neurones profonds pour la classification de chiffres manuscrits, pour la reconnaissance d'image, pour le plongement lexical, pour les réseaux de neurones récurrents, pour les modèles « sequence-to-sequence » de traduction automatique, pour le traitement naturel du langage, et pour les simulations basées sur les équations aux dérivées partielles.[45]
- **Numpy** : NumPy est une bibliothèque Python très populaire qui est principalement utilisée pour effectuer des calculs mathématiques et scientifiques. Elle offre de nombreuses fonctionnalités et outils qui peuvent être utiles pour les projets de Data Science. Se familiariser avec NumPy est une étape indispensable dans un projet de formation en Data Science.[46]
- **OpenCV** : OpenCV (Open Source Computer Vision) est une bibliothèque open-source très populaire en Python utilisée pour le traitement d'images, la vision par ordinateur et la reconnaissance de formes. Elle a été développée par Intel et est maintenant maintenue par la communauté open-source. [47]
- **Matplotlib** : Matplotlib est une bibliothèque du langage de programmation Python destinée à tracer et visualiser des données sous forme de graphiques. Elle peut être combinée avec les bibliothèques python de calcul scientifique NumPy et SciPy. [48]

3.3.2.3 Kaggle

Kaggle est une plateforme de concours de science des données et une communauté en ligne de scientifiques des données et de praticiens de l'apprentissage automatique sous Google LLC. Il permet aux utilisateurs de rechercher et de publier des ensembles de données, d'explorer et de créer des modèles dans un environnement de science des données basé sur le Web, de travailler avec d'autres scientifiques des données et ingénieurs en apprentissage automatique, et de participer à des concours pour résoudre les défis de la science des données. [49]

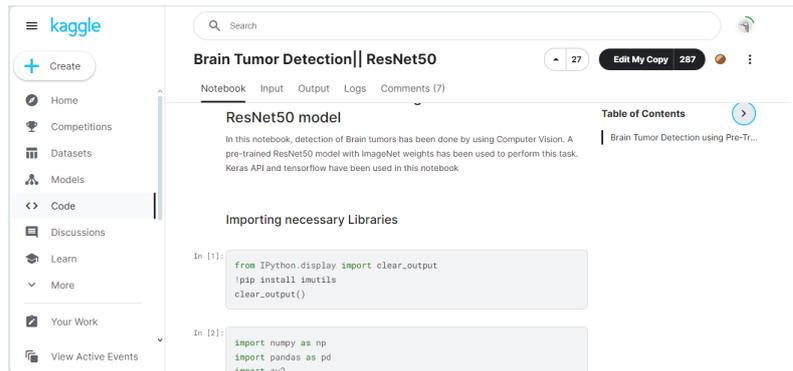


FIGURE 3.3: Interface de Kaggle

3.3.2.4 Google Colab

Google Colab, abréviation de Google Colaboratory, est une plateforme cloud offerte gratuitement par Google pour écrire et exécuter du code Python dans un environnement de notebook Jupyter directement depuis un navigateur web. Google Colab est un outil puissant pour le développement en Python, en particulier dans le domaine de l'apprentissage automatique, offrant un environnement interactif, un accès aux ressources de calcul, un stockage sur Google Drive, la collaboration en temps réel et de nombreuses autres fonctionnalités avancées. [50]

Nous avons utilisé Google Colab dans notre implémentation, parce que Cette plateforme permet d'entraîner des modèles de Deep Learning.

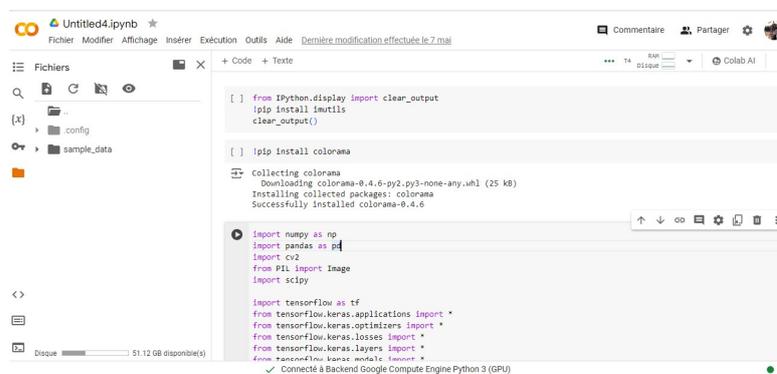


FIGURE 3.4: Interface de Google Colab

3.3.2.5 Letex (Overleaf)

LaTeX est un langage et un système de composition de documents. Il s'agit d'une collection de macrocommandes destinées à faciliter l'utilisation du « processeur de texte » TeX de Donald Knuth. Est un outil puissant pour la création de documents de qualité professionnelle, offrant une typographie soignée, une gestion avancée des formules mathématiques et une structure logique facilitant la création de documents complexes et structurés.

Voici quelques points clés sur LaTeX :

- **Typographie de haute qualité** LaTeX produit des documents avec une typographie soignée et professionnelle, idéale pour les articles de recherche, thèses, rapports techniques, présentations, etc.
- **Structure logique** Les utilisateurs définissent la structure du document en utilisant des commandes et des environnements, ce qui facilite la gestion de la numérotation des sections, des références croisées, des tableaux et des figures.
- **Gestion avancée des formules mathématiques** : est largement utilisé pour la rédaction de documents contenant des formules mathématiques complexes, offrant un rendu de haute qualité et une gestion efficace des équations.
- **Personnalisation et extensions** : est hautement personnalisable, avec de nombreuses extensions et packages disponibles pour étendre ses fonctionnalités et répondre à des besoins spécifiques.]
- **Gratuit et multiplateforme** : est un logiciel libre et gratuit, disponible pour différentes plateformes, ce qui le rend accessible à tous. [51]

Nous rédigeons notre code en LaTeX.

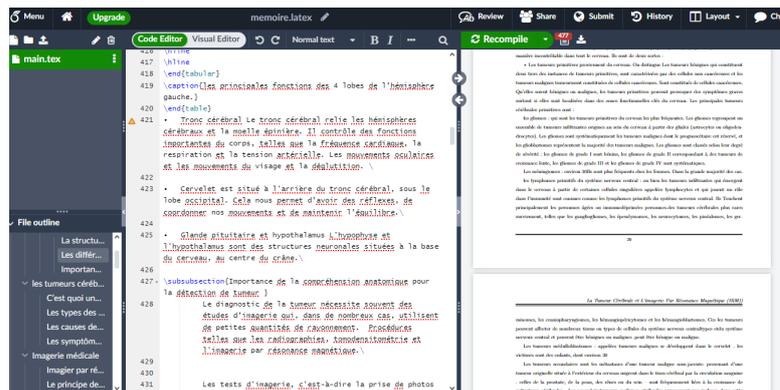


FIGURE 3.5: Interface de LATEX

3.4 Approche Proposée

Dans notre parcours de développement d'un modèle d'apprentissage profond, nous avons traversé plusieurs phases et accompli diverses tâches cruciales. Pour commencer, nous avons entrepris la collecte de données, rassemblant un ensemble de données pertinent et représentatif. Ensuite, nous avons procédé

au prétraitement de ces données, utilisant des techniques telles que l'augmentation des données pour enrichir et diversifier notre ensemble de données, garantissant ainsi une meilleure généralisation de notre modèle.

