

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique

جامعة سعد دحلب البليدة
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الإلكترونيك
Département d'Électronique



Mémoire de Master

Mention : Génie Biomédical

Spécialité : Instrumentation Biomédicale

présenté par :

Benali Khodja Khaoula

&

Guennaz Amel

Analyse d'Images Médicales pour la Détection et le Suivi des Pathologies du Cerveau

Proposé par : Pr.Cherfa Yazid & Dr.Cherfa Assia

Année Universitaire 2021-2022

Remerciements

Tout d'abord, nous remercions Dieu de nous avoir donné la force, la patience et la volonté de mener à bien ce travail.

Avec tout le respect, nous tenons à remercier vivement nos promoteurs Mr Y.Cherfa et Mme A.Cherfa pour tout le temps qu'ils nous ont accordé durant la préparation de notre mémoire, pour leur aide, leurs conseils, leurs orientations.

De plus, Nous remercions les membres du jury d'avoir accepté d'examiner ce travail.

Nous remercions tous les enseignants du Génie Biomédical.

Enfin, nous remercions nos familles et nos proches pour leurs encouragements, sans oublier les personnes qui nous ont aidés de près ou de loin dans notre travail.

Dédicaces

A nos chers parents, pour tous leurs sacrifices, leur amour, leur tendresse, leur soutien
et leurs prières tout au long de nos études,

A nos chers sœurs et frères pour leurs encouragements et leur soutien moral.

A tous les membres de la famille Benali Khodja & Guennaz.

A tous nos amis(es) sans exception.

A tous nos collègues de Master 2 promotion 2022 Génie Biomédical.

Khaoula & Amel

Résumé

La maladie d'Alzheimer est une maladie neurodégénérative qui touche le cerveau dans le lobe temporal, exactement dans une petite structure appelée hippocampe qui commence par la perte de mémoire, des conversations...etc. Dans ce travail, nous avons réalisé un système d'aide au diagnostic de la maladie d'Alzheimer basé sur les algorithmes de l'apprentissage profond. Nous avons choisi de travailler avec les réseaux de neurones convolutionnels CNN, et l'un de ses modèles qui est AlexNet, pour classer les images IRM de notre base de données en CN, MCI et AD. Les résultats d'implémentation de ces deux architectures par MATLAB R2019a ont montrés que le modèle AlexNet est plus performant en termes d'indicateurs de performance que CNN.

Les mots clés : Maladie d'Alzheimer, Imagerie par Résonance Magnétique (IRM), L'apprentissage profond, CNN, AlexNet, AD, CN et MCI.

Abstract:

Alzheimer's disease is a neurodegenerative disease that affects the brain in the temporal lobe exactly in a small structure called hippocampus, which begins with memory loss, conversations...etc. In this work, we realized a diagnostic aid system for Alzheimer's disease based on deep learning algorithms. We chose to work with CNN convolutional neural networks and one of its models, which is AlexNet to classify the images MRI in our database into CN, MCI and AD. The implementation results of these two architectures by MATLAB R2019a showed that the AlexNet model is more efficient in terms of performance indicators than CNN.

Keywords: Alzheimer's disease, Magnetic Resonance Imaging (MRI), Deep Learning, CNN, AlexNet, AD, CN and MCI.

المخلص:

مرض الزهايمر هو مرض تنكس عصبي يصيب الدماغ في الفص الصدغي بالضبط في هيكل صغير يسمى الحصين ويبدأ بفقدان الذاكرة والمحادثات ... إلخ. في هذا العمل، أدركنا نظاماً مساعداً في التشخيص لمرض الزهايمر يعتمد على خوارزميات التعلم العميق. لقد اخترنا العمل مع شبكات CNN العصبية التلافيفية وأحد نماذجها، وهو AlexNet، لتصنيف صور التصوير بالرنين المغناطيسي من قاعدة بياناتنا إلى AD و CN و MCI. أظهرت نتائج تنفيذ هاتين البنيتين بواسطة MATLAB R2019a أن نموذج AlexNet أكثر كفاءة من حيث مؤشرات الأداء من CNN.

الكلمات المفتاحية: مرض الزهايمر، التصوير بالرنين المغناطيسي، التعلم العميق، شبكات العصبية التلافيفية.

Table des matières

Remerciements

Dédicaces

Résumé

Table de matières

Liste des figures

Liste des tableaux

Liste des abréviations

Introduction générale.....1

Chapitre 1: Contexte médical

1.1 Anatomie cérébrale.....	3
1.1.1 Encéphale.....	3
1.1.2 Moelle épinière	7
1.2 Quelques structures cérébrales d'intérêt.....	8
1.3 Maladies neurodégénératives	10
1.4 Maladie d'Alzheimer	10
1.4.1 Différents stades de l'Alzheimer	11
1.4.2 Diagnostic de la maladie d'Alzheimer.....	13
1.5 Notions de base de l'IRM.....	14
1.5.1 Excitation	15
1.5.2 Relaxation	16
1.5.3 Produit de contraste	17
1.5.4 Coupes d'IRM.....	18

Chapitre 2: Etat de l'art

2.1 Travaux antérieurs	20
2.2 Récapitulatif des méthodes de la classification de la maladie d'Alzheimer... 31	

Chapitre 3: Outils mathématiques

3.1 Définition de l'apprentissage profond (Deep Learning).....	37
3.2 Réseaux de neurones	38

3.2.1	Neurones biologiques	38
3.2.2	Réseaux de neurones artificiels.....	39
3.3	Classification des images médicales.....	40
3.4	Réseaux de neurones convolutionnels CNN	40
3.5	Différentes couches des réseaux de neurone convolutifs	42
3.5.1	Couche de convolution (CONV)	42
3.5.2	Couche de Pooling (POOL).....	43
3.5.3	Couche de correction ReLU	44
3.5.4	Couche entièrement connectée (fully-connected).....	45
3.6	Avantages des CNN.....	45
3.7	Inconvénients des CNN	46
3.8	Organigramme d'un CNN	46
3.9	Options de l'apprentissage.....	47
3.9.1	Optimiseurs	47
3.9.2	Epoque	47
3.9.3	Taux d'apprentissage (InitialLearnRate)	48
3.9.4	Taille de mini lots (Mini batch size).....	48
3.9.5	Ressources matérielles	48
3.10	Problème de sur-apprentissage et sous-apprentissage	48

Chapitre 4: Implémentation, résultats et discussion

4.1	Base de données.....	51
4.2	Logiciel et matériel	52
4.3	Langage de programmation utilisé	52
4.4	Intérêt du notre travail	53
4.5	Classification par CNN.....	54
4.5.1	Chargement de la base de données	54
4.5.2	Normalisation des données	54

4.5.3	Division de la base de données et visualisation des données	55
4.5.4	Définition de l'architecture du réseau CNN utilisé	56
4.5.5	Définition des options d'apprentissage.....	59
4.5.6	Entraînement du réseau.....	59
4.5.7	Résultats.....	60
4.5.8	Test de précision	64
4.5.9	Augmentation de données.....	64
4.5.10	Interprétation après augmentation de données.....	65
4.6	Classification par AlexNet.....	66
4.7	Evaluation des performances.....	69
4.8	Présentation de l'interface	73
	Conclusion générale.....	76
	Bibliographie	77

Liste des figures

Figure 1.1: L'encéphale.	4
Figure 1.2: Les deux hémisphères du cerveau.....	4
Figure 1.3: Les quatre lobes de l'hémisphère.....	5
Figure 1.4: Les trois matières principales du cerveau.	6
Figure 1.5: Le cervelet et le tronc cérébral.....	7
Figure 1.6: Coupe transversale de la moelle épinière.....	8
Figure 1.7: Les différentes structures composant les ganglions de la base.	9
Figure 1.8: Localisation de l'hippocampe.....	10
Figure 1.9: Comparaison d'un cerveau normal âgé (gauche) et du cerveau d'un patient atteint d'un MA (droite).	11
Figure 1.10: La rotation de spin autour de champ magnétique.	14
Figure 1.11: Le principe de l'excitation.	16
Figure 1.12: Le principe de la relaxation.....	17
Figure 1.13: Séquences IRM : (a) image en T1, (b) image en T2.....	18
Figure 1.14: Les trois coupes pour la visualisation du cerveau.....	18
Figure 3.1: Le Deep Learning est une sous-discipline du Machine Learning.....	37
Figure 3.2: Le neurone biologique.	39
Figure 3.3: Neurone biologique et neurone artificiel.	39
Figure 3.4: Architecture standard d'un réseau de neurone convolutionnel.	41
Figure 3.5: Schéma du parcours de la fenêtre de filtre sur l'image.....	42
Figure 3.6: Exemple de Max-Pooling et Average Pooling.....	44
Figure 3.7: La fonction ReLU.	44
Figure 3.8: L'architecture de Fully-connected.....	45
Figure 3.9: L'organigramme principal du CNN.	46
Figure 3.10: Le graphe de chaque état.....	50
Figure 4.1: (a) Image de classe AD, (b) image de classe CN et (c) image de classe MCI.	52
Figure 4.2: L'environnement MATLAB R2019a.	53
Figure 4.3: Les étapes d'implémentation de CNN.....	54
Figure 4.4: Image de taille 256*256.....	55
Figure 4.5: Résultat de la visualisation des données.	56
Figure 4.6: Résultat de l'entraînement du réseau avec la première architecture.	60

Figure 4.7: Résultat de l'entraînement du réseau avec la deuxième architecture.	61
Figure 4.8: Résultat de l'entraînement du réseau avec la troisième architecture.....	62
Figure 4.9: La deuxième architecture avec 12 couches.....	63
Figure 4.10: A gauche, image originale et à droite image après rotation.....	64
Figure 4.11: Courbe de précision et de perte après augmentation de données.....	65
Figure 4.12: Visualisation de l'architecture AlexNet.	66
Figure 4.13: Les étapes d'implémentation de réseau AlexNet.	66
Figure 4.14: Résultats d'entraînement de réseau AlexNet.....	68
Figure 4.15: Matrice de confusion.....	69
Figure 4.16: Matrice de confusion de CNN pour l'ensemble de test.....	70
Figure 4.17: Matrice de confusion de réseau AlexNet pour l'ensemble de test.	71
Figure 4.18: Interface graphique.	73
Figure 4.19: Résultat de l'interface graphique pour sujet sain.....	74
Figure 4.20: Résultat de l'interface graphique pour sujet atteint de troubles cognitifs légers.	75

Liste des tableaux

Tableau 2-1: Les méthodes de classification pour la maladie d'Alzheimer.	36
Tableau 3-1: Passage du neurone biologique vers le neurone artificiel.	40
Tableau 4-1: Les classes de la base de données.	54
Tableau 4-2: Résultats d'accuracy et de loss en fonction du nombre d'époques.	60
Tableau 4-3: Résultats d'accuracy et de loss en fonction du nombre d'époques.	61
Tableau 4-4: Résultats d'accuracy et de loss en fonction du nombre d'époques.	62
Tableau 4-5: Résultats d'accuracy et de loss en fonction du nombre d'époques.	65
Tableau 4-6: Résultats d'accuracy et de loss en fonction du nombre d'époques.	68
Tableau 4-7: Comparaison entre CNN et AlexNet.....	71
Tableau 4-8: Performances de notre méthode par rapport d'autres méthodes.	72

Liste des abréviations

AD : Alzheimer Disease

ADNI : Alzheimer's Disease Neuroimaging Initiative

Adam : Adaptive moment estimation

CNN : Convolutional Neural Network

CS : Control Subjects

CPU: Central Processing Unit

cMCI: converting MCI

DCNN: Deep Convolution Neural Network

DL: Deep Learning

DTI: Diffusion Tensor Imaging

DenseNet: Dense CNN

DNN: Deep Neural Network

DT : arbre de décision

EMCI : Early Mild Cognitive Impairment

FP: False Positive

FN: False Negative

GPU: Graphics Processing Unit

GMM : Model of Mixture Gaussian

GLM : modèle linéaire généralisé

HC : Les sujets sains

IA : Intelligence artificielle

IRM : Imagerie par Résonance Magnétique

IRMf : Imagerie par Résonance Magnétique fonctionnel

JADE : Java Agent Development Framework

KNN : K-nearest voisins

KSVM-DT : arbre de decision de la machine à vecteurs de support du noyau

LCR : Liquide Céphalo-Rachidien

LMCI : Late Cognitive Mild Impairment

MA : Maladie d'Alzheimer

MCI : Mild Cognitive Impairment

MRI : Magnetic Resonance Imaging

MD : Déments légers

MDD : Déments modérés
NC: Normal Control
OASIS: Open Access Series of Imaging Studies
RMN : Résonance Magnétique Nucléaire
RF : Random Forest
ROI: Region of Interest
RNN: Recurrent Neural Network
ResD : Resnet18 et Densenet121
Res-Net : Res-Network
ReLU: Rectified Linear Units
RF: Radio Frequency
SVM: Support Vector Machine
SSD: Single shot multi-box detector
SCNN: Siamese convolutional neural network
sMRI: Structural Magnetic Resonance Imaging
SMC: Significant Memory Concern
SGDM: Stochastic Gradient Descent with Momentum
TEP : Tomographie par Emission de Positons
TL: Transfer Learning
TSVM: The Twin Support Vector Machine
TRRA: Two stage Random Rand Augment
TDNN: Time Delay Neural Network
TP: True Positive
TN: True Negative
VMD: Very Mild Dementia
VGG: Visual Geometry Group
WM: White Matter

Introduction générale

Introduction générale

La maladie d'Alzheimer est un trouble neurologique progressif qui provoque le rétrécissement (atrophie) et la mort du cerveau. C'est la cause la plus fréquente de démence, et une condition qui implique une diminution persistante de la capacité de penser. Les premiers signes de la maladie comprennent l'oubli d'événements récents, ou de conversations, perte de la mémoire et de la capacité d'effectuer des tâches quotidiennes.

Grâce à l'imagerie cérébrale, nous pouvons connaître le degré de dégénérescence des cellules cérébrales. Il existe de nombreuses techniques d'imagerie cérébrale. Dans cette recherche, nous travaillerons avec l'imagerie par résonance magnétique (IRM). Elle utilise de fortes ondes radio et champs magnétiques pour créer une vue détaillée du cerveau. Grâce à l'IRM, un rétrécissement du cerveau peut apparaître dans les zones associées à la maladie d'Alzheimer.

Nous discuterons dans notre mémoire de trois stades de la maladie d'Alzheimer, donc comment déterminer, à partir d'images IRM du cerveau, déterminer si une personne est atteinte ou non de la maladie d'Alzheimer, et quel est le degré de la maladie ? C'est ce que des chercheurs ont développé, grâce à l'intelligence artificielle, des logiciels capables de détecter la maladie neurodégénérative (Alzheimer), en identifiant les changements se produisant dans des régions spécifiques du cerveau, et ils ont conçu un algorithme d'apprentissage en profondeur. Cet algorithme est basé sur les réseaux de neurones artificiels (RNA) qui reflètent la façon dont le cerveau calcule l'information.

Les modèles d'apprentissage en profondeur utilisent plusieurs algorithmes, dont celui que nous utiliserons dans notre recherche, qui est un réseau de neurones convolutif. C'est une technique qui permet aux ordinateurs de classer les images, en saisissant une image et reconnaître son contenu et la classer en une ou plusieurs classes sous forme de sorties comme par exemple, le classement des stades de la maladie d'Alzheimer AD (les sujets atteints d'Alzheimer), CN (les sujets sains), MCI (déficience cognitive légère). Dans un réseau convolutionnel, l'image d'entrée traverse une série de couches convolutionnelles, de Max Pooling, entièrement connectés, et se termine par la couche de sortie ou de résultats.

On a plusieurs techniques de classification, par exemple l'apprentissage en profond, fait partie de l'apprentissage automatique. Le but de notre travail est de développer un outil de classification des images IRM cérébrales, basé sur le réseau neuronal convolutionnel (CNN), pour classer trois stades de la maladie d'Alzheimer, en utilisant la base de données ADNI.

Introduction générale

Notre mémoire est organisé en quatre chapitres :

Dans le premier chapitre, nous fournirons des informations sur le cerveau et en quoi il consiste, ainsi que les caractéristiques de chacune de ses composantes, puis nous donnerons quelques notions sur les maladies neurodégénératives qui affectent le système nerveux, parmi lesquelles fait partie la maladie d'Alzheimer (MA), qui est le sujet de nos recherches. Nous aborderons également la technologie d'imagerie par résonance magnétique (IRM) et son fonctionnement, puisque c'est la modalité que nous avons utilisée.

Dans le deuxième chapitre, nous avons cité des travaux déjà réalisés liés à des méthodes de classification, afin de voir toutes les recherches sur le même thème que notre étude et de noter les méthodes les plus utilisées et les plus précises en termes de résultats. Donc nous allons présenter un état de l'art qui donne une vision générale sur les méthodes de classification de la maladie d'Alzheimer.

Dans le troisième chapitre, nous allons définir l'apprentissage en profond (Deep Learning), nous allons donc présenter les réseaux des neurones, et détailler les neurones biologiques et artificiels et comment obtenir ces derniers à partir d'un neurone biologique. Ensuite, nous aborderons la méthode de classification choisie : les réseaux de neurones convolutifs (CNN), les couches qui les composent de leur fonctionnement, et les avantages et inconvénients de cette méthode. Nous terminerons le chapitre par la présentation de notre organigramme et des différentes options que l'on a étudiées.

Dans le quatrième chapitre, nous commencerons par les bases de données que nous avons utilisées (ADNI), le matériel nécessaire pour notre implémentation, et le langage de programmation (MATLAB 2019a). Ensuite, nous présenterons et discuterons les résultats obtenus avec l'approche proposée pour classer les trois classes d'Alzheimer. Nous avons également comparé les résultats obtenus avec les deux architectures utilisées : CNN et AlexNet, pour déterminer la technique qui donne les meilleures performances, avec peu d'erreurs et moins de temps d'exécution, et nous avons terminé par la présentation de l'interface graphique.

Notre mémoire se termine par une conclusion générale, qui résume le travail que nous avons fait et présente les perspectives qui l'on peut faire dans le futur, pour améliorer les résultats obtenus.

