

**REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE**

UNIVERSITE MOULOUD MAMMERI DE TIZI-OUZOU

Faculté De Génie Électrique Et Informatique

Département : Génie Biomédical



Mémoire de fin d'étude

Master Académique

Filière : Génie Biomédical

Spécialité : Instrumentation Biomédical

Thème

Classification des images médicales cérébrales (affectée, non affectée) en utilisant les réseaux de neurones profonds

Soutenu le 30/06/2024

Réalisé par :

BOULKHIR Saida

AIT MOHAMMED Kahina

Devant le jury :

Président : M. BACHIR M'Hamed Saadi

MCB

UMMTO

Promoteur : M. CHELLI Takfarinas

MAA

UMMTO

Examineur : M. NAIT OUSLIMANE Ahmed

MCB

UMMTO

Année universitaire : 2023/2024

REMERCIEMENTS

Nous tenons à exprimer notre gratitude sincère à notre promoteur, M. CHELLI Takfarinas, pour sa disponibilité, ses conseils et son soutien précieux qui ont rendu ce travail possible.

Nous remercions également M. BACHIR M'Hamed Saadi, président du jury, et M. NAIT OUSLIMANE Ahmed, membre examinateur du jury, pour avoir accepté d'évaluer notre travail.

Enfin, nous remercions tous ceux qui ont contribué, de près ou de loin, à la réalisation de ce projet, en particulier les enseignants qui ont partagé leurs connaissances avec nous.

Dédicace

Je dédie ce mémoire à mon papa chéri, mon pilier, qui m'a toujours soutenu pendant tout ce temps. Je n'oublierai jamais les matins où il se levait tôt pour m'accompagner à mon stage. Papa, merci pour tout ce que tu fais pour moi.

Je remercie aussi ma maman adorée, qui m'a toujours aimée et soutenue, même dans les moments difficiles. Maman, merci pour tout ce que tu es.

Je n'oublie pas mes sœurs, Farida et Dyhia, qui m'ont toujours encouragée et aidée. Merci pour tout ce que vous faites pour moi.

À mes frères, Aghiles et Yacine, merci pour votre soutien et vos conseils. Vous avez toujours été là pour moi.

Enfin, je remercie mes amis, Hanane, Ania, Taw Taw, lycia, Anis et Fares, qui ont toujours été présents pour moi. Merci pour votre amitié. Je vous aime plus que les pizzas de « papa's pizza ».



SAIDA B

Dédicace

Je dédie ce mémoire à ma maman, mon papa adoré, qui m'ont toujours soutenues, même dans les moments difficiles. Maman, merci pour tout ce que tu es.

Je n'oublie pas mon grand-père, qui m'a toujours encouragé et aidé, Qui je souhaite une bonne santé.

A mes frères et sœurs. Merci pour tout ce que vous faites pour moi.

A ma famille, mes proches, oncles ,tantes et à ceux qui me donnent de l'amour vivacité.

Kahina A

Table des matières

Table des matières

<i>Remerciements</i>	i
<i>Dédicaces</i>	ii
Résumé	iii
Table des matières	iv
Liste des figures	vii
Liste des tableaux	ix

INTRODUCTION GENERALE 1

CHAPITRE I : CONTEXTE MEDICALE

1. Introduction.....	3
2. L'Anatomie cérébrale	3
2.1. Système nerveux central	3
2.2. Les principales substances du SNC	4
3. Tumeur.....	5
3.1. Type de tumeur cérébrale.....	6
3.2. La classification et le degré de tumeurs	7
3.3. Traitement de tumeurs	8
3.4. Diagnostique des tumeurs	8
4.Modalité d'imagerie Médicale	9
4.1. La tomodensitométrie ou le scanner TDM	9
4.2. Imagerie par Résonance Magnétique.....	9
5.Conclusion	19

CHAPITRE II : RESEAUX DE NEURONE ET DEEP LEARNING

1. Introduction.....	19
2. Machine Learning	19
2.1. Approches de l'apprentissage automatique	20
3. Réseaux de neurones artificiel	23
3.1. Neurone biologique.....	23
3.2. Neurone Artificiel (formel).....	24

Table des matières

3.3. Structure d'un neurone formel	25
3.4. Structure d'un réseau de neurones	27
3.5. Fonction d'activation	27
3.6. Fonctionnement des RNA.....	30
3.7. Forward propagation : La transposition.....	31
3.8. L'algorithme d'apprentissage par Rétro propagation	32
3.9. Fonction de coût.....	34
3.10. Descente du gradient.....	35
4. Deep Learning.....	36
4.1. Développement de deep Learning	36
4.2. Fonctionnement.....	38
4.3. Le développement de l'apprentissage profond	38
5. Deep Learning vs machine Learning	40
6. Création et entraînement des modèles de Deep Learning.....	41
7. Bibliothèques d'apprentissage profond	42
8. Conclusion	42

CHAPITRE III : ETAT DE L'ART

1. Introduction.....	43
2. Applications de l'apprentissage profond dans l'analyse d'images médicales	43
2.1. La détection.....	43
2.2. Segmentation.....	45
2.3. Classification.....	46
3. Exemple d'utilisation de l'apprentissage profond dans l'imagerie médicale	47
3.1. Radiographique	47
3.2. Tomodensitométrie (TDM).....	48
3.3. La mammographie (MG)	49
4. Apports du Deep Learning dans le diagnostic et le traitement des tumeurs cérébrales.....	52
5. Conclusion	56

CHAPITRE IV : IMPLIMENTATION, RESULTATS ET DISCUSSION

Table des matières

1. Introduction.....	58
2. Ressource	58
2.1. Kaggle Notebooks.....	58
2.2. Langage de programmation	59
2.3. Bibliothèque.....	59
2.4. La base donnée.....	60
3. Les réseaux de neurones convolutifs	60
3.1. Définition	60
3.2. Fonctionnement des CNN.....	61
3.3. Architecture CNN	61
3.4. Les architectures CNN performantes pour la classification deep Learning en imagerie médicale	64
4. Métrique d'évaluations	67
Accuracy and Loss	67
5. Les modèles implémentés	68
5.1. Modèle 1	68
5.2. Modèle 2	69
5.3. Modèle 3	71
5.4. Modèle 4	72
5.5. Modèle 5	73
6. Discussion des Résultats et Améliorations Futures	75
6.1. Analyse des Résultats	75
6.2. Améliorations Futures.....	76
7. Conclusion	77
 CONCLUSION GENERAL.....	78
Bibliographie	79

LISTE DES FIGURES

LIST DES FIGURES

Chapitre1

Figure 1 : Les lobes, gyrus et sillons du cerveau	5
Figure 2 : la formation des cellules cancéreuses.....	6
Figure 3 : représente les différentes type de tumeurs	7
Figure 4 : a quoi ressemble l'équipement IRM.....	10
Figure 5 : types d'aimant.....	11
Figure 6 : Bobine de gradient.....	12
Figure 7: antenne radiofréquence.....	12
Figure 9 : blindage de champ magnétique.....	14
Figure 10 : absence de champ, désordre dans la direction d'aimantation	14
Figure 11 : présence de champ B_0	15
Figure 12 : aimantation macroscopique	15
Figure 13 : activation de champ B_1	16
Figure 14 : M_z retrouve son état avec T_1	17
Figure 15 : M_{xy} décroît jusqu'à 0 de temps T_2	17
Figure 16 image réelle	18
Figure 17 : image IRM pondérée en T_1 et T_2	18

Chapitre2

Figure 1: diagramme des types de machine Learning	20
Figure 2 : la classification VS la régression.	21
Figure 3: la différence entre la classification et le clustering	22
Figure 4 : Diagramme schématisé du réseau de neurones	23
Figure 5 : structure d'un neurobiologique	24
Figure 6 : architecture d'un neurone formel	25
Figure 7 : structure d'un réseau de neurone.....	27
Figure 8 : La courbe de la fonction sigmoïde	28
Figure 9 : La courbe de la fonction ReLU	29
Figure 10 : La courbe de la fonction tangente hyperbolique.....	30
Figure 11: structure d'un réseau de neurone.....	31
Figure 12 architecture de rétropropagation	33
Figure 13 : structure de la descente de gradient	35

Figure 14:Machine Learning VS Deep Learning	41
Chapitre 3	
Figure 1: architecture CNN pour la détection	44
Figure 2:Architecture de modèle CNN pour la segmentation	46
Figure 3:schéma de la classification basé sur DL pour les images mammographique	47
Chapitre 4	
Figure 1 Synoptique de la méthode utilisée	58
Figure 2:Schéma d'une couche de convolution avec un noyau de taille 3*3 et un pas de 2.	62
Figure 3 : Exemple d'application de l'opération max pooling.....	63
Figure 4: Fonctionnement de la fonction ReLU	63
Figure 5:Exemple d'architecture d'un CNN	64
Figure 6 : Architecture d VGG-16.....	65
Figure 7 : architecture Inception et ces dérivées.....	66
Figure 8:Graphique de précision et de perte de la formation CNN	68
Figure 9:schéma de modèle 1	68
Figure 10: graphe loss and accuracy pour le modèle 1	69
Figure 11:schéma de modèle 2	70
Figure 12:graphe de la précision et de la perte pour le model 2.....	70
Figure 13:shéma de modèle 2	71
Figure 14:graphe de la précision et de la perte pour le model 3.....	72
Figure 15:schéma de quatrième modèle.....	73
Figure 16: les graphes de perte de précision pour le modèle 4	73
Figure 17: schéma de modèle 5	74
Figure 18:graphe de perte et précision de dernier model entrainer.....	75

Liste des tableaux

Liste des tableaux

Tableau 1: neurone biologique VS neurone formel.....	25
Tableau 2:Architecture, description brève et caractéristiques principales d'un modèle basé sur l'apprentissage profond (DL)	39
Tableau 3:Bibliothèques d'apprentissage profond disponibles.....	42
Tableau 4: travaux faites au cours des dix dernières années	50

LISTE DES ABREVIATIONS

Les abréviations

SNC système nerveux centrale

LCR Le liquide céphalo-rachidien

MG La matière grise

MB La substance blanche

TDM tomodensitogrammes

MRI imagerie par résonance magnétique

RMN La résonance magnétique nucléaire

RF radio fréquence

CT computed tomography

ANN artificiel neuronal network RNA réseaux de neurones artificiels

ReUL Rectified Linear Units

CNN Réseau de neurone convolutif

DNN les réseaux de neurones profonds

GPU unités de traitement graphique

DBN les réseaux de croyances profondes

RBM machines de Boltzmann restreintes

IA Intelligence artificiel

CAD diagnostic assisté par ordinateur

YOLO You Only Look Once

FCNN Fully Convolutional Neural Network

U-NET U-shaped Neural Network Architecture for Segmentation

R-CNN Region-based Convolutional Neural Network

Fast R-CNN Fast Region-based Convolutional Neural Network

MSS U-NET Multi-Scale Supervised U-Net

ACR American College of Radiology Breast Imaging Reporting and Data System

GBM Glioblastoma Multiforme

LGG Lower-Grade Glioma

ANFIS Adaptive Neuro-Fuzzy Inference Systeme

Introduction Générale

Introduction Générale

L'intelligence artificielle (IA) bouleverse de nombreux secteurs, et le domaine médical n'est pas en reste. Parmi ses applications prometteuses, la détection des tumeurs cérébrales se présente comme un défi majeur où l'IA peut jouer un rôle crucial. En effet, le diagnostic précoce et précis de ces tumeurs est essentiel pour la survie et la qualité de vie des patients.

L'analyse manuelle d'un grand nombre d'images d'IRM est devenue une tâche chronophage et fastidieuse pour les médecins, en raison de l'augmentation du nombre de patients à examiner. Cette charge de travail importante peut conduire à des erreurs de diagnostic. De plus, la variabilité des caractéristiques des tumeurs cérébrales rend leur détection difficile pour l'œil humain, nécessitant une grande expertise pour identifier les anomalies subtiles sur les images. Les méthodes d'imagerie traditionnelles comme l'IRM présentent également des limites pour le diagnostic précis des tumeurs, ne permettant pas toujours de distinguer avec certitude les tissus sains des tissus pathologiques. Enfin, le diagnostic précoce des tumeurs cérébrales, crucial pour le pronostic des patients, peut être manqué par les radiologues, soulignant le besoin d'une méthode d'analyse plus rapide et fiable. Cette technologie peut aider les médecins à détecter plus rapidement et avec précision les anomalies présentes sur les images, telles que les tumeurs cérébrales..

C'est là qu'on passe à la méthode des réseaux de neurones, qui est un sous-domaine de l'IA, entrent en jeu. Ces réseaux, inspirés du fonctionnement du cerveau humain, sont capables d'apprendre à partir de vastes quantités de données et de reconnaître des patterns complexes plus précisément. La conception des CNN qui est basée sur un modèle d'apprentissage profond, qui est particulièrement performant pour l'analyser des images de IRM et identifier des tumeurs avec une précision et une sensibilité accrues par rapport aux méthodes traditionnelles.

Pour cela nous avons organisé notre travail comme suit :

Le premier chapitre nous introduira d'abord l'anatomie du cerveau ainsi que les tumeurs cérébrales, nous présenterons leurs degrés et traitements, ensuite nous aborderons les modalités d'imagerie médicale (TDM) et le (RMN).

Le deuxième chapitre se consacre aux fondements théoriques des réseaux de neurones et du deep learning. Nous présenterons les concepts clés de ces technologies, tels que les

neurones artificiels, les couches cachées, les fonctions d'activation et les algorithmes d'apprentissage. Et expliqué également les principes du deep Learning et ses avantages par rapport aux modèles d'apprentissage automatique traditionnels.

Le troisième chapitre nous explorons l'état de l'art en matière de recherche sur l'application du deep learning à la détection des tumeurs cérébrales. Et présentée une revue critique des travaux antérieurs, en mettant l'accent sur les différentes architectures de réseaux de neurones convolutifs (CNN) utilisées et les résultats obtenus. on identifie également les défis et les perspectives de ce domaine de recherche en pleine expansion.

Le quatrième et dernier chapitre présente le travail original réalisé dans le cadre de ce projet. Il décrit en détail la conception et l'implémentation de modèles CNN spécifiques à la détection des tumeurs cérébrales. Il expose les choix méthodologiques effectués, les données utilisées et les résultats obtenus. Enfin, il discute des implications de ces résultats et propose des directions de recherche futures.

Chapitre 1

Contexte médical

1. Introduction

Dans ce chapitre, nous explorons les connaissances médicales essentielles pour aborder notre sujet de recherche sur les tumeurs cérébrales. Nous présentons en détail l'anatomie du cerveau ainsi que les pathologies spécifiques qui peuvent l'affecter, en mettant l'accent sur les tumeurs cérébrales. Nous décrivons les différents types de tumeurs, leur classification en termes de grade et les traitements associés. De plus, nous examinons le système d'imagerie le plus approprié pour les tissus mous du cerveau, en mettant en lumière son rôle crucial dans le diagnostic des tumeurs cérébrales et des autres pathologies, notamment l'IRM.

2. L'Anatomie cérébrale

2.1. Système nerveux central

Le système nerveux central (SNC), ou névraxe, se divise en quatre régions principales : la moelle épinière, le tronc cérébral, le cervelet et le cerveau. L'encéphale, qui se compose essentiellement de matière blanche, de matière grise et de liquide céphalo-rachidien, représente l'ensemble des parties du névraxe localisées dans la cavité crânienne, c'est-à-dire le tronc cérébral, le cervelet et le cerveau [1][2].

- **La moelle épinière** : La moelle épinière (ou spinale) est incluse dans la colonne vertébrale (ou rachis), qui la protège, mais elle n'occupe pas sa longueur totale : elle s'étend de la base du crâne à la première vertèbre lombaire. La moelle épinière est constituée de deux substances d'aspect différent : la substance grise en forme d'aile de papillon ou en "H", au centre, et la substance blanche,
- **Le tronc cérébral** : Le tronc cérébral, constituant le prolongement de la moelle épinière, représente un carrefour majeur du système nerveux central. Situé sous le cerveau et en avant du cervelet à l'intérieur de la colonne vertébrale.
- **Le cervelet** : Le cervelet est un centre nerveux régulateur de la fonction motrice, au sens large (mouvement + posture + équilibre). Il se compose de deux moitiés appelées hémisphères entourant une partie centrale appelée le vermis.
- **Le cerveau** : est la partie la plus volumineuse de l'encéphale, de la forme générale d'un ovoïde. Il est composé du télencéphale et du diencephale (ou cerveau intermédiaire). Le télencéphale est formé des deux hémisphères, droit et gauche, reliés par un pont de fibres nerveuses appelé corps calleux (Figure I). L'hémisphère droit du cerveau commande le côté gauche du corps tandis que l'hémisphère gauche commande le côté droit du corps. La surface des hémisphères présente de nombreux plis dont les plus profonds et les plus constants s'appellent sillons (anciennement scissures). Les

hémisphères sont divisés en quatre régions, les lobes : frontal, pariétal, temporal et occipital, délimités par trois sillons principaux : le sillon central, qui sépare le lobe frontal et pariétal. Le sillon latéral, qui sépare le lobe temporal et le lobe frontal. Le sillon occipital transverse ou pariéto-occipital, qui sépare le lobe pariétal et le lobe occipital [1][2].

2.2. Les principales substances du SNC

Dans le SNC, on distingue trois substances principales :

- **La matière grise (MG)** ; ou matière grise correspond aux corps cellulaires des neurones avec leur dense réseau de dendrites.

- Elle se répartit en : Une couche superficielle d'une épaisseur de quelques millimètres recouvrant le cerveau et le cervelet : le cortex.
- En noyaux profonds : les noyaux gris centraux.