Après avoir préparé nos données, nous nous sommes attelés à la création du modèle proprement dit. Cette phase a impliqué la conception et la mise en place de l'architecture du réseau de neurones, en choisissant les couches appropriées et en définissant les hyperparamètres optimaux pour notre tâche spécifique.

Suite à la création du modèle, nous avons amorcé la phase d'entraînement, où le modèle a été exposé aux données pour apprendre les motifs et les relations sous-jacents. Ce processus a nécessité l'utilisation d'algorithmes d'optimisation pour ajuster les poids du réseau afin de minimiser l'erreur entre les prédictions du modèle et les vérités de terrain.

Une fois l'entraînement terminé, nous avons évalué les performances du modèle à l'aide de diverses métriques et techniques d'évaluation. Cela nous a permis de comprendre la capacité du modèle à généraliser sur des données qu'il n'avait pas encore vues, ainsi que d'identifier les éventuels problèmes ou lacunes à résoudre.

Enfin, avec un modèle entraîné et évalué, nous avons procédé à la phase de prédiction, où le modèle a été utilisé pour faire des prédictions sur de nouvelles données. Cette étape finale représente la concrétisation de notre travail, transformant les connaissances acquises et les capacités du modèle en actions utiles et prédictives.

Nous pouvons illustrer cette approche dans l'image suivante :

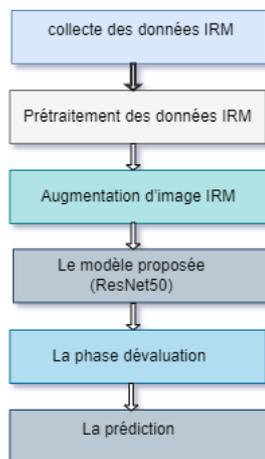


FIGURE 3.6: Architecture de méthode proposée

3.4.1 Collecte des données IRM

Le corpus de données IRM utilisé dans cette étude est un corpus open source accessible au public qui est divisé en deux sections : une avec une tumeur (Oui) et une sans tumeur (Non).

La collection de données comprend des informations classées recueillies par des examinateurs médi-

caux, incluant des radiologues et des médecins, et partagées en ligne. En outre, de nombreuses études ont été menées sur ce corpus de données. [52]

Au total, il y a 2998 images de MR cérébrales de diverses formes et longueurs dans la base de données. De plus, cette collection de données a été classée en deux catégories : avec tumeur et sans tumeur. 1499 images étaient classées dans la catégorie tumorale, tandis que 1499 images MR étaient classées dans la catégorie normale. La figure 1 présente l'ensemble des données MR en fonction de leurs étiquettes. Les données sans tumeur sont présentées dans une catégorie avec l'étiquette «Non» tandis que celles avec tumeur sont présentées dans l'autre catégorie avec l'étiquette «Oui».

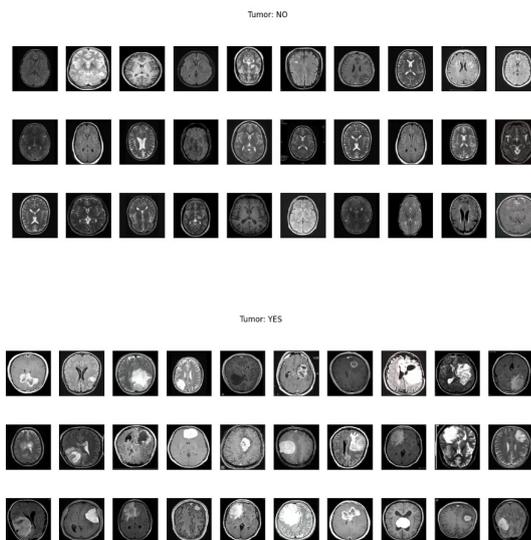


FIGURE 3.7: Collecte de données IRM

La répartition des données en ensembles d'apprentissage, de test et de validation est une méthode largement adoptée dans le domaine de l'apprentissage profond. Cette approche vise à évaluer et à valider les performances d'un modèle de manière rigoureuse et indépendante.

- **Ensembles de d'entraînement** : L'ensemble d'apprentissage est utilisé pour entraîner le modèle en lui permettant d'assimiler les motifs et les caractéristiques des données. C'est sur cet ensemble que le modèle ajuste ses paramètres afin de minimiser l'erreur de prédiction.

Ils représentent généralement la majorité des données, environ 70 à 80% de l'ensemble total des données disponibles

- **L'ensemble de validation** : est utilisé pour évaluer les performances du modèle pendant son entraînement. Il sert à vérifier si le modèle généralise correctement sur des données qu'il n'a pas vues pendant l'entraînement. De plus, cet ensemble permet d'ajuster les hyperparamètres du modèle et de prendre des décisions telles que l'arrêt prématuré de l'entraînement pour éviter le surapprentissage. Ces ensembles sont généralement plus petits que l'ensemble d'entraînement, représentant environ 10 à 20% de l'ensemble d'entraînement.

- **Ensembles de test** : est utilisé pour évaluer les performances finales du modèle une fois qu'il a été entraîné et validé. Ces données sont totalement indépendantes de celles utilisées pour l'apprentissage et la validation. Elles permettent d'évaluer la capacité du modèle à généraliser sur de nouvelles données et à fournir des prédictions précises dans des situations réelles, sans risque de biais lié à l'entraînement.

Ils sont également plus petits que l'ensemble d'entraînement et représentent le reste des données disponibles, soit environ 10 à 20%.

3.4.2 Prétraitement des données IRM

Le prétraitement des données revêt une importance capitale dans le processus d'analyse des données, garantissant ainsi la qualité et la pertinence des résultats obtenus. En effectuant des opérations telles que la normalisation des niveaux de gris et le redimensionnement des images, il devient plus aisé de comparer les images entre elles et d'extraire des informations significatives.

En plus de ces techniques de base, d'autres méthodes de prétraitement peuvent également être employées pour améliorer davantage la qualité et la pertinence des résultats de l'analyse des données. Ces techniques supplémentaires peuvent inclure la suppression du bruit, l'amélioration du contraste, la correction des artefacts et d'autres procédures visant à optimiser la qualité et la cohérence des données avant leur analyse approfondie.