Chapitre 1

Contexte médical

1 La maladie d'Alzheimer (MA) est une maladie neurodégénérative qui touche le cerveau, exactement le lobe temporel, et très précisément l'hippocampe. Dans ce chapitre, nous allons donc donner des notions de bases sur l'anatomie cérébrale et sur la maladie d'Alzheimer (définition, stades, diagnostic,...etc.), ainsi que la technique d'imagerie, que nous avons choisie : l'IRM (Imagerie par résonance magnétique).

1.1 Anatomie cérébrale

Le système nerveux correspond au système le plus complexe et le mieux organisé du corps. Il reçoit des informations provenant des organes sensoriels par le biais des nerfs, transmet ces informations par l'intermédiaire de la moelle épinière, et les traite dans le cerveau. Le système nerveux dirige les réactions de notre corps face au monde, il contrôle également la majeure partie de nos fonctions internes [1].

Il est constitué du système nerveux central est formé de substance grise et de substance blanche, le tout étant compris dans un tissu de soutien, la névroglie. Ses grandes unités morphologiques et fonctionnelles sont l'encéphale (protégé par la boîte crânienne) et la moelle épinière (incluse dans la colonne vertébrale). Le système nerveux périphérique, rassemble les nerfs, et est constitué de substance blanche [2].

1.1.1 Encéphale

L'encéphale (Figure 1.1) est le centre de commande du corps. Il reçoit et interprète constamment les signaux nerveux du corps et envoie de nouveaux signaux fondés sur ces informations. Il contient deux types de cellules [3] :

- Les neurones qui réceptionnent et qui envoient les influx nerveux.
- Les cellules gliales qui soutiennent, protègent et alimentent les neurones.

Il est constitué du cerveau, du cervelet et du tronc cérébral.

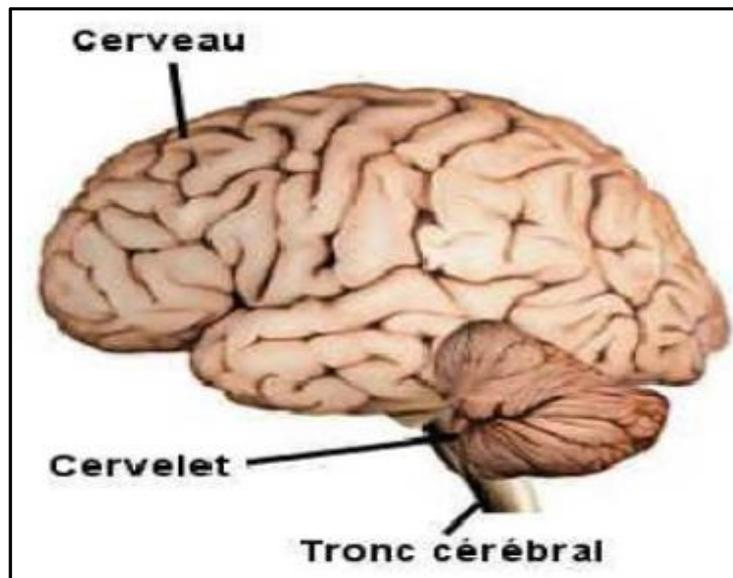


Figure 1.1: L'encéphale [4].

➤ Le cerveau

C'est la partie la plus volumineuse de l'encéphale, c'est une masse molle de 1500 g environ localisée dans la partie supérieure de l'encéphale, Il est divisé en 2 moitiés appelées hémisphère cérébral gauche et hémisphère cérébral droit (Figure 1.2). Ces 2 hémisphères sont reliés par un pont de fibres nerveuses appelé corps calleux [3].

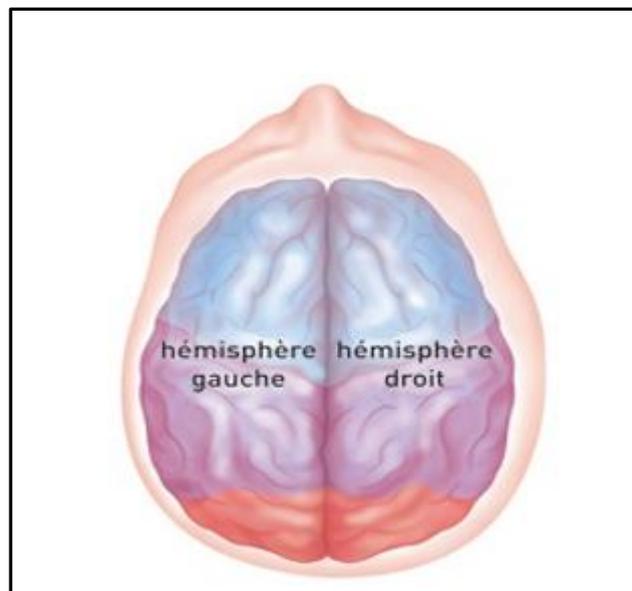


Figure 1.2: Les deux hémisphères du cerveau [5].

Chaque hémisphère est divisé en 4 sections appelées lobes qui comprennent les lobes frontal, pariétal, temporal et occipital (Figure 1.3).

- **Le lobe frontal** : impliqué dans les tâches cognitives supérieures comme la résolution de problèmes, la pensée, la planification et les émotions [6].
- **Le lobe pariétal** : qui intervient dans les processus sensoriels, l'attention et le langage, comme le touché la pression, la douleur, la température... [6].
- **Le lobe occipital** : à l'arrière du cerveau, il participe à l'information visuelle y compris dans la reconnaissance des formes et des couleurs [6].
- **Le lobe temporal** : qui joue un rôle important dans l'encodage des informations auditives et dans l'intégration des informations provenant des autres modalités sensorielles [6].

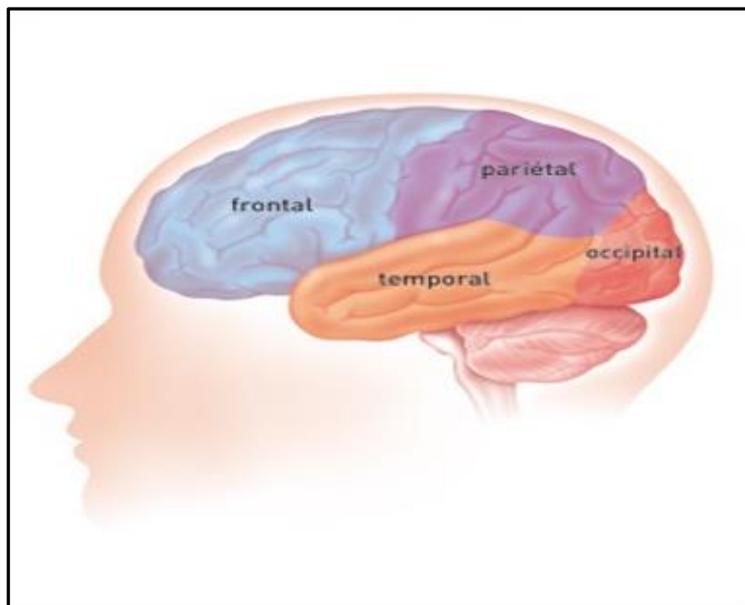


Figure 1.3: Les quatre lobes de l'hémisphère [5].

Le cerveau est composé de trois matières principales : la substance blanche, la substance grise et le liquide céphalo rachidien (Figure 1.4).

- **La matière blanche** est constituée des fibres des cellules nerveuses appelées axones, qui permettent la transmission de l'information traitée, au niveau de la matière grise [7].
- **La matière grise** contient le corps des cellules nerveuses et est répartie en deux types de structures : le cortex et les noyaux [7].

- **Le liquide céphalo rachidien (LCR)** est un liquide clair et aqueux qui entoure et protège le cerveau et la moelle épinière et leur sert de coussinet. Le LCR transporte aussi les éléments nutritifs du sang au cerveau et il en élimine les déchets. Le LCR circule dans des cavités appelées ventricules et à la surface du cerveau et de la moelle épinière [5].

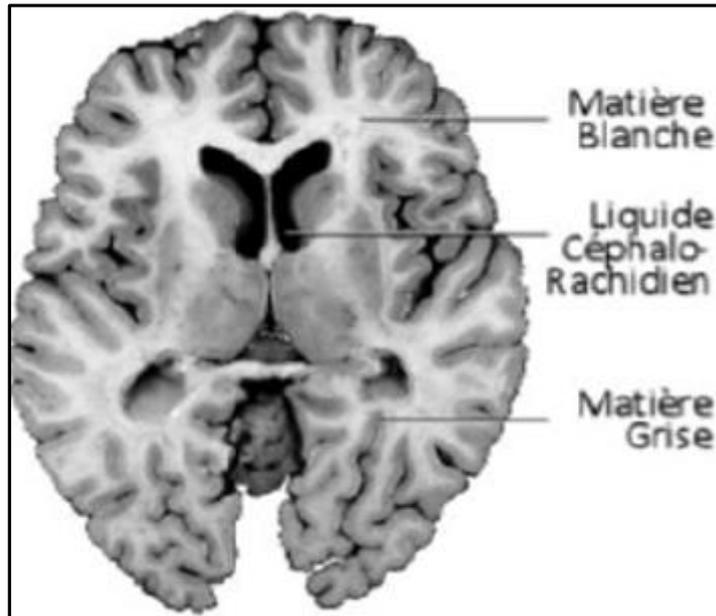


Figure 1.4: Les trois matières principales du cerveau [8].

➤ Le cervelet

Le cervelet est situé sous le cerveau, à l'arrière du crâne, dans la région occipitale. C'est un centre nerveux qui communique avec l'ensemble du système nerveux. Il traite les informations qu'il reçoit de la moelle épinière et du cerveau, pour donner une organisation chronologique et temporo-spatiale aux organes moteurs du mouvement [9].

Le cervelet assure la régulation, la coordination et la synchronisation des activités musculaires de mouvements volontaires, tels que la marche ou la course. C'est aussi une horloge interne qui marque le temps. Il informe le cerveau des adaptations à mettre en œuvre pour initier le mouvement, l'arrêter, le répéter ou en diminuer la vitesse [9].

Le cervelet communique avec les organes de la vision et de l'audition. Il intervient indirectement dans les fonctions d'apprentissage (processus cognitif) et de la mémorisation [9].

➤ Le tronc cérébral

C'est une partie du système nerveux central servant de relai entre les structures de l'encéphale et la moelle épinière. Sur un plan anatomique, on le situe devant le cervelet et juste en dessous du cerveau. Il se divise en plusieurs parties : le mésencéphale en haut, le pont également appelé protubérance annulaire au milieu et le bulbe rachidien à sa partie inférieure [10].

Le tronc cérébral (Figure 1.5) assure des fonctions régulatrices sur plusieurs plans notamment le plan sensitif avec la perception de la douleur, végétatif avec la régulation du rythme cardiaque et de la fonction respiratoire... Il donne aussi naissance à de nombreux nerfs assurant des fonctions au niveau de la tête, notamment sensorielles [10].

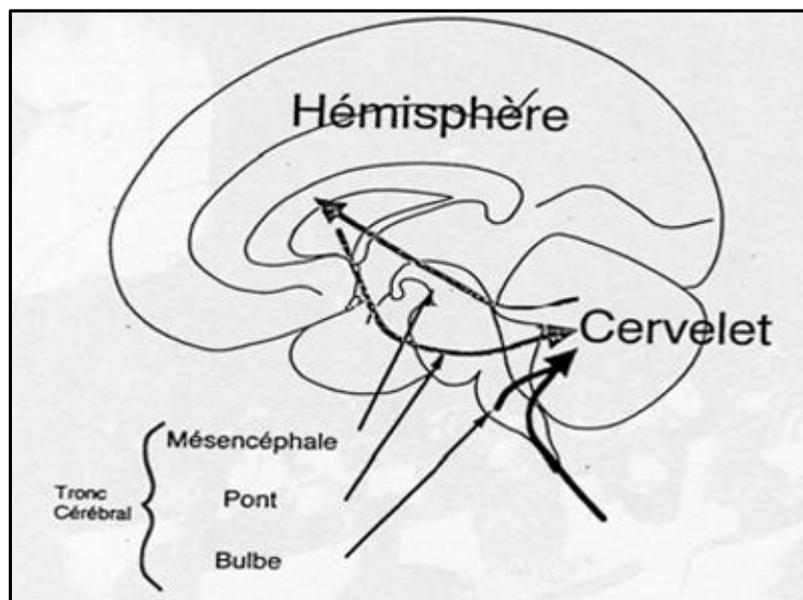


Figure 1.5: Le cervelet et le tronc cérébral [9].

1.1.2 Moelle épinière

La moelle épinière (Figure 1.6) est aussi appelée la moelle spinale. Il s'agit d'une longue et fragile structure tubulaire qui commence à l'extrémité inférieure du tronc cérébral et se termine au niveau des premières vertèbres lombaires. Sa longueur est de 40 à 45 cm et son diamètre est de 1 cm et elle a pour fonction la transmission des messages nerveux entre le cerveau et le reste du corps ainsi que le contrôle de certains réflexes [11].

Comme l'encéphale, la moelle épinière est protégée et recouverte par les méninges avec le liquide céphalo rachidienne LCR qui circule dans l'espace-sous arachnoïdienne. En coupe transversale, on peut distinguer deux régions :

- **Matière blanche** : située en périphérie elle contient des axones, des neurones sensoriels et des motoneurones et qui correspond au passage des grandes voies motrices sensitives, cérébelleuses et extrapyramidale [11].
- **Matière grise** : elle est en forme de papillon au centre, elle est constituée de corps cellulaires des neurones [11].

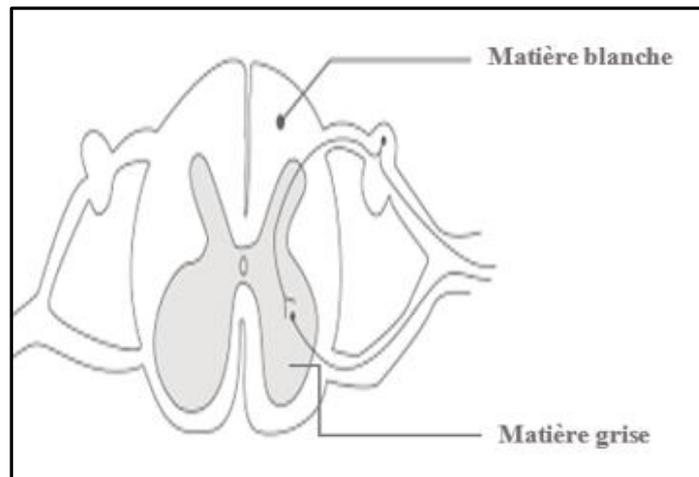


Figure 1.6: Coupe transversale de la moelle épinière [12].

1.2 Quelques structures cérébrales d'intérêt

Situées au centre du cerveau, les petites structures impliquées sont principalement l'hypothalamus, le noyau accumbens (centre du plaisir, appartenant aux ganglions de la base) et l'amygdale (centre des émotions comme la peur ou le stress) et l'hippocampe [13].

- **Les ganglions de base** : Les ganglions de la base, ou noyaux gris centraux, sont un ensemble de structures sous corticales, historiquement connues par leurs fonctions motrices, et leurs implications dans les pathologies neurodégénératives, affectant le contrôle exécutif du mouvement, telles que la maladie de Parkinson [14]. Anatomiquement, les ganglions de la base sont composés de plusieurs noyaux (Figure 1.7) :

- **Le striatum** : qui regroupe le noyau caudé, le putamen et le striatum ventral(également appelé noyau accumbens) [14].
- **Le globus pallidus** : composé de deux segments, interne et externe [14].

- Le noyau sous-thalamique [14].
- La substance noire [14].

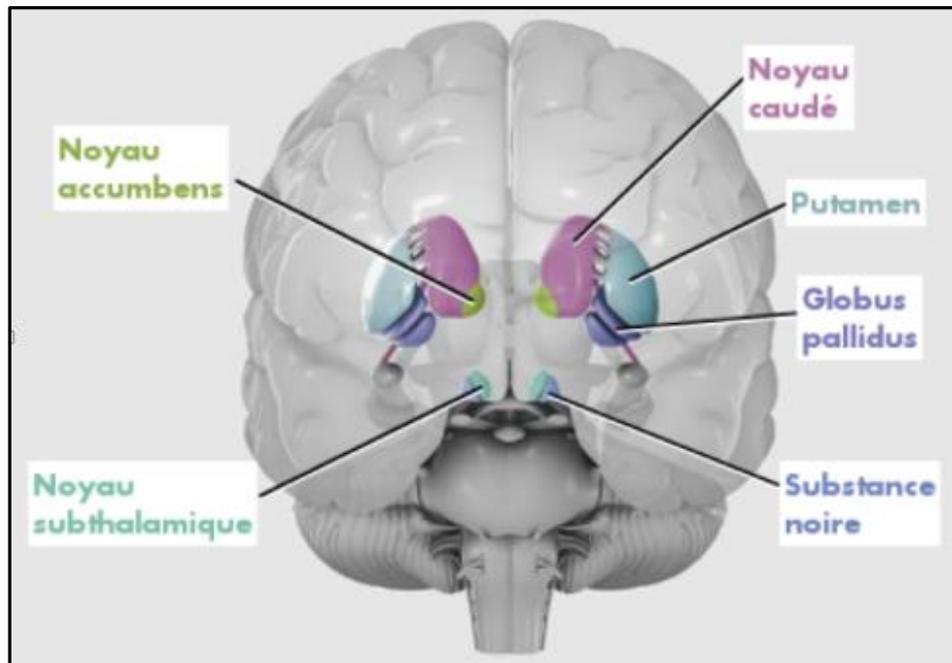


Figure 1.7: Les différentes structures composant les ganglions de la base [15].

- **L'hippocampe** : L'hippocampe (Figure 1.8) est une petite partie du cerveau de la cinquième circonvolution temporale précisément, qui se situe à l'intérieur des lobes temporaux et appartient au système limbique qui jouent un rôle important dans le comportement, la mémoire, etc.... [16].