- **La substance blanche** : la matière blanche (MB) correspond à la gaine de myéline qui recouvre les axones des neurones pour en accélérer la conduction. Les axones myélinisés s'assemblent en faisceaux pour établir des connexions entre groupes de neurones.

- **Le liquide céphalo-rachidien** : Le liquide céphalo-rachidien (LCR) (ou liquide cérébro-spinal, LCS) est le liquide dans lequel baignent le cerveau et le cervelet. D'un volume moyen de 150ml, il est absorbé par le système veineux cérébral et continuellement renouvelé. Ses principaux rôles sont : [2]

- La protection mécanique du système nerveux central contre les chocs par amortissement des mouvements.
- La protection contre les infections, car il contient les médiateurs de l'immunité humorale et cellulaire.

Le transport des hormones entre les différentes régions éloignées du cerveau




Figure 1 : Les lobes, gyri et sillons du cerveau [54]

Le schéma ci-dessus représente la subdivision des hémisphères par des sillons formant les lobes (frontal en avant, occipital en arrière, pariétal et temporal latéralement). Le lobe insulaire n'a pas été mentionné précédemment car celui-ci est particulier et complexe dont le rôle est encore mal connu.

3. Tumeur

Les tumeurs prennent naissance à partir de cellules qui subissent des modifications, les amenant à se multiplier de façon anormale plutôt que de mourir naturellement comme le font les cellules saines. Chaque type de cellule dans l'organisme, que ce soit les cellules musculaires, nerveuses, osseuses ou autres, a un rôle spécifique à jouer et une durée de vie limitée. Cependant, lorsque certaines cellules se modifient de manière inconnue, elles continuent à se diviser de manière excessive, formant ainsi une masse tumorale. Ce processus dérégulé de multiplication cellulaire est à l'origine du développement des différents types de tumeurs [3][4], qu'elles soient :

- Les tumeurs non cancéreuses, connues sous le nom de tumeurs bénignes, ont une croissance lente et demeurent localisées. Après traitement, elles ont généralement un faible risque de récurrence
- Les tumeurs cancéreuses, appelées tumeurs malignes, se développent rapidement et ont la propension à envahir des zones autres que leur site d'origine. Elles peuvent également donner naissance à de nouvelles tumeurs appelées métastases.




Figure 2 : la formation des cellules cancéreuses [53]

3.1. Type de tumeur cérébrale

Il existe de nombreux types de tumeurs cérébrales, qui peuvent être classées en fonction de leur origine, de leur localisation et de leurs caractéristiques histologiques. Voici quelques-uns des types les plus courants :

3.1.1. Tumeurs primitives du cerveau

Ces tumeurs se développent à partir des cellules du cerveau ou des tissus environnants. Elles représentent environ 95 % des tumeurs cérébrales. Les types les plus fréquents incluent :

- **Gliomes:** Ce sont les tumeurs cérébrales les plus communes, et elles se développent à partir des cellules gliales, qui soutiennent et protègent les neurones. Les gliomes sont classés en fonction de leur grade de malignité, allant de 1 (le moins agressif) à 4 (le plus agressif). Les glioblastomes (grade 4) sont les plus graves
- **Les méningiomes :** sont des tumeurs qui prennent naissance dans les méninges, les membranes entourant le cerveau et la moelle épinière. Bien que la plupart des méningiomes soient généralement bénins, ils peuvent parfois présenter un comportement agressif.
- **Neurinomes de l'acoustique :** Ces tumeurs se développent à partir du nerf vestibulo-cochléaire, qui est responsable de l'équilibre et de l'audition. Les neurinomes de l'acoustique sont généralement bénins, mais ils peuvent grossir et comprimer le nerf facial, provoquant des problèmes de paralysie faciale.
- **Les adénomes hypophysaires :** sont des tumeurs qui prennent origine dans l'hypophyse, une glande située à la base du cerveau. Ces tumeurs peuvent perturber la production

d'hormones essentielles, entraînant ainsi des complications liées à la croissance, à la thyroïde et à la reproduction

3.1.2. Tumeurs secondaires

Les tumeurs cérébrales secondaires ou métastatiques sont des cancers qui se sont propagés depuis un autre organe vers le cerveau. Elles proviennent de cellules cancéreuses qui se sont détachées d'un foyer primaire (poumon, sein, rein, peau, etc.) et ont atteint le cerveau via la circulation sanguine




Figure 3 : représente les différentes type de tumeurs [55]

3.2. La classification et le degré de tumeurs

Le degré d'agressivité d'une tumeur cérébrale est lié à sa vitesse de croissance. Plus une tumeur se développe rapidement, plus elle est considérée comme agressive.

La classification des tumeurs cérébrales par l'OMS est basée sur un système de grades, allant de I à IV. Les tumeurs de grade I et II sont considérées comme à croissance lente, tandis que les tumeurs de grade III et IV sont plus agressives et ont un pronostic plus sombre [12].

- **Les tumeurs de grade I** se développent lentement et ne se propagent pas rapidement. Elles sont associées à de meilleures chances de survie à long terme et peuvent être éliminées presque complètement par chirurgie. Exemple de tumeur de grade I : l'astrocytome pilotypique.

- **Les tumeurs de grade II** : se développent également lentement mais peuvent se propager aux tissus voisins et devenir des tumeurs de grade supérieur. Ces tumeurs peuvent même réapparaître après la chirurgie.
- **Les tumeurs de grade III** : se développent à un rythme plus rapide que le grade II et peuvent envahir les tissus voisins. La chirurgie seule est insuffisante pour de telles tumeurs, et une radiothérapie post-chirurgicale ou une chimiothérapie est recommandée.
- **Les tumeurs de grade IV** : sont les plus agressives et sont très propagules. Ils peuvent même utilise les vaisseaux sanguins pour une croissance rapide.

3.3. Traitement de tumeurs

Les traitements des tumeurs dépendent de divers facteurs tels que la taille de la tumeur, son grade, l'atteinte des ganglions lymphatiques et d'autres caractéristiques spécifiques de la tumeur. Les traitements courants incluent la chirurgie, la radiothérapie, l'hormonothérapie, la chimiothérapie, les thérapies ciblées, l'immunothérapie, les médicaments de soutien(corticothérapie), et les vaccins thérapeutiques anticancéreux. Ces traitements peuvent être utilisés seuls ou en combinaison pour supprimer la tumeur, réduire le risque de récurrence, ralentir la croissance tumorale, améliorer la qualité de vie du patient, et optimiser les chances de guérison [11].

3.4. Diagnostique des tumeurs

Généralement, c'est l'apparition des symptômes qui permet de suspecter la présence d'une tumeur du cerveau. Plusieurs étapes sont nécessaires pour déterminer l'origine des symptômes décrits et confirmer ou infirmer la présence d'une tumeur cérébrale [11]

3.4.1. Examen clinique et neurologique

L'examen clinique et neurologique est réalisé au cours d'une consultation médicale, soit par le médecin traitant, soit par un neurologue. Il consiste à évaluer l'état de santé général d'une part et le bon fonctionnement du système nerveux d'autre part. L'examen clinique et neurologique permet de constater d'éventuelles anomalies. Pour déterminer si ces anomalies sont dues à une tumeur ou non, des examens d'imagerie sont indispensables [11].[12]

3.4.2. Examen d'imagerie médical

Les examens d'imagerie consistent à réaliser des images précises du cerveau, afin de confirmer ou infirmer la maladie. En cas de résultat positif, Ils permettent de détecter une tumeur, de la localiser de façon précise, de mesurer sa taille et d'évaluer les conséquences qu'elle a ou peut avoir sur le cerveau. Pour le diagnostic d'une tumeur du cerveau, une IRM est indispensable. Pour des raisons pratiques, l'IRM est souvent précédée d'un scanner. L'IRM demeure la technique radiologique de choix. [11]

4.Modalité d'imagerie Médicale

4.1. La tomodensitométrie ou le scanner TDM

Peut aussi être utilisé vu qu'il est souvent plus rapide à obtenir qu'une IRM ce qui peut être un avantage dans certaines situations d'urgence. Les images de tomographie (TDM) fournissent des informations plus détaillées que les radiographies traditionnelles. La tomographie est largement recommandée et adoptée depuis son introduction. Aux États-Unis seulement, on dénombre environ 62 millions d'exams TDM par an, dont 4 millions pour les enfants. Les images tomographiques permettent de visualiser les tissus mous, les vaisseaux sanguins et les os de différentes régions du corps. Cependant, la tomographie utilise une dose de rayonnement plus élevée que les radiographies standard. Les tomographiques permettent de visualiser les tissus mous, les vaisseaux sanguins et les os dans diverses parties du corps humain, mais ils impliquent une exposition plus élevée aux rayonnements que les radiographies standard. Cette exposition accrue peut accroître le risque de cancer, notamment en cas de répétition fréquente des tomographiques. Les risques de cancer associés ont été évalués en fonction des doses de rayonnement des TDM [10][14].

4.2. Imagerie par Résonance Magnétique

L'imagerie par résonance magnétique (MRI), est une technique d'imagerie médicale révolutionnaire qui offre un regard sans précédent sur l'intérieur du corps humain. Cette technologie non invasive et totalement sûre utilise le principe de la résonance magnétique ,il a été découvert en 1945 par E.Purcell et F.Bloch il est utilisé pour générer des images détaillées des organes, des tissus et même des structures fines comme les vaisseaux sanguins et les nerfs le premier essai a été réalisé par Lauterbur en 1973 sur un animal et ils ont pu Améliorer des

techniques de recueil des signaux en intégrant des gradients de champ magnétique pour la formation des images.[5][13]

Au lieu de cela, l'IRM utilise des champs magnétiques puissants et des ondes radio pour exciter les atomes d'hydrogène présents dans les tissus. Ces atomes en résonance émettent ensuite des signaux qui sont captés par des antennes et transformés en images par ordinateur, la production de la première image d'un doigt était faite au cours des années 1973 au 1976.[5]




Figure 4 à quoi ressemble l'équipement IRM[5]

4.2.1. Composant d'un IRM

Les composants d'un IRM sont comme les suivants :

- ❖ **Aimant** : L'aimant est un composant essentiel de l'IRM, car il génère le champ magnétique B_0 statique nécessaire à l'alignement des noyaux d'hydrogène présents dans les tissus, permettant ainsi l'apparition de l'aimantation. Il existe différents types d'aimants, tels que les aimants permanents, les aimants résistifs et les aimants supraconducteurs [13]. Trois technologies d'aimants sont utilisées pour produire le champ magnétique B_0 dans lequel le patient est placé lors d'une IRM :
 - **Les aimants permanents** : fabriqués à partir de matériaux magnétisés de manière permanente, ils ne nécessitent ni électricité, ni cryogène, ni système de refroidissement

pour générer un champ magnétique. Cependant, leur principal inconvénient réside dans leur poids et leur limitation en intensité (0.3T).

- **Les électro-aimants résistifs** : composés de bobines de fil électrique, ils produisent un champ magnétique lorsqu'elles sont alimentées par un courant électrique. Leurs inconvénients majeurs sont leur forte consommation d'électricité, le champ magnétique maximum atteint à peine (0,5 T), nécessité de refroidissement car il est très sensible aux variations de température et parfois leur poids, notamment lorsqu'un noyau de fer est inséré pour augmenter l'intensité du champ magnétique. [13]
- **Les électro-aimants supraconducteurs** : ces aimants exploitent des matériaux supraconducteurs qui perdent leur résistance à des températures très basses, permettant ainsi d'augmenter l'intensité du champ magnétique produit et consommation d'énergie qu'est faible et permet d'obtenir une meilleure qualité d'image. Le principal inconvénient de cette technologie réside dans le coût associé à l'utilisation de cryogène, tel que l'hélium liquide.




Figure 5 types d'aimant[13]

❖ Bobines de gradient

Il s'agit de trois bobines métalliques enfermées dans un cylindre en fibres de verre et placées autour du tunnel de l'aimant, permettent d'établir la relation entre distance et fréquence de résonance à l'origine de la formation de l'image, On les nomme respectivement : bobine X, bobines-Y et bobine Z. Elles établissent un champ magnétique linéairement croissant dans une direction donnée, ce qui permet de localiser les signaux dans l'espace.



Figure 6 Bobine de gradient[13]

❖ Antenne

Ce sont des bobinages de cuivre, de formes variables, qui entourent le patient ou la partie du corps à explorer. Il existe 2 types d'antenne[13] :

- **Antenne Volumique** : au centre de laquelle est positionné le segment à examiner.




Figure 7: antenne radiofréquence

- **Antenne Surfactive** : est une antenne plane positionnée au contact de la région à explorer. Elle est réceptrice simple et donc ne permet pas de recevoir le signal restitué par les protons, Elle procure un très bon rapport signal sur le bruit dans la région d'intérêt

❖ Table d'examen

C'est une table mobile et permet de positionner le patient dans l'aimant. Elle peut être équipée de coussins et d'accessoires pour assurer le confort du patient.

❖ Blindage

En IRM, on parle de blindages pour certains dispositifs destinés au confinement des champs magnétiques produits par la machine et à l'isolement de celui-ci des champs magnétiques extérieurs qui viendraient perturber l'acquisition [13]. Il existe deux type de blindage :

- **Blindage des ondes radiofréquences** : Il est assuré par la cage de Faraday constituée d'un maillage de cuivre qui recouvre presque toutes les parois de la salle de l'aimant et étanche aux ondes R.F. Son rôle est d'empêcher les ondes R.F. intérieures produites par le système de sortir de la salle de l'aimant et empêcher les ondes R.F. extérieures produites par tout appareil électronique et objets métalliques en mouvement situés à l'extérieur de la salle [10].



Figure 8 blindage des ondes radiofréquence[13]

- **Blindage de champ magnétique** : Il a pour rôle de rapprocher les lignes de champ au plus près de l'aimant, il existe deux types :
 - **Un Blindage Passif** : ensemble de poutrelles d'acier ou de fer doux, entourant l'aimant. Ce dispositif est très lourd
 - **Un Blindage Actif** : c'est un bobinage métallique inversé placé aux deux extrémités du bobinage de champ principal B0




Figure 8 blindage de champ magnétique[13]

❖ Système informatique

Le système informatique est nécessaire pour le contrôle de l'acquisition et le calcul de l'image. Il permet de traiter les données recueillies par les différents composants de l'IRM et de produire une image de haute qualité.

4.2.2. Principe physique de IRM

L'imagerie par résonance magnétique (IRM) repose sur un certain nombre de principes physiques fondamentaux pour générer des images détaillées des tissus et organes du corps humain [6]

❖ Aimantation des électrons

Lorsque le patient est placé dans le champ magnétique puissant (B_0) de l'appareil IRM, les noyaux d'hydrogène (protons) présents dans son corps se comportent comme de petits aimants. À l'état de repos, ces protons ont un moment magnétique μ d'orientation aléatoire, ce qui fait que leur aimantation résultante est nulle $M_0 = 0$. Comme on le voit dans la figure suivante :




Figure 9 absence de champ, désordre dans la direction d'aimantation [14]

Cependant, sous l'effet du champ magnétique B_0 , les protons s'alignent dans la direction de ce champ (polarisation). Certains adoptent une orientation parallèle au champ [6], tandis que d'autres s'orientent dans le sens opposé, de manière antiparallèle [7]. Plus le champ est fort, plus l'aimantation M_0 est forte. Comme s'est présente dans la figure suivante :




Figure 10 présence de champ B_0 [14]

Cette différence d'orientation des protons crée une aimantation nette dans la direction du champ magnétique B_0 . C'est cette aimantation macroscopique M_0 des protons qui va être détectée et exploitée pour former les images en IRM.

De plus, le moment magnétique μ associé à cette aimantation macroscopique est animé d'un mouvement de précession autour de l'axe du champ magnétique B_0 , à la manière d'une toupie tournant autour de la verticale. La fréquence angulaire ω_0 de cette précession est proportionnelle à l'intensité du champ B_0 et est appelée "pulsation de Larmor"[8].




Figure 11 : aimantation macroscopique [14]

❖ La résonance magnétique nucléaire (RMN)

Le principe essentiel de la mesure en résonance magnétique nucléaire implique l'induction d'un mouvement de précession du moment magnétique μ autour d'un champ magnétique fixe

B_0 , suivi d'une perturbation temporaire de ce mouvement par l'application brève d'un champ magnétique B_1 . Cette perturbation modifie la trajectoire de μ , mais une fois que B_1 est éteint, le moment magnétique retrouve son mouvement initial en présence de B_0 uniquement. Ce processus de retour à l'équilibre s'accompagne de l'émission d'ondes électromagnétiques détectables, constituant ainsi le signal mesuré en RMN et IRM. Durant une expérience de RMN, on étudie un ensemble de spins nucléaires actifs, tels que les spins de protons, noyaux d'hydrogène, de spin $1/2$, largement utilisés en RMN et IRM. [16]

Sous l'influence du champ magnétique statique B_0 , les moments μ effectuent une précession autour de l'axe de B_0 à une fréquence propre μ_0 , formant ainsi une aimantation M alignée avec B_0 . Ensuite, l'application d'un champ B_1 alternatif, perpendiculaire à B_0 et de fréquence de résonance, déplace l'aimantation M autour de l'axe de B_1 . Après avoir pivoté dans le plan perpendiculaire à B_0 , l'extinction du champ B_1 entraîne le retour à l'équilibre de l'aimantation M en présence de B_0 seul, accompagné de l'émission d'ondes électromagnétiques détectables, constituant ainsi le signal distinctif de la RMN [16]




Figure 12 activation de champ B_1

❖ Phénomène de Relaxation

Lorsque l'impulsion RF est interrompue, le système tend à retrouver progressivement son état d'équilibre initial. Ce phénomène est appelé la relaxation, qui se comporte deux en composantes distinctes :

- **La relaxation longitudinale T1 (ou spin-réseau) :** caractérisée par le temps de relaxation T1 qui dépend du tissu $\frac{dM_z}{dt} = \frac{(M_z - M_0)}{T_1}$ et $M_z(t) = \left(M_0 - e^{-\frac{t}{T_1}} \right)$

Celui-ci représente le temps nécessaire pour que l'aimantation longitudinale M_z récupère 63% de sa valeur initiale M_{z0} [13][14].