Dans le processus de prétraitement des données pour les images par résonance magnétique (IRM), le recadrage et le redimensionnement constituent deux étapes essentielles.

3.4.2.1 Recadrage d'images IRM

Le recadrage d'images IRM (Imagerie par Résonance Magnétique) est une étape importante du prétraitement des données IRM. Il permet de sélectionner et de découper une région spécifique d'une image IRM pour se concentrer sur une zone d'intérêt ou pour améliorer la visualisation de certaines structures anatomiques.

Le recadrage est souvent nécessaire car il existe de nombreuses zones et espaces indésirables disponibles dans presque toutes les images IRM, ce qui peut entraîner des performances médiocres des algorithmes de classification et d'analyse. En se concentrant uniquement sur les régions pertinentes, le recadrage permet d'améliorer la qualité et l'efficacité des traitements d'images IRM, en particulier dans le contexte des algorithmes d'apprentissage automatique. [11]

La figure 2 illustre le processus d'images recadrées à chaque étape. La figure 3 présente l'ensemble des données d'image RM après le processus de recadrage appliqué.

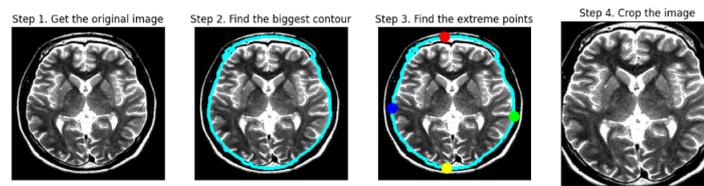


FIGURE 3.8: Recadrage des images IRM



FIGURE 3.9: Dataset après le recadrage

3.4.2.2 Le redimensionnement des images IRM

Le redimensionnement des images dans le processus de prétraitement des données revêt une importance capitale, notamment lorsqu'on vise à les adapter à la configuration prévue du modèle, tel que le modèle ResNet 50. L'objectif principal de cette étape est d'assurer que toutes les images présentent une taille uniforme, ce qui favorise la cohérence dans le traitement des données par le modèle. Il garantit des dimensions uniformes, préservant ainsi les caractéristiques essentielles des images.

En normalisant les dimensions des images, on évite les distorsions ou les pertes d'informations importantes qui pourraient survenir lors de la transformation des images. Cette uniformisation permet d'optimiser l'exploitation des capacités d'apprentissage du modèle, en garantissant une entrée cohérente et bien structurée. Ainsi, chaque image est redimensionnée pour correspondre à une taille spécifique, ce qui assure une homogénéité dans les données d'entrée du modèle.

Dans cette étude, les images MR sont ajustées en termes de largeur, de hauteur et de canal ($224 \times 224 \times 3$). La raison particulière de cette taille est que notre modèle suggéré utilise ResNet50 dans son

architecture, qui prend en compte 224×224 dans sa couche d'entrée.

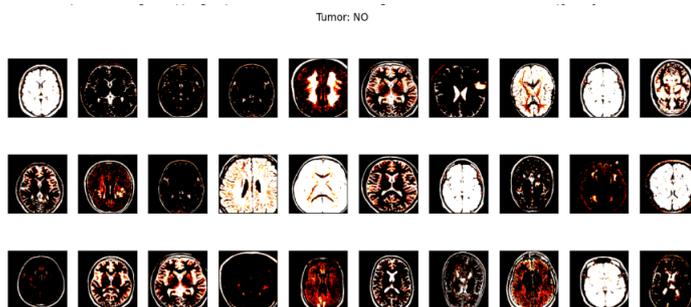


FIGURE 3.10: Les images IRM redimensionnées

3.4.3 Augmentation d'image IRM

L'augmentation d'images IRM est une pratique courante dans le domaine médical pour améliorer la qualité des données d'entraînement des modèles d'apprentissage automatique utilisés en imagerie médicale. Cette technique permet de générer des variations artificielles des images IRM, telles que des rotations, des changements d'échelle, des déformations, ou des ajustements de contraste, afin d'accroître la diversité des données et d'améliorer la capacité des modèles à généraliser et à détecter les tumeurs avec précision.

Dans cette étude, on a créé des images augmentées à partir de chaque image, en modifiant légèrement l'image initiale. Dans la figure on peut observer l'image originale et ses images augmentées, avec l'image originale visible en haut et les images augmentées visibles en bas. Nous avons utilisé la méthode d'augmentation des données dans notre étude pour combattre le surajustement. Cette approche a été mise en œuvre sur un ensemble de données comprenant 2998 images afin de produire un nombre important d'images pour l'entraînement. Nous avons utilisé différentes méthodes pour augmenter les données en utilisant le générateur de données d'images et les fonctions de flux avec Python. La rotation, le décalage en largeur et en hauteur, le cisaillement, la variation de luminosité, le retournement horizontal et vertical, ainsi que la fonction de prétraitement ont été employées parmi ces techniques. En sélectionnant une sélection parmi les 2998 disponibles, nous avons utilisé ces huit méthodes d'augmentation afin de produire en même temps 21 nouvelles images. Grâce à cela, notre base de données a été enrichie et les performances de nos modèles d'apprentissage ont été améliorées.

Dans cette étude, les images augmentées ont été créées à partir de chaque image, en modifiant légèrement l'image initiale. Dans la figure ci dessous, on peut observer l'image originale et ses images augmentées, avec l'image originale visible en haut et les images augmentées visibles en bas.

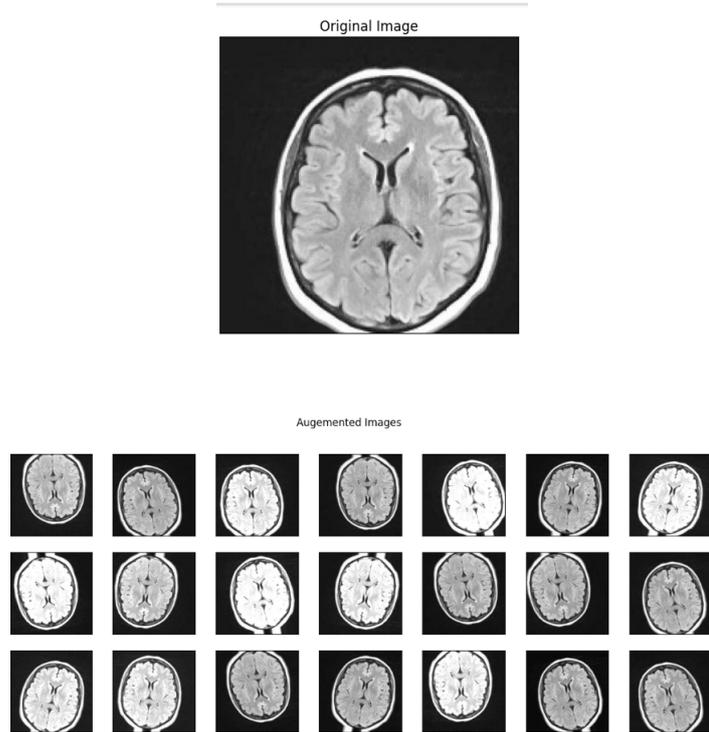


FIGURE 3.11: Technique d'augmentation sur l'image originale

3.4.4 Architecture du modèle proposée pour le diagnostique

3.4.4.1 Réseau de neurones à convolution (CNN)

Les réseaux de neurones convolutifs (CNN ou ConvNet), sont largement considérés comme la méthode la plus appropriée pour les applications de vision par ordinateur. Leur efficacité découle de leur capacité à extraire automatiquement des caractéristiques pertinentes à partir des données d'entrée, ce qui en fait l'une des architectures les plus prisées en apprentissage profond.