L'hippocampe est un biomarqueur, car il s'agit d'un des marqueurs de la maladie d'Alzheimer dans ses premiers stades. On sait qu'avoir un petit hippocampe est facteur de risque de développer une maladie d'Alzheimer [16].

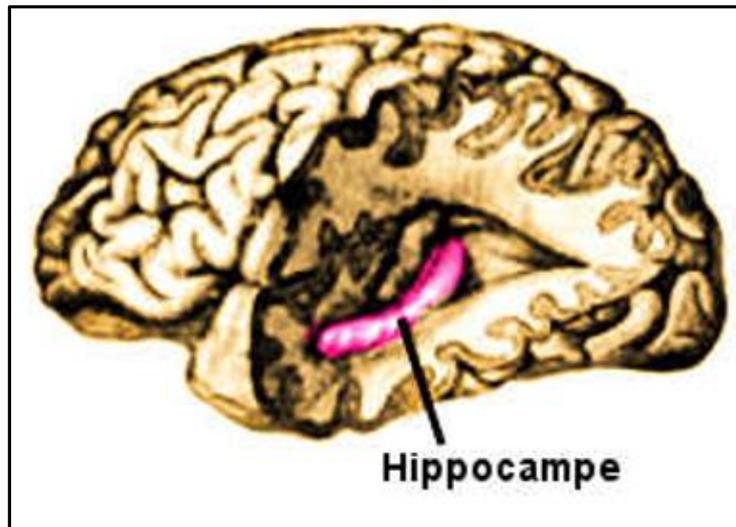


Figure 1.8: Localisation de l'hippocampe [17].

1.3 Maladies neurodégénératives

Les maladies neurodégénératives sont des maladies chroniques invalidantes à évolution lente et discrète. Elles provoquent généralement une détérioration du fonctionnement des cellules nerveuses, en particulier les neurones, pouvant conduire à la mort cellulaire telle que la maladie d'Alzheimer, la maladie de Parkinson, l'épilepsie, la sclérose en plaques, les tumeurs cérébrales et la chorée de Huntington [18].

1.4 Maladie d'Alzheimer

La maladie d'Alzheimer (MA) (Figure 1.9) est une maladie neuro dégénérative (Atteinte cérébrale progressive conduisant à la mort neuronale) caractérisée par une perte progressive de la mémoire et de certaines fonctions intellectuelles (cognitives) conduisant à des répercussions dans les activités de la vie quotidienne [19].

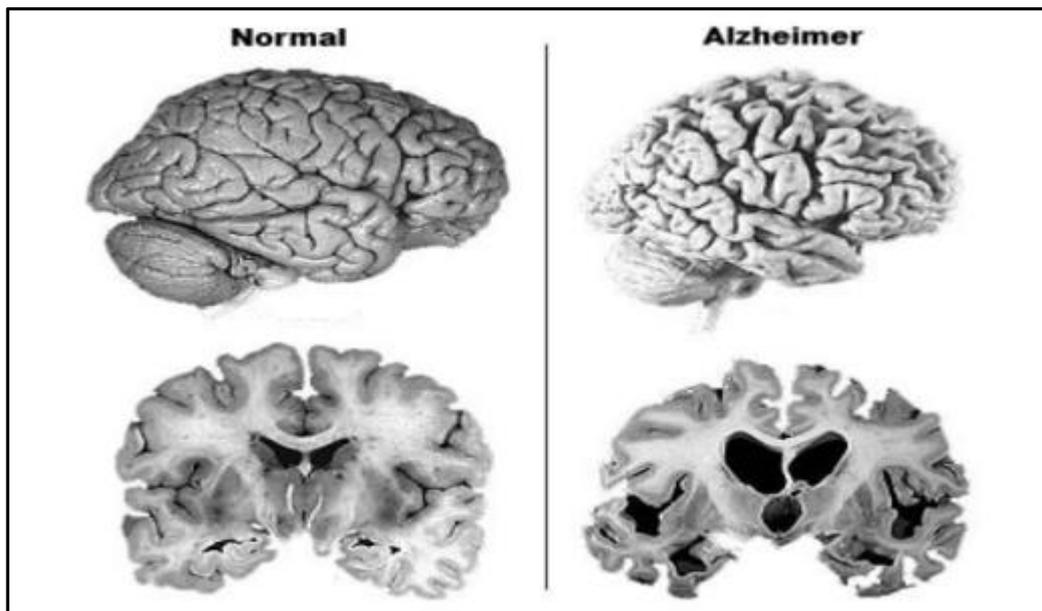


Figure 1.9: Comparaison d'un cerveau normal âgé (gauche) et du cerveau d'un patient atteint d'un MA (droite) [20].

La maladie d'Alzheimer se caractérise par l'apparition de lésions bien particulières, qui envahissent progressivement le cerveau et détruisent ses cellules, les neurones. Les neurones de l'hippocampe, la région qui contrôle la mémoire, sont les premiers touchés [21].

1.4.1 Différents stades de l'Alzheimer

Les différents stades de la maladie d'Alzheimer sont divisés de différentes façons par différents chercheurs, chaque stade à ses propres caractéristiques [22] :

- **Stade 1 : pas de déclin cognitif**

À ce stade, la personne n'éprouve pas de difficultés dans la vie quotidienne. Elle ne présente aucun symptôme de la maladie d'Alzheimer : ni trouble de mémoire ni changements de comportement, caractéristiques de la maladie.

- **Stade 2 : déclin cognitif très léger**

Ce stade décrit les pertes de mémoire normales associées au vieillissement :

- Oublier des noms.
- Ne plus se souvenir où l'on a laissé ses clés.

Les aidants familiaux ne remarquent généralement pas ces très légers déficits cognitifs.

- **Stade 3 : déclin cognitif léger**

Lorsque les pertes de mémoire et les troubles cognitifs deviennent plus fréquents et commencent à être remarqués par les aidants, la personne atteint ce qu'on appelle le stade du « déficit cognitif léger ».

Les symptômes souvent observés sont :

- Légère difficulté à se concentrer.
- Baisse de performance.
- Difficulté à trouver les bons mots.
- Répétitions verbales.
- Tendance à s'égarer plus souvent.

- **Stade 4 : déclin cognitif modéré**

À ce point, la personne présente clairement des signes de déficit mental et cognitif, indiquant un début de démence ou de maladie d'Alzheimer.

Les symptômes mentionnés au stade 3 se renforcent :

- Déclin de la mémoire des événements récents.
- Difficultés à se concentrer.
- Difficultés à conduire ou à se rendre seul quelque part.
- Difficultés à gérer ses finances.
- Difficultés à accomplir précisément des tâches complexes.

- **Stade 5 : déclin cognitif relativement grave**

À partir de ce stade de la maladie d'Alzheimer, le patient risque de ne plus être capable de s'acquitter normalement des tâches du quotidien.

- Il a ainsi besoin d'aide pour se laver, s'habiller, préparer les repas.
- Les problèmes de mémoire sont de plus en plus sérieux et touchent des aspects importants de la vie : le patient peut oublier son adresse, son numéro de téléphone, le jour ou l'endroit où il se trouve.

- **Stade 6 : déclin cognitif grave**

Ce stade se caractérise par un besoin d'aide accru du patient atteint de la maladie d'Alzheimer, même pour effectuer des tâches simples du quotidien : s'habiller, manger, utiliser les toilettes et assurer son hygiène corporelle.

- **Stade 7 : déclin cognitif très grave**

À ce stade, le patient n'est pratiquement plus capable de parler ou de communiquer.

- Il a besoin d'aide pour presque toutes les activités du quotidien.
- Il perd souvent ses capacités psychomotrices, par exemple la marche.

1.4.2 Diagnostic de la maladie d'Alzheimer

Le diagnostic de la maladie d'Alzheimer repose sur le couplage de plusieurs examens [23] :

- Un examen clinique du patient.
- Des tests cognitifs (de mémoire, exercices sur le langage, etc.)
- L'imagerie cérébrale.
- L'analyse de biomarqueurs du liquide céphalorachidien.

➤ **L'imagerie cérébrale**

L'imagerie cérébrale fait partie intégrante de l'exploration d'une démence. Elle recherche des causes éventuellement curables, comme les tumeurs, des signes positifs de démence neuro-dégénératives, comme une atrophie de localisation évocatrice, ou des lésions vasculaires [23]. Les techniques d'imagerie utilisées dans le diagnostic de la maladie d'Alzheimer sont l'imagerie par résonance magnétique et la tomographie par émission de positons.

- **L'imagerie par résonance magnétique (IRM)** : permet d'observer le volume du cerveau et de ses différentes régions. La maladie se caractérise par une atrophie de certaines structures cérébrales comme l'hippocampe, première région atteinte par la maladie et une réduction globale du volume cérébral. De nouveaux « traceurs », des molécules marquées et détectables par imagerie, permettent aujourd'hui de visualiser les lésions dans le cerveau des malades [23].
- **La tomographie par émission de positons (TEP)** : permet une évaluation plus précoce et plus spécifique. Elle permet de visualiser une baisse de la consommation de glucose dans certaines régions du cerveau, qui indique une diminution pathologique de l'activité des neurones dans ces régions [23].

1.5 Notions de base de l'IRM

L'IRM est un examen qui permet d'obtenir des vues en deux ou trois dimensions de l'intérieur de corps. Elle donne des informations sur des lésions qui ne sont pas visibles sur la radiographie standard, l'échographie ou le scanner [24].

L'IRM est basée sur le principe de la résonance magnétique nucléaire (RMN), elle utilise un champ magnétique 'les aimants' et des ondes radio. Le terme "Nucléaire" du sigle RMN, vient du fait qu'on s'intéresse ici à une propriété particulière de certains noyaux d'atomes. En effet, ce terme vient du latin "nucleus" qui signifie "noyau". Les noyaux atomiques sont composés de protons et de neutrons (les nucléons). Or, la physique quantique a montré que chaque nucléon est animé d'un mouvement de rotation axiale qui crée autour de lui un petit champ magnétique et donc une "mini-aimantation" [25].

Les physiciens parlent alors de "spin". Au niveau du noyau, ce spin s'annule si le noyau possède un nombre pair de charge. En revanche, le spin se répercute sur le noyau s'il y a un nombre impair de nucléons, ce qui confère ainsi des propriétés magnétiques au noyau [25].

En IRM on s'intéresse principalement au noyau d'hydrogène, car il est très présent dans le corps humain, étant donné qu'on le retrouve dans les molécules d'eau (H₂O). Il ne possède qu'un seul proton [25].

En présence d'un champ magnétique externe B_0 uniforme, constant et suffisamment important, les moments magnétiques μ des noyaux d'hydrogène se mettent à tourner autour de la direction du champ magnétique externe B_0 selon un angle donné (Figure 1.10). Leurs mouvements sont analogues à ceux des toupies et ils décrivent des cônes de révolution autour de l'axe de B_0 [26].

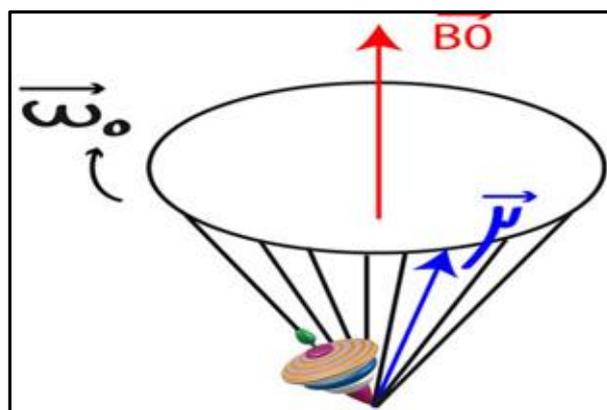


Figure 1.10: La rotation de spin autour de champ magnétique [26].

L'apparition de ce mouvement de rotation des spins, sous l'influence du champ magnétique externe B_0 , est appelé mouvement de précession [26].

1.5.1 Excitation

L'onde RF provoque une bascule de l'aimantation tissulaire, résultante d'un groupe de spins placés dans un champ magnétique. Cette bascule est liée à un transfert d'énergie vers le système de spins. Au niveau quantique, elle se traduit par une modification des niveaux énergétiques des spins (passage de l'état de basse énergie "parallèle" vers le niveau de haute énergie "antiparallèle") et de leurs phases [27].

L'angle de bascule de l'aimantation tissulaire dépend de l'intensité et de la durée pendant laquelle est appliquée l'onde RF. Pour une représentation mathématique plus simple, on étudie la bascule dans un repère XYZ, tournant à la fréquence de précession [27].

On peut décomposer l'aimantation tissulaire en une composante longitudinale (selon l'axe Z, dans l'axe de B_0) et une composante transversale. La phase d'excitation (Figure 1.11), et la bascule, se traduisent par une diminution de l'aimantation longitudinale (qui peut aller jusqu'à s'inverser), et l'apparition d'une aimantation transversale (sauf pour une bascule à 180°) [27].

L'aimantation longitudinale est la traduction de la différence de population entre spins "parallèles" et "antiparallèles". L'aimantation transversale est la traduction de la mise en phase plus ou moins complète des spins [27].

Si l'on prend l'exemple d'une onde RF 90° : il n'y a plus de composante longitudinale car il y a égalisation des populations "parallèle" et "antiparallèle". Par contre, il apparaît une composante transversale car les spins sont mis en phase [27].

- La composante longitudinale de l'aimantation tissulaire dépend de la différence entre le nombre de spins "parallèles" et "antiparallèles" [27].
- La composante transversale de l'aimantation tissulaire dépend de la mise en phase plus ou moins complète des spins [27].

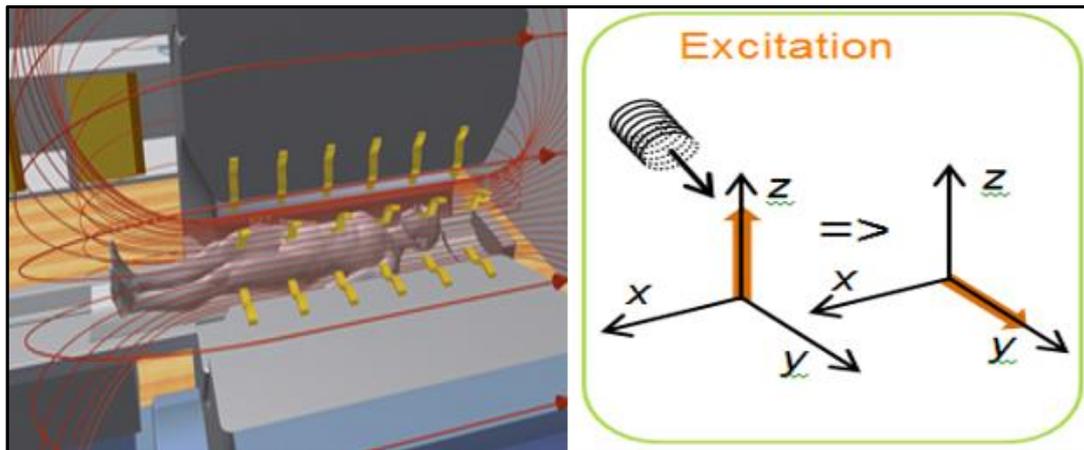


Figure 1.11: Le principe de l'excitation [25].

1.5.2 Relaxation

La relaxation (Figure 1.12) correspond au retour à l'équilibre de l'aimantation tissulaire. Elle s'accompagne d'une émission d'énergie sous la forme d'ondes RF qui constituent le signal enregistré en RMN. Elle se décompose en 2 phénomènes obéissant à des mécanismes très différents [28] :

- La relaxation longitudinale :** La repousse longitudinale correspond au retour au niveau de basse énergie ("parallèle") des spins excités. C'est la relaxation spin-réseau. La croissance de l'aimantation longitudinale lors de la relaxation suit une courbe exponentielle. Elle est caractérisée par le temps T_1 . Le T_1 correspond au temps nécessaire pour que l'aimantation longitudinale retourne à 63 % de sa valeur finale. Le temps T_1 est de l'ordre de 200 à 3000 ms pour un champ de 1,5 Tesla. Il est caractéristique des tissus et dépend de la mobilité des molécules où sont engagés les noyaux d'hydrogène. Le temps T_1 est plus court pour de grosses molécules.
- La relaxation transversale :** est due au déphasage des spins : le déphasage est lié aux interactions spins-spins qui créent des hétérogénéités de champ, et donc de fréquence de précession. Les spins n'ayant pas exactement la même fréquence, ils se déphasent rapidement. Cette chute de l'aimantation transversale suit une courbe exponentielle décroissante caractérisée par le temps T_2 . Le T_2 correspond au temps mis par l'aimantation transversale pour revenir à 37 % de sa valeur initiale. La relaxation transversale est beaucoup plus rapide que la relaxation longitudinale : T_2 est toujours plus court ou égal à T_1 .

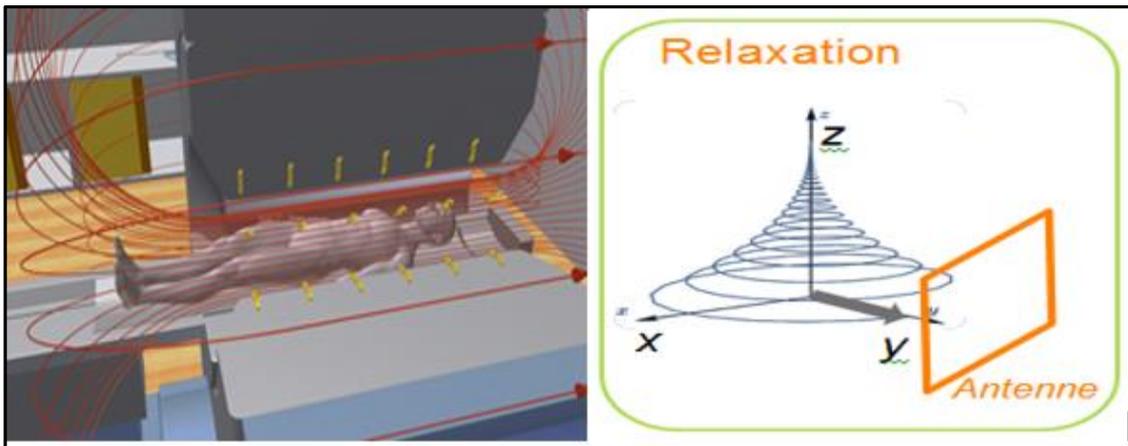


Figure 1.12: Le principe de la relaxation [25].