Figure 13 : M_z retrouve son état avec T1[14]

- **La relaxation transversale T2 (ou spin-spin) :** caractérisée par le temps de relaxation T2 avec $\frac{dM_{xy}}{dt} = -\frac{M_{xy}}{T_2}$ et $M_{xy}(t) = \left(M_0 e^{-\frac{t}{T_2}} \right)$

Ce temps correspond au délai requis pour que l'aimantation transversale M_{xy} ne représente plus que 37% de sa valeur initial[13][14].




Figure 14 : M_{xy} décroît jusqu'à 0 de temps T2 [14]

Ainsi, lorsque l'impulsion RF s'arrête, l'aimantation longitudinale M_z , qui était devenue nulle, recommence à croître pour retrouver sa valeur de départ M_{z0} . Par Contre l'aimantation transversale M_{xy} diminue rapidement pour tendre vers zéro. Les temps de relaxation T1 et T2 sont des paramètres caractéristiques des différents tissus biologiques. Leur mesure permet

d'obtenir un contraste entre ces tissus dans les images en imagerie par résonance magnétique (IRM).




Figure 15 image réelle [4]




Figure 16 : image IRM pondéré en T1et T2 [4]

5. Conclusion

Dans ce chapitre, nous avons initié notre discussion en abordant l'anatomie du cerveau et les tumeurs cérébrales, en définissant ces notions, leurs degrés, leur diagnostic et leur traitement. Ensuite, nous avons présenté les modalités d'imagerie utilisées pour le diagnostic de ces tumeurs, notamment l'imagerie par résonance magnétique (IRM) et la tomодensitométrie (TDM). Il est important de noter que nous nous sommes principalement concentrés sur les différentes notions liées à l'imagerie par résonance magnétique car notre base de données est composée d'images IRM .

Chapitre 2

Réseaux de neurones et deep Learning

1. Introduction

L'interprétation manuelle des images IRM est souvent longue, chaotique et peut être erronée. Cependant, un praticien expérimenté peut reconnaître instantanément certaines pathologies, comme des tumeurs cérébrales, et poser un diagnostic. Cette capacité à identifier rapidement des anomalies est le fruit de l'expérience et de l'expertise du praticien. En revanche, pour une machine, la classification de telles lésions à partir d'images médicales nécessite généralement beaucoup de données d'entraînement et de temps de calcul.

C'est ici qu'intervient le deep Learning (DL), un domaine de l'intelligence artificielle (IA) et de la vision par ordinateur, qui a révolutionné les performances des systèmes de classification automatiques. Les réseaux de neurones artificiels (RNA), inspirés du fonctionnement du cerveau humain, font partie des outils les plus performants dans ce domaine. [17]

Dans ce chapitre, nous allons explorer les principes des réseaux de neurones artificiels et du deep Learning. Nous commencerons par expliquer le concept des neurones biologiques et comment les(RNA)cherchent à les imiter. Nous détaillerons ensuite le fonctionnement général des réseaux de neurones, ainsi que les principes clés du (DL).

2. Machine Learning

Machine Learning (ML), ou apprentissage automatique en français, est une sous branche de (IA) qui s'inspire des mécanismes d'apprentissage humain.

Contrairement à la programmation traditionnelle où les instructions sont explicites, l'apprentissage automatique permet aux machines d'améliorer progressivement leurs performances par l'analyse et l'exploitation de données. Le ML, qui utilise beaucoup les maths et les stats, peut facilement être représenté de façon mathématique.

En gros, un modèle de machine learning est comme une boîte noire qui calcule une réponse à partir d'informations qu'on lui donne. La partie importante, c'est de trouver la bonne façon de calculer cette réponse. C'est ce qu'on appelle l'apprentissage. Une fois qu'on a trouvé la bonne façon de calculer, on peut s'en servir pour prédire de nouvelles réponses. C'est ce qu'on appelle l'inférence. [18]

2.1. Approches de l'apprentissage automatique

Au cœur de ce domaine se trouve une multitude d'algorithmes, chacun se distinguant par son objectif spécifique. Une répartition des types courants de Machine Learning est illustrée dans le diagramme suivant




Figure 1:diagramme des types de machine Learning

2.1.1. L'apprentissage supervisé

L'apprentissage supervisé se réfère à une famille d'algorithmes de (ML) dont les données d'apprentissage englobent simultanément des valeurs de caractéristiques et des valeurs d'étiquettes au sein d'observation passées. L'objectif ultime est de pouvoir prédire les étiquettes inconnues associées aux caractéristiques de cas futurs.

En d'autres termes, l'apprentissage supervisé fonctionne comme un apprentissage par l'exemple. L'algorithme analyse un ensemble de données existantes, où les caractéristiques et les résultats sont déjà connus. À partir de cette base de connaissances, l'algorithme peut classifie des patterns et déduire des règles. Il peut ensuite utiliser ces règles pour prédire les résultats pour de nouvelles observations, dont seules les caractéristiques sont connues [19]

Et avec ce type d'apprentissage, on peut résoudre des tâches telles que la classification et la régression [19] .

➤ La classification

L'objectif est d'apprendre à prédire la catégorie à laquelle appartient une nouvelle instance, en se basant sur un ensemble d'exemples étiquetés. En d'autres termes, on souhaite apprendre une fonction qui mappe les caractéristiques d'une instance à une étiquette de classe. et on distingue deux catégories de classification :

- Classification binaire : Il s'agit du cas le plus simple où il n'y a que deux classes possibles. Par exemple, spam ou non-spam, malade ou non-malade
- Classification multiclasse : Il y a plus de deux classes possibles. Par exemple, prédire l'espèce d'une fleur parmi plusieurs espèces possibles

Et parmi les algorithmes de classification les plus utilisés sont le **K-plus proches voisins (KNN)**, **Support Vector Machines (SVM)** son objectif est de trouver l'hyperplan qui maximise la marge entre les deux classes, la **régression linéaire** et on a aussi les **réseaux de neurones profonds**. [20]

➤ La régression

La régression est un autre type d'apprentissage supervisé où l'objectif est de prédire une valeur numérique continue, plutôt qu'une catégorie.[20] En d'autres termes, on souhaite apprendre une fonction qui mappe les caractéristiques d'une instance à une valeur numérique, et parmi les types de régression on cite la **régression linéaire**, la **régression polynomiale** et la **régression sigmoïde**.

Et pour les algorithmes connus utilisés pour la régression, **Moindres carrés ordinaires (OLS)**, **Régression par gradient descendant** et les **reseaux de neurones profonds**.




Figure 2 :la classification VS la régression.[20]

2.1.2. L'apprentissage non supervisé

L'apprentissage non supervisé est utilisé lorsque le problème nécessite une quantité massive de données non étiquetées. Par exemple, les applications de médias sociaux, telles que Twitter, Instagram et Snapchat, contiennent toutes de grandes quantités de données non étiquetées. Comprendre la signification de ces données nécessite des algorithmes qui classent les données en fonction des modèles ou des clusters qu'elles trouvent.

L'apprentissage non supervisé mène un processus itératif, analysant les données sans intervention humaine. Il est utilisé avec la technologie de détection du spam par courrier électronique. Il y a beaucoup trop de variables dans les e-mails légitimes et les spams pour qu'un analyste puisse marquer les e-mails en masse non sollicités. Au lieu de cela, des classificateurs d'apprentissage automatique, basés sur le regroupement et l'association, sont appliqués pour identifier les courriers électroniques indésirables. [19]

➤ Le clustering

Est une technique d'apprentissage automatique non supervisé. Contrairement à la classification et à la régression qui font partie de l'apprentissage supervisé, le clustering ne dispose pas d'étiquettes prédéfinies pour les données.

En d'autres termes, on fournit au clustering un ensemble de données non étiquetées et l'objectif est de regrouper ces données en fonction de leurs similarités. Ces groupes, appelés clusters (ou segments), rassemblent des instances (points de données) qui partagent des caractéristiques communes

Les algorithmes courants utilisés pour le clustering sont **k-means**, **Clustering par densité** et, **Clustering hiérarchique**.




Figure 3: la différence entre la classification et le clustering[19]

3. Réseaux de neurones artificiels

Les réseaux de neurones artificiels (ANN) s'inspirent du fonctionnement du cerveau humain pour apprendre et analyser des données. Ils constituent la base de la plupart des méthodes de Deep Learning et s'appuient sur des opérations mathématiques simples et de l'algèbre linéaire avancée.

Un réseau neuronal est composé de plusieurs couches qui traitent les données. Chaque couche est constituée de neurones interconnectés à la couche suivante, et ces connexions sont définies par des poids numériques. Chaque couche possède également un biais, un neurone supplémentaire avec une valeur numérique fixe. Lorsque des données entrent dans le réseau par la couche d'entrée, elles sont transformées au fur et à mesure qu'elles traversent les couches suivantes. Chaque couche effectue des calculs mathématiques sur les données qu'elle reçoit et transmet les résultats à la couche suivante. Ce processus se poursuit jusqu'à ce que les données atteignent la couche de sortie, qui produit le résultat final du réseau neuronal.[21] [22]




Figure 4 : Diagramme schématique du réseau de neurones [21]

3.1. Neurone biologique

Le cerveau humain est un organe d'une complexité stupéfiante, composé d'environ 100 milliards de cellules nerveuses appelées neurones. Ces neurones sont organisés en un réseau dense et interconnecté, qui permet au cerveau de réaliser des prouesses cognitives

extraordinaires. Les deux tiers de ces neurones forment un le cortex, une couche de 4,6 cm d'épaisseur située à la surface du cerveau, est responsable de nos capacités cognitives supérieures. Il est composé de neurones qui traitent et envoient des messages électriques et chimiques, codant l'information sous forme de signaux d'intensité variable. [20]

Les neurones communiquent entre eux par des synapses, des points de jonction qui permettent la transmission des messages d'un neurone à l'autre. La force de la synapse peut être modifiée en fonction de l'activité des neurones, ce qui permet au cerveau d'apprendre et de s'adapter. L'information est traitée de manière distribuée dans le cerveau. Cela signifie qu'une information n'est pas stockée dans un seul neurone, mais dans un ensemble de neurones qui travaillent ensemble. Cette redondance permet au cerveau de mieux résister aux dommages et de maintenir ses capacités cognitives.

Le fonctionnement du cerveau est encore loin d'être entièrement compris. Cependant, les scientifiques découvrent chaque jour de nouveaux secrets de cet organe fascinant, qui nous permet de penser, de sentir et d'agir. [20]




Figure 5 : structure d'un neurobiologique [20]

3.2. Neurone Artificiel (formel)

Un neurone formel, parfois appelé neurone de McCulloch-Pitts, est un modèle mathématique simple inspiré du fonctionnement des neurones biologiques du cerveau. On peut le considérer comme la brique élémentaire qui compose les réseaux de neurones artificiels (RNA). Ces réseaux, utilisés dans de nombreux domaines de l'intelligence artificielle,

apprennent et traitent l'information en mimant de manière simplifiée le fonctionnement du cerveau humain. [23]




Figure 6 : architecture d'un neurone formel[23]

3.3. Structure d'un neurone formel

La structure et la modélisation des réseaux de neurones artificiels consiste à transposer les principes biologiques du neurone dans un cadre mathématique et informatique. Cela suppose d'établir une correspondance entre les différents éléments constitutifs du neurone biologique et leur représentation dans le neurone artificiel.

Le tableau 1 résume cette analogie entre le neurone biologique et le neurone formel (artificiel) .

Tableau 1: neurone biologique VS neurone formel

Neurone biologique	Neurone formel
Synapses	Poids des connexion
Axones	Signal de sorti
Dendrites	Signal d'entrée
Noyau	Fonction d'activation

- **Entrées multiples** : Un neurone formel reçoit des informations provenant d'autres neurones sous la forme de valeurs numériques X_i . Ces valeurs représentent l'activité des neurones "parents".
- **Sommation pondérée** : Chaque entrée est associée à un poids w qui représente son importance relative. Le neurone formel effectue ensuite la somme pondérée de toutes ces valeurs d'entrée.
- **Fonction d'activation** : Le résultat de la sommation pondérée est ensuite passé par une fonction d'activation. Cette fonction introduit une non-linéarité dans le modèle, permettant au neurone de ne pas se contenter de transferts d'information passifs. En fonction du type de fonction d'activation utilisée, la sortie du neurone peut être binaire (0 ou 1) ou continue (entre une valeur minimale et une valeur maximale).
- **Sortie unique** : La sortie du neurone formel est une valeur unique calculée à partir de la fonction d'activation. Cette valeur représente l'activité du neurone et est envoyée à d'autres neurones du réseau en tant qu'entrée.
- **Poids et biais** (valeurs numériques) : Les poids et biais sont des variables du modèle qui sont mises à jour pour améliorer la précision du réseau. Un poids est appliqué à l'entrée de chacun des neurones pour calculer une donnée de sortie. Les RNA mettent à jour ce poids de manière continue. Il existe donc une boucle de rétro-action mise en oeuvre dans la plupart des réseaux de neurones. Les biais sont également des valeurs numériques qui sont ajoutées une fois que les poids sont appliqués aux valeurs d'entrée. Les poids et les biais sont donc en quelque sorte des valeurs d'auto-apprentissage de nos RNA

Mathématiquement, le modèle du neurone artificiel consiste en une somme pondérée des entrées, à laquelle est ajouté un biais, le tout étant transformé par une fonction d'activation pour produire la sortie du neurone, indiqué dans l'équation (1).

$$Z = \sum_{i=1}^n X_i . W_{ii} + b \dots\dots(1)$$

Cette représentation matricielle permet de capturer les principes fondamentaux du fonctionnement du neurone biologique dans un cadre formel.

3.4. Structure d'un réseau de neurones

- Couche d'entrée : Ensemble des neurones qui prennent une donnée d'entrée (X_i) et produisent une donnée de sortie. Le nombre de neurones dans la couche d'entrée correspond au nombre de feature des données
- Couches Caché (groupement de neurones) : Les couches (hidden layers) contiennent des neurones sont responsable de l'apprentissage et aident à faire circuler l'information, Il existe au moins deux couches dans un réseau de neurones successives
- Couche de sortie : elle produit le résultat final du réseau neuronal




Figure 7 :structure d'un réseau de neurone[55]

3.5.Fonction d'activation

Comme vu précédemment, le résultat de la somme des inputs pondérées et du biais, est soumis en entrée à une fonction, appelée fonction d'activation qui est simplement une fonction qui est appliquée à la somme pondérée d'un neurone. Elle est utilisée pour déclencher ou non le neurone ou pour le rendre actif ou non, en d'autres termes est-ce que ma sortie est égale à 1 ou 0(Un exemple de fonction d'activation est la fonction de Heaviside qui renvoie tout le temps 1 si elle est activée, 0 si elle n'est pas activée. [24]

3.5.1. Fonctionnement

- **Calcul de la sortie brute :** Le neurone calcule d'abord une valeur brute, généralement une somme pondérée de ses entrées.
- **Application de la fonction d'activation :** La fonction d'activation est ensuite appliquée à cette valeur brute pour obtenir la sortie finale du neurone.
- **Propriétés :** La fonction d'activation est souvent non linéaire, ce qui permet au réseau de modéliser des relations complexes entre les variables. Elle peut également borner la sortie du neurone dans un intervalle défini. [24]

3.5.2. Type de fonction d'activation

Il existe une grande variété de fonctions d'activation utilisées dans les réseaux de neurones. Parmi les plus courantes, on trouve :

➤ Sigmoid

Est une fonction continue, différentiable et non linéaire. La sortie de la fonction Sigmoid est comprise entre 0 et 1. A cet effet, la fonction est utilisée pour prédire une probabilité notamment dans la classification. Son expression mathématique est (2) :

$$f(x) = \frac{1}{(1+e^{(-x)})} \dots \dots (2)$$




Figure 8 : La courbe de la fonction sigmoid [55]

➤ ReLU

(Rectified Linear Units) désigne la fonction réelle non-linéaire très utilisée dans le DL elle est définie par l'expression mathématique [29] suivante :

$$fRelu(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$$

Cette fonction remplace toutes les valeurs négatives reçues en entrées par des zéros.




Figure 9 :La courbe de la fonction ReLU [55]

➤ Tanh

La fonction de la tangente hyperbolique notée tanh est similaires à la fonction Sigmoidé, celle-ci a une sortie comprise entre -1 et 1 , la tanh est exprimée par l'équation(3) :

$$ftanh(x) = \tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} \dots\dots\dots(3)$$




Figure 10 :La courbe de la fonction tangente hyperbolique[55].

➤ Softmax

Cette fonction est très utilisée pour la classification et souvent c'est la couche de sortie qui porte cette fonction d'activation. Si n est le nombre de neurones de la couche Softmax et $j \in \{1, \dots, n\}$, alors son expression

$$fsoftmax(x_j) = \frac{e^{x_j}}{\sum_{i=1}^n e^{x_i}} \dots\dots\dots(5)$$

3.6.Fonctionnement des RNA

Définissons maintenant le principe de fonctionnement d'un réseau de neurone en représentant les grandes étapes réalisées lors l'utilisation de ce réseau, On attribue à chaque neurone constituant le réseau un coefficient qu'on appelle poids. [25]

Chaque donnée d'entrée (input) va être multipliée par ce coefficient et on va appliquer une fonction d'addition à l'ensemble des résultats. Cette fonction est appelée fonction de combinaison ou fonction de pré-activation.