Les CNN adoptent une approche unique dans l'extraction des caractéristiques en utilisant une hiérarchie de modèles. Ils combinent des couches de traitement locales, telles que des filtres de convolution, des couches de sous-échantillonnage (pooling), et des couches non linéaires comme les fonctions d'activation, pour former des représentations de plus en plus abstraites des données en entrée. Cette hiérarchie permet aux CNN de capturer des structures et des motifs complexes dans les données, en assemblant des modèles simples pour former des modèles plus complexes.

Comparés à d'autres types de réseaux neuronaux, tels que les réseaux neuronaux entièrement connectés, les CNN se distinguent par leur capacité à effectuer un prétraitement simplifié des données grâce à l'inclusion de filtres internes. Les filtres de convolution apprennent automatiquement à extraire des caractéristiques importantes des images en parcourant la matrice de l'image avec des noyaux de filtre, ce qui réduit la dépendance à des techniques de prétraitement manuelles souvent nécessaires dans d'autres approches.

Cette capacité des CNN à capturer des caractéristiques pertinentes de manière automatique et à réduire la nécessité d'un prétraitement manuel en fait des choix efficaces et performants pour la classification de données visuelles. Ils ont été largement utilisés avec succès dans une gamme d'applications, telles que la reconnaissance d'objets, la détection de visages, la classification d'images médicales, et bien plus encore. En raison de leur efficacité et de leur flexibilité, les CNN continuent d'être au cœur de nombreuses avancées en vision par ordinateur et en apprentissage profond.

3.4.4.2 ResNet50

ResNet50 est une architecture de réseau neuronal convolutionnel profond (CNN) utilisée en vision par ordinateur. Il s'agit d'une variante de l'architecture populaire ResNet, qui signifie « Residual Network ». Le « 50 » dans le nom fait référence au nombre de couches du réseau, qui a une profondeur de 50 couches.

ResNet50 est un modèle puissant de classification d'images qui peut être entraîné sur de grands ensembles de données et obtenir des résultats de pointe. L'une de ses innovations clés est l'utilisation de connexions résiduelles, qui permettent au réseau d'apprendre un ensemble de fonctions résiduelles qui mappent l'entrée à la sortie souhaitée. Ces connexions résiduelles permettent au réseau d'apprendre des architectures beaucoup plus profondes qu'il n'était possible auparavant, sans souffrir du problème de la disparition des gradients.

L'architecture de ResNet50 est divisée en quatre parties principales : les couches convolutives, le bloc d'identité, le bloc convolutif et les couches entièrement connectées. Les couches convolutives sont chargées d'extraire les caractéristiques de l'image d'entrée, tandis que le bloc d'identité et le bloc convolutif sont responsables du traitement et de la transformation de ces caractéristiques. Enfin, les couches entièrement connectées sont utilisées pour effectuer la classification finale.

- **Les couches convolutives :** Se composent de plusieurs couches convolutives suivies d'une normalisation par lots et d'une activation ReLU. Ces couches sont chargées d'extraire les caractéristiques de l'image d'entrée, telles que les bords, les textures et les formes. Les couches convolutives sont suivies de couches de pooling maximum, qui réduisent les dimensions spatiales des cartes de caractéristiques tout en préservant les caractéristiques les plus importantes.
- **Bloc d'Identité :** est un bloc simple qui fait passer l'entrée à travers une série de couches convolutives et rajoute l'entrée à la sortie. Cela permet au réseau d'apprendre les fonctions résiduelles qui mappent l'entrée à la sortie souhaitée et facilite l'apprentissage de modèles profonds.
- **Bloc Convolutif :** Le bloc convolutif est composé de plusieurs couches de convolution qui traitent les caractéristiques extraites précédemment. Ces couches sont souvent suivies de couches de normalisation par lot et d'activations ReLU.

Le bloc convolutif est similaire au bloc d'identité, mais avec l'ajout d'une couche convolutive 1x1 utilisée pour réduire le nombre de filtres avant la couche convolutive 3x3.

- **Les couches entièrement connectées :** Ces couches sont chargées de réaliser le classement final.

La sortie de la couche finale entièrement connectée est introduite dans une fonction d'activation softmax pour produire les probabilités de classe finales. [14]

En résumé, l'architecture de ResNet-50 est conçue pour faciliter l'apprentissage de modèles profonds en utilisant des connexions de raccourci et des blocs résiduels. Les couches convolutives et les blocs convolutifs extraient les caractéristiques des images, tandis que les couches entièrement connectées produisent la sortie finale.

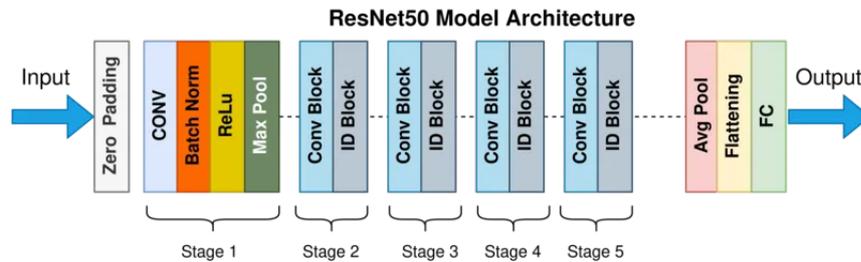


FIGURE 3.12: Architecture du Modèle ResNet50

3.4.5 La phase d'évaluation

L'apprentissage et l'évaluation du modèle de détection que nous avons proposé ont été effectués sur 20 itérations (époques) en utilisant une division des données. Nous avons réparti les données de manière à ce que 80% des données soient consacrées à l'apprentissage du modèle, tandis que les 20% restants ont été réservés pour évaluer les performances du modèle. En outre, Notre entraînement sur Google Colab a été réalisé en utilisant l'exécution avec GPU afin d'obtenir des résultats rapides.