1.5.3 Produit de contraste

Les produits de contraste sont des médicaments injectés dans le corps pour augmenter la visualisation d'un tissu par rapport à son environnement [29].

En IRM, on utilise des produits à base de gadolinium qui accélèrent la relaxation des protons de l'eau [29], et il y a deux types de relaxation donc on distingue deux types de contraste (Figure 1.13) :

- **Contraste en T1** : on peut voir la graisse de couleur très blanche, le liquide céphalorachidien de couleur sombre, la substance grise apparaît en gris sombre et la substance blanche apparaît en gris clair [24].
- **Contraste en T2** : la graisse est moins blanche, le liquide céphalorachidien est sombre, la matière grise est gris claire, et la substance blanche est gris sombre [24].

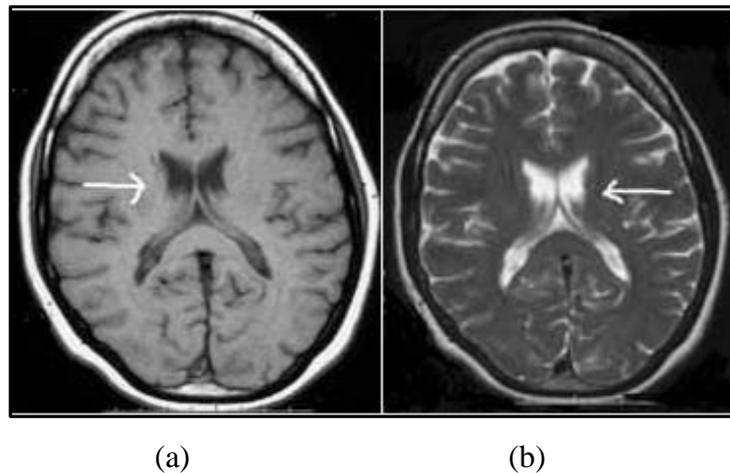


Figure 1.13: Séquences IRM : (a) image en T1, (b) image en T2 [30].

1.5.4 Coupes d'IRM

En acquisition IRM on a 3 sortes de coupe (Figure 1.14) :

- **Coupe coronale ou frontale** : ce sont des coupes parallèles à la colonne vertébrale vue de face du cerveau [24].
- **Coupe sagittale 'médiane'** : c'est coupe parallèle à la colonne vertébrale, vue du côté latérale du cerveau [24].
- **Coupe axiale** : c'est une coupe du corps humain perpendiculaire à la colonne vertébrale [24].

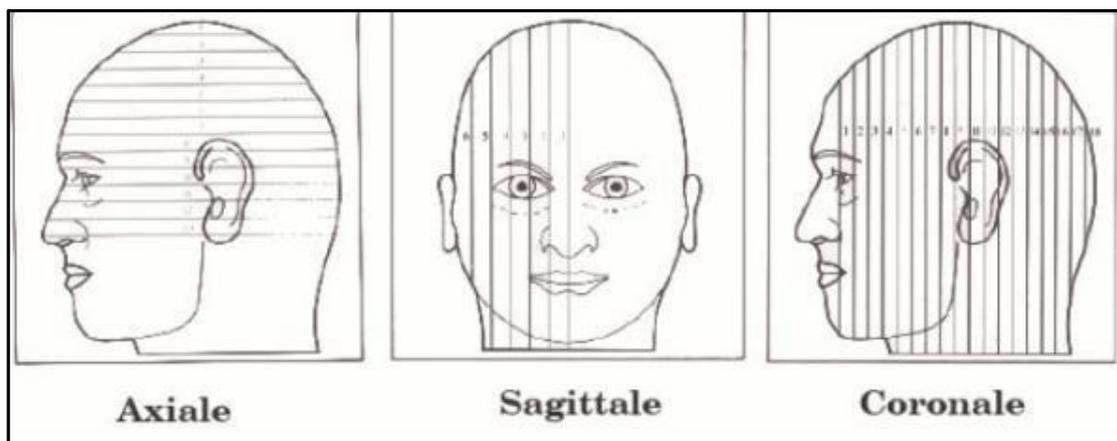


Figure 1.14: Les trois coupes pour la visualisation du cerveau [7].

Discussion

Nous avons présenté brièvement, dans ce chapitre, l'anatomie du système nerveux et quelques notions sur la maladie d'Alzheimer nécessaires à la compréhension de ce mémoire.

Le chapitre suivant présente les principales méthodes existantes pour la classification de la maladie d'Alzheimer et permet ainsi de situer notre méthode par rapport à la littérature.

Chapitre 2

Etat de l'art

2

Dans ce chapitre, nous présentons les méthodes de classification de modèles les plus largement étudiés, pour l'analyse d'images cérébrales, et pour le diagnostic de la maladie d'Alzheimer. Grâce à l'imagerie par résonance magnétique et à l'étude de base de données d'images, il est possible de donner des informations sur les lésions en cours et le degré de dégradation du cerveau.

2.1 Travaux antérieurs

De nombreux chercheurs ont discuté des techniques utilisées et appliquées pour la détection et la classification de la maladie d'Alzheimer (MA), avec l'utilisation de l'IRM (Imagerie par résonance magnétique). Nous allons dans ce qui suit, passer en revue un certain nombre d'articles parus entre 2007 et 2022.

- **F. Shi, T. Jiang, Y. Wang et al. (2007) [31]** : cet article cherche à évaluer les changements régionaux critiques associés à la MA dans l'hippocampe, à l'aide de méthodes d'apprentissage automatique. Des images IRM à haute résolution ont été acquises à partir de 19 patients atteints de MA et de 20 sujets témoins sains de même âge et sexe. Les changements régionaux des hippocampes bilatéraux ont été caractérisés à l'aide de méthodes de cartographie anatomique informatique. Une méthode de sélection de caractéristiques pour la machine à vecteurs de support et la validation croisée Leave-1-out a été introduite pour déterminer les différences de forme régionales qui minimisent le taux d'erreur dans les ensembles de données.

- **N. Belmokhter, N. Benamrane (2012) [32]** : ils ont proposé une méthode basée sur des machines à vecteurs de support binaire (SVM) pour distinguer les patients atteints de la maladie d'Alzheimer (MA), les patients atteints de troubles cognitifs légers (MCI) et les sujets témoins âgés (CS) à partir des données d'imagerie par résonance magnétique (IRM). Afin de réduire le temps de calcul total, ils ont utilisé la plateforme multi-agents JADE (Java Agent Development Framework). Les résultats montrent que la meilleure précision de l'ensemble de l'algorithme (100%) a été obtenue lors de l'utilisation de processus d'extraction de caractéristiques pour SVM avec un noyau polynomial de degré 3.

- **H. Suk, D. Shen (2013) [33]** : dans cet article, ils ont proposé une représentation de caractéristiques basée sur l'apprentissage profond avec un auto-encodeur empilé. À l'aide de l'ensemble de données ADNI, ils ont mené des expériences montrant que la méthode proposée est précise à 95,9 %, 85,0 % et 75,8 % pour le diagnostic AD, MCI et MCI-converter.

- **F. Liu, Ch .Shen (2014) [34]** : dans ce travail, les auteurs ont proposé d'apprendre des caractéristiques d'images issues de réseaux convolutionnels profonds, en utilisant l'apprentissage non supervisé et supervisé. L'apprentissage en profondeur est devenu un outil puissant dans la communauté de l'apprentissage automatique, et a été appliqué avec succès à diverses tâches. Ils ont proposé donc d'exploiter les caractéristiques profondes des images IRM, basées sur un grand réseau de neurones convolutionnels (CNN) pré-entraîné pour la classification AD et MCI, ce qui épargne l'effort du processus d'annotation manuelle des ROI.

- **Z. Yu-Dong, W. Shuihua, D. Zhengchao (2014) [35]** : ils ont proposé une méthode basée sur arbre de décision de la machine à vecteurs de support du noyau (kSVM-DT) pour distinguer les patients atteints de la maladie d'Alzheimer (MA), les patients atteints de troubles cognitifs légers (MCI) et les sujets témoins âgés (CS), à partir des données d'imagerie par résonance magnétique (IRM). Les résultats montrent que le kSVM-DT proposé atteint une précision de classification de 80 %, mieux que 74 % de la méthode sans noyau.

- **S. Saman, T. Ghassem (2016) [36]** : dans cet article, ils ont utilisé un réseau neuronal convolutif pour distinguer un cerveau Alzheimer d'un cerveau normal et sain. L'importance de la classification de ce type de données médicales, réside dans son potentiel à développer un modèle ou un système prédictif, afin de reconnaître les symptômes de la maladie d'Alzheimer, par rapport à des sujets normaux, et d'estimer les stades de la maladie. En utilisant le réseau de neurones convolutifs (CNN) et la célèbre architecture LeNet-5, ils ont réussi à classer les données d'IRM fonctionnelles des sujets Alzheimer, à partir de témoins normaux, avec une précision des données de test qui a atteint 96,85 %. Cette expérience suggère que les caractéristiques invariantes de décalage et d'échelle extraites par CNN, suivies d'une classification d'apprentissage en profondeur, représentent la méthode la plus

puissante, pour distinguer les données cliniques des données saines en IRMf.

- **K. Gunawardena, R. Rajapakse, N. Kodikara et al. (2017) [37]** : cette étude consiste en deux expériences principales. Ces deux expériences ont été mises en œuvre à l'aide de l'ensemble de données ADNI (Alzheimer's Disease Neuroimaging Initiative). Ils ont vérifié comme première expérience, que la méthode existante la plus performante est Support Vector Machine. Une technique basée sur l'apprentissage en profondeur (réseau de neurones convolutifs) a été proposée comme deuxième expérience. Le modèle de réseau neuronal convolutif (CNN) proposé, a été testé à l'aide de différentes méthodes de segmentation d'images et de différents ensembles de données.

- **M. Hon, N.M. Khan (2017) [38]** : ils ont appliqué l'apprentissage par transfert, où des architectures de pointe telles que VGG et Inception sont initialisées avec des poids pré-entraînés, à partir de grands ensembles de données de référence, constitués d'images naturelles, et la couche entièrement connectée est recyclé avec seulement un petit nombre d'images IRM.

- **I. Jyoti, Y. Zhang (2017) [39]** : cet article présente un nouveau modèle d'apprentissage en profondeur qui est les réseaux de neurones convolutifs, pour la détection et la classification multi-classes, de la maladie d'Alzheimer, à l'aide de données d'IRM cérébrales. Les résultats obtenus sont très satisfaisants. Ils ont trouvé 71,25% et 73,25% comme indice de performance, pour 5 et 10 époques respectivement.

- **N. Amoroso, D. Diacono, A. Fanizzi et al. (2018) [40]** : ce travail présente une stratégie de classification basée sur la sélection des caractéristiques de la forêt aléatoire, et la classification du réseau neuronal profond ,en utilisant une cohorte mixte comprenant quatre classes , à savoir HC, AD, MCI et cMCI, pour entraîner le modèle. De plus, ils ont comparé cette approche avec une nouvelle stratégie de classification basée sur la logique floue apprise sur une cohorte mixte comprenant uniquement HC et AD. Les DNN atteignent une précision de classification nettement supérieure à celle des autres stratégies d'apprentissage automatique.

➤ **F. Lia, M. Liu (2018) [41]** : cet article propose une méthode de classification basée sur des réseaux de neurones convolutifs denses à clusters multiples (DenseNets) pour apprendre les différentes caractéristiques locales des images cérébrales IRM, qui sont combinés pour la classification AD.

Principe de méthode est comme suit :

1. L'image complète du cerveau est d'abord partitionnée en différentes régions locales.
2. Un certain nombre de patches sont extraits de chaque région et regroupés en différents clusters.
3. Plusieurs clusters DenseNets sont conçus pour apprendre les fonctionnalités au niveau du patch qui sont ensuite agrégées pour les représentations au niveau de la région.
4. La classification finale des images est faite en combinant les représentations des différentes régions.
5. Les caractéristiques des images cérébrales IRM sont progressivement apprises des patches locaux au niveau global de l'image pour la tâche de classification.

➤ **I. Jyoti, Z. Yanqing (2018) [42]** : cet article propose un réseau de neurones convolutionnels profonds pour le diagnostic de la maladie d'Alzheimer à l'aide de l'analyse des données d'IRMs cérébrales. Alors que la plupart des approches existantes effectuent une classification binaire, ce modèle peut identifier différents stades de la maladie d'Alzheimer, et obtient des performances supérieures pour le diagnostic précoce. Les auteurs ont mené de nombreuses expériences, pour démontrer que ce modèle surpassait les bases comparatives sur l'ensemble de données Open Access Series of Imaging Studies.

➤ **T. Jo, K. Nho, A.J. Saykin (2019) [43]** : l'application de l'apprentissage en profondeur à la détection précoce et à la classification automatisée de la maladie d'Alzheimer (MA), a récemment attiré une attention considérable, car les progrès rapides des techniques de neuroimagerie ont généré des données de neuroimagerie multimodales à grande échelle. Les approches d'apprentissage en profondeur, telles que le réseau neuronal convolutif (CNN) ou le réseau neuronal récurrent (RNN),

qui utilisent des données de neuroimagerie sans prétraitement, pour la sélection des caractéristiques, ont donné des précisions allant jusqu'à 96,0 % pour la classification AD et 84,2 % pour la prédiction de conversion MCI.

- **F. Lia, M. Liu (2019) [44]** : cet article propose un réseau neuronal hybride convolutionnel et récurrent, pour une analyse plus détaillée de l'hippocampe, à l'aide d'images MR structurales dans la MA. Les DenseNets sont construits sur les patches extraits d'images de l'hippocampe interne et externe pour apprendre les caractéristiques d'intensité et de forme. Le réseau neuronal récurrent (RNN) est mis en cascade pour combiner les caractéristiques des hippocampes gauche et droit et apprendre les caractéristiques de haut niveau pour la classification des maladies.

- **H. Wang, Y. Shen, S. Wang et al. (2019) [45]**: cet article propose un ensemble de réseaux convolutifs 3D densément connectés (3D-DenseNets), pour le diagnostic AD et MCI. Tout d'abord, des connexions denses ont été introduites pour maximiser le flux d'informations, où chaque couche se connecte directement à toutes les couches suivantes. Ensuite, une méthode de fusion basée sur les probabilités a été utilisée pour combiner 3D-DenseNets avec différentes architectures.

- **M. Shahbaz, A. Shahzad, A. Guergachi et al. (2019) [46]** : dans cet article, six algorithmes différents d'apprentissage automatique, y compris k-nearest voisins (k-NN), arbre de décision (DT), induction de règles, Naive Bayes, modèle linéaire généralisé (GLM) et algorithme d'apprentissage en profondeur sont appliqués sur l'ensemble de données (ADNI), afin de classer les cinq différentes étapes de la maladie d'Alzheimer. Les résultats de l'étude ont révélé que le GLM peut classer efficacement les étapes de la MA avec une précision de 88,24 % sur l'ensemble de données de test.

- **P.C. Alejandro, F.B. Enrique, P. Alejandro et al. (2020) [47]** : l'objectif principal de ce travail, est de développer un système qui détecte automatiquement la présence de la maladie, dans les images de résonance magnétique sagittale (IRM), qui ne sont généralement pas utilisées. Les IRM sagittales des ensembles de données ADNI et OASIS ont été utilisées. Des expériences ont été menées en utilisant des techniques d'apprentissage par transfert (TL) afin d'obtenir des résultats plus précis.

- **H. Parmar, B. Nutter, R. Long et al. (2020) [48]** : l'objectif principal est d'utiliser le potentiel des techniques d'apprentissage en profondeur, pour les données IRMf à des fins cliniques. Ils ont présenté une telle synergie d'IRMf et d'apprentissage en profondeur, où ils ont appliqué une méthode simplifiée mais précise, utilisant un réseau de neurones convolutionnels 3D modifié (CNN) appliqué aux données d'IRMf à l'état de repos, pour l'extraction de caractéristiques et la classification de la maladie d'Alzheimer (MA). Le CNN est conçu de manière à utiliser les données IRMf avec beaucoup moins de prétraitement, en préservant à la fois les informations spatiales et temporelles.

- **J.X. Fong, M.I. Shapiari, Y.Y. Tiew et al. (2020) [49]** : les travaux les plus récents utilisant des méthodes d'apprentissage en profondeur telles que le réseau neuronal convolutif (CNN), résolvent le diagnostic de la maladie d'Alzheimer sur la base d'un problème de classification. Ils ont proposé une solution de diagnostic de la maladie d'Alzheimer sans nécessiter de technique de pré-traitement IRM basé sur des architectures récentes de détection d'objets d'apprentissage en profondeur telles que Faster R-CNN, SSD et YOLOv3. Ils ont obtenu une précision de détection de 0,998 pour YOLOv3 et 0,982 pour SSD.

- **T.A. Tuan, T.B. Phamb, J.Y. Kim et al. (2020) [50]** : dans cet article, les auteurs ont présenté une nouvelle méthode de calcul pour diagnostiquer la maladie d'Alzheimer, à partir d'images IRM cérébrales 3D. Une approche efficace de diagnostic de la maladie d'Alzheimer à partir d'IRM cérébrales est proposée comprenant deux phases : I) la segmentation et II) la classification, toutes deux basées sur l'apprentissage profond. Une fois les tissus cérébraux segmentés par un modèle combinant le modèle de mélange gaussien (GMM) et le réseau de neurones convolutifs (CNN), un nouveau modèle combinant l'amplification de gradient extrême (XGBoost) et la machine à vecteur de support (SVM) est utilisé pour classer la maladie d'Alzheimer en fonction des tissus segmentés.