Cette fonction est toujours la même, elle est définie par la formule (6) :

$$Z = \sum (x_i * w_i) + b \quad \dots\dots\dots(6)$$

Avec x_i : la donnée en entrée.

w_i : le poids

b : le biais.

Puis on va appliquer une fonction d'activation, en comparant la somme obtenue à un seuil déterminé. Si la somme est en dessous du seuil (souvent dans le cas où la somme est négative), le neurone ne s'active pas, ce qui signifie que la donnée n'est pas intéressante. Si cette somme est au-dessus du seuil (souvent dans le cas où la somme est positive), alors le neurone s'active et envoie l'information au neurone de la couche suivante (couches cachées), jusqu'à ce que la donnée ultime atteigne le dernier neurone. On aura alors un résultat final (output).




Figure 11: structure d'un réseau de neurone[25]

3.7. Forward propagation : La transposition

La propagation directe, aussi appelée "forward pass" en anglais, est une étape fondamentale dans le processus d'apprentissage des réseaux de neurones artificiels (RNA). Elle consiste à calculer la sortie du réseau pour une entrée donnée, en simulant le flux d'informations à travers les différentes couches du réseau. (26)

On se donne de quelle on désire faire passer une matrice comme suivant (7):

$$Z^1 = \begin{bmatrix} W_{11}^1 & W_{12}^1 \\ W_{21}^1 & W_{22}^1 \\ W_{31}^1 & W_{32}^1 \end{bmatrix} * \begin{bmatrix} X_1^{(1)} & X_1^{(2)} & X_1^{(m)} \\ X_2^{(1)} & X_2^{(2)} & X_2^{(m)} \end{bmatrix} + \begin{bmatrix} b_1^1 \\ b_2^1 \\ b_3^1 \end{bmatrix} = \begin{bmatrix} Z_1^{1(1)} & \dots & Z_1^{1(m)} \\ Z_2^{1(1)} & \dots & Z_2^{1(m)} \\ Z_3^{1(1)} & \dots & Z_3^{1(m)} \end{bmatrix} \quad \dots\dots\dots(7)$$

Pour calculer les éléments de la première couche nous allons commencer par calculer Z^1 comme suivant équation (8) :

$$Z^1 = W^1.X.b^1 \dots\dots\dots(8)$$

et puis cette matrice sera utilisée par une fonction d'activation (équation 9), afin d'en déduire les sorties

$$A^1 = \frac{1}{e^{(-Z^1)}+1} \dots\dots\dots(9)$$

Et pour calculer les éléments de la deuxième couche fallait prendre la sortie de la première et l'injecter dans la formule de l'entrée de deuxième. Les sorties de la couche d'entrée deviennent les entrées de la couche suivante, et le processus se répète jusqu'à atteindre la dernière couche cachée du réseau. Chaque couche cachée applique le même principe de multiplication pondérée, suivies par l'application de la fonction d'activation équation (9):

$$Z^2 = W^2.A^1.b^1 \text{ Avec } A^2 = \frac{1}{e^{(-Z^2)}+1}$$

$$Z^3 = W^3.A^2.b^3 \text{ Avec } A^3 = \frac{1}{e^{(-Z^3)}+1}$$

Après l'obtention de la fonction de sortie de réseau on va passer à une autre étape qui s'appelle la fonction de coût.

3.8.L'algorithme d'apprentissage par Rétro propagation

Une percée dans notre capacité à construire et à entraîner des réseaux neuronaux artificiels (ANN) plus complexes à plusieurs couches est survenue en 1986, lorsque Rumelhart et al. ont introduit la méthode de rétropropagation de l'erreur. Cette méthode repose sur la différentiation des fonctions de transfert (d'où la fonction d'erreur à minimiser est également différentiable) et sur la recherche d'un minimum local de la fonction d'erreur par la méthode de descente de gradient la plus raide. [26]




Figure 12 architecture de rétropropagation [26]

Commençons calculer le dérivé de la fonction de coût par rapport à la fonction d'activation puis celle de l'activation par rapport à $W^{(1)}$ et après $b^{(2)}$ et à $W^{(2)}$ et à $b^{(2)}$ comme suivant :

Calcul des dérivées partielles :

En partant de la couche de sortie, on calcule récursivement les dérivées partielles en remontant dans les couches cachées.

1). dZ^2 :

$$\frac{\partial E}{\partial W^2} = \frac{\partial E}{\partial A^2} * \frac{\partial A^2}{\partial Z^2} * \frac{\partial Z^2}{\partial W^2}$$

$$\frac{\partial E}{\partial b^2} = \frac{\partial E}{\partial A^2} * \frac{\partial A^2}{\partial Z^2} * \frac{\partial Z^2}{\partial b^2}$$

2). dZ^1 :

$$\frac{\partial E}{\partial W^1} = \frac{\partial E}{\partial A^2} * \frac{\partial A^2}{\partial Z^2} * \frac{\partial Z^2}{\partial A^1} * \frac{\partial A^1}{\partial Z^1} * \frac{\partial Z^1}{\partial W^1}$$

$$\frac{\partial E}{\partial b^1} = \frac{\partial E}{\partial A^2} * \frac{\partial A^2}{\partial Z^2} * \frac{\partial Z^2}{\partial A^1} * \frac{\partial A^1}{\partial Z^1} * \frac{\partial Z^1}{\partial b^1}$$

On commence par dZ^2 , calculons la dérivée partiels (10)

$$dZ^2 = \frac{1}{m} \sum \left(\frac{y^2}{A^2} + \frac{1-y}{1-A^2} \right) * A^2(1-A) \quad (10)$$

On va simplifier $dZ^2 = \frac{1}{m} \sum (-y(1 - A^2) + 1 - y(A^2))$ (11)

Et on l'équation finale est $dZ^2 = \frac{1}{m} \sum (-y + A^2)$

$$dZ^2 = A^2 - y$$

Avec $dZ^2 = \frac{\partial E}{\partial A^2} * \frac{\partial A^2}{\partial Z^2}$

$$\rightarrow \begin{cases} \frac{\partial E}{\partial W^2} = dZ^2 * \frac{\partial Z^2}{\partial W^2} \\ \frac{\partial E}{\partial b^2} = dZ^2 * \frac{\partial Z^2}{\partial b^2} \end{cases}$$

Passons maintenant a $dZ^1 = \frac{\partial E}{\partial W^1} = \frac{\partial E}{\partial A^2} * \frac{\partial A^2}{\partial Z^2} * \frac{\partial Z^2}{\partial A^1} * \frac{\partial A^1}{\partial Z^1}$

$$dZ^1 = dZ^2 * \frac{\partial Z^2}{\partial A^1} * \frac{\partial A^1}{\partial Z^1}$$

$$\rightarrow \begin{cases} \frac{\partial E}{\partial W^1} = dZ^1 * \frac{\partial Z^1}{\partial W^1} \\ \frac{\partial E}{\partial b^1} = dZ^1 * \frac{\partial Z^1}{\partial b^1} \end{cases}$$

Une fois les dérivées partielles calculées, on met à jour les poids et les biais en utilisant une règle de la descente de gradient .

3.9.Fonction de coût

La fonction de coût, aussi appelée "loss function" en anglais, est un élément crucial dans l'apprentissage des réseaux de neurones artificiels (RNA). Elle permet d'évaluer la performance du réseau en mesurant l'écart entre sa sortie prédite et la valeur cible attendue. En d'autres termes, elle quantifie l'erreur du réseau pour une entrée donnée voire équation (12).

$$\mathcal{L} = -\frac{1}{m} \sum y \log(A^{(1)}) + (1 - y) \log(1 - A^1) \dots\dots\dots(12)$$

On prend la sortie de réseaux qu'on a obtenue et on l'injecte dans la formule de glosse ce qui retourne les erreurs de notre modèle.

➤ Fonctionnement

- Calcul de l'erreur : Pour chaque entrée, la fonction de coût compare la sortie prédite du réseau par la propagation directe à la valeur cible attendue (souvent appelée "label"). La différence entre la sortie et la cible représente l'erreur du réseau pour cette entrée.

- Agrégation des erreurs : La fonction de coût ne se contente pas de mesurer l'erreur pour une seule entrée. Elle agrège généralement les erreurs de toutes les entrées d'un ensemble d'apprentissage afin d'obtenir une mesure globale de la performance du réseau. Cette agrégation peut se faire par somme simple, par moyenne, ou par d'autres techniques plus sophistiquées.
- Minimisation de la fonction de coût : L'objectif principal de l'apprentissage des RNA est de minimiser la fonction de coût. Cela signifie que l'on cherche à ajuster les paramètres du réseau (poids et biais) de manière à réduire l'erreur globale et à rapprocher les sorties du réseau des valeurs cibles attendues.

3.10. Descente du gradient

Maintenant que nous avons couvert la propagation avant et arrière, passons à la descente de gradient (Rumelhart, Hinton et Williams 1986), une méthode de calcul fondamentale dans l'apprentissage des réseaux de neurones. Cette méthode mathématique ajuste les poids et les biais des neurones afin de minimiser une fonction de coût, comme nous l'avons vu précédemment lors de la rétropropagation. Visuellement, on peut imaginer les neurones comme des curseurs pouvant être tournés dans une direction ou dans l'autre. La descente de gradient stochastique ajuste les poids et les biais en fonction du gradient et d'un hyperparamètre appelé "learning rate" ou taux d'apprentissage.




Figure 13 :structure de la descente de gradient[5]

Un réseau de neurones contient des millions de poids et donc autant de dimensions, mais le principe reste le même. Chaque poids est mis à jour selon la formule (13)

$$W_i = W_i - \alpha \frac{\partial J}{\partial W_i} \dots\dots\dots(13)$$

où W_i représente le poids,

α le taux d'apprentissage

$\frac{\partial J}{\partial W_i}$ le gradient

$$W^2 = W^2 - \alpha \frac{\partial E}{\partial W^2} ; \quad b^2 = b^2 - \alpha \frac{\partial E}{\partial b^2}$$

$$W^1 = W^1 - \alpha \frac{\partial E}{\partial W^1} ; \quad b^1 = b^1 - \alpha \frac{\partial E}{\partial b^1}$$

4. Deep Learning

L'apprentissage profond, un domaine essentiel de l'apprentissage automatique, se caractérise par sa capacité à utiliser des architectures de réseaux neuronaux artificiels multicouches, s'inspirant du fonctionnement des neurones du cerveau humain. Ces réseaux, appelés réseaux neuronaux profonds, sont structurés en plusieurs couches de neurones interconnectés, où chaque couche traite et extrait des caractéristiques complexes des données en amont.

Cette hiérarchie de couches permet une représentation progressive et abstraite des informations, favorisant ainsi une compréhension approfondie des structures et des motifs des données. Parmi les nombreuses applications du deep learning, on peut citer les voitures autonomes, qui utilisent des réseaux neuronaux pour interpréter les données des capteurs et prendre des décisions en temps réel, ainsi que la traduction linguistique et le traitement du langage naturel, où les modèles de deep learning sont utilisés pour analyser et générer du texte avec une précision et une fluidité accrue. [27]

4.1. Développement de deep Learning

Depuis son apparition en 2006, l'apprentissage profond s'est imposé comme un nouveau domaine de recherche en apprentissage automatique. En quelques années seulement, ses

techniques ont révolutionné de nombreux champs du traitement du signal et de l'information, tant dans les domaines traditionnels que dans les plus récents, influençant également des aspects clés de l'apprentissage automatique et de l'intelligence artificielle.

L'engouement pour l'apprentissage profond dans le domaine du traitement du signal et de l'image se traduit par une multitude d'événements et de publications spécialisés. Ateliers, tutoriels et numéros spéciaux de conférences se consacrent à l'exploration des applications et des progrès de l'apprentissage profond dans divers domaines, tels que la reconnaissance de la parole, la vision par ordinateur et l'analyse multimédia. Parmi les exemples notables, on peut citer: [29]

- Atelier NIPS 2008 sur l'apprentissage profond
- Atelier NIPS 2009 sur l'apprentissage profond pour la reconnaissance de la parole et les applications connexes
- Atelier ICML 2009 sur l'apprentissage de hiérarchies de caractéristiques
- Atelier ICML 2011 sur les architectures d'apprentissage, les représentations et l'optimisation pour le traitement de l'information audio-visuelle
- Tutoriel ICASSP 2012 sur l'apprentissage profond pour le traitement du signal et de l'information
- Atelier ICML 2012 sur l'apprentissage de représentations
- Section spéciale 2012 sur l'apprentissage profond pour le traitement de la parole et du langage dans les transactions IEEE sur l'audio, la parole et le traitement du langage (T-ASLP, janvier)
- Ateliers NIPS 2010, 2011 et 2012 sur l'apprentissage profond et l'apprentissage non supervisé de caractéristiques
- Ateliers NIPS 2013 sur l'apprentissage profond et sur l'apprentissage de représentations de sortie
- Numéro spécial 2013 sur l'apprentissage d'architectures profondes dans les transactions IEEE sur l'analyse et la machine intelligence (T-PAMI, septembre)
- Conférence internationale 2013 sur les représentations d'apprentissage
- Atelier ICML 2013 sur les défis de l'apprentissage de représentations
- Atelier ICML 2013 sur l'apprentissage profond pour l'audio, la parole et le traitement du langage
- Session spéciale ICASSP 2013 sur les nouveaux types d'apprentissage de réseaux neuronaux profonds pour la reconnaissance de la parole et les applications connexes

4.2. Fonctionnement





Le deep learning repose sur un réseau de neurones artificiels qui s'inspire du fonctionnement des neurones biologiques du cerveau humain. Avec l'ajout de chaque nouvelle information, les connexions entre les neurones s'étendent et se modifient, ce qui permet au système d'apprentissage profond d'apprendre de nouvelles choses en autonomie. Il améliore également ses prévisions et ses prises de décision sans aucune intervention humaine. Cette capacité à apprendre de ses propres erreurs est une caractéristique unique du deep learning .

4.3. Le développement de l'apprentissage profond

Un réseau de neurones artificiels (ANN) avec plus de couches cachées offre une grande capacité d'extraction de caractéristiques. Cependant, un ANN converge souvent vers un optimum local, ou rencontre une diffusion du gradient lorsqu'il contient des structures profondes et complexes. Un gradient propagé vers l'arrière diminue rapidement en magnitude le long des couches, entraînant une légère modification des poids dans les couches proches de l'entrée. Par la suite, un réseau pré-entraîné couche par couche d'encodeurs auto-associatifs (AE) profonds a été proposé, amenant les ANN à une nouvelle étape de développement .Dans ce réseau, chaque couche est entraînée en minimisant l'écart entre les données d'origine et les données reconstruites .Le pré-entraînement couche par couche brise la barrière de la diffusion du gradient ,et conduit également à un meilleur choix des poids pour les réseaux de neurones profonds (DNN), empêchant ainsi les données reconstruites d'atteindre un optimum local, généralement causé par la sélection aléatoire des poids initiaux. De plus, l'utilisation des unités de traitement graphique (GPU) a également renouvelé l'intérêt des chercheurs pour l'apprentissage profond. [29]

Avec une attention et des efforts plus importants, l'apprentissage profond a connu une forte croissance ces dernières années et a été largement appliqué dans l'industrie. Par exemple, les réseaux de croyances profondes (DBN) et les piles de machines de Boltzmann restreintes (RBM) , ont été appliqués à la reconnaissance de la parole et des images [29], et au traitement du langage naturel . Proposés pour mieux imiter la perception des objets par les animaux, les réseaux de neurones convolutifs (CNN) ont été largement appliqués à la reconnaissance d'images, à la segmentation d'images, à la reconnaissance vidéo et au traitement du langage naturel. Les réseaux de neurones récurrents (RNN) constituent une autre classe d'ANN qui présentent un comportement dynamique, avec des neurones artificiels associés à des pas de temps. Les RNN sont devenus l'outil principal pour traiter les données séquentielles et ont été appliqués au traitement du langage naturel et à la reconnaissance de l'écriture manuscrite. [29]

Tableau 2: Architecture, description brève et caractéristiques principales d'un modèle basé sur l'apprentissage profond (DL)[29]

Architecture des modèles basés sur le deep learning	Description brève	Caractéristiques clés
 Input layer Hidden layer 1 Hidden layer N Output layer	Réseau de neurones profond • Cadre généralisé du modèle de deep Learning • Largement applicable pour les modèles de classification et de régression • Composé de plus de 2 couches cachées	Avantages • Largement utilisé avec un taux de réussite élevé dans différents domaines Inconvénients • Le processus d'apprentissage est très lent
 Input layer Hidden layer 1 Hidden layer N Output layer	Autoencodeur profond • Principalement utilisé pour l'extraction de caractéristique et la réduction de la dimensionnalité de l'espace. • Il a le même nombre de nœuds d'entrée et de sortie • Types d'apprentissage non supervisé	Avantage • Pas besoin de données étiquetées • de nombreuses versions modifiées d'autoencodeurs conçues en fonction des besoins Inconvénients • La formation peut être sujette à des erreurs
 Output stream Memory Input stream	Réseau neuronal récurrent (RNN) Un réseau de neurones ayant la capacité d'analyser un flux de données Partage le même poids pour chaque étape. Très utile lorsque la sortie dépend des résultats précédents.	Avantage Peut mémoriser des événements séquentiels Bonne réponse dans le domaine du traitement du langage naturel Inconvénient Problèmes d'apprentissage dus au problème du gradient
 Conv2D + ReLU Conv2D + ReLU Fully connected maxpool maxpool Output Input Image Convolutional layer 1 Convolutional layer 2 Classification	Réseau de neurones convolutif CNN Ce modèle est adapté aux données 2D Conçu selon le fonctionnement des neurones humaine. Chaque couche cachée de filtres transforme son entrée en volume de sortie 3D pour l'activation des neurones	Avantage Peu de connexions neuronales requises par rapport à un réseau de neurones classique De nombreuses variantes ont été proposées comme Alex Net, Google Net, etc. Inconvénient Il nécessite un grand ensemble de données étiquetées

5. Deep Learning vs machine Learning

Le deep Learning et le machine Learning sont deux domaines de l'intelligence artificielle qui présentent des différences notables. Le machine Learning est la technologie la plus ancienne et la plus simple. Elle repose sur un algorithme qui adapte le système en fonction des retours fournis par l'humain. La mise en place de cette technologie nécessite l'existence de données organisées. Le système est ensuite alimenté par des données structurées et catégorisées, ce qui lui permet de comprendre comment classer de nouvelles données similaires. En fonction de ce classement, le système exécute ensuite les actions programmées. Par exemple, il peut identifier si une photo montre un chien ou un chat et classer le document dans le dossier correspondant.