L'efficacité de la détection des tumeurs est évaluée en utilisant l'ensemble des données des images reconstruites proposées. Différents critères d'évaluation sont employés pour évaluer le modèle entraîné, tels que la précision (P), Accuracy (A), le score F1 et la sensibilité (Rappel). Grâce à ces paramètres, il est possible d'évaluer diverses mesures de performance du modèle, telles que sa capacité à repérer les tumeurs avec précision. Chaque paramètre a une fonction particulière dans l'évaluation de la qualité de la détection des tumeurs et il est décrit en détail ci-dessous :

- Le nombre d'images de tumeurs correctement classées est défini comme "**True positive**".
- Le nombre d'images non tumorales correctement classées est connu sous le nom de "**True Négative**".
- Les images non tumorales mal classées en tant que tumeurs sont appelées "**False Positive**".
- le terme "**False Négative**" désigne le nombre d'images de tumeurs mal classées comme "**non tumorales**".

Ces paramètres permettent une évaluation exhaustive de la performance du modèle de détection, en mettant en lumière ses capacités à distinguer correctement les tumeurs des tissus non tumoraux. Une compréhension approfondie de ces mesures est essentielle pour évaluer précisément l'efficacité du modèle dans sa capacité à détecter et à classifier les tumeurs cérébrales à partir des images IRM.

- **TP** : True Positive .
- **TN** : True Négative .
- **FP** : False Positive .
- **FN** : False Négative .

► **La Précision :**

La précision est évaluée en fonction de la proportion d'observations positives correctement prédites parmi toutes les observations prédites positives. L'exactitude témoigne de la capacité du modèle à réduire au minimum les erreurs de classification des observations positives.

Précision	Précision (P) = TP / (TP +FP) (%)
------------------	--

► **Accuracy :**

Évalue la fréquence à laquelle un modèle de classification génère des prédictions exactes, qu'elles soient positives ou négatives. L'exactitude permet d'obtenir une évaluation globale des performances du modèle en prenant en considération à la fois les vrais positifs et les vrais négatifs.

Accuracy	Accuracy = TP +TN /TN+TP +FP +FN(%)
-----------------	--

► **Recall :**

la capacité d'un modèle à retrouver les images positives de manière adéquate. Il s'agit du rapport entre le nombre d'images de tumeurs classées correctement et le nombre total d'images de tumeurs. En raison de sa grande sensibilité, le modèle est performant pour repérer les images de tumeurs, car il réduit le nombre de faux négatifs, c'est-à-dire les images de tumeurs erronées comme non tumorales.

Recall	Recall = TP/ TP +FN(%)
---------------	-------------------------------

► **Le score F1 :**

Il est calculé en prenant la moyenne harmonique de la précision et du rappel. La précision évalue le pourcentage de résultats corrects parmi les résultats prévus, tandis que le rappel évalue le pourcentage de résultats corrects parmi tous les résultats réels.

Score F1	F-Score = 2(Precision Recall) / (Precision+ Recall) (%)
-----------------	--

3.4.6 Résultats et discussion

Le processus d'entraînement du modèle se déroule en utilisant l'ensemble de données d'entraînement (« train set »), tandis que l'évaluation de ses performances et l'ajustement des paramètres du modèle sont effectués sur l'ensemble de validation (« val set »). Cette division en deux ensembles distincts permet de garantir que le modèle est entraîné sur un ensemble de données indépendant de celui utilisé pour l'évaluation, ce qui contribue à évaluer de manière fiable sa capacité à généraliser à de nouvelles données.

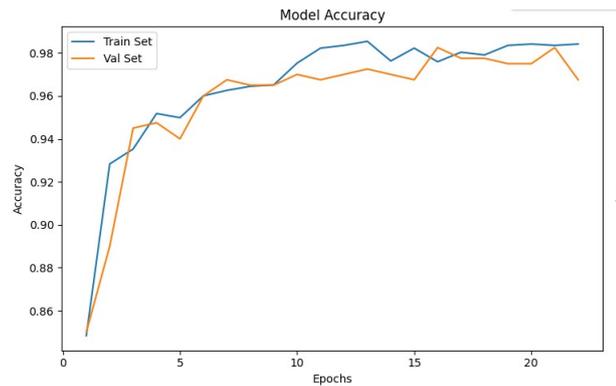


FIGURE 3.13: Accuracy durant les phases d'entraînement et d'évaluation sur 20 itérations.

La figure illustre l'évolution de l'exactitude (Accuracy) du modèle au cours de 20 itérations d'entraînement et d'évaluation.

- Au cours des cinq premières itérations, on observe une augmentation rapide de l'exactitude tant pour les données d'entraînement que pour les données d'évaluation, jusqu'à ce qu'elle atteigne une valeur de 0,95.

Cette augmentation rapide de l'exactitude au début de l'entraînement peut être attribuée à plusieurs facteurs, le modèle commence à apprendre les motifs et les structures présents dans les données d'entraînement, ce qui se traduit par une amélioration significative de sa capacité à prédire correctement les étiquettes des données d'entraînement. De plus, les premières itérations peuvent être caractérisées par une forte réactivité du modèle aux modifications des paramètres et à l'ajustement aux caractéristiques spécifiques des données.

- De la cinquième à la vingtième itération, nous observons une croissance lente et fluctuante de l'exactitude à la fois pour les données d'apprentissage et d'évaluation, jusqu'à ce qu'elles atteignent leur niveau maximal.

Cette croissance lente et fluctuante de l'exactitude pendant cette période peut être attribuée à plusieurs facteurs. D'abord à mesure que le modèle s'entraîne davantage, il peut devenir de plus en plus difficile d'améliorer sa performance, car il se rapproche de sa capacité maximale à apprendre à partir des données disponibles. De plus, les fluctuations dans l'exactitude peuvent être dues à des variations aléatoires dans les données d'entraînement et d'évaluation, ainsi qu'à des phénomènes tels que le surapprentissage ou le sous-apprentissage.

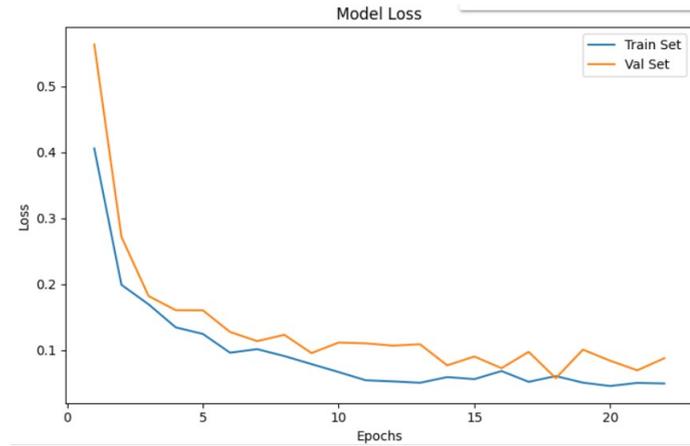


FIGURE 3.14: Perte d’entraînement, d’évaluation sur 20 itérations

- Au cours des deux premières époques, une baisse rapide et constante de la perte d’entraînement et de la perte d’évaluation est observée, passant de 0,5 à 0,25. Cette diminution rapide de la perte indique que le modèle s’ajuste efficacement aux données d’entraînement et d’évaluation, ce qui est un signe positif de sa capacité à apprendre à partir des données disponibles.
- De la deuxième à la vingtième époque, une baisse lente et variable de la perte d’entraînement et d’évaluation est observée. Au fil du temps, les deux pertes atteignent leur niveau minimum. Ce qui signifie que le modèle parvient à minimiser à la fois la perte sur les données d’entraînement et sur les données d’évaluation.