- **S.S. Kundaram, K.C. Pathak (2020) [51]** : ce travail propose un réseau de neurones à convolution profonde (DCNN) pour la classification de la maladie d'Alzheimer, à l'aide d'échantillons d'imagerie par résonance magnétique (IRM). La méthode proposée classe la maladie en tant que maladie d'Alzheimer (MA),

déficience cognitive légère (MCI) et contrôle normal (NC). Des expériences sont menées à l'aide de l'ensemble de données ADNI, et le résultat de la classification des sorties a montré une précision de 98,57 % par rapport à d'autres études.

- **M. Atif, B. Muzaffar, M. Muazzam et al. (2020) [52]** : dans cette recherche, les chercheurs ont développé un modèle de réseau neuronal convolutionnel siamois (SCNN) inspiré du VGG-16 (également appelé Oxford Net), pour classer les stades de démence. Dans cette approche, ils ont étendu les données insuffisantes et déséquilibrées en utilisant des approches d'augmentation. Des expériences sont réalisées sur une série d'études d'imagerie, en libre accès à un ensemble de données accessible au public (OASIS). En utilisant l'approche proposée, une excellente précision de 99.05% est obtenue pour la classification des stades de démence. Ils ont comparé ce modèle avec les modèles de pointe, et ont découvert que le modèle proposé surpassait les modèles de pointe en termes de performances, d'efficacité et de précision.

- **M.Liu, M.Xu, K.Wanq et al. (2020) [53]** : dans cette étude, ils ont proposé un cadre d'apprentissage en profondeur multi-modèles basé sur un réseau de neurones convolutifs (CNN) pour la segmentation automatique conjointe de l'hippocampe et la classification AD à l'aide de données d'IRM structurelles.

- **A. Rehmat, M. Usman, F. Ramzan et al. (2020) [54]** : cette étude explore l'efficacité de l'IRMf-rs pour la classification multi-classes de la MA et de ses stades associés, notamment CN, SMC, EMCI, MCI, LMCI et AD. Une cohorte longitudinale d'IRMf à l'état de repos de 138 sujets (25 CN, 25 SMC, 25 EMCI, 25 LMCI, 13 MCI et AD) de l'Alzheimer's Disease Neuroimaging Initiative (ADNI) est étudiée. Pour fournir un meilleur aperçu des approches d'apprentissage en profondeur et de leurs applications à la classification AD, ils ont étudié en détail l'architecture ResNet-18. Ils ont obtenu de meilleurs résultats avec ce modèle affiné pour toutes les étapes AD avec une précision de 100 %, 96,85 %, 97,38 %, 97,43 %, 97,40 % et 98,01 % pour CN, SMC, EMCI, LMCI, MCI et AD respectivement.

- **H. Nawaz, M. Maqsood, S. Afzal et al. (2021) [55]** : dans cette étude, un système de détection de stade de la maladie d'Alzheimer est proposé, sur la base de caractéristiques profondes, à l'aide d'un modèle AlexNet pré-entraîné, en transférant les couches initiales du modèle AlexNet pré-entraîné et en extrayant les caractéristiques profondes du réseau neuronal convolutif (CNN). Pour la classification des caractéristiques profondes extraites, ils ont utilisé les algorithmes d'apprentissage automatique largement utilisés, notamment la machine à vecteurs de support (SVM), les k-plus proches voisins (KNN) et la forêt aléatoire (RF).
- **M. Tanveer, R.U. Khan, R.B. Pachori (2021) [56]** : dans cet article, une nouvelle approche est développée pour classer le MCI, le contrôle normal (NC) et la MA à l'aide de l'imagerie par résonance magnétique structurale (sMRI), de l'ensemble de données de l'initiative de neuro-imagerie de la maladie d'Alzheimer (ADNI) (50 AD, 50 NC, 50 sujets MCI). FreeSurfer est utilisé pour traiter ces données IRM, et obtenir des caractéristiques corticales, telles que le volume, la surface, l'épaisseur, la matière blanche (WM) et la courbure intrinsèque des régions du cerveau. Ces caractéristiques sont modifiées en normalisant les caractéristiques de chaque région corticale, en utilisant la valeur maximale absolue des caractéristiques de cette région, de tous les sujets de chaque groupe de MCI, NC et AD, indépendamment. Un total de 420 caractéristiques est obtenu. Pour répondre à la malédiction de la dimensionnalité, les caractéristiques obtenues sont réduites à 30 caractéristiques en utilisant une technique de sélection séquentielle des caractéristiques. Trois classifications, à savoir la machine à vecteurs de support jumeaux (TSVM), les moindres carrés TSVM (LST SVM) et les moindres carrés robustes basés sur l'énergie TSVM (RELS-TSVM), sont utilisés pour évaluer la précision de la classification à partir des caractéristiques obtenues. Des validations croisées quintuples et décuples, sont utilisées pour valider la méthode proposée. Les résultats expérimentaux montrent une précision de 100%, pour la base de données étudiée. L'approche proposée est innovante, en raison de sa plus grande précision de classification, par rapport aux méthodes de la littérature existante.

- **H.A. Helaly, M. Badawy, A.Y. Haikal (2021) [57]** : cette étude utilise une approche d'apprentissage en profondeur, en particulier les réseaux de neurones convolutifs (CNN), est utilisée dans ce travail. Quatre étapes du spectre AD sont multi-classées. De plus, des classifications d'images médicales binaires séparées sont mises en œuvre entre chaque classe, à deux paires d'étages AD. Deux méthodes sont utilisées pour classer les images médicales, et détecter la MA. La première méthode utilise des architectures CNN simples, qui traitent des scans cérébraux structurels 2D et 3D, de l'ensemble de données ADNI (Alzheimer's Disease Neuroimaging Initiative), basé sur la convolution 2D et 3D. La deuxième méthode applique le principe d'apprentissage par transfert, pour tirer parti des modèles pré-entraînés, pour les classifications d'images médicales, tels que le modèle VGG19.
- **K. Aderghal (2021) [58]** : dans cette thèse, l'auteur s'est intéressé à la classification automatique des images IRM cérébrales, pour le diagnostic de la maladie d'Alzheimer (MA). L'objectif consiste à classer les patients (sujets) en trois catégories principales : sujets sains (NC), sujets atteints de troubles cognitifs légers (MCI), et sujets atteints de la maladie d'Alzheimer (AD). Ils ont utilisé des méthodes d'apprentissage profond (Deep learning), plus précisément les réseaux neuronaux convolutifs (CNN), basés sur des biomarqueurs visuels, à partir d'images IRM multimodales (IRM structurelle et l'IRM de tenseur de diffusion - DTI), pour détecter les changements structurels dans le cerveau, en particulier dans la région hippocampique du cortex limbique. Ils ont proposé une approche appelée "2-D+e" appliquée sur la ROI (Region-of-Interest) : hippocampe.
- **J. Venugopalan, L. Tong, H.R. Hassanzadeh et al. (2021) [59]** : ils ont utilisé l'apprentissage en profondeur (DL) , pour analyser intégralement les données d'imagerie (imagerie par résonance magnétique (IRM)), génétiques (polymorphismes mononucléotidiques (SNP)) et de tests cliniques pour classer les patients en AD, MCI et témoins (CN). Ils ont utilisé des auto-encodeurs de débruitage empilés, pour extraire les caractéristiques des données cliniques et génétiques, et utiliser des réseaux de neurones à convolution 3D (CNN) pour les données d'imagerie. Ils ont développé également une nouvelle méthode d'interprétation des données, pour identifier les caractéristiques les plus performantes apprises par les modèles profonds, avec une analyse de clustering et

de perturbations.

➤ **F. Zhang, B. Pan, P. Shao et al. (2021) [60]** : dans cette recherche, les auteurs ont proposé une nouvelle approche d'apprentissage en profondeur de bout en bout, pour le diagnostic automatisé de la MA, et la localisation des régions cérébrales importantes, liées à la maladie à partir des données d'IRMs. Cette approche est basée sur une stratégie de modèle unique 2D, et présente les différences suivantes par rapport aux approches actuelles.

1. Des modèles de réseaux de neurones convolutionnels (CNN) de différentes structures, et capacités sont évalués de manière systématique et le modèle le plus approprié est adopté pour le diagnostic de la MA.

2. Une stratégie d'augmentation des données appelée Two-stage Random RandAugment (TRRA) est proposée, pour atténuer le problème de surajustement, causé par des données d'entraînement limitées, et pour améliorer les performances de classification dans le diagnostic de la MA.

3. Une méthode Grad-CAM++ est introduite, pour générer les cartes thermiques visuellement explicables qui localisent, et mettent en évidence les régions du cerveau sur lesquelles ce modèle se concentre, et pour rendre ce modèle plus transparent.

➤ **B. Lu, H.X. Li (2021) [61]** : ils ont construit un classificateur de diagnostic AD basé sur l'IRM cérébrale, pratique utilisant l'apprentissage en profondeur/apprentissage par transfert sur un ensemble de données, d'une taille et d'une diversité sans précédent. Un réseau neuronal à convolution profonde à la pointe de la technologie, Inception-ResNet-V2, a été conçu comme un classificateur de sexe avec une capacité de généralisation élevée.

➤ **A. Abida, N. Saeeda, P. Mukesh et al. (2021) [62]** : dans cet article, les chercheurs ont utilisé différentes méthodes d'apprentissage par transfert, basées sur CNN, pour la classification de la maladie d'Alzheimer. Ils ont appliqué différents paramètres et obtenu une précision remarquable de 99.05% sur l'ensemble de données de référence ADNI. Ils ont testé 13 versions différentes de différents modèles CNN pré-entraînés en utilisant une approche affinée d'apprentissage par transfert, dans deux domaines différents, sur l'ensemble de données ADNI (94 AD,

138 MCI et 146 NC).

- **M. Golrokkh, A. Hojjat (2022) [63]** : cet article passe en revue les recherches de pointe sur les techniques d'apprentissage automatique, utilisées pour la détection et la classification de la MA, en mettant l'accent sur la neuroimagerie et principalement les articles de revues publiés depuis 2016. Ces techniques incluent Support Vector Machine, Random forest, Convolutional Neural Network, K-means, entre autres. Cette étude suggère qu'il n'y a pas de meilleure approche. Cependant, les techniques d'apprentissage en profondeur telles que les réseaux de neurones convolutifs, semblent prometteuses pour le diagnostic de la MA, d'autant plus qu'elles peuvent tirer parti de l'apprentissage par transfert, qui surmonte les limites de disponibilité d'un grand nombre d'images médicales.

- **L.F. Samhan, A.H. Alfarra, S.S. Abu-naser (2022) [64]** : dans cet article, les chercheurs ont passé en revue les moyens et les techniques d'utilisation de la classification par apprentissage profond basé sur CNN, pour classer la maladie d'Alzheimer. La méthode proposée est utilisée pour améliorer les soins aux patients, réduire les coûts et permettre une analyse rapide et fiable dans de grandes études. Le modèle conçu en utilisant le langage Python pour la mise en œuvre du système, qui est très utile pour les médecins, classant la maladie d'Alzheimer, a été utilisé. Le modèle a utilisé 70 % de la base d'images pour l'apprentissage et 30 % de la base pour la validation. Ce modèle entraîné a atteint une précision de 100 % sur un ensemble de test retenu.

- **M. Odusami, R. Maskeliunas, S. Misra et al. (2022) [65]** : les auteurs ont utilisé une approche hybride ResD basée sur Resnet18 et Densenet121 pour la classification multiclassées de la maladie d'Alzheimer, sur un ensemble de données IRM. Les informations des deux modèles pré-entraînés sont combinées pour la classification. Les expériences montrent que le modèle hybride proposé surpasse les techniques alternatives des travaux existants. Le modèle ResD proposé donne un score de précision moyen pondéré (macro) de 99.61 %. A partir d'expériences, ils ont montré que le modèle hybride proposé produit moins d'erreur de classification avec une perte de Hamming de 0.003.

- **H.M. Kamrul, Z.S. Binish, A. Sagheer et al. (2022) [66]** : le système de détection de la maladie d'Alzheimer proposé, utilise l'apprentissage par transfert sur la classification multi-classes à l'aide de l'imagerie par résonance magnétique (IRM) du cerveau, pour classer les images en quatre étapes, déments légers(MD), déments modérés (MOD), démence très légère (VMD). Les résultats de la simulation ont montré que le modèle de système proposé, donne une précision de 91.70 %. Ils ont également observé, que le système proposé donne des résultats plus précis, par rapport aux approches précédentes.
- **P. Bhaskaran, J. Venkatraman Shanmugam (2022) [67]** : cet article se concentre sur la détection précoce de divers stades de troubles cognitifs et de la MA en utilisant des neuroimages avec Transfert Learning (TL). Les images (IRM) obtenues à partir de la base de données (ADNI), avec différentes classes de troubles cognitifs normaux (CN), de troubles cognitifs légers précoces (EMCI), de troubles cognitifs légers (MCI), de troubles cognitifs légers tardifs (LMCI), sont classées à l'aide de l'approche d'apprentissage par transfert. Trois réseaux pré-entraînés, tels que GoogLeNet, AlexNet et ResNet-18 sont utilisés dans cette classification. Ils sont entraînés et testés sur 6000 images collectées à partir de la base de données ADNI.

2.2 Récapitulatif des méthodes de la classification de la maladie d'Alzheimer

Auteurs	Année	Méthode	Résultats
F. Shi, T. Jiang, Y. Wang et al.	2007	La machine à vecteurs de support (SVM)	Précision supérieure à 80%
N. Belmokhter, N. Benamrane	2012	SVM	Précision de 100%
H. Suk, D. Shen	2013	L'apprentissage profond avec un auto-encodeur empilé	Précision de 95,9 %, 85,0 % et 75,8 %, pour le diagnostic AD, MCI et MCI-converter respectivement

F. Liu, Ch. Shen	2014	Réseau de neurones convolutionnels (CNN)	-
Z. Yu-Dong, W. Shuihua, D. Zhengchao	2014	kSVM-DT	Précision de 80%
S. Saman, T. Ghassem	2016	CNN	Précision de 96,85 % sur données de test
K. Gunawardena, R. Rajapakse, N. Kodikara et al.	2017	CNN et SVM	Précision 96%
M. Hon, N.M. Khan	2017	L'apprentissage par transfert (TL)	-
I. Jyoti, Y. Zhang	2017	L'apprentissage en profondeur	Performance de 71,25 % pour 5 époques, et 73,25% pour 10 époques
N. Amoroso, D. Diacono, A. Fanizzi et al.	2018	Réseau neuronal profond DNN	Précision globale 38.8%
F. Lia, M. Liu	2018	CNN	Précision 89.5% pour AD vs NC, et 73.8% pour MCI vs NC
I. Jyoti, Z. Yanqing	2018	Réseau de neurones convolutionnels profonds	Précision de 93.18%
T. Jo, K. Nho, A.J. Saykin	2019	CNN et RNN	Précision 96,0 % pour la classification AD et 84,2 % pour la prédiction de conversion MCI

F. Lia, M. Liu	2019	CNN et RNN	La précision 75.8%, et 74.6% pour les classifications AD vs NC, MCI vs NC
H. Wang, Y. Shen, S. Wang et al.	2019	Réseaux convolutifs 3D	-
M. Shahbaz, A. Shahzad, A. Guergachi et al.	2019	KNN, induction de règles, Naive Bayes, GLM et l'apprentissage en profondeur	Précision de GLM de 88.24%
P.C. Alejandro, F.B. Enrique, P. Alejandro et al.	2020	L'apprentissage par transfert (TL)	-
H. Parmar, B. Nutter, R. Long et al.	2020	CNN	-
J.X. Fong, M.I. Shapiai, Y.Y. Tiew et al.	2020	CNN	Précision de détection de 0.998 pour YOLOv3, 0.982 pour SSD et 0.988 pour Faster R-CNN
T.A.Tuan, T.B.Phamb, J.Y.Kim et al.	2020	CNN et l'amplification extrême de gradient (XGBoost)	Précision de 0.88 et 0.80 pour la classification
S.S. Kundaram, K.C. Pathak	2020	Réseau de neurones à convolution profonde (DCNN)	Précision de 98.57%

M.Atif, B.Muzaffar, M.Muazzam et al.	2020	Réseau neuronal convolutionnel siamois (SCNN)	Précision de test de 99.05%
M.Liu, M.Xu, K.Wanq et al.	2020	CNN	Précision de 92.5% et 77.5% pour les sujets classés AD vs NC, et MCI vs NC respectivement
A.Rehmat, M.Usman, F.Ramzan et al.	2020	ResNet-18	Précision moyenne de 97.92%, et 97.88% pour les modèles standard et affinés respectivement
H.Nawaz, M.Maqsood, S.Afzal et al.	2021	CNN et RNN	Précision de 99.21%
M.Tanveer, R.U.Khan, R.B.Pachori	2021	La machine à vecteurs de support jumeaux (TSVM), les moindres carrés TSVM (LST SVM), les moindres carrés robustes basés sur l'énergie TSVM (RELS- TSVM)	Précision de 100%
H.A.Helaly, M.Badawy, A.Y.Haikal	2021	CNN	Précision de 93.61% et 95.17% pour les classifications d'étages AD multi-classes

K.Aderghal	2021	CNN	-
J.Venugopalan, L.Tong, H.R. Hassanzadeh et al.	2021	CNN	-
F. Zhang, B.Pan, P.Shao et al.	2021	CNN and Two-stage Random RandAugment (TRRA) and Grad- CAM++	-
B. Lu, H.X. Li	2021	Inception-ResNet-V2 et l'apprentissage par transfert (TL)	-
A. Abida, B.N. Saeeda, P. Mukesh et al.	2021	L'apprentissage par transfert basées sur CNN	Précision de 99.05%
M. Golrokkh, A, Hojjat	2022	Support Vector Machine, Random forest, Convolutional Neural Network, K-means	-
L.F. Samhan, A.H. Alfarra, S.S. Abu-naser	2022	L'apprentissage profond CNN	Precision de 100%
M. Odusami, R. Maskeliunas, S. Misra et al.	2022	ResD basée sur Resnet18 et Densenet121	Précision de 99.61 %
H.M. Kamrul, Z.S. Binish, A. Sagheer et al.	2022	L'apprentissage par transfert (TL) ?	Précision de 91.70 %.
P. Bhaskaran, J. Venkatraman Shanmugam	2022	L'apprentissage par transfert GoogleNet, AlexNet 9 et ResNet-18	Précision globale de GoogleNet 96.39% et AlexNet 94.08%

			et ResNet-18 97.51%
--	--	--	------------------------

Tableau 2-1: Les méthodes de classification pour la maladie d'Alzheimer.