En revanche, le deep Learning ne nécessite pas de données structurées. Le système fonctionne à partir de plusieurs couches de réseaux neuronaux, qui combinent différents algorithmes en s'inspirant du cerveau humain. Cette approche est particulièrement adaptée pour les tâches complexes, lorsque tous les aspects des objets à traiter ne peuvent pas être catégorisés en amont. Avec le deep Learning, le système identifie lui-même les caractéristiques discriminantes des données, sans avoir besoin d'une catégorisation préalable. Le système n'a pas besoin d'être entraîné par un développeur. Il évalue lui-même le besoin de modifier le classement ou de créer des catégories inédites en fonction des nouvelles données.

Le deep learning nécessite un volume de données bien plus considérable pour donner des résultats fiables, contrairement au machine learning qui fonctionne à partir d'une base de données contrôlable. Une IA à apprentissage profond possède également la capacité à apprendre en toute autonomie à un IA à apprentissage, ce qui nécessite l'intervention humaine.

Le deep learning est un sous-domaine du machine learning, mais il présente des caractéristiques uniques qui le rendent particulièrement adapté pour les tâches complexes et les données non structurées. Il permet une analyse plus approfondie des données et une meilleure compréhension des relations entre les différentes caractéristiques. Cependant, le machine learning reste une technologie importante pour les tâches de classification simples et les données structurées [30] .




Figure 14:Machine Learning VS Deep Learning [30]

6. Création et entraînement des modèles de Deep Learning

Les trois méthodes les plus répandues dans la classification d'objets avec le processus du Deep Learning sont :

- **L'entraînement à partir de zéro** : Entraîner un réseau profond à partir de zéro exige un volume important de données étiquetées et la conception d'une architecture de réseau capable d'apprendre les caractéristiques et le modèle. Bien que cette méthode soit adaptée aux nouvelles applications, elle n'est pas très répandue en raison de la grande quantité de données et du rythme d'apprentissage, qui peuvent entraîner une durée de formation allant de plusieurs jours à plusieurs semaines. [31]
- **Apprentissage par transfert (Transfer Learning)** : La méthode d'apprentissage par transfert est la méthode la plus utilisée dans les applications de deep learning. Elle consiste à mettre à jour un modèle pré-entraîné en utilisant un réseau existant, tel que ResNet, Inception ou LeNet, et en enrichissant ce réseau avec de nouvelles données contenant des classes auparavant inconnues du réseau. Cette méthode présente l'avantage de nécessiter un volume de données beaucoup plus faible, ce qui réduit le temps de calcul à seulement quelques heures ou minutes. [31]
- **Extraction de caractéristiques** : Cette approche implique l'utilisation du réseau de neurones comme extracteur de caractéristiques. Chaque couche du réseau est chargée d'apprendre des caractéristiques spécifiques à partir des images en entrée, ce qui permet de récupérer ces caractéristiques à tout moment du processus d'entraînement. Ces caractéristiques extraites sont ensuite utilisées comme données d'entrée pour des modèles

de Machine Learning tels que les arbres de décision, les forêts aléatoires ou les machines à vecteurs de support (SVM). [31]

7. Bibliothèques d'apprentissage profond

Jusqu'à présent, divers packages d'apprentissage profond comme Caffe, CNTK, Deeplearning, TensorFlow, Torch, Keras ont été développés pour fonctionner sur les systèmes d'exploitation Linux, Win, OSX, Android en utilisant les interfaces C/C++, MATLAB, Python, Java, Clojure, Lua, LuaJIT, Scala. Les modèles pris en charge par ces packages sont DBN, RNN et CNN. Parmi ces modèles, seul Neon prend en charge les fonctionnalités de cloud computing. Les bibliothèques d'apprentissage profond disponibles, la plate-forme prise en charge, l'interface et les modèles sont donnés dans le tableau 1. (29)

Tableau 3::Bibliothèques d'apprentissage profond disponibles

Name	Supported platform	Interface	Supported models			Clouding computing
			DBN	RNN	CNN	
Caffe	Linux, Android, Win, OSX	C++, MATLAB, Python	X	✓	✓	X
CNTK	Linux, Win	Command-Line	X	✓	✓	X
Deeplearning4j	Linux, Android, Win, OSX	Java, Scala, clojure	✓	✓	✓	X
TensorFlow	Linux, OSX	Python	✓	✓	✓	X
Torch	Linux, Android, Win, OSX, Ios	C, Lua, LuaJIT	✓	✓	✓	X
Keras	Linux, Win, OSX	Python	✓	✓	✓	X
Neon	OSX, Linux	Python	✓	✓	✓	✓

8. Conclusion

Dans ce chapitre, nous avons d'abord introduit les différentes classes du machine Learning, notamment l'apprentissage supervisée, non supervisée et par renforcement. Nous avons ensuite présenté les concepts fondamentaux des réseaux de neurones et de l'apprentissage profond (deep Learning). Nous avons expliqué le fonctionnement d'un neurone artificiel et sa relation avec un neurone biologique, l'initialisation des poids, les différents types de fonctions d'activation, ainsi que la fonction d'erreur et la fonction de sortie. Nous avons également abordé la rétro propagation du gradient et l'optimisation par descente de gradient. Enfin, nous avons examiné en détail le deep Learning, son fonctionnement et son développement récent.

Chapitre 3

Etat de l'art

1. Introduction

Les avancées rapides dans le domaine de l'apprentissage profond ont transformé l'analyse des images médicales, offrant ainsi des solutions innovantes pour la détection, la segmentation et la classification des anomalies médicales. L'une des applications les plus prometteuses est la classification des tumeurs cérébrales. Grâce à des réseaux de neurones profonds, les systèmes d'apprentissage automatique peuvent désormais extraire des caractéristiques complexes des images médicales, facilitant ainsi une interprétation plus précise et plus rapide.

Ce chapitre explore les travaux récents et les innovations dans ce domaine, en mettant en lumière les différentes méthodes et approches utilisées pour améliorer la précision et l'efficacité des systèmes de classification et de détection des tumeurs cérébrales.

2. Applications de l'apprentissage profond dans l'analyse d'images médicales

Les images médicales se distinguent des autres types d'images par la sensibilité des informations qu'elles contiennent, utilisées principalement pour l'interprétation clinique et le diagnostic. Un défi majeur est de préserver ces informations pendant le traitement ou l'acquisition des images.

L'apprentissage profond a révolutionné l'extraction des caractéristiques pertinentes dans les images médicales. Les réseaux de neurones profonds peuvent combiner plusieurs couches pour apprendre à extraire des caractéristiques de plus en plus abstraites à partir des données brutes. Cela facilite l'apprentissage et permet de construire une représentation de haut niveau du contenu de l'image, ce qui rend ces architectures très puissantes pour des tâches complexes comme l'analyse d'images médicales.

L'apprentissage profond a de nombreuses applications en imagerie médicale, notamment pour la détection, la segmentation et la classification des éléments d'intérêt dans les images. Ces applications sont intégrées dans les systèmes d'aide au diagnostic assisté par ordinateur, fournissant aux médecins des diagnostics précis en analysant rapidement et automatiquement les images. [32 ,33].

2.1 La détection

La détection d'objets est une étape clé du traitement d'images, combinant classification et localisation. Elle consiste à détecter les instances d'objets sémantiques dans une image, en dessinant des boîtes englobantes autour des objets et en leur attribuant une

étiquette de classe. La performance des modèles de détection d'objets est évaluée en utilisant la précision et le rappel pour les objets identifiés dans l'image (voir figure1)[34] [35] .

Il existe de nombreuses architectures de détection d'objets en apprentissage profond très populaires, comme R-CNN, Fast R-CNN, Faster R-CNN et YOLO. R-CNN, proposé par Ross Girshick en 2014, est l'une des premières applications réussies de CNN pour la détection d'objets. Il se compose de trois blocs : proposition de régions, extraction de caractéristiques et classification. Wenyan Li a montré que l'utilisation de R-CNN pour la prédiction multitâche permet d'intégrer des informations contextuelles supplémentaires, améliorant ainsi les performances.

Fast R-CNN, une variante de R-CNN en termes de vitesse, a été proposée par Girshick en 2015. En 2016, Shaoqing Ren a apporté des améliorations supplémentaires en termes de vitesse d'entraînement et de précision de détection. Dans les modèles R-CNN et Fast R-CNN, la détection d'objets s'effectue en deux étapes : identification des zones potentielles puis classification. Pour optimiser ce processus gourmand en ressources, Faster R-CNN supprime cette étape de recherche sélective et laisse le réseau apprendre directement les propositions de régions. [36] [37]

Les modèles You Only Look Once (YOLO) sont beaucoup plus rapides que R-CNN, atteignant même la détection en temps réel. Contrairement aux travaux antérieurs, YOLO encadre la détection comme un problème de régression et effectue la détection et la classification en un seul passage. Le modèle de base souffre d'erreurs de localisation mais apprend des représentations générales des objets. Il existe diverses variantes de YOLO améliorant encore la précision et la vitesse, comme YOLOv2 qui ajoute une normalisation par lots et traite des images de plus haute résolution. Le principal défi de ces méthodes est de minimiser les faux positifs tout en maximisant les vrais positifs. [38]




Figure 1: architecture CNN pour la détection [44]

2.2 Segmentation

Le prochain pas dans le traitement d'images est la segmentation d'images. Il s'agit d'une tâche complexe en traitement d'images, nécessitant des algorithmes précis et efficaces sur le plan computationnel. Il existe de nombreuses applications de la segmentation d'images médicales, comme la segmentation des tumeurs cérébrales avec extraction des contours dans les coupes IRM, la détection du cancer dans les scanners CT des poumons, la segmentation de la zone affectée dans les radiographies thoraciques, et ainsi de suite. L'apprentissage profond a été largement utilisé pour la segmentation d'images médicales, et de nombreux articles ont été publiés documentant les progrès de cette technologie dans ce domaine (figure2) .

Nous mentionnons ici quelques applications de ces architectures dans le domaine médical. Un exemple concret est la segmentation sémantique des tumeurs cérébrales, réalisée grâce à une architecture CNN à deux voies innovante introduite par Mohammad Havaei en 2017. Cette approche permet d'extraire à la fois des informations fines sur des zones spécifiques du cerveau et des informations contextuelles à plus grande échelle, améliorant ainsi la précision de l'analyse. Et aussi ils ont conçu une architecture CNN pour la segmentation des tissus cérébraux dans les images IRM .

Basé sur l'architecture FCN, Zhang et al. ont proposé en 2017 une segmentation du foie dans les scanners CT. Et Christ et al. en 2016, ont conçu une architecture FCN en cascade pour la segmentation du foie, puis le résultat final de segmentation est fourni en utilisant un champ aléatoire conditionnel 3D dense.

La segmentation du tissu mammaire en utilisant uniquement l'apprentissage profond a été mise en œuvre avec succès par Sun en 2019, qui a développé une architecture d'apprentissage profond pour la segmentation du cancer gastrique montrant l'avantage d'utiliser conjointement des modules multi-échelle et des opérations de convolution

spécifiques. La figure 3 montre que le réseau U-Net est le plus couramment utilisé pour la segmentation.




Figure 2: Architecture de modèle CNN pour la segmentation [45]

2.3 Classification

La classification est l'étape finale du traitement d'images médicales, essentielle pour fournir un diagnostic précis. La qualité de la classification dépend de toutes les étapes précédentes du traitement d'images, ainsi que des modèles de classification utilisés. La classification d'images est un problème d'apprentissage supervisé qui consiste à définir un ensemble d'étiquettes cibles, puis à entraîner un modèle à les reconnaître dans de nouvelles images d'entrée. La précision de la classification est cruciale pour l'interprétation clinique et le diagnostic médical. [34]

Il existe deux stratégies de transfert d'apprentissage : Utiliser un réseau pré-entraîné comme extracteur de caractéristiques et affiner un modèle pré-entraîné sur de nouvelles données.

Antony et al. (2016) ont utilisé le transfert d'apprentissage pour entraîner un CNN en tant que modèle de fine-tuning sur des données médicales, obtenant une précision de 57,6% dans l'évaluation du grade de l'arthrose du genou, contre 53,4% pour la stratégie d'extraction de caractéristiques.

Cependant, Kim et al. (2016) ont montré le contraire, indiquant qu'utiliser un CNN pré-entraîné comme extracteur de caractéristiques surpassait la stratégie de fine-tuning dans la classification d'images de cytopathologie, atteignant 70,5% contre 69,1% de précision.

Bien qu'il puisse être déroutant de choisir entre les deux stratégies, Kornblith et al. (2019) ont montré qu'en utilisant un modèle pré-entraîné comme extracteur, on ne peut pas obtenir de meilleurs résultats qu'en affinant le modèle. Ils ont affiné Inception v3 pré-entraîné sur des données médicales et ont presque atteint les performances d'experts humains.

Shen et al. (2015) ont réalisé une classification des nodules pulmonaires en s'appuyant sur un CNN multi-échelle, traitant chaque patch de nodule à différentes échelles avant de combiner les sorties. Une approche similaire a été utilisée par Kawahara et Hamarneh (2016) pour la classification des lésions cutanées.

Enfin, le traitement d'images médicales 3D a été étudié, comme par Nie et al. (2016) qui ont entraîné un CNN 3D sur des images IRM 3D pour classifier les gliomes de haut grade.




Figure 3:schéma de la classification basé sur DL pour les images mammographique [46]

3. Exemple d'utilisation de l'apprentissage profond dans l'imagerie médicale.

Pour l'acquisition des organes du corps humain, il existe diverses options, selon le type d'organe acquis et la qualité de l'acquisition. Les modalités les plus utilisées dans la pratique médicale sont la tomodensitométrie (CT), l'imagerie par résonance magnétique (IRM), mammographie et la radiographie. Chacune d'entre elles a sa propre manière d'obtenir les informations sur l'organe.

3.1. Radiographique

La radiographie du thorax est largement utilisée pour le diagnostic afin de détecter les pathologies cardiaques et les maladies pulmonaires telles que la tuberculose le pneumothorax. Les radiographies sont accessibles, abordables et moins irradiantes que les autres méthodes d'imagerie, et constituent un outil puissant pour le dépistage de masse. [40]

On cite quelques exemples de l'utilisation de deep Learning dans les images de radiographie, prenons l'exemple de S. Hwang et al. Qui ont proposé le premier système de dépistage de la tuberculose basé sur un réseau de neurones convolutifs profonds avec une technique d'apprentissage par transfert. Rajaraman lui, il a proposé un apprentissage par ensemble spécifique à la modalité pour la détection d'anomalies dans les radiographies pulmonaires (CXR). Les prédictions de ces modèles sont combinées en utilisant diverses techniques d'ensemble pour minimiser la variance de prédiction.

Waheed et al. ont proposé un modèle Covid GAN basé sur le réseau antagoniste génératif à classificateur auxiliaire (ACGAN) pour produire des images CXR synthétiques pour la détection du COVID-19. S. Rajaraman et S. Antani ont introduit une augmentation des données faiblement étiquetées pour augmenter l'ensemble de données d'entraînement afin d'améliorer les performances de détection du COVID-19 dans les images CXR. (voir tableau 1).

3.2. Tomodensitométrie (TDM)

CT utilise des ordinateurs et des équipements à rayons X rotatifs pour créer des images en coupe transversale du corps. Les tomodensitogrammes montrent les tissus mous, les vaisseaux sanguins et les os de différentes parties du corps. La tomodensitométrie a une capacité de détection élevée, révèle de petites lésions et fournit une évaluation plus détaillée. Les examens tomodensitométriques sont fréquemment utilisés pour l'identification des nodules pulmonaires.[40]

Masood et al. ont proposé le réseau entièrement convolutif multidimensionnel basé sur les régions (mRFCN) pour la détection/classification des nodules pulmonaires et ont atteint une précision de classification de 97,91%. Dans la détection des nodules pulmonaires, le travail de référence est la détection des micronodules (moins de 3 mm) sans perte de sensibilité et de précision.

Zhao et Zeng 2019 ont proposé DLA basé sur MSS U-Net et 3DU-Net supervisés pour segmenter automatiquement les reins et les tumeurs rénales à partir d'images TDM.

Dans la situation pandémique 2020, Fan et al. Et Li et al ont utilisé des techniques basées sur l'apprentissage profond pour la détection du COVID-19 à partir d'images TDM. (voir tableau 1).

3.3. La mammographie (MG)

Le cancer du sein figure parmi les principales causes de décès chez les femmes atteintes de cancer à l'échelle mondiale. La mammographie est un outil fiable et la méthode la plus répandue pour la détection précoce du cancer du sein. La détection du cancer du sein lors du dépistage par mammographie présente des défis en raison de la petite taille des tumeurs par rapport à l'image complète du sein. L'analyse des lésions mammaires à partir de la mammographie implique trois étapes : la détection, la segmentation et la classification. [41]

Au cours de la dernière décennie, l'apprentissage profond a montré des avancées significatives dans la détection et la classification du cancer du sein. Le tableau 4 résume les dernières avancées de l'apprentissage profond dans l'étude de l'analyse d'images de mammographie.