Une fois notre modèle proposé appliqué, nous avons obtenu les résultats suivants de l’évaluation :

	Approche proposée
Accuracy	0.98
Précision	0.99
Recall	0.97
F1-score	0.98

TABLE 3.1: Les résultats obtenus par notre approche

3.4.6.1 Comparaison des performances entre le modèle existant et le modèle proposé

Voici les résultats comparatifs présentés dans le tableau ci-dessous :

Auteurs	Méthodes	Évaluation (Accuracy)
Kang et al(2020)[41].	ResNeXt-101	91.20 %
Notre proposition	ResNet50	98 %

TABLE 3.2: La performance de modèle proposée.

Le tableau présente une comparaison détaillée des différentes approches utilisées par plusieurs chercheurs pour détecter les images IRM, mettant en avant les accuracies respectives de chaque méthode. Par exemple, Kang et al. (2020) ont utilisé le modèle ResNeXt-101 pour obtenir une accuracy de 91,20%. En revanche, notre méthode, basée sur ResNet50, a abouti à une accuracy de 98%, démontrant ainsi sa supériorité par rapport aux autres approches. Ces résultats soulignent l'efficacité de notre méthode dans la segmentation des images IRM pour la détection des tumeurs cérébrales, surpassant les performances des travaux antérieurs.

```

Accuracy score is : 0.9783
Precision score is : 0.9785
Recall score is : 0.9783
F1 Score is : 0.9783
ROC AUC Score is : 0.9942
Cohen Kappa Score: 0.9567
Classification Report:
precision  recall  f1-score  support
0          0.99    0.97    0.98     300
1          0.97    0.99    0.98     300

accuracy          0.98     600
macro avg         0.98    0.98    0.98     600
weighted avg      0.98    0.98    0.98     600
    
```

FIGURE 3.15: Résultat de notre méthode

3.4.7 Prédiction :

Une fois que le modèle est entraîné, il est utilisé pour prédire les tumeurs cérébrales dans de nouvelles images IRM qui lui sont présentées. Le modèle analyse chaque pixel ou voxel de l'image pour déterminer s'il appartient à une tumeur ou non.

3.4.7.1 Le fonctionnement de l'application

► **La page d'accueil :**

La Figure ci dessous présente l'écran d'accueil de notre application, offrant un accès facile à toutes ses fonctionnalités. Cette interface centrale regroupe l'ensemble des fonctionnalités disponibles pour les utilisateurs.

- Charger IRM
- Détection de la tumeur

- Quitter



FIGURE 3.16: La page d'accueil

- **Charger IRM :**

Nous entamons par l'importation de l'image en vue de préparer une image nette pour l'analyse ultérieure. Dans cette optique, nous récupérerons spécifiquement une image provenant de l'IRM cérébrale.

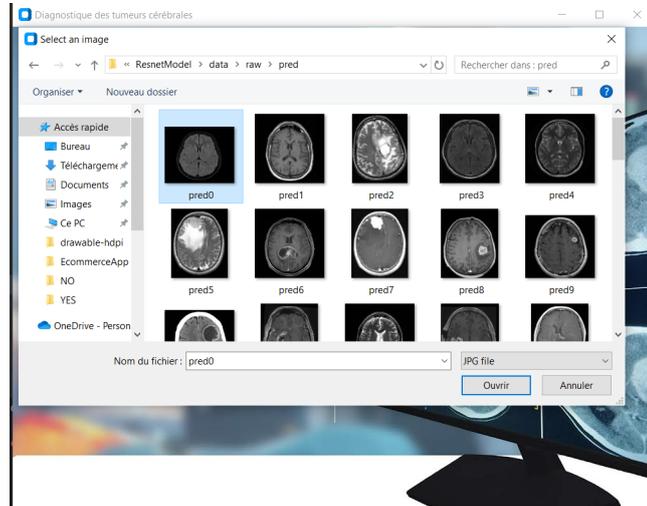


FIGURE 3.17: La page d'accueil

- **Détection de la tumeur :**

Il existe deux résultats de détection :

- **Un cas de présence de la tumeur cérébrale :** Dans ce scénario, lorsque le résultat est positif (oui), cela signifie que la présence d'une tumeur est confirmée.

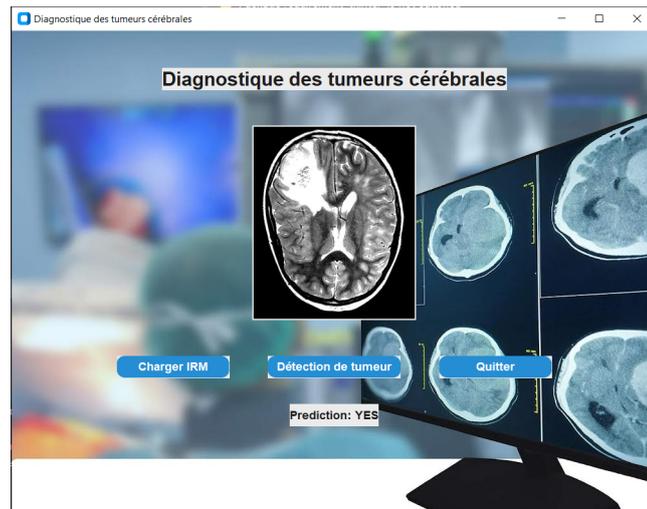


FIGURE 3.18: Résultat positif.

- **Un cas d'absence de la tumeur cérébrale.** : Dans ce cas, lorsque le résultat est négatif (NO), cela indique en réalité que la présence d'une tumeur n'est pas confirmée.