Le tableau 2-1, contient les méthodes les plus utilisées pour la classification de la maladie d'Alzheimer, grâce à l'utilisation de l'Imagerie par résonance magnétique du cerveau.

On trouve dans la littérature plusieurs méthodes de classification pour la détection et la classification des stades de la maladie d'Alzheimer. Actuellement, plusieurs chercheurs se sont intéressés au Deep Learning, plus exactement aux CNNs (Réseau de neurones convolutionnels), et la méthode SVM (machine à vecteurs de support), à partir des images IRM. Notons que la méthode CNN donne une bonne précision et le modèle le plus performants pour la classification, par rapport d'autres techniques comme l'apprentissage par transfert (TL), le réseau neuronal récurrent (RNN) et SVM, nous avons donc opté pour la méthode CNN pour notre travail.

Discussion

Les méthodes proposées dans l'état de l'art s'intéressent à la résolution du problème lié à la classification précise des stades de démence (la maladie d'Alzheimer). Le but principal de notre travail est de classer les images IRM en AD, MCI et CN en utilisant les CNN.

Dans le prochain chapitre, nous allons voir quelques notions sur l'apprentissage profond (Deep Learning) et les réseaux de neurones convolutifs (CNN).

Chapitre 3

Outils mathématiques

3

Le domaine du traitement d'images en intelligence artificielle (IA) comprend plusieurs branches. Parmi les branches les plus utilisées, on trouve la classification des images de type IRM par la méthode du Deep Learning (apprentissage profond).

Dans ce chapitre, nous allons donner des notions sur l'apprentissage profond, et présenter les réseaux de neurones convolutifs (CNN), leurs couches, leurs avantages et leurs inconvénients, puisqu'ils constituent notre outil de travail.

3.1 Définition de l'apprentissage profond (Deep Learning)

Le Deep Learning ou apprentissage profond (Figure 3.1) est un sous domaine de l'intelligence artificielle (IA). Ce terme désigne l'ensemble des techniques de l'apprentissage automatique (machine Learning), autrement dit une forme d'apprentissage fondée sur des approches mathématiques, utilisées pour modéliser des données [68].

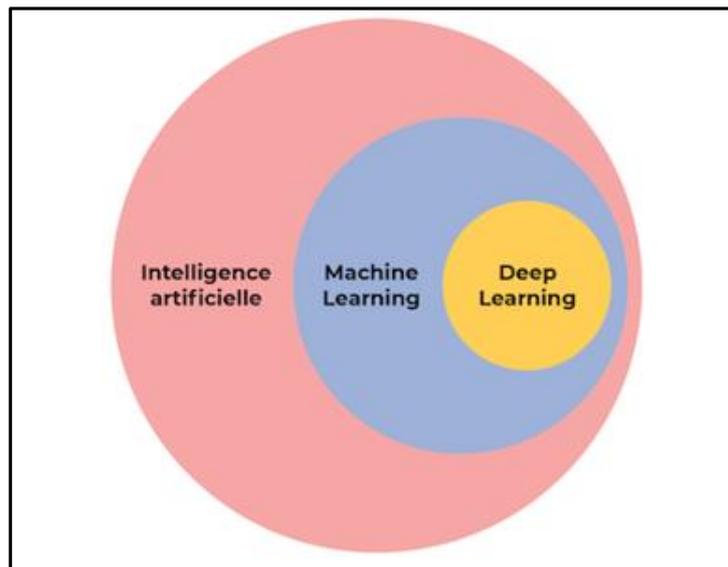


Figure 3.1: Le Deep Learning est une sous-discipline du Machine Learning [68].

Le Deep Learning s'appuie sur un réseau de neurones artificiels s'inspirant du cerveau humain . Ce réseau est composé de dizaines voire de centaines de "couches" de neurones, chacune recevant et interprétant les informations de la couche précédente [68].

Dans l'apprentissage en profondeur, un modèle informatique apprend à effectuer des tâches de classification directement à partir d'images, de textes ou de sons. Les modèles d'apprentissage en profondeur peuvent atteindre une précision de pointe, dépassant parfois les

performances d'un niveau humain. Les modèles sont entraînés en utilisant une grande masse de données étiquetées, et des architectures de réseau neuronal qui contiennent de nombreuses couches [69].

3.2 Réseaux de neurones

Un réseau de neurones artificiels est une série d'algorithmes qui s'efforcent de reconnaître les relations sous-jacentes dans un ensemble de données, grâce à un processus qui imite le fonctionnement du cerveau humain. En ce sens, les réseaux de neurones font référence à des systèmes de neurones, de nature organique ou artificielle [70].

3.2.1 Neurones biologiques

Le cerveau humain est composé de près de 100 milliards de neurones reliés entre eux. Chacun de ces éléments est lui-même constitué de plusieurs parties [71].

En premier lieu, on retrouve au cœur du neurone son noyau, ou « corps cellulaire » (Figure 3.2). Cette partie centrale a pour rôle de contrôler la réaction de la cellule, en fonction des informations reçues en entrée [71].

Ces données lui parviennent grâce à des branches appelées « dendrites ». Ce sont elles qui transmettent les signaux depuis l'extérieur vers le corps cellulaires [71].

Ce dernier traite alors l'information et renvoie des signaux électriques via son « axone ». Celui-ci permet ainsi de véhiculer le message en sortie [71].

Enfin, au bout de cet axone, se situent les « synapses ». Ceux-ci assurent alors la communication de l'information aux autres neurones, ainsi qu'aux fibres musculaires (pour d'éventuelles réponses nerveuses) [71].

Ce sont ces connexions synaptiques qui permettent à l'être humain de réaliser certaines tâches, telles que reconnaître des formes, mémoriser des informations ou apprendre par l'exemple. Chaque neurone n'agit donc pas indépendamment. C'est le comportement global de l'ensemble du réseau qui permet d'effectuer ces actions [71].

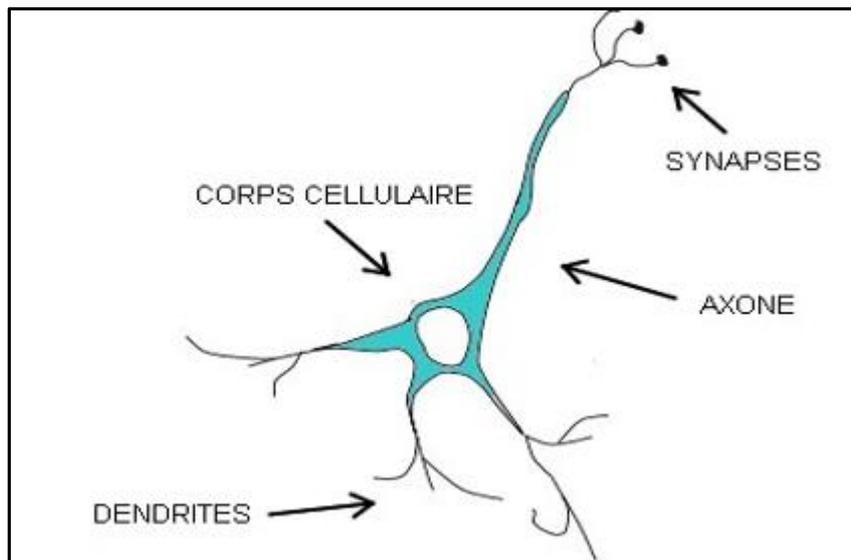


Figure 3.2: Le neurone biologique [72].

3.2.2 Réseaux de neurones artificiels

Les réseaux de neurones artificiels peuvent être décrits comme des systèmes composés d'au moins deux couches de neurones ,une couche d'entrée et une couche de sortie, et comprenant généralement des couches intermédiaires « hidden layers ». Plus le problème à résoudre est complexe, plus le réseau de neurones artificiels doit comporter de couches. Chaque couche contient un grand nombre de neurones artificiels spécialisés [73].

Les dendrites du réseau de neurones biologiques (Figure 3.3) représentent les entrées des réseaux de neurones artificiels, le noyau cellulaire représente les nœuds, la synapse représente les poids et Axone représente la sortie [74].

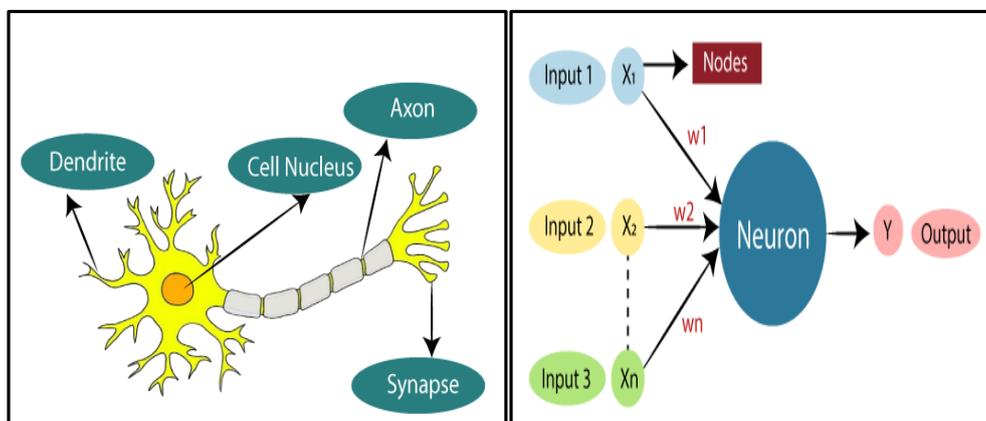


Figure 3.3: Neurone biologique et neurone artificiel [74].

On peut résumer le passage du neurone biologique vers le neurone artificiel par le tableau suivant :

Neurone biologique	Neurone artificiel
Synapses	Poids de connexions
Axones	Signal de sortie
Dendrites	Signal d'entrée
Noyau cellulaire	Fonction d'activation

Tableau 3-1: Passage du neurone biologique vers le neurone artificiel.

3.3 Classification des images médicales

La classification des images médicales définit une partition de l'image en un ensemble de classes. Chaque classe rassemble des pixels ayant des caractéristiques (souvent réduites au niveau de gris) aussi similaires que possible, et les classes obtenues doivent être aussi distinctes que possible [75].

La classification commence par l'attribution des pixels de l'image à des classes connues à priori (c'est la classification supervisée) ou à des classes inconnues (classification non supervisée). La classification, qu'elle soit supervisée ou non, a toujours été un outil fort, employé dans le domaine de l'analyse et du traitement des images numériques, en particulier à des fins de segmentation ou d'interprétation [75].

Dans notre étude, nous nous intéressons à l'un des outils de classification le plus utilisé qui est : les réseaux de neurones convolutionnels.

3.4 Réseaux de neurones convolutionnels CNN

Les réseaux de neurones convolutionnels (Figure 3.4) sont à ce jour les modèles les plus performants, pour classer des images. Désignés par l'acronyme CNN, de l'anglais Convolutional Neural Network, ils 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 trois pour représenter les couleurs fondamentales [Rouge, Vert, Bleu] [76].

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. Au final, les cartes de convolutions sont concaténées en un vecteur de caractéristiques, appelé code CNN [76].

Ce code CNN en sortie de la partie convolutive est ensuite branché en entrée d'une deuxième partie (une partie classification), constituée de couches entièrement connectées (perceptron multicouches). Le rôle de cette partie est de combiner les caractéristiques du code CNN pour classer l'image [76].

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 [76].

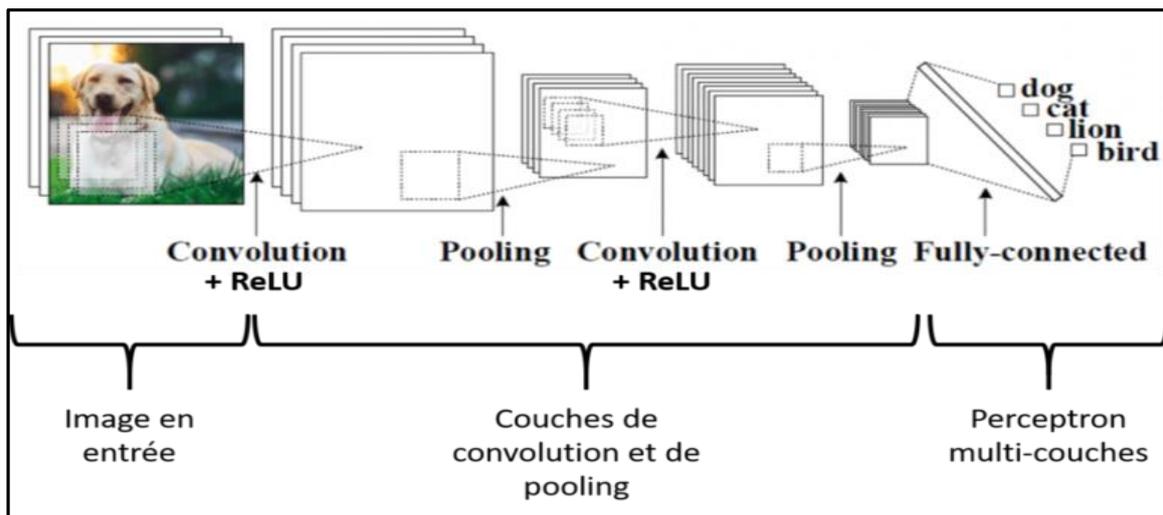


Figure 3.4: Architecture standard d'un réseau de neurone convolucional [76].

3.5 Différentes couches des réseaux de neurone convolutifs

Il existe quatre types de couches pour les réseaux de neurones convolutifs : la couche de convolution, la couche de pooling, la couche de correction Relu et la couche fully-connected.

3.5.1 Couche de convolution (CONV)

La convolution est une opération mathématique simple généralement utilisée pour le traitement et la reconnaissance d'images. Sur une image, son effet s'assimile à un filtrage dont voici le fonctionnement [77] (Figure 3.5) :

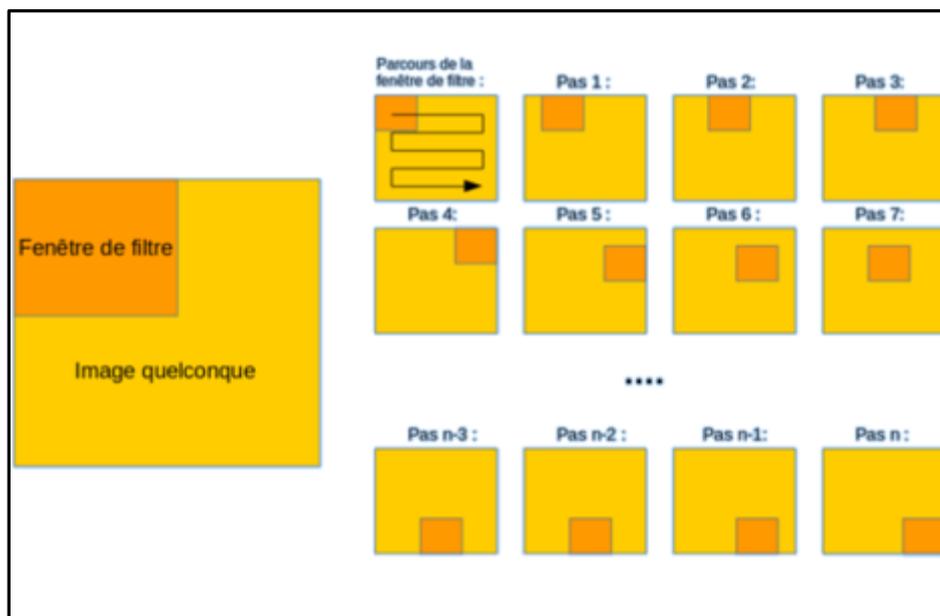


Figure 3.5: Schéma du parcours de la fenêtre de filtre sur l'image [77].

- Dans un premier temps, on définit la taille de la fenêtre de filtre située en haut à gauche [77].
- La fenêtre de filtre, représentant la caractéristique (feature), se déplace progressivement de la gauche vers la droite d'un certain nombre de cases, défini au préalable (le pas) jusqu'à arriver au bout de l'image [77].
- A chaque portion d'image rencontrée, un calcul de convolution s'effectue, permettant d'obtenir en sortie une carte d'activation ou feature map, qui indique où sont localisées les features dans l'image : plus la feature map est élevée, plus la portion de l'image balayée ressemble à la feature [77].

Parmi les filtres les plus connus, on retrouve notamment le filtre moyenneur (il calcule pour chaque pixel la moyenne du pixel avec ses 8 proches voisins), ou encore le filtre gaussien permettant de réduire le bruit d'une image fournie en entrée [77].

Donc le rôle de cette première couche est d'analyser les images fournies en entrée et de détecter la présence d'un ensemble de features. On obtient en sortie de cette couche un ensemble de features maps [77].

3.5.2 Couche de Pooling (POOL)

Ce type de couche est souvent placé entre deux couches de convolution : elle reçoit en entrée plusieurs feature maps, et applique à chacune d'entre elles l'opération de pooling.

L'opération de pooling consiste à réduire la taille des images, tout en préservant leurs caractéristiques importantes [78].

Pour cela, on découpe l'image en cellules régulières, puis on garde au sein de chaque cellule la valeur maximale. En pratique, on utilise souvent des cellules carrées de petite taille pour ne pas perdre trop d'informations. Les choix les plus communs sont des cellules adjacentes de taille 2*2 pixels qui ne se chevauchent pas, ou des cellules de taille 3*3 pixels, distantes les unes des autres d'un pas de 2 pixels (qui se chevauchent donc) [78].

On obtient en sortie le même nombre de feature maps qu'en entrée, mais celles-ci sont bien plus petites [78].

La couche de Pooling permet de réduire le nombre de paramètres et de calculs dans le réseau et éviter le sur-apprentissage [78].

Parmi les plus utilisés, on trouve le Max-Pooling mentionné précédemment ou encore l'Average Pooling (Figure 3.6) dont l'opération consiste à conserver à chaque pas, la valeur moyenne de la fenêtre de filtre [77].