Fonseca et al, ont proposé une classification de la composition mammaire selon la norme ACR basée sur un CNN pour l'extraction de caractéristiques. Wang et al ont proposé un CNN à 12couches pour détecter les calcifications artérielles mammaires (BACs) dans les images de mammographie pour l'évaluation du risque de maladie coronarienne. Ribli et al ont développé un système CAD basé sur FasterRCNN pour la détection et la classification des lésions bénignes et malignes sur une image de mammographie sans aucune intervention humaine. Wu et al ont présenté un CNN profond formé et évalué sur plus de 1 000 000 d'images de mammographie pour la classification des examens de dépistage du cancer du sein. Conant et al. ont développé un système d'IA basé sur un CNN profond pour détecter les lésions calcifiées et les tissus mous dans les images de tomosynthèse mammaire numérique (DBT). Kang et al. ont introduit une architecture de couche complètement connectée floue (FFCL), qui se concentre principalement sur la fusion de règles floues avec un CNN traditionnel pour le score sémantique BI-RADS. Le cadre FFCL proposé a obtenu des résultats supérieurs dans le score BI-RADS pour les classifications à la fois triple et multi-classes.

Riddle et al.ont proposé le modèle Faster R-CNN pour la détection des lésions mammographiques et ont classé ces lésions en bénignes et malignes, ce qui leur a valu la deuxième place du Digital Mammographie DREAM Challenge (voir tableau 1).

Tableau 1: travaux faites au cours des dix dernières années [44]

Description	méthode	basedonné
Modèles CNN pré-entraînés (MG-CNN) pour la classification des masses : Huych 2016	CNN	607 Digital MG images(219 breast lesions)
Détection des maladies cardiovasculaires basée sur la calcification des vaisseaux.:Wang2017	Deep CNN	840standard screening FFDMs
CNN profond multi-vues pour le dépistage du cancer du sein et la résolution d'image sur la précision des prédictions. Geras 2017	MV-CNN	Screening mammograms images 129, 208
Méthodes d'augmentation des données et d'apprentissage par transfert avec un CNN pour la classification. Zhang 2017	CNN	3000 MG images
CNN profond pour la classification de la densité mammaire:Wu 2017	CNN	200,000 Breast cancer screening Exams
CNN basé sur l'apprentissage profond pour la classification de la densité mammaire mammographique	ResNet-18	41,479 Mammogram images
DIB-MG est un apprentissage supervisé faible. DIB-MG apprend des caractéristiques radiologiques sans annotations humaines Kim 2018	DIB-MG	29,107 Digital MG (24,765 normalcases and 4339 cancer cases)
CNN détecte et classe les lésions malignes ou bénignes sur les images de MG :Ribli. 2018	FasterR-CNN VGG16	DDSM (2620),INbreast (115),Private database
Stratégie d'apprentissage par transfert et de fine-tuning basée sur CNN pour classer les lésions de masse de la MG. :Chougrad.2018	VGG16, ResNet50 Inceptionv3	Inceptionv3 MIAS,DDSM, INbreast, BCDR
Réseau neuronal profond (DNN) en tant que modèle de classification pour les données sur le cancer du sein :Karthik. 2018	DNN-RFS	WBCD

CNN profond pour la discrimination des microcalcifications pour le dépistage du cancer du sein.:Cai 2019	DCNN	990 MG images,540 Malignant masses, and 450 benign lesions
Classificateur de dépistage du cancer du sein basé sur CNN :Wu 2019	DCNN	1000 000 images
Estimation de la densité mammaire et notation du risque Ionescu 2019	CNN	Private data set
- Détection de nodules dans la TDM thoracique avec des modèles CNN pré-entraînés à partir de patches orthogonaux autour du candidat /Van Ginneken 2015	CNN	LIDC (865 CTscans)
-Classification des nodules avec un CNN 2D qui traite de petits patches autour d'un nodule :Li. 2016	CNN	LIDC database.
-Algorithmes basés sur CNN pour la détection de nodules pulmonaires avec 9 patches par candidat :Setio 2016	Multi-vieux CovNet	LIDC-IDRI, ANODE09
-Classification des maladies interstitielles pulmonaires (ILD) et détection des ganglions lymphatiques (LN) en utilisant des CNN basés sur l'apprentissage par transfert /Shin 2016	CNN	ILD dataset
- Les caractéristiques discriminatives des nodules dans les images de TDM et de TEP sont combinées en utilisant la méthode de fusion pour la classification des nodules /Qiang, Yan 2017	Deep SDAE-ELM	Independent dataset
- CNN entraîné par GAN de Wasserstein pour la classification des nodules pulmonaires :Onishi Y 2019	CNN	Independent Dataset

H-Dense UNet pour la segmentation des tumeurs et du foie à partir du volume de TDM /Li2018	H-Dense Unet	2017 LiTS,3DIRCADb dataset
- Classification du type de cancer du poumon à partir d'images de TDM en utilisant le réseau DenseNet /Pang et al. 2020	CNN (DanseNet)	Shandong Provincial Hospital
Classification et détection de nodules pulmonaires en utilisant un système d'aide à la décision automatisé basé sur mRFCN /Masood et al.2020	mREFCN	LIDC
- 3D U-Net supervisé multi-échelle pour segmenter simultanément les reins et les tumeurs rénales à partir d'images de TDM	3D-UNet	KiTS19 challeng
- Réseau neuronal de détection du COVID-19 (COVNet) utilisé pour la reconnaissance du COVID-19 à partir d'examens volumétriques de TDM thoracique /Li et al. 2020	COVNet	4356ChestCT images

4. Apports du Deep Learning dans le diagnostic et le traitement des tumeurs cérébrales

Au cours des dix dernières années, le Deep Learning a bouleversé le paysage du diagnostic des tumeurs cérébrales. En analysant des images médicales complexes avec une précision et une efficacité inégalée, les algorithmes de Deep Learning ont permis d'améliorer la détection et la classification des tumeurs cérébrales. L'impact du Deep Learning sur le diagnostic des tumeurs cérébrales a été considérable. Les recherches menées dans ce domaine ont donné naissance à une multitude d'approches innovantes [42] , tel que :

Un système de diagnostic assisté par ordinateur pour la classification des gliomes développer par I. NJEH et al en 2014. Ce système comporte plusieurs étapes : d'abord, un prétraitement qui élimine les caractéristiques extra-cérébrales, ensuite, l'extraction de la

région d'intérêt (ROI), et enfin, la reconstruction 3D de la tumeur et de l'œdème pour permettre la classification de la tumeur.

On a aussi une méthode qui utilise une analyse des caractéristiques localisées dans les images de pathologie par (coarse-to-fine analysis) qui est proposé par R.A. Barker et al en 2015. Suivi par D.L. Rubin qui présentent un pipeline de classification modulaire basé sur l'apprentissage profond comprenant un ensemble de réseaux de neurones convolutifs (CNN). Ertosun et Rubin ont créé un ensemble de deux CNN : Le premier CNN classe une lame histologique en GBM ou LGG, et le second CNN détermine le grade de la tumeur en un grade II, ou un grade III, pour les cas de LGG. Par conséquent, la sortie du pipeline donne un grade possible allant du grade II au grade IV.

Au cours de l'année 2016 K. Fukuma, V.B. Sury a Prasath adoptent des méthodes d'analyse d'images automatiques, pour l'extraction de caractéristiques, et la classification des images histopathologiques de tumeurs cérébrales. Les auteurs utilisent la segmentation et l'étiquetage automatiques des noyaux pour les données d'image d'histopathologie, obtenues à partir de l'Atlas du génome du cancer (TCGA), et appliquent la classification à l'aide de Random Forests (RF). Les auteurs utilisent CellProfiler pour mettre en Suivre le pipeline de segmentation des noyaux.

Avançant jusqu'à 2018 ou Chenjie Ge, Qixun Qu proposent d'intégrer l'apprentissage de caractéristiques multi-échelles dans une architecture de réseau convolutif profond, permettant d'extraire des caractéristiques sémantiques multi-échelles ainsi que des caractéristiques fines pour le classement des gliomes. La méthode se compose de trois blocs principaux : le premier est conçu pour extraire des caractéristiques en utilisant des couches convolutives multi-échelles, avec des images IRM du cerveau comme entrée ; le deuxième fusionne les paramètres multi-échelles à l'aide de couches de fusion multi-échelles ; le troisième utilise des couches entièrement connectées (FC) pour le classement et la classification des gliomes, produisant des étiquettes de classe prédites. Par ailleurs, A. Selvapandiana et K. Manivannan proposent une méthode de détection et de segmentation des tumeurs cérébrales du gliome basé sur la fusion d'images à l'aide de l'approche de classification ANFIS. Ils ont utilisé une transformation de contourlet non sous-échantillonnée pour améliorer les images IRM et en extraire les caractéristiques. Ces caractéristiques extraites sont ensuite entraînées et classées à l'aide de l'approche ANFIS, qui distingue entre les images cérébrales normales et celles présentant un gliome. Les

régions tumorales des images cérébrales du gliome sont ensuite segmentées à l'aide d'outils morphologiques.

L'année 2019 a été marquée par des développements transformateurs grâce à L. Pei et al. Proposent une méthode pour la segmentation et la classification des tumeurs cérébrales, en employant deux réseaux de neurones profonds en 3D. Le premier réseau identifie les tissus normaux et tumoraux à partir d'images IRM multimodales, tandis que le second se charge de classer les tumeurs. Abd-Ellah crée une technique d'apprentissage en profondeur pour détecter et classer les tumeurs cérébrales à partir d'images IRM. En tant qu'extracteur de fonctionnalités, ils ont utilisé AlexNet CNN et, lors de l'étape de classification, un code de sortie de correction d'erreurs SVM a été appliqué. Pour l'extraction et la sélection de fonctionnalités. Gupta et al développent un système de diagnostic assisté par ordinateur (CAD) basé sur l'IRM pour détecter les tumeurs. Ce système utilise différentes méthodes de segmentation pour diverses séquences d'impulsions, la fusion de caractéristiques de texture, et un classificateur d'ensemble pour effectuer trois niveaux de classification. Le système analyse ensuite la localisation de la tumeur pour identifier son type via des caractéristiques morphologiques, atteignant une précision moyenne de 97,76 % sur un ensemble de données national et de 97,13 % sur les ensembles de données de BraTS. Enfin, S. Banerjee et al proposent trois architectures de réseau de neurones convolutifs (CNN) – le P-Net, le U-Net avec regroupement spatial, et le ResInc-Net – pour la segmentation des sous-régions de gliome (nécrose, œdème, corps de la tumeur, tumeur entière) à partir d'images IRM multimodales du cerveau. Ils utilisent le volume tumoral VOI pour extraire des caractéristiques spatiales pertinentes pour prédire la survie globale des patients, en se basant sur les images obtenues du BraTS 2019 Challenge.[43]

En 2020, des avancées impressionnantes ont été apportées par H. Khotanlou et al ont proposé une méthode basée sur les réseaux de neurones convolutifs (CNN). Cette méthode comprend deux parties : une unité de prétraitement qui extrait le cerveau du crâne, suivie de l'introduction de l'image obtenue dans un réseau CNN pour classification. Le réseau CNN extrait les caractéristiques primaires des images et génère des cartes de caractéristiques, à partir desquelles il extrait ensuite des caractéristiques secondaires pour les classer. Les images proviennent des données de BraTS2017. X. Ma et F. Jia ont développé deux modèles basés sur des CNN pour prédire le grade des gliomes à partir de données radiologiques et pathologiques. Le premier modèle est un modèle 2D basé sur le ResNet pour la classification d'images de diapositives entières de pathologie (WSI), et le

second est un modèle 3D basé sur le DenseNet pour la classification des images IRM multimodales. Ils utilisent diverses techniques d'augmentation des données pathologiques, telles que le mirroring, les rotations, le scaling, le recadrage et l'augmentation des couleurs. Après la formation des deux modèles séparément, le résultat final est obtenu via un modèle simple de régression. Leur approche leur a permis de remporter la première place du défi CPMRadPath2019. H.-W. Chan et al. ont utilisé deux réseaux de neurones, VGG16 et ResNet50, pour extraire des paramètres des images de diapositives (WSI). Ils ont également employé le module pyradiomics de Van Griethuysen et al., fourni par le Computational Imaging and Bioinformatics Lab de Harvard Medical School, pour calculer les caractéristiques radiomiques. Ils ont utilisé deux méthodes de classification, le K-means et le Random Forest (RF), et ont comparé les résultats de prédiction avec et sans les caractéristiques de l'IRM. Les résultats montrent que la classification avec les caractéristiques d'image extraites par VGG16 a la précision de prédiction la plus élevée. Enfin, Y. Xue et al présentent une méthode de classification des images IRM et pathologiques basée sur une segmentation avec le ResNet18, développée pour le défi BraTS 2019. Ils proposent un modèle de réseau neuronal convolutif résiduel à double voie, où l'un des chemins traite les segmentations tumorales 3D tandis que l'autre traite les images pathologiques. Pour éviter le sur-apprentissage, l'entraînement du modèle à double entrée est arrêté après 90 % de son apprentissage. [45]

Au cours des années suivantes, en 2021 et 2022, les recherches ont continué à progresser de manière décisive avec des contributions innovatrices, Tazin et coll. ont utilisé un CNN et une technique d'apprentissage par transfert pour déterminer si une tumeur cérébrale était présente ou non sur les images radiographiques ; VGG19, InceptionV3 et MobileNetV2 ont été utilisés pour une extraction approfondie des fonctionnalités. MobileNetV2 s'est avéré précis à 92 %, InceptionV3 à 91 % et VGG19 à 88 %[44]. Yin et al utilisent une méthode basée sur le Deep Learning pour classer les gliomes, en adaptant un réseau individuel à chaque modalité pour extraire et fusionner les caractéristiques afin de prédire le sous-type de gliomes. Pour les images IRM, ils utilisent un 3D-CNN, et pour les images WSI, ils appliquent deux étapes de prétraitement : la segmentation des noyaux des images WSI, en éliminant celles dont la surface des noyaux est inférieure à 7 %, et l'utilisation d'un module de rang de bruit pour supprimer les régions de bruit. La classification finale est obtenue par fusion des caractéristiques des deux modalités via un module pondéré linéaire. M. Lerousseau et al proposent une méthode de Deep Learning combinant des images de diapositives entières (WSI) et des images de résonance

magnétique (IRM) pour classer les tumeurs cérébrales, utilisant une architecture puissante et modulaire pour la classification. L. Pei et al proposent une méthode hybride pour la classification des sous-types de tumeurs cérébrales, en utilisant des images WSI et IRM multimodales (IRMm) basées sur l'apprentissage profond. Cette méthode comporte deux prédictions distinctes fusionnées par vote majoritaire pour obtenir le résultat final. Ils utilisent également un échantillonnage des données WSI et un outil open-source cleanlab pour améliorer la robustesse des prédictions. B. Zhao et al proposent un pipeline entièrement automatisé pour la classification des gliomes, incluant l'extraction de caractéristiques sur les images IRM multimodales et pathologiques, et leur fusion. Leur modèle combine un réseau auto-supervisé sans segmentation pour les volumes d'IRM 3D avec un autre modèle pour les images WSI. A. Hamidinekoo et al utilisent une méthode de Deep Learning pour la classification des gliomes avec un modèle 3D basé sur Densely Connected Network (DCN) pour les images IRM multiparamétriques et les patches pathologiques, combinant les deux modalités pour améliorer la prédiction. Miron et al développent un réseau neuronal avec des modules hétérogènes pour analyser les images IRM multiparamétriques de gliomes, visant à identifier les sous-régions histologiques et estimer le pronostic des patients. Enfin, B. Sangeetha et al développent un modèle de classification distinguant les oligodendrogliomes (bénignes) des astrocytomes (malignes) en combinant des caractéristiques radiologiques et pathologiques avec un modèle Inception v3 pré-entraîné, utilisant un SVM pour la classification finale.

En terminons avec, Alsaïf et ses collègues, afin de détecter les tumeurs cérébrales à partir d'images IRM ont utilisé divers modèles CNN en recourant à l'augmentation des données. Ils ont mis en œuvre les architectures VGG16, VGG19, ResNet-50, ResNet-101, Inception-V3 et DenseNet121 pour différencier les échantillons sains de ceux présentant des tumeurs. Parmi ces modèles, VGG16 a obtenu la meilleure précision, atteignant 96 %.[44]

5. Conclusion

Les recherches sur l'application de l'apprentissage profond pour la classification des tumeurs cérébrales ont considérablement évolué, démontrant l'efficacité et la puissance des réseaux de neurones dans l'analyse des images médicales. Les techniques telles que les R-CNN, YOLO et U-Net ont permis des avancées significatives en termes de précision et de rapidité, révolutionnant ainsi le diagnostic et le traitement des tumeurs cérébrales.

Les travaux discutés dans ce chapitre illustrent comment l'intégration de l'apprentissage profond dans les systèmes de diagnostic assisté par ordinateur peut améliorer la qualité des soins médicaux, en permettant des diagnostics plus précis et des interventions plus ciblées. À mesure que la technologie continue de progresser, il est crucial de poursuivre les recherches pour affiner ces méthodes et les adapter aux nouvelles modalités d'imagerie et aux différents types de tumeurs, afin de maximiser les bénéfices pour les patients.

CHAPITRE 4

Implémentation, Résultats et discussion

1. Introduction

Au fur et à mesure que les technologies de réseaux de neurones se développent avec des architectures plus complexes. Et avec difficulté de réaliser des modèles en se basant sur les bases de données disponibles dans le domaine médical en raison de leur texture complexe, de leur taille limitée et de leur variabilité. Il existe un fort besoin de concevoir des architectures plus simples mais puissantes capables de gérer avec succès le problème de la classification de tumeurs cérébrales. Pour atteindre cet objectif, nous présentons dans ce chapitre la méthode sur laquelle nous avons travaillé selon le schéma (2), les différentes ressources et logiciels que nous avons utilisés, et en fin on terminera par une discussion des résultats d'évaluation obtenus.