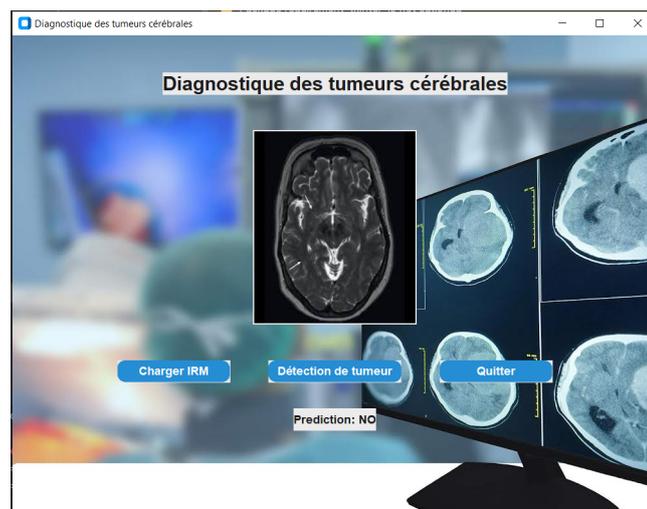


FIGURE 3.19: Résultat négatif.

3.5 Conclusion

Dans ce chapitre, nous avons abordé l'architecture de notre modèle suggéré, ResNet50, qui repose sur des éléments de réseau neuronal convolutif (CNN), ainsi que la méthode de travail et les procédures. Par la suite, nous avons exposé les technologies qui ont contribué à la mise en place de notre application, incluant le langage de programmation et le Framework employés. Finalement, nous avons présenté les indicateurs d'évaluation de notre modèle proposé, ce qui prouve que notre méthode a donné les meilleurs résultats qui peuvent rivaliser avec les méthodes actuelles.

3.6 Conclusion générale

La détection des tumeurs cérébrales par apprentissage profond est un domaine en plein essor qui combine l'imagerie médicale, en particulier l'imagerie par résonance magnétique (IRM), avec les techniques d'apprentissage automatique pour améliorer le diagnostic et le suivi des tumeurs cérébrales. Les réseaux de neurones convolutifs (CNN) sont une classe d'algorithmes d'apprentissage profond qui ont montré une grande efficacité dans la détection et la classification des tumeurs cérébrales à partir des images IRM. Les CNN peuvent extraire des caractéristiques pertinentes des images IRM, ce qui permet une classification plus précise des tumeurs cérébrales en différentes catégories, comme les tumeurs malignes ou bénignes.

L'utilisation de modèles pré-entraînés comme ResNet50 améliorer encore la performance de la détection des tumeurs cérébrales. En fin de compte, l'apprentissage profond offre de nouvelles perspectives pour améliorer la précision et la rapidité du diagnostic des tumeurs cérébrales, aidant ainsi les médecins et les radiologues dans leur travail

En conclusion, ce mémoire a démontré l'efficacité de l'apprentissage profond dans la détection des tumeurs cérébrales à partir d'images IRM. Notre méthode offre un potentiel considérable pour améliorer le diagnostic précoce de ces affections et ouvre la voie à de futures recherches dans ce domaine crucial de la santé.

nous allons envisager d'ajouter des perspectives futures pour le développement de modèles de détection des tumeurs cérébrales par apprentissage profond. Outre la détection initiale des tumeurs cérébrales, il est impératif de poursuivre les efforts de recherche pour concevoir des modèles capables de prédire avec précision la progression tumorale au fil du temps. Ces modèles devraient être capables d'analyser l'évolution des caractéristiques des tumeurs à partir des données d'imagerie longitudinales et de prédire leur comportement future. En intégrant des données cliniques telles que l'âge du patient, le type de tumeur, les marqueurs biologiques, et la réponse au traitement, ces modèles pourraient fournir des informations précieuses pour une prise en charge plus personnalisée des patients. De plus, en identifiant les patients à haut risque de progression tumorale, ces modèles pourraient permettre une planification thérapeutique proactive et une optimisation des stratégies de traitement, contribuant ainsi à améliorer les résultats cliniques et la qualité de vie des patients atteints de tumeurs cérébrales. Ces avancées dans le domaine de la prédiction de la progression tumorale représentent un pas important vers une médecine de précision et personnalisée, où les décisions thérapeutiques sont guidées par des données probantes et des informations spécifiques au patient.

Bibliographie

- [1] "Institut National Du Cancer. (n.d.). Les différentes parties. E-cancer.fr. Retrieved May 26, 2024", from <https://www.e-cancer.fr/Patients-et-proches/Les-cancers/Tumeurs-du-cerveau/Le-cerveau/Les-differentes-parties>.
- [2] Vital,"(Doctissimo, 2024) Doctissimo. (2024, April 23). Le cerveau : rôle, anatomie, dysfonctionnements. Doctissimo ".
- [3] Sicard, A., Joyal, M., Tremblay, P. (n.d.). Anatomie du cerveau humain – Speechneurolab. Speechneurolab.ca. Retrieved May 26, 2024, <https://speechneurolab.ca/anatomie-du-cerveau-humain/>
- [4] Khê Hoang-Xuan, Matthieu Peyre, Loïc Feuvret, Fondation pour la recherche sur le cancer-arc.org. Retrieved May 26, 2024, (Paris). from <https://www.fondation-arc.org/cancer/cancer-cerveau/quest-ce-quun-cancer-du-cerveau->
- [5] Marie-Odile KREBS,Jean-Philippe PIN,Sébastien BOURET, Anatomie du cerveau et du système nerveux. (2015, November 30). Fédération pour la Recherche sur le Cerveau (FRC). <https://www.frcneurodon.org/comprendre-le-cerveau/a-la-decouverte-du-cerveau/anatomie-du-cerveau-et-du-systeme-nerveux>
- [6] Wilhelm-Mausier Clinisciences. (n.d.). Cerveau humain adulte normal. Clinisciences.com. Retrieved May 26, 2024, from <https://www.clinisciences.com/lire/neurosciences-17/cerveau-humain-adulte-normal-1325.html>
- [7] Mark H. Bilsky , mai 2023,Présentation des tumeurs cérébrales, MD, Weill Medical College of Cornell University
- [8] Kelly Northey ,2019,Fondation canadienne des tumeurs cérébrales , 205 Horton St E, Suite 203, London, ON N6B 1K7
- [9] ROSARIA ABRITTI, Tumeurs cérébrales. (2017, November 11). Service de Neurochirurgie Lariboisière | Hôpitaux de Paris - APHP; Service de Neurochirurgie Lariboisière. <https://www.neurochirurgie-lariboisiere.com/tumeurs-cerebrales/>