Dans notre travail, nous avons utilisé le Max-Pooling est plus efficace que la moyenne, car il maximise le poids des activations fortes.

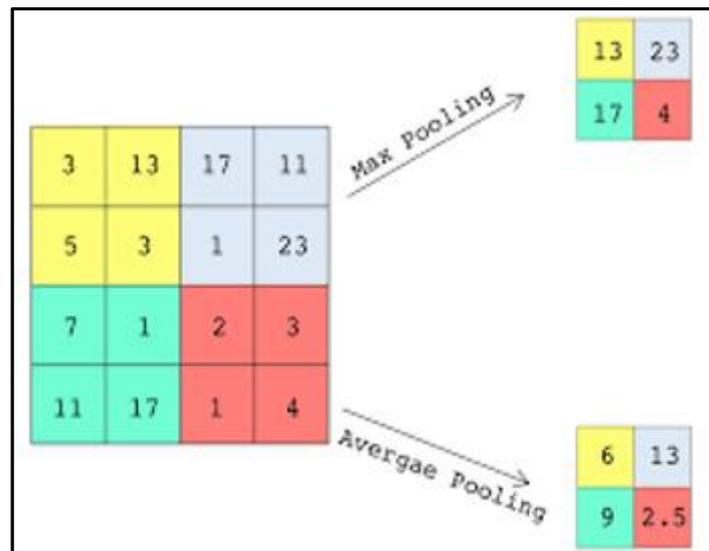


Figure 3.6: Exemple de Max-Pooling et Average Pooling [79].

3.5.3 Couche de correction ReLU

Pour améliorer l'efficacité du traitement, on intercale entre les couches de traitement, une couche qui va opérer une fonction mathématique (fonction d'activation) sur les signaux de sortie. Dans ce cadre, on trouve la fonction ReLU (Rectified Linear Units) qui désigne la fonction réelle non-linéaire définie par $ReLU(x) = \max(0, x)$ [80].

La couche de correction ReLU (Figure 3.7) remplace donc toutes les valeurs négatives reçues en entrées par des zéros. Elle joue le rôle de fonction d'activation [80].

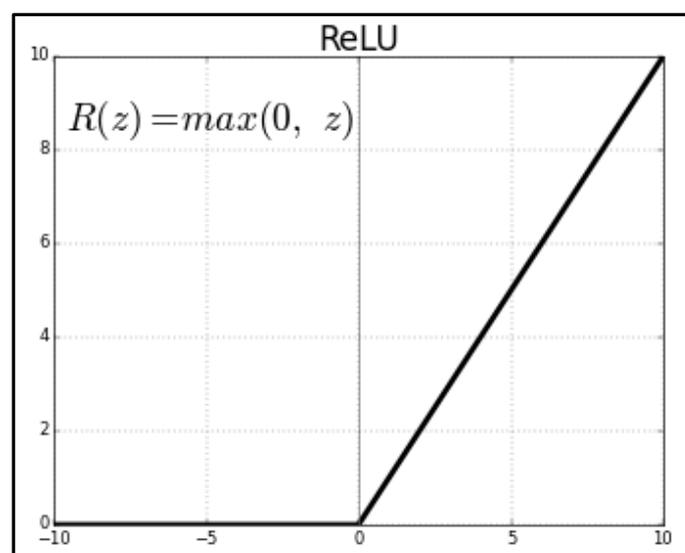


Figure 3.7: La fonction ReLU [81].

3.5.4 Couche entièrement connectée (fully-connected)

La couche fully-connected (Figure 3.8) constitue toujours la dernière couche d'un réseau de neurones, convolutif ou non : elle n'est donc pas caractéristique d'un CNN [78].

Ce type de couche reçoit un vecteur en entrée et produit un nouveau vecteur en sortie. Pour cela, elle applique une combinaison linéaire puis éventuellement une fonction d'activation aux valeurs reçues en entrée [78].

La dernière couche fully-connected permet de classifier l'image en entrée du réseau.

Chaque élément du vecteur indique la probabilité pour l'image en entrée d'appartenir à une classe [78].

La couche fully-connected détermine le lien entre la position des features dans l'image et une classe [78].

La couche fully-connected peut être utilisée pour optimiser des objectifs tels que les scores de classe [82].

L'application de la fonction softmax aux sorties de la couche fully-connected, nous donne la probabilité d'une classe [83].

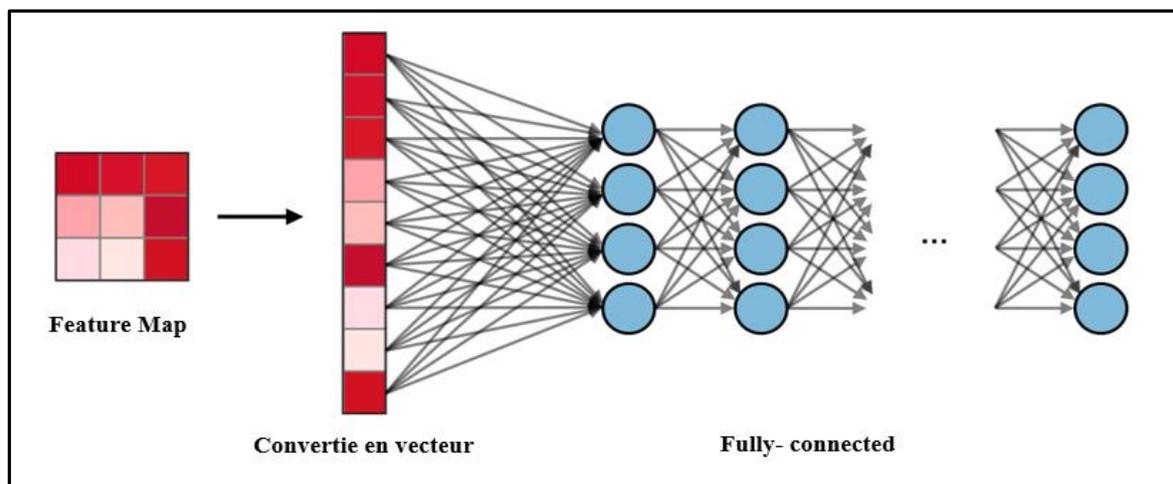


Figure 3.8: L'architecture de Fully-connected [82].

3.6 Avantages des CNN

Dans ce type d'approche (CNN), il y a plusieurs avantages, donc parmi les points forts :

- De meilleurs résultats qu'avec d'autres méthodes [84].
- Une exécution efficace des tâches de routine, sans écarts de qualité [84].
- Les caractéristiques typiques d'une image sont ainsi facilement identifiées [85].

- Ils constituent un outil de pointe pour le Deep Learning et la classification dans la reconnaissance d'images [85].
- Lorsque le volume d'entrée varie dans le temps (vidéo ou son), il devient intéressant de rajouter un paramètre de temporisation (delay) dans le paramétrage des neurones. On parlera dans ce cas de réseau neuronal à retard temporel (TDNN) [86].

3.7 Inconvénients des CNN

Comme dans toutes les méthodes de recherche, il y a des avantages et bien sûr des inconvénients. Nous avons dans cette partie, présenté les inconvénients à éviter pour permettre de prendre la méthode la plus utile :

- Le CNN nécessite une grande puissance de calcul [84].
- Il nécessite une grande quantité de données [84] (Big data au minimum 2500 images). Cette exigence en matière de données entraîne un sur-apprentissage et un sous-apprentissage (overfitting et underfitting) [87].
- Calcul coûteux (Temps d'apprentissage important) [87].

3.8 Organigramme d'un CNN

Pour la réalisation de notre modèle d'apprentissage, nous avons représenté l'organigramme suivant (Figure 3.9) :

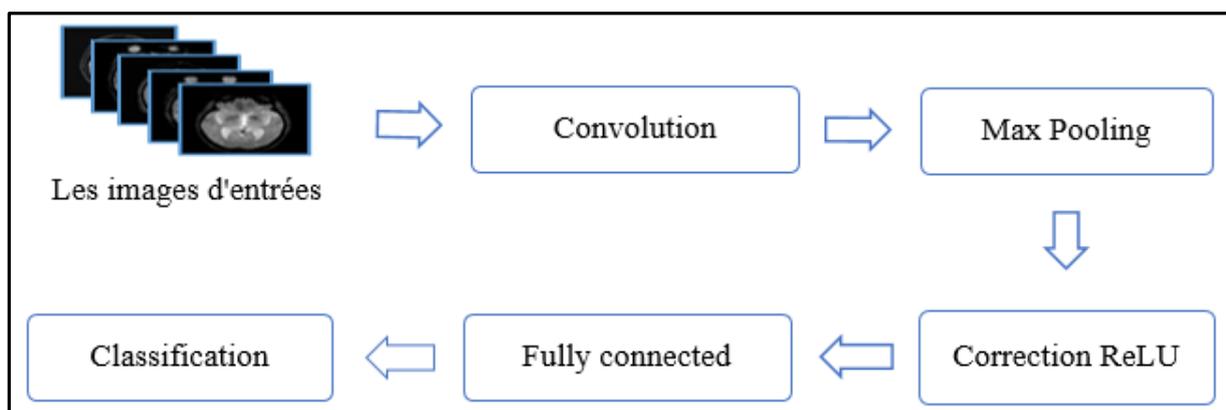


Figure 3.9: L'organigramme principal du CNN.

- **Les images d'entrées** : c'est la base de données qui est utilisée pour la classification.
- **La convolution** : elle sert à faire l'extraction des caractéristiques des images, et nous avons pour cela utilisé des filtres.
- **Max Pooling** : elle permet de réduire la taille des images, et éviter le sur-apprentissage.

- **Correction ReLU** : elle a pour rôle d'améliorer l'efficacité du traitement (fonction d'activation).
- **Fully connected** : elle connecte tous les neurones de la couche précédente à tous les neurones de sorties.
- **Classification** : elle sert à affecter chaque image d'entrée à une classe.

3.9 Options de l'apprentissage

3.9.1 Optimiseurs

Les optimiseurs peuvent être expliqués comme une fonction mathématique pour modifier les poids du réseau compte tenu des gradients et des informations supplémentaires, en fonction de la formulation de l'optimiseur. Les optimiseurs sont construits sur l'idée de descente de gradient, afin de diminuer de manière itérative la fonction de perte en suivant le gradient.

- **Adam (adaptive moment estimation)** : l'optimiseur Adam comprend les informations sur le taux d'apprentissage, le facteur de régularisation L2 et la taille du mini-batch size [88].
- **SGDM (stochastic gradient descent with momentum)** : option d'apprentissage pour la descente de gradient stochastique avec moment, il comprend les informations de taux d'apprentissage, le facteur de régularisation L2 et la taille du mini-batch size [88].

3.9.2 Epoque

- **Epoch** : (numéro d'époque) correspond à un passage complet des données [88].
Le nombre d'époques est un hyperparamètre qui définit le nombre de fois que l'algorithme d'apprentissage fonctionnera sur l'ensemble de données d'apprentissage. Une époque signifie que chaque échantillon de l'ensemble de données d'apprentissage a eu l'occasion de mettre à jour les paramètres du modèle interne. Une époque est composée d'un ou plusieurs lots (batch). La taille du batch correspond au nombre d'échantillons traités avant la mise à jour du modèle.
- **MaxEpochs** : c'est le nombre maximal d'époques à utiliser pour l'apprentissage [88].

3.9.3 Taux d'apprentissage (**InitialLearnRate**)

C'est la quantité de mise à jour des pondérations pendant l'apprentissage, qui a une petite valeur positive, souvent comprise entre 0,0 et 1,0. La valeur par défaut est 0,001 pour l'optimiseur 'Adam'. Si le taux d'apprentissage est trop faible, l'entraînement prend du temps [88].

3.9.4 Taille de mini lots (**Mini batch size**)

C'est un sous-ensemble de l'ensemble d'apprentissage utilisé pour évaluer le gradient de la fonction de perte et mettre à jour les pondérations [88].

3.9.5 Ressources matérielles

L'environnement d'exécution (Execution Environment) : Ressource matérielle pour l'entraînement du réseau : ' CPU ', ' GPU ', ' Multi-GPU ' et ' Multi-CPU ' [88].

- **CPU** : est le processeur central de l'ordinateur, son acronyme signifie unité de traitement principal. Le CPU est chargé d'effectuer toutes sortes de calculs. Il est capable de mener de nombreuses tâches différentes [89].
- **GPU** : désigne le processeur qui équipe la carte graphique, son acronyme signifie unité de traitement graphique. Le GPU gère uniquement les calculs graphiques. Il s'occupe de l'affichage des pixels, textures et formes à l'écran, ainsi que du traitement de la vidéo [89]. L'entraînement avec un GPU est beaucoup plus rapide qu'un CPU.

3.10 Problème de sur-apprentissage et sous-apprentissage

Les facteurs déterminant le rendement d'un algorithme d'apprentissage profond sont sa capacité à [90] :

- Réduire l'erreur dans la phase d'apprentissage.
- Réduire l'écart entre le résultat d'apprentissage et l'erreur de test.

Ces deux facteurs correspondent aux deux enjeux centraux d'apprentissage profond qui sont [90] :

- **Le sur-apprentissage** : pour mieux expliquer cette notion, nous commençons à donner un exemple. Une équipe de football se comporte mal durant le passage des journées de la ligue. Par conséquent, tous les joueurs de l'équipe seront jugés par l'échec ; bien qu'il y ait des joueurs compétents et même le buteur de la ligue. Cette situation s'appelle « la généralisation ». Le problème de la généralisation est très connu chez les êtres humains, et même les machines peuvent tomber dans ce problème. Au niveau du Deep Learning,

ce problème s'appelle le sur-apprentissage « overfitting ». Cela signifie que le modèle fonctionne sur les données d'apprentissage, mais il ne peut pas se généraliser sur d'autres données.

- **Le sous-apprentissage** : si nous prenons le même exemple cité dans la section précédente, mais cette fois on ne connaît pas les joueurs de l'équipe, et aussi les supporters ne connaissent même pas les résultats de l'équipe dans de nombreuses journées. Par conséquent, l'équipe est jugée qu'elle est faible et même tous ses joueurs, donc nous avons une mauvaise idée sur l'équipe malgré le manque d'informations. Cette situation s'appelle « le sous-apprentissage ; underfitting », cela signifie que le modèle développé est faible pour apprendre la structure sous-jacente des données, vu le manque d'informations.

La résolution du problème de sur-apprentissage, nous pouvons [90] :

- Utiliser plus de données durant la phase d'apprentissage.
- Réduire le bruit dans les données d'apprentissage (fixer les erreurs dans la base de données).
- Utiliser le dropout qui fait la suppression de neurones dans les couches d'un modèle de Deep Learning. Cela consiste à désactiver temporairement certains neurones dans le réseau, ainsi que toutes ses connexions entrantes et sortantes.

Pour résoudre le problème de sous-ajustement, nous pouvons [90] :

- Fournir une meilleure base de données à l'algorithme d'apprentissage.
- Réduire les contraintes sur le modèle.

La figure 3-10 donne un exemple de sur-apprentissage et sous-apprentissage. Comme nous pouvons le voir, en cas de sous-apprentissage, le modèle classe mal un certain nombre de points, en cas d'apprentissage idéale le modèle accepte quelques erreurs, par contre en cas de sur-apprentissage, il ne tolère pas d'erreurs, donc le modèle échoue dans la classification des données imparfaites.

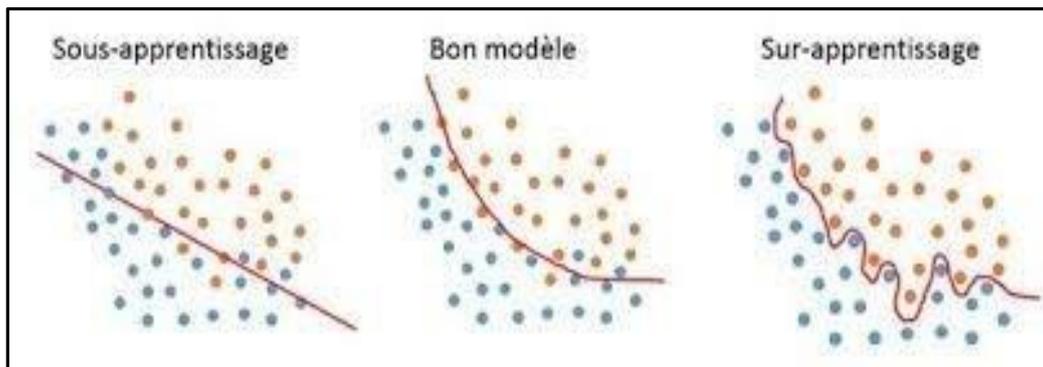


Figure 3.10: Le graphe de chaque état [90].

Discussion

Dans ce chapitre, nous avons présenté l'architecture du modèle de classification d'image, et aussi les notions essentiels du Deep Learning (apprentissage profond), ensuite la description des réseaux de neurones convolutifs (CNN), leur fonctionnement (donnée présentation de leurs couches principales), ainsi que leurs avantages et leurs inconvénients. Dans le prochain chapitre, nous présenterons l'implémentation de notre approche ainsi que les différents résultats obtenus.

Chapitre 4

Implémentation, résultats et discussion

4

Dans le chapitre présent, nous allons tout d'abord présenter la base de données, le logiciel et matériel avec lesquels nous avons implémenté notre méthode. Par la suite, nous définissons les différentes étapes qui servent à créer notre réseau de classification, et les résultats obtenus.

4.1 Base de données

Une base de données est un ensemble de données numériques qui possèdent une structure qui répond à une logique systématique, et a pour fonction de stocker l'information de façon fiable et traiter un grand volume de données [91].

Dans notre travail, nous avons utilisé une base de données téléchargée à partir du site Kaggle. Elle contient 4 classes de la maladie d'Alzheimer : « non demented », « moderate demented », « mild demented » et « very mild demented », divisées en deux parties pour l'entraînement et les tests.

En réalité, la classe « non demented » représente les sujets sains CN, la classe « moderate demented » représente les sujets atteinte d'Alzheimer AD et les deux classes « mild demented » et « very mild demented » représentent le stade MCI (déficience cognitive légère).