Ce projet de recherche vise à développer un système d'aide automatisé pour la classification des tumeurs cérébrales à partir d'images d'IRM. Le système sera basé sur une méthode de la CNN. L'objectif principal est d'améliorer la détection des tumeurs cérébrales par rapport aux méthodes traditionnelles.




Figure 1 Synoptique de la méthode utilisée

Figure 2 Synoptique de la méthode utilisée

2. Ressource

2.1. Kaggle Notebooks

Kaggle Notebooks est une plateforme en ligne qui offre un environnement de travail aux professionnels de l'analyse de données. Cet outil permet de créer, d'exécuter et de partager des

cahiers de code pour l'analyse et le traitement des données. Les utilisateurs peuvent ainsi collaborer, reproduire leurs résultats et partager leurs découvertes. [48]

D'autre part, Kaggle offre d'autres spécifications :

- GPU Tesla P100 avec RAM de 71.1GB
- Un CPU Intel Xeon Dual Core -2.33GHz avec 16.4GB de RAM .
- Limitation de la session 9heures.
- Accès au GPU limité à 30 heures/semaine contrairement au Colab qui donne un accès illimité au GPU .
- Propose de nombreux jeux de donnée qu'on peut importer facilement.

2.2.Langage de programmation

MATLAB, ou Matrix Laboratory, est un logiciel interactif basé sur le calcul matriciel. Il est plébiscité dans le domaine des calculs scientifiques et de l'ingénierie pour sa rapidité et son efficacité dans la résolution de problèmes numériques complexes. Cette performance est rendue possible grâce à une multitude de fonctions intégrées et de programmes outils testés et classés par usage dans des dossiers appelés "toolboxes". Contrairement aux langages de programmation traditionnels, MATLAB vise à simplifier au maximum la traduction d'un problème mathématique en langage informatique en utilisant une syntaxe proche du langage scientifique naturel.

2.3. Bibliothèque

2.3.1. DeepNetWorkDesigner

Le DeepNetworkDesigner est une application MATLAB qui permet de concevoir, visualiser et éditer des réseaux de neurones profonds pour le deep learning. Cette application offre une interface graphique pour construire et combiner des réseaux de neurones, en important des réseaux pré-entraînés ou en créant de nouveaux à partir de zéro.

Utilisation de l'application

Pour ouvrir le Deep Network Designer, on va également taper deepNetworkDesigner dans la fenêtre command Window. Une fois l'application ouverte, on va créer un réseau vierge, on va importer un réseau pré-entraîné ou choisir un modèle de réseau pré-défini adapté à un type de problème. Le réseau se construit en glissant-déposant des couches depuis une

bibliothèque sur un canevas et en les connectant entre elles. On peut éditer les propriétés des couches, les aligner automatiquement et analyser le réseau pour vérifier qu'il est correctement défini. Enfin, le réseau peut être exporté vers l'espace de travail MATLAB ou bien le code pour le recréer peut-être généré. Le Deep Network Designer peut être utilisé pour des tâches variées de deep learning, comme la classification d'images en utilisant un réseau de neurones convolutif, le traitement de séquences avec des réseaux récurrents, et l'adaptation de réseaux pré-entraînés pour du transfer learning. En résumé, le Deep Network Designer est un outil puissant et intuitif pour concevoir et expérimenter des architectures de deep learning dans MATLAB, que ce soit pour des projets de recherche ou des applications industrielles.

2.4.La base donnée

La base de données qui a été utilisé dans les expériences et le test s'est formé sur la base de l'ensemble d'images IRM cérébrales disponible sur la plateforme Kaggle, accessible directement à partir d'un Notebook Kaggle ou en téléchargement le lien [49] Cette base a été publiée en 2020 par Jean DJHONSON et contient 253 examens médicaux, offre aux chercheurs et aux développeurs un outil précieux pour explorer l'application de l'apprentissage automatique à la détection des tumeurs cérébrales. L'ensemble de données comprend 253 examens médicaux provenant de patients présentant des pathologies diverses, répartis en deux dossier :

- ☐ 155 images d'examens médicaux de patients malades
- ☐ 98 images d'examens médicaux de patients sains.

Toutes les images sont au format NPG, elles sont de différentes taille pour cela on les a normalise pour la même dimension 50*50Repartie en deux dossier .

3. Les réseaux de neurones convolutifs

3.1. Définition

Un réseau neuronal convolutif est un algorithme d'apprentissage en profondeur qui peut reconnaître et classer les caractéristiques des images pour la vision par ordinateur. Il s'agit d'un réseau neuronal multicouche conçu pour analyser les entrées visuelles est effectué des tâches telles que la classification d'images, la segmentation et la détection d'objets.

Les réseaux de neurones convolutionnels sont à ce jour les modèles les plus performants pour classer les pixels d'une image. [50]

3.2. Fonctionnement des CNN

Les CNN comportent deux parties bien distinctes. En entrée, une image est fournie sous la forme d'une matrice de pixels. Elle a deux dimensions pour une image en niveaux de gris. La couleur est représentée par une troisième dimension, de profondeur 3 pour représenter les couleurs fondamentales [Rouge, Vert, Bleu]. La première partie d'un CNN est la partie convolutive à proprement parler. Elle fonctionne comme un extracteur de caractéristiques des images. Une image est passée à travers une succession de filtres, ou noyaux de convolution, créant de nouvelles images appelées cartes de convolutions. Certains filtres intermédiaires réduisent la résolution de l'image par une opération de maximum local (fonction de max pooling). [51]

Au final, les cartes de convolutions sont mises à plat et concaténées en un vecteur de caractéristiques, appelé code CNN. Ce code CNN en sortie de la partie convolutive est ensuite branché en entrée d'une deuxième partie, constituée de couches entièrement connectées (perceptron multicouche). Le rôle de cette partie est de combiner les caractéristiques du code CNN pour classer les pixels d'image ou les images elles-mêmes. La sortie est une dernière couche comportant un neurone par catégorie. Les valeurs numériques obtenues sont généralement normalisées entre 0 et 1, de somme 1 pour produire une distribution de probabilité sur les catégories

3.3. Architecture CNN

Un CNN est composé de quatre types de couches : la couche de convolution, la couche de pooling, la couche de correction ReLU et la couche fully connected. [51]

3.3.1. La couche de convolution

La couche de convolution est la composante clé des réseaux de neurones convolutifs, et constitue toujours au moins leur première couche.

Son but est de repérer la présence d'un ensemble de caractéristiques (features) dans les images reçues en entrée. Pour cela, on réalise un filtrage par convolution : le principe est de faire "glisser" une fenêtre représentant la caractéristique sur l'image, et de calculer le produit de convolution entre la caractéristique et chaque portion de l'image balayée. Une caractéristique est alors vue comme un filtre : les deux termes sont équivalents dans ce contexte.

La couche de convolution reçoit donc en entrée plusieurs images, et calcule la convolution de chacune d'entre elles avec chaque filtre. Les filtres correspondent exactement aux caractéristiques que l'on souhaite retrouver dans les images.

On obtient pour chaque paire (image, filtre) une carte d'activation, ou **feature map**, qui nous indique où se situent les caractéristiques dans l'image : plus la valeur est élevée, plus l'endroit correspondant dans l'image ressemble à la caractéristique.




Figure 3:Schéma d'une couche de convolution avec un noyau de taille 3*3 et un pas de 2. [51]

3.3.2. Couche de mise en commun (pooling)

La couche de Pooling est une opération généralement appliquée entre deux couches de convolution.

Celle-ci reçoit en entrée les features maps formées en sortie de la couche de convolution et son rôle est de réduire la taille des images, tout en préservant leurs caractéristiques les plus essentielles.

Parmi les plus utilisés, on retrouve le max-pooling qui est un processus de discrétisation basé sur des échantillons. Son objectif est de diviser la taille de l'entrée par 2 en prenant le maximum des carrés de taille 2 x 2 pixels, comme le montre la figure 3 .




Figure 4 : Exemple d'application de l'opération max pooling. [51]

3.3.3. Couche de correction (Relu)

Cette couche remplace toutes les valeurs négatives reçues en entrées par des zéros. L'intérêt de ces couches d'activation est de rendre le modèle non linéaire et de ce fait plus complexe (figure 4).




Figure 5: Fonctionnement de la fonction ReLU. [51]

3.3.4. Couche entièrement connectées (fully connected)

La sortie des couches de convolution et de regroupement d'un CNN est le vecteur des caractéristiques d'image. L'objectif de la couche entièrement connectée est d'utiliser ces vecteurs d'entités pour classer les images d'entrée en plusieurs classes en fonction d'un jeu de données d'apprentissage étiqueté.




Figure 6:Exemple d'architecture d'un CNN [51]

3.4. Les architectures CNN performantes pour la classification deep Learning en imagerie médicale

3.4.1. L'architecture VGG-16

Le modèle VGG, développé par Andrew Zisserman et Karen Simonyan en 2013, introduit une approche novatrice dans le domaine de la vision par ordinateur. Contrairement aux modèles précédents, il utilise des filtres de convolution de petite taille (3×3) avec un pas d'un seul pixel, ce qui permet de couvrir un champ réceptif plus large. Cette approche offre plusieurs avantages, notamment une meilleure capacité à capturer les caractéristiques spatiales des images et une réduction du risque de suradaptation lors de l'entraînement. De plus, en utilisant plusieurs couches de convolution de petite taille, le modèle VGG intègre davantage de couches d'activation non linéaires, ce qui favorise une convergence rapide du réseau. En résumé, le modèle VGG représente une avancée significative dans la conception des réseaux de neurones convolutifs, en proposant une architecture plus efficace et facile à gérer.[51]

- **Entrée** : Le modèle VGGNet prend en entrée des images de taille 224×224 . Pour maintenir une taille d'entrée constante lors de la compétition ImageNet, les créateurs du modèle ont recadré une section de 224×224 pixels au centre de chaque image.
- **Couches de convolution** : Les filtres de convolution utilisés par VGG ont un petit champ récepteur de 3×3 . De plus, VGG utilise des filtres de convolution de 1×1 pour la transformation linéaire de l'entrée.
- **Activation ReLu** : Le modèle utilise la fonction d'activation ReLU (Rectified Linear Unit), une innovation majeure qui permet de réduire le temps d'entraînement. Cette fonction fournit une sortie linéaire pour les entrées positives et produit zéro pour les entrées négatives. VGG utilise une valeur de pas de convolution fixe de 1 pixel pour préserver la résolution spatiale après la convolution.

- **Couches cachées** : Contrairement à AlexNet, toutes les couches cachées du modèle VGG utilisent ReLU au lieu de la Normalisation de la Réponse Locale, ce qui contribue à réduire le temps d'entraînement et la consommation de mémoire sans compromettre la précision.
- **Couches de regroupement** : Des couches de regroupement suivent plusieurs couches de convolution pour réduire la dimensionnalité des cartes de caractéristiques.
- **Couches entièrement connectées** : VGGNet est doté de trois couches entièrement connectées, dont les deux premières ont chacune 4096 canaux et la dernière compte 1000 canaux, correspondant à chaque classe.




Figure 7 : Architecture d VGG-16 [51]

3.4.2. L'architecture du modèle GoogleNet/Inception

L'architecture Inception a été conçue pour réduire la consommation de ressources des réseaux de neurones convolutifs profonds (DCNN) tout en conservant leur capacité à capturer la variabilité des données. Cette architecture est particulièrement utile pour les applications d'imagerie médical où les jeux de données.




Figure 8 : architecture Inception et ces dérivées. [51]

Cette architecture repose sur l'utilisation de blocs de traitement qui combinent plusieurs filtres de tailles différentes à un même niveau du réseau. Cette technique permet de capturer des informations d'échelles différentes, ce qui est crucial pour la classification précise d'images médicales

L'utilisation de plusieurs filtres implique une augmentation de la consommation de ressources. Pour réduire cet impact, l'architecture Inception utilise deux techniques :

- Filtrage 1x1 : Une étape de filtrage 1x1 est ajoutée avant les filtres 3x3 et 5x5. Cette convolution de taille 1x1 effectue une opération de pooling sur les valeurs d'un pixel, réduisant ainsi la dimension de l'image analysée. La réduction de dimension permet de conserver l'information tout en réduisant le coût des ressources lors de l'étape de convolution suivante.
- Dérivés de l'architecture Inception : Des architectures dérivées d'Inception ont été développées pour améliorer ses performances et réduire sa consommation de ressources.

Deux exemples importants sont :

- Xception : Remplace les modules Inception par des modules de convolutions séparables en profondeur, ce qui réduit considérablement l'utilisation de ressources lors du calcul matriciel.
- Inception-ResNet: Intègre une liaison résiduelle dans les modules Inception, ce qui améliore considérablement les performances du modèle en classification.

L'architecture Inception est souvent utilisée pour la classification des anomalies en imagerie médicale, notamment pour :

- Définir le stade de la maladie (cancer des poumons, cancer des reins, inflammation du complexe ostioméatal)
- Détecter des pathologies (nodules pulmonaires, hémorragies intracrâniennes)

4. Métrique d'évaluations

Accuracy and Loss

La précision et la perte sont deux paramètre adopter pour mesurer les performances d'un modèle de classification tel que :

La précision est le nombre de prédictions où la valeur prédite est égale à la valeur vraie. C'est binaire (vrai/faux) pour un échantillon particulier. La précision est généralement exprimé en pourcentage est souvent représentée graphiquement et surveillée pendant la phase de formation, bien que la valeur soit souvent associée à la précision globale ou finale du modèle. La précision est plus facile à interpréter que la perte.

Une fonction de perte, prend en compte les probabilités ou l'incertitude d'une prédiction en fonction de l'écart entre la prédiction et la valeur réelle. Cela nous donne une vision plus nuancée des performances du modèle. Contrairement à la précision, la perte n'est pas un pourcentage : il s'agit d'une somme des erreurs commises pour chaque échantillon dans les ensembles d'entraînement ou de validation. La perte est souvent utilisée dans le processus de formation pour trouver les meilleures valeurs de paramètres pour le modèle . Pendant le processus de formation, l'objectif est de minimiser cette valeur.[52]

Les fonctions de perte les plus courantes sont **la perte logarithmique** et **la perte d'entropie croisée** (qui donnent le même résultat lors du calcul des taux d'erreur entre 0 et 1),

On remarque que la précision s'améliore généralement quand la perte diminue (figure 8), mais ce n'est pas toujours le cas. En effet, la précision et la perte mesurent des aspects distincts du modèle et n'ont pas de relation mathématique directe. Bien qu'elles semblent souvent aller dans des directions opposées, il n'y a pas de règle absolue qui les lie.




Figure 9: Graphique de précision et de perte de la formation CNN [52]

5. Les modèles implémentés

5.1. modèle 1

En guise de premier modèle, nous avons mis en place un ConvNet de petite taille. Son architecture simple se compose de donnée d'entrée qui est des image de format jpg et de taille [50,50] et de 3 couches convolutives, chacune suivie d'une activation ReLU et d'une couche de pooling max. Deux couches entièrement connectées finalisent ensuite le modèle. L'entraînement de ce modèle a permis d'atteindre une précision de 77,27% et une perte de 0,5 (figure10).




Figure 10: schéma de modèle 1




Figure 11: graphe loss and accuracy pour le modèle 1

5.2. Modèle 2

Après le modèle initial, nous avons décidé d'implémenter un ConvNet plus profond en utilisant 5 blocs composés de couches convolutives avec des nombres de couches variables.

Le nombre de filtres, la taille du filtre et la taille de pooling de réduction d'échelle pour les couches sont respectivement implanté tel que :

- 2couche de convolution de taille $[8, (3,3),]$, suivi de leur couche de normalisation pour chacune et une couche de max pooling
- 2 couche de convolution de taille $[16, (3,3),]$ suivi de leurs couches de normalisation Relu et une couche max pooling.
- 3 couche de convolution de taille $[32, (3,3),]$. Suivi respectivement par leur couche de normalisation Relu et une couche de max pooling
- 3 couche de convolution de taille $[64, (3,3)]$
- 4 couche de convolution de taille $[128, (3,3)]$, ensuite on'a laisser les trois couche entièrement connecter pour déférente taille telle que Fully Connected1=1000, fc2=500, fc3= 2 avec leur couche de normalisation sigmoïde pour la classification des images en binaire suivi d'une couche de normalisation softmax (figure 11) :




Figure 12:schéma de modèle 2

Est l'entraînement de ce modèle CNN a permis d'atteindre une précision de 89%. La valeur de la perte associée à ce modèle est de 0,29, comme illustré dans la figure 9.




Figure 13:graphe de la précision et de la perte pour le model 2

5.3. Modèle 3

Dans le troisième modèle, nous avons réduit le nombre de couches convolutives tout en augmentant leur taille. Une troisième couche entièrement connectée a également été ajoutée (figure 10):

- 2 couche de convolution de taille [16 (3,3)]
- 3 couche de convolution de taille [32(3,3)].
- 4 couche de convolution de taille [64(3,3)].
- 5 couche de convolution de taille [128(3,3)].
- Fully Connected1=250, Fully Connected2=100, Fully Connected3=50, Fully Connected4=2 .




Figure 14:schéma de modèle 2

Ces modifications ont permis d'atteindre une précision de 90,91% et une perte de 0,25, comme la montre la (figure11).




Figure 15: graphe de la précision et de la perte pour le model 3

5.4. Modèle 4

Pour optimiser ce modèle, nous avons adopté une stratégie de simplification architecturale. En effet, nous avons supprimé la couche convolutive la plus petite et une couche entièrement connectée. De plus, la taille des couches restantes a été augmentée figure 12 :

- 3 couche de convolution de taille [32(3,3)].
- 4 couche de convolution de taille [64(3,3)].
- 5 couche de convolution de taille [128(3,3)].
- Fc1=2500, fc2=1500,.