-
- [10] Sylvie Retailleau Cancer tumeur au cerveau : causes, symptômes, traitements, recherche. (2015, February 6). Institut du Cerveau. <https://institutducerveau-icm.org/fr/tumeurs-cerebrales/>
- [11] Thomas Berthy ,2022, ARTC - Association pour la recherche sur les tumeurs cérébrales, Paris, France
- [12] Perrin de Nancy, IRM (imagerie par résonance magnétique nucléaire). (n.d.). VIDAL. Retrieved May 26, 2024, from <https://www.vidal.fr/sante/examens-tests-analyses-medicales/irm-imagerie-resonance-magnetique.html>
- [13] Elsa Cortijo ,2021, Le CEA, acteur clef de la recherche scientifique et technologique
- [14] ELSA Cortijo , CEA. (2022). L'imagerie médicale. <https://www.cea.fr/comprendre/Pages/sante-sciences-du-vivant/essentiel-sur-imagerie-medicale.aspx>
- [15] ThemeFuse. (n.d.). IRM. Radiologie92.com. Retrieved May 26, 2024, from <https://radiologie92.com/vos-examens/irm/>
- [16] Mémoire Rectifié de université Blida by Boutiara Abdelouhab,Khermaza Elyes , 2019-2020
- [17] Article tumeurs du cerveau : un diagnostic grâce à l'intelligence artificielle ,par FLORIANE BOYER ,1 Avril 2018
- [18] Bougherira, Traitement des images IRM pour la détection des tumeurs cérébrales par les algorithmes de Deep Learning CNN, Faster RCNN, Mask R-CNN et Transfer Learning sous environnement Cloud. Univ-Blida.Dz. Retrieved May 26, 2024, from https://di.univ-blida.dz/jspui/bitstream/123456789/11334/1/M%C3%A9moire_R%C3%A9ctifi%C3%A9_Boutiarav_Khermaza
- [19] Baptiste Morel , 2016 ,HAL open science IRM du cerveau néonatal : segmentation et analyse du signal. Médecine humaine et pathologie. Télécom ParisTech, Français.
- [20] Boughaba Mohammed, B. B., 2017. L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu, Master, UNIVERSITE KASDI MERBAH OUARGLA..
- [21] Boca Raton, FL, Taylor Francis ,2019, 264 p.Machine learning in translation corpora processing".
- [22] SAHLI Aoulia,2020-2021."Segmentation des images médicales par apprentissage profond. Mémoire de fin d'étude en vue d'obtention d'un diplôme de Master en Informatique.
- [23] Frost, Sullivan 2024,"décerne le prix Entreprise de l'année à NetApp dans la gestion du stockage dans le cloud hybride."
- [24] David Rousseau, Clément Douarre, octobre 2021. "CultureSciences Physique - ISSN 2554-876X"
- [25] F. Rosenblatt , G. Cybenkot , (1958), (1989), datascientest ,The perceptron : a probabilistic model for information storage and organization in the brain, Approximation by Superpositions of a Sigmoidal Function
- [26] HOURRANE Oumaima , "DataScienceToday,2018 ,PhD Student, HASSAN 2 University, Casablanca, Faculty of Sciences Ben M'Sik ,Morocco"
- [27] F. Rosenblatt , G. Cybenkot , (1958), (1989), datascientest ,The perceptron : a probabilistic model for information storage and organization in the brain, Approximation by Superpositions of a Sigmoidal Function
-

-
- [28] Michael Rolland, Devoteam, 18 mai 2021, "Hébergement/ISP : Microsoft Azure Ireland – Building 3, Carmanhall Road, Sandyford Industrial Estate, Dublin 18, Ireland"
- [29] Barral, Jean-Pierre. "Approche ostéopathique du cerveau". Elsevier Health sciences, 2021.
- [30] Gaël Bonnardot, Datakeen, Feb 25, 2018 , " Deep Learning, Machine Learning, Statistics"
- [31] Alcyone Guillevic , 2016 , Les Echos Solution, 3-minutes-pour-comprendre-la-difference-entre-deep-learning-et-machine-learning-37147
- [32] TAIEB BADIS ,21 JUIN 2022, BLENT, CATEGORIE MACHINE LEARNING ,RESEAUX CONVOLUTIFS (CNN), DATA SCIENTIST
- [33] Intel.Fr. Retrieved May 26, 2024, from <https://www.intel.fr/content/www/fr/fr/internet-of-things/computer-vision/convolutional-neural-networks.html>
- [34] Alberto Diaspro, 05 January 2021,article Brain tumor detection and multi-classification using advanced deep learning techniques
- [35] M. Toğaçar, B. Ergen and Z. Cömert. (2019). BrainMRNet : Brain Tumor Detection using Magnetic Resonance Images with a Novel Convolutional Neural Network Model. *Medical Hypotheses*, 134. 109531.
- [36] 2022 Abdul Hannan Khan et al. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.
- [37] <https://ieeexplore.ieee.org/document/10034876>
- [38] P. Modiya and S. Vahora. (2022). Brain Tumor Detection Using Transfer Learning with Dimensionality Reduction Method. *International Journal of Intelligent Systems and Applications in Engineering*, 10(2), 201–206.
- [39] 2020 IEEE India Council International Subsections Conference (INDISCON)
- [40] X. Wu, R. Liu, H. Yang, and Z. Chen. (2020). An xception based convolutional neural network for scene image classification with transfer learning. in 2020 2nd international conference on information technology and computer application (ITCA), (pp. 262–267). IEEE.
- [41] S. Sarkar, A. Kumar, S. Chakraborty, S. Aich, J.-S. Sim, and H.-C. Kim. (2020). A CNN based approach for the detection of brain tumor using MRI scans. *Test Engineering and Management*, 83, 16580–16586.
- [42] S. Sarkar, A. Kumar, S. Chakraborty, S. Aich, J.-S. Sim, and H.-C. Kim. (2020). A CNN based approach for the detection of brain tumor using MRI scans. *Test Engineering and Management*, 83, 16580–16586.
- [43] Mandar Chandorkar, Researchgate.net. Retrieved May 26, 2024, from https://www.researchgate.net/figure/Repartition-des-donnees-entre-sous-ensemble-dentrainement-test-et-validation-De_fig14_330823454
-

- [44] python, Why. Python. Python Releases Wind, 2021.
- [45] TensorFlow : le framework de Machine Learning de Google -Data Science by Raphael Kassel- 7 Jan 2021-
- [46] NumPy : la bibliothèque Python la plus utilisée en Data Science by Raphael Kassel- 20 Avr 2021-
- [47] No title. (n.d.). Google.com. Retrieved May 26, 2024, from https://www.google.com/url?sa=trct=jq=esrc=ssource=webcd=ved=2ahUKEwiewyJi4sY6GAXohP0HHQLFC&usq=__Fusg=AOvVaw10gFdmfNAPTh98SPEvCoj0opi=89978449
- [48] Matplotlib for Python Developers - About dependencies [archive] », novembre 2009 (consulté le 22 janvier 2014)
- [49] "A Beginner's Guide to Kaggle for Data Science". MUO. 2023-04-17. Retrieved 2023-06-10.
- [50] Data Science, IA, Programmation / Par Henri Michel - 31 MARS 2022
- [51] <https://fr.wikipedia.org/wiki/LaTeX>
- [52] kaggle kernels pull abhranta/brain-tumor-detection-resnet50
- [53]