Figure 16:schéma de quatrième modèle

Ces modifications ont permis d'améliorer significativement la performance du modèle, qui a atteint une précision remarquable de **92,42%** et une perte minimale de **0,20**, comme en témoigne la (figure 13).




Figure 17: les graphes de perte de précision pour le modèle 4

5.5. Modèle 5

Dans le cadre de l'entraînement du dernier modèle, nous avons opté pour une approche de simplification architecturale par augmentation de la taille des couches existantes. En effet,

les trois couches convolutives ont été conservées, mais leur taille a été augmentée. De même, la taille des deux couches entièrement connectées a été augmentée (figure 14) :

- 3 couche de convolution de taille $[64(3,3)]$.
- 4 couche de convolution de taille $[128(3,3)]$.
- 5 couche de convolution de taille $[256(3,3)]$.
- $Fc1=4000$, $fc2=2000$.




Figure 18: schéma de modèle 5

Cette stratégie a permis d'améliorer significativement la performance du modèle, qui a obtenu une précision remarquable de 95,45% et une perte minimale de 0,23, comme en témoigne la (figure 15).




Figure 19: graphe de perte et précision de dernier model entrainer

6. Discussion des Résultats et Améliorations Futures

Les résultats obtenus à travers les différents modèles CNN montrent une progression significative de la performance avec des ajustements progressifs de l'architecture. Voici une analyse détaillée de ces résultats et des suggestions pour les améliorations futures.

6.1. Analyse des Résultats

Premier Modèle CNN

- **Précision** : 77,27%
- **Perte** : 0,5
- **Discussion** : Le premier modèle, avec une architecture simple comprenant 3 couches convolutives et deux couches entièrement connectées, a atteint une précision modeste de 77,27%. Cela indique que, bien que le modèle puisse apprendre certaines caractéristiques des images, sa capacité à généraliser est limitée par sa complexité relativement faible.

Deuxième Modèle CNN

- **Précision** : 89%
- **Perte** : 0,29

- **Discussion** : L'augmentation de la profondeur avec 5 blocs convolutifs a permis une amélioration significative de la précision à 89%. Les couches supplémentaires ont aidé le modèle à capturer des caractéristiques plus complexes des images, augmentant ainsi sa performance globale.

Troisième Modèle CNN

- **Précision** : 90,91%
- **Perte** : 0,25
- **Discussion** : En augmentant la taille des couches convolutives tout en réduisant leur nombre, le modèle a encore amélioré sa précision à 90,91%. Cette approche montre que, dans certains cas, la taille des filtres peut être plus bénéfique que la profondeur totale.

Quatrième Modèle CNN

- **Précision** : 92,42%
- **Perte** : 0,20
- **Discussion** : La simplification architecturale combinée à l'augmentation de la taille des couches a permis d'atteindre une précision de 92,42%. Ce modèle a trouvé un bon équilibre entre la profondeur et la taille des couches, ce qui a amélioré la performance sans complexifier excessivement le modèle.

Cinquième Modèle CNN

- **Précision** : 95,45%
- **Perte** : 0,23
- **Discussion** : Le dernier modèle, qui a augmenté la taille des couches existantes tout en conservant leur nombre, a atteint la meilleure précision de 95,45%. Cela confirme que l'augmentation de la capacité du modèle par la taille des couches peut capturer des caractéristiques encore plus détaillées des images, conduisant à une performance supérieure.

6.2. Améliorations Futures

L'utilisation du CPU limite la capacité de calcul et prolonge le temps d'entraînement. Passer à des unités de traitement graphique (GPU) peut accélérer considérablement l'entraînement des modèles. Les GPU sont spécialement conçus pour les calculs parallèles massifs, ce qui est

essentiel pour les tâches de Deep Learning. En utilisant ces ressources, il sera possible de tester des architectures plus complexes et de travailler avec des jeux de données plus volumineux.

7. Conclusion

Dans ce chapitre, nous avons exploré la conception et l'implémentation de différentes architectures de réseaux de neurones convolutifs (CNN) pour la classification automatisée des tumeurs cérébrales (affecté ou non affecté) à partir d'images IRM. En utilisant des ressources et des outils spécifiques tels que Kaggle Notebooks et MATLAB, nous avons développé et évalué plusieurs modèles CNN de complexité croissante.

Les résultats obtenus démontrent une amélioration progressive des performances des modèles, atteignant une précision maximale de 95,45% avec une perte minimale de 0,23 pour le cinquième modèle. Cette progression a été réalisée en ajustant les paramètres architecturaux, notamment la profondeur du réseau et la taille des couches convolutives.

En conclusion, cette étude a démontré la faisabilité et l'efficacité des CNN pour la détection des tumeurs cérébrales à partir d'images IRM. Les résultats prometteurs obtenus ouvrent la voie à des développements futurs pour des applications cliniques plus précises et efficaces.

Conclusion Générale

CONCLUSION GENERAL

Dans le cadre de notre mémoire, nous nous sommes intéressés à la classification automatique des images médicales cérébrales, en distinguant celles présentant des pathologies des images saines. Pour ce faire, nous avons mis en œuvre une approche basée sur l'utilisation de réseaux de neurones profonds, une technique d'apprentissage machine particulièrement performante pour ce type de tâche de reconnaissance d'images.

Notre travail a consisté à concevoir et entraîner un réseau de neurones profond, composé de plusieurs couches successives, afin d'apprendre à extraire automatiquement les caractéristiques pertinentes des images cérébrales pour effectuer une classification fiable entre les cas pathologiques et non pathologiques.

À l'issue de nos expérimentations, nous avons obtenu des résultats très satisfaisants, avec un taux de validation atteignant 95%. Cela démontre que notre modèle de réseau de neurones profond a su parfaitement maîtriser les subtilités de la classification des images cérébrales, en s'appuyant sur les capacités du deep learning à apprendre des représentations complexes à partir des données.

Ce travail illustre ainsi notre bonne compréhension et notre maîtrise des techniques de réseaux de neurones profonds, qui constituent aujourd'hui un outil incontournable dans de nombreux domaines de l'intelligence artificielle, y compris pour des applications médicales comme celle traitée dans ce mémoire.

Dans les travaux futurs, nous envisageons d'ajouter d'autres couches à notre réseau afin d'améliorer encore davantage notre modèle et de pousser plus loin les performances de notre approche. Cette perspective d'amélioration continue reflète notre engagement à exploiter pleinement le potentiel des réseaux de neurones profonds pour des applications médicales avancées.

BIBLIOGRAPHIE

Bibliographie

- [1] Gérard, Outrequin et Bertrand, Boutillier. « Neuro-Anatomie fonctionnelle ». Neuro- anatomie fonctionnelle et illustrations d'anatomie, [en ligne].
<http://www.anatomie-humaine.com/-Neuro-Anatomie->
- [2] - M.D. Netter, Frank H « Atlas D'Anatomie Humaine » livre ,parution 2011
- [3] MARKH.BILSKY « Présentation de tumeur cérébral »MSD manuel publie a MD Weill Medical clege of carnel university le Mai/2023
- [4] Bouhaddou ahmed « Les tumeurs cérébrale »—chu de tlemcen –service de neurochirurgie soutenu l'année 2014-2015
- [5] Dominique Sappey-Marinier "Imagerie par Résonance Magnétique" Livre publié en 2004
- [6] "Principes physiques de l'IRM» Article de la Société Française de Radiologie
- [7] Hgop Demirdjian « les origines de l'IRM la résonance Magnétique nucléaire(RMN) » article publier le 01/11/2007
- [8] Cours de IRM –Matière Complément de physique université Toulouse-III-Paul-Paul-Sabatier
- [9] ALLEGUE AHMED Ziyad, BERREDAI Radwane « ÉTUDE SUR L'IMAGERIE MÉDICALE » mémoire master , université de gualema soutenu le 2020
- [10] Patrice TAOUREL « scanner ou IRM »article – CHU de Montpellier hôpital Lapeyronie
- [11] Les tumeurs du cerveau, diagnostic imagerie L'Encyclopédie collection Guides de référence Cancer info, INCa, juin 2010.
- [12] [Types de tumeurs - Les tumeurs du cerveau \(e-cancer.fr\)](#)
- [13] « Irm : technologie , maintenance et contrôle qualité » université hassan 1^{er} 2017/2018
- [14] PROF M.DAHOU Bouzid « Cour instrumentation d'imagerie médiclae » master2 université mouloud mammeri tizi ouzou 2023/2024
- [15] Frédéric devernay « analyse d'image » cours de l'université joseph fourier –Grenoble 1,unité de formation et de recherche en informatique et mathématique appliqué (consulté 4/2024
- [16] Marine BEAUMONT. « développements en imagerie rmn spirale et application a la caractérisation de la perméabilité de la barrière hémato-encéphalique sur deux modèles de tumeurs intracérébrales » L'Université Grenoble I

- [17] H. Ye, F. Gao, Y. Yin, and al. "Precise diagnosis of intracranial hemorrhage and subtypes using a three-dimensional joint convolutional and recurrent neural network". Eur Radiol **29**, 6191–6201 (2019). <https://doi.org/10.1007/s00330-019-06163>
- [18] J. Hurwitz, D. Kirsch, "Machine Learning For Dummies", IBM Limited Edition 2018 John Wiley & Sons, Inc. 111 River St. Hoboken, NJ 07030-5774
- [19] Younes Benzazi "apprentissage supervise ,machine learning" article publié le 19/02/2017
- [20] A. Souad et B. Lamia, «Mise en oeuvre de l'apprentissage profond pour la détection de Fake News,» mémoire Master , Université Mouloud Mammeri de Tizi-Ouzou, 2018.
- [21] Cloude touzed « les réseaux de neurones artificiels , introduction au connexionnisme » article publier le 27/Juin/2016
- [22] H. M. Amel et A. Rania, «Implémentation d'un modèle de Deep Learning basé sur un réseau de neurones sur la carte STM32,» Mémoire Master, Université Mouloud Mammeri de Tizi-Ouzou,2021.
- [23] B. Jugurtha, «Développement d'outils de vision artificielle embarquée avec Deep Learning :Application à la reconnaissance de panneaux de signalisation routière,» Mémoire Master,Université Abderrahmane Mira-Bejaia, 2021.
- [24] «TUTORIEL | Machine Learning : comprendre ce qu'est un réseau de neurones et en créer un,»[En ligne]. Available: <https://fr.blog.businessdecision.com/tutoriel-machine-learningcomprendre-ce-quest-un-reseau-de-neurones-et-en-creer-un/>.
- [25] FORMATION DEEP LEARNING COMPLETE (2021) <https://youtu.be/XUFLq6dKQok?si=PYijHW9suXCawSKV>
- [26] I. Goodfellow, Y. Bengio, A. Courville, "Deep Learning". MIT Press (2016)
- [27] Boughaba Mohammed et Boukhris Brahim "L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu » mémoire master , UNIVERSITE KASDI MERBAH OUARGLA présenté le 2017
- [28] J Amin, M.Sharif .A Haldorai3 « Brain tumor detection and classification using machine learning: a comprehensive survey» artiel publier en novembre 2021
- [29] <https://www.ionos.fr/digitalguide/web-marketing/search-engine-marketing/deep-learning-vs-machine-learning/>
- [30] Juba Ait idir « Les réseaux de neurones convolutifs pour la classification des tumeurs cérébrales » mémoire master , école d'informatique et du numérique ,paris présenté le 08/08/2022
- [31] Alexandre Lundervold, Arvid Lundervold "An overview of deep learning in medical imaging focusing on MRI" article publier sur Science Direct décembre 2018

- [32] Juri Yanase « a systematic survey of computer Aided diagnosis in Medicine Past and present Developments” article publié juillet 2019
- [33] Brahim Ait Skourt. “Medical Image Analysis Using Deep Learning.” Computer Science [cs]. Faculty of Science and Technology, 2023.
- [34] M.Pommier , L. Chave “ Etat de l’art en imagerie medicale “ article publie 2017
- [35] Girshick, R., Donahue, J., Darrell, T., and Malik, J “Rich feature hierarchies for accurate object detection and semantic segmentation.” In Proceedings of the IEEE conference on computer vision and pattern recognition, (2014). <https://arxiv.org/pdf/1311.2524>
- [36] Shaoqing Ren, Kaiming He “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks” article publié en 2015 <https://arxiv.org/abs/1506.01497>
- [37] Detection Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi “ You Only Look Once: Unified, Real-Time Object” article publier le 9 mai 2016 <https://arxiv.org/pdf/1506.02640>
- [38] Mohammad Havaei , Axel Davy “**Brain tumor segmentation with Deep Neural Networks** “ article publié le 20 mai 2016
- [39] Muralikrishna Puttagunta1 & S. Ravi1 “Medical image analysis based on deep learning approach” article publié en ligne le 6 avril 2021.
- [40] Alessandro Carriero, Léon Groenhoff , Elizaveta Vologina, Paola Basile and Marco Albera” “Deep Learning in Breast Cancer Imaging: State of the Art and Recent Advancements in Early 2024” article publié 19 avril 2024
- [41] M. Viviane Tone « Classification des Images Histologiques pour la Détection des Gliomes » Mémoire de master Université SAAD DAHLAB de BLIDA Faculté de Technologie 2022
- [42] Antonio Curci1 a , Andrea Esposito “Detecting Brain Tumors through Multimodal Neural Networks” artiel publier janvier 2024
- [43] Mahmoud Khaled Abd-Ellah “Automatic brain-tumor diagnosis using cascaded deep convolutional neural networks with symmetric U-Net and asymmetric residual-blocks” Published online 2024 Apr 25.
- [44] Alessandro Crimi, Spyridon Bakas “Brain tumor classification with tumor segmentations and a dual path residual convolutional neural network from MRI and pathology images” articles sélectionnés révisés 2019
- [45] Mohammad Shafkat Islam”A Deep Learning Approach for Neuronal Cell Body Segmentation in Neurons Expressing GCaMP Using a Swin Transformer” artiel publié le 13/09/2023

- [46] C.Singh « Medical Imaging using Deep Learning Models” article publié dans le journal European Journal of Engineering and Technology Research le23/08/2021
- [47] <https://www.kaggle.com/>
- [48] Jean DJHONSON « base de données » publiée en 2020
<https://www.kaggle.com/datasets/jjprotube/brain-mri-images-for-brain-tumor-detection>
- [49] L. Z, L. F., Y. W., P. S et Z. J., «A survey of convolutional neural networks:analysis, applications,and prospects,» IEEE transactions on neural networks and learning systems, 2021.
- [50] H. M. Amel et A. Rania, «Implémentation d'un modèle de Deep Learning basé sur un réseau de neurones sur la carte STM32,» Mémoire Master, Université Mouloud Mammeri de Tizi-Ouzou, 2021.
- [51] «Classifiez les images à l'aide de réseaux de neurones convolutifs.,» [En ligne].
 Available:<https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles>.
- [52] Nathan FILLÂTRE « Comparaison de méthodes de classification classique avec des algorithmes récents d'intelligence artificielle en télédétection aéroportée pour des applications côtières » MASTER 2e année Mention « Sciences de la Terre et des planètes, Environnement » Parcours « INGÉNIERIE ET GÉOSCIENCES DU LITTORAL » 2018/2019
- [53] « Innovation santé N° 3 cancer une guerre inachevée » article publié le 25/02/2020
- [54] Article biologique humaine publié en 2009
- [55] Réseau de neurones- on va essayer de démystifier un peu tout ça(1)_architecture neuronale publié le 8 avril 2019

RESUME

Résumé

Dans le cadre de ce mémoire, nous nous sommes intéressés à la classification automatique des images médicales cérébrales, en distinguant celles présentant des pathologies des images saines. Pour relever ce défi, nous avons mis en œuvre une approche basée sur l'utilisation de réseaux de neurones convolutifs (CNN), une architecture de réseaux de neurones profonds particulièrement performante pour les tâches de reconnaissance d'images.

Notre travail a consisté à concevoir et entraîner un modèle de réseau de neurones convolutif capable de prendre en entrée des images IRM cérébrales et de les classer avec précision entre cas pathologiques (présence de tumeurs) et cas sains. À l'issue de nos expérimentations, nous avons obtenu des résultats très satisfaisants, atteignant un taux de classification de 95%.

Abstract

In the context of this dissertation, we were interested in the automatic classification of medical brain images, distinguishing those with pathologies from healthy images. To meet this challenge, we implemented an approach based on the use of convolutional neural networks (CNNs), a deep neural network architecture particularly effective for image recognition tasks.

Our work consisted of designing and training a convolutional neural network model capable of taking brain MRI images as input and classifying them with precision between pathological cases (presence of tumors) and healthy cases. At the end of our experiments, we obtained very satisfactory results, achieving a classification rate of 95%.

ملخص

في سياق هذه الأطروحة، كنا مهتمين بالتصنيف التلقائي لصور الدماغ الطبية، مع تمييز تلك التي تحتوي على أمراض عن الصور السليمة. لمواجهة هذا التحدي، قمنا بتنفيذ نهج يعتمد على استخدام شبكات الالتفاف العصبي (CNNs)، وهي بنية شبكة عصبية عميقة فعالة بشكل خاص لمهام التعرف على الصور.

تضمن عملنا تصميم وتدريب نموذج لشبكة عصبية متراكمة قادر على أخذ صور التصوير بالرنين المغناطيسي للدماغ كمداخلات وتصنيفها بدقة بين الحالات المرضية (وجود أورام) والحالات السليمة. في نهاية تجاربنا، حصلنا على نتائج مرضية للغاية، حيث حققنا معدل تصنيف بنسبة 95%.