Dans notre travail, nous nous intéressons aux trois classes AD, CN et MCI (mild demented) (Figure 4.1). La première partie de l'entraînement se compose de 3329 images IRM en niveaux de gris, de tailles différentes, de format JPEG et la partie de test contient 831 images.

Notre base de données contient peu d'images dans le stade AD (moderate demented), ce qui est insuffisante pour l'apprentissage profond (nécessite une grande quantité de données pour avoir des résultats précise). C'est pour cela, que nous avons téléchargé une autre base de données à partir de site Kaggle, extraite de la base de données ADNI, contenant aussi 5 classes : AD, CN, MCI, LMCI et EMCI .Cela permet d'ajouter à la première base de données des images de la classe AD (moderate demented) dans la partie de l'entraînement, et celle de test. La nouvelle base de données contient 4331 images.

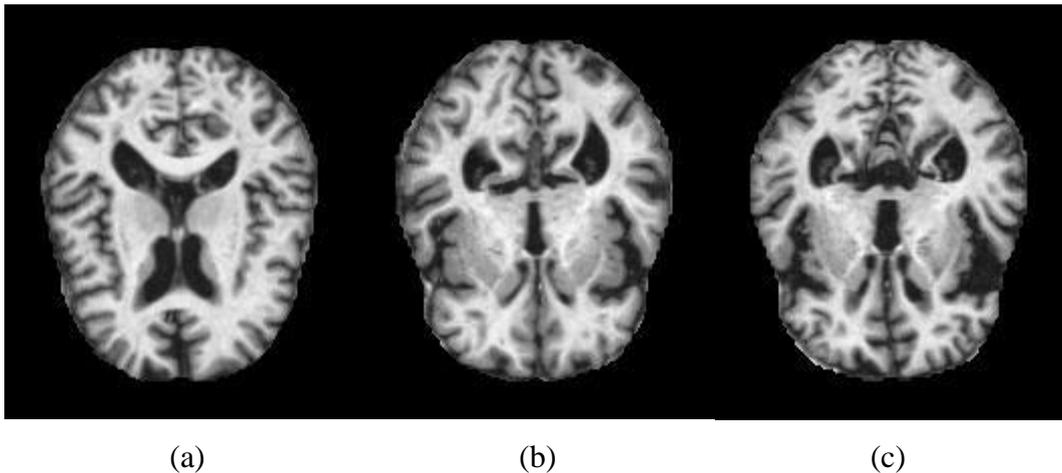


Figure 4.1: (a) Image de classe AD, (b) image de classe CN et (c) image de classe MCI.

La base ADNI (Alzheimer's Disease Neuroimaging Initiative) est un consortium d'universités et de centres médicaux aux États-Unis et au Canada, créé pour développer des techniques d'imagerie standardisées, et des procédures de biomarqueurs chez les sujets normaux, les sujets atteints de MCI et les sujets atteints de AD légère [92].

4.2 Logiciel et matériel

Le matériel utilisé pour notre implémentation est un PC personnel HP caractérisé par :

- Une mémoire RAM de 4.00 Go.
- Un processeur Intel(R) Core (TM) i3-3110M CPU 2.40 GHz.
- Windows 8.1 professionnel avec 64 bits.

4.3 Langage de programmation utilisé

MATLAB (MATrix Tool LABoratory) est un excellent outil pour l'exploration, l'analyse et la visualisation de données. Il combine de nombreux outils de qualité supérieure et des fonctionnalités importantes, pour la recherche scientifique. Il est souvent utilisé par les chercheurs, pour concevoir un système simple à compliqué et le simuler pour analyser les performances du modèle [93]. C'est pour cela, que nous avons choisi de travailler avec le langage MATLAB R2019a.

Dans notre travail, nous avons utilisé la boîte à outils « Toolbox » de l'apprentissage en profondeur qui permet la conception des différents modèles de CNN comme AlexNet.

La figure 4-2 l'interface graphique de MATLAB qui apparaît lors du lancement de MATLAB.

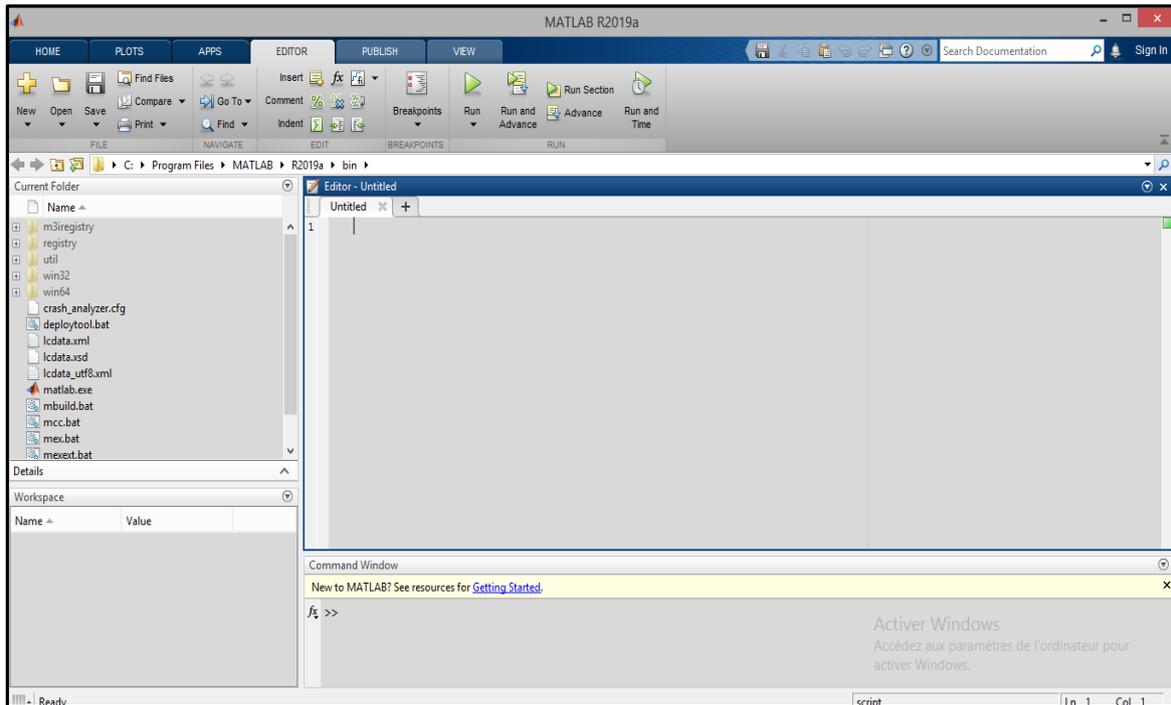


Figure 4.2: L'environnement MATLAB R2019a.

4.4 Intérêt du notre travail

L'intérêt de travail est de réaliser un système d'aide au diagnostic de la maladie d'Alzheimer basé sur l'une des méthodes de l'apprentissage profond qui est les réseaux de neurones convolutionnels CNN.

Dans ce travail, nous avons réalisé la classification de trois stades de la maladie d'Alzheimer avec deux architectures qui sont :

- Classification par CNN.
- Classification par l'un des modèles de réseau de neurones convolutionnels AlexNet.

4.5 Classification par CNN

Pour créer notre réseau de classification par CNN, nous allons suivre les étapes montrées ci-dessous (Figure 4.3) :

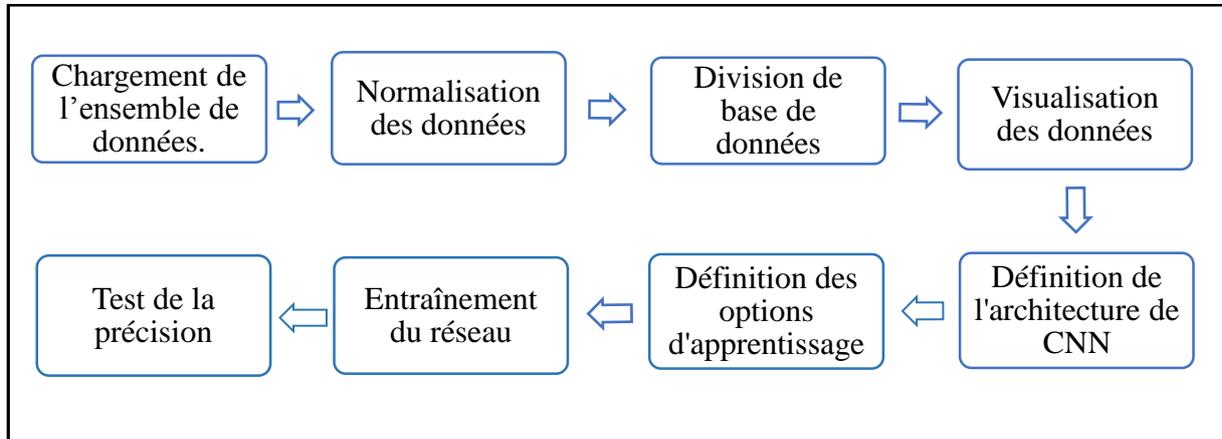


Figure 4.3: Les étapes d'implémentation de CNN.

4.5.1 Chargement de la base de données

Tout d'abord, nous allons charger notre base de données avec les classes et le nombre d'images par classes.

Classe	Nombre d'image par classe
AD	235
MCI	896
CN	3200

Tableau 4-1: Les classes de la base de données.

Le tableau 4-1 indique que la première classe AD (Alzheimer) contient 235 images, la deuxième classe MCI (déficience cognitive légère) contient 893 images et la dernière classe CN (sujet sain) 3200 images, donc notre base de données contient 4331 images.

4.5.2 Normalisation des données

La normalisation est l'un des concepts de base de la modélisation des données relationnelles. Dans le modèle de base de données relationnelle, une bonne conception de base de données se caractérise par une redondance minimale [94].

On utilise la fonction « `imresize` » qui permet de redimensionner les images en augmentant ou en diminuant leurs pixels.

La base de donnée qui nous avons utilisé contient des images de tailles différentes. Pour cela, nous avons utilisé la fonction « `imresize` » et grâce à cette fonction les images auront la même taille de 256×256 (Figure 4.4).

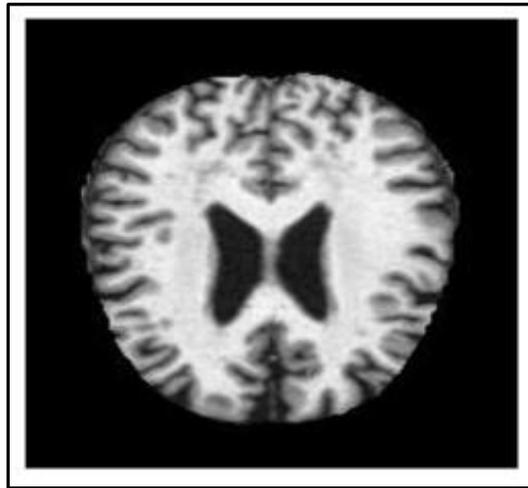


Figure 4.4: Image de taille 256×256 .

4.5.3 Division de la base de données et visualisation des données

Tout d'abord, nous avons divisé notre base de données en deux parties 70% des images seront utilisées pour l'entraînement et 30% pour le test. Ensuite, nous avons visualisé quelques images de la partie de l'entraînement (apprentissage) pour vérifier si elles ont été correctement chargées (Figure 4.5).

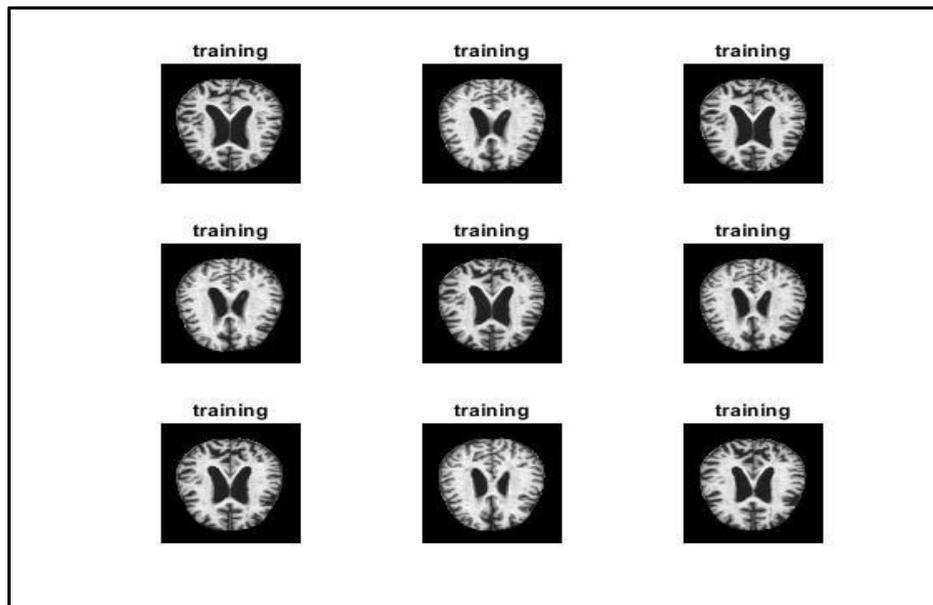


Figure 4.5: Résultat de la visualisation des données.

4.5.4 Définition de l'architecture du réseau CNN utilisé

Dans ce qui suit, nous allons définir les différentes couches de notre algorithme de classification. Dans notre travail, nous avons testé trois architectures de CNN :

- La première architecture contient 8 couches, et dans laquelle on appelle la couche de convolution une fois.
- La deuxième architecture contient 12 couches, et dans laquelle on appelle la couche de convolution deux fois.
- La troisième architecture contient 15 couches, et dans laquelle on appelle la couche de convolution trois fois.

L'architecture de CNN commence par la couche d'entrée et se termine par la couche de classification. Entre les deux on a la couche de convolution, la couche d'activation ReLU, la couche de normalisation, la couche de maxpooling, la couche entièrement connectée et la couche Softmax.

➤ Couche d'entrée

Dans cette couche, nous définissons la taille de l'image qui est 256×256 en niveaux de gris.

```
ImageInputLayer()
```

➤ **Couche de convolution**

Pour faire la convolution, nous faisons appel à la fonction MATLAB :

```
Convolution2dLayer(filterSize,numfiltres,Name,Value)
```

Cette fonction est appelée n fois. Dans la première convolution, nous avons utilisé 8 filtres de taille 3x3.

➤ **Couche ReLU**

La fonction d'activation la plus couramment utilisée est l'unité linéaire redressée (ReLU). La fonction MATLAB qui la réalise est :

```
reluLayer
```

➤ **Couche de normalisation par lots**

On utilise la couche de normalisation par lots (batch) entre la couche de convolution et la couche ReLU, pour accélérer l'entraînement du réseau et réduire la sensibilité à l'initialisation du réseau [95].

Pour cela, nous utilisons la fonction MATLAB :

```
batchNormalizationLayer
```

➤ **Couche de regroupement maximal**

La couche de regroupement maximal ou maxpooling permet de réduire le nombre d'entités inutiles et ne garder que les caractéristiques les plus significatives. La fonction Matlab utilisée est :

```
maxPooling2dLayer(poolsize,Name,Value)
```

- Le paramètre poolsize donne la taille de la couche de pooling,
- La paire Name, value permet de définir le stride ou le padding.
- Le stride est la taille du pas ou la valeur avec laquelle le filtre sera déplacé horizontalement et verticalement dans l'image.

- La padding consiste à ajouter des 0 (lignes et colonnes) aux bords de l'image, du fait que l'application d'une convolution provoque le rétrécissement de l'image.

Plus le stride est élevé est plus les images rétrécissent rapidement. Pour conserver la taille initiale de l'image, on utilise le « same » padding.

Par exemple : `maxPooling2dLayer(2,'Stride',3)` crée une couche de maxpooling avec de taille [2 2] et un stride [3 3].

➤ **Couche entièrement connectée**

La couche entièrement connectée est la couche de sortie. À ce niveau, nous devons définir pour combien de classes le réseau va être entraîné. La fonction MATLAB utilisée pour cela est :

```
fullyConnectedLayer(outputsize)
```

➤ **Couche Softmax**

La fonction d'activation softmax normalise la sortie de la couche entièrement connectée. La sortie de la couche softmax consiste en des nombres positifs qui totalisent un '1', pour pouvoir être utilisée par la suite comme probabilités de classification par la couche de classification [95]. La fonction MATLAB qui permet de définir cette fonction est :

```
SoftmaxLayer
```

➤ **Couche de classification**

Le réseau de neurone convolutif est complété par la couche de classification. Cette couche utilise les probabilités renvoyées par la fonction d'activation softmax pour chaque entrée, pour affecter l'entrée à l'une des classes mutuellement exclusives, et calculer la perte [95]. La fonction MATLAB utilisée pour la classification est :

```
classificationLayer
```

4.5.5 Définition des options d'apprentissage

Maintenant, nous allons définir les options d'apprentissage.

Les optimiseurs sont des algorithmes ou des méthodes utilisées pour modifier les attributs d'un réseau de neurones tels que les poids et le taux d'apprentissage afin de réduire les pertes. Ces optimiseurs affectent largement la précision du modèle d'apprentissage en profondeur. La fonction MATLAB qui permet de définir les options d'apprentissage est :

```
trainingOptions( )
```

Dans notre cas, nous avons utilisé l'optimiseur 'sgdm' ou 'Stochastic Gradient Descent Momentum'. Ensuite, nous avons défini le taux d'apprentissage 'InitialLearnRate' que nous avons fixé à 0.0001 et le nombre maximal d'époques choisi est égal à 10. Nous avons défini la paire ['Plots', 'training_progress'] pour obtenir le tracé en temps réel, de la courbe d'apprentissage et la courbe de perte, lors de l'entraînement du réseau, son exécution sera donné sur l'environnement CPU.

4.5.6 Entraînement du réseau

Nous allons entraîner notre réseau sur les données d'apprentissage, en définissant les options d'apprentissage et les couches de l'architecture en utilisant la fonction MATLAB train :

```
net = trainNetwork(images, layers, options)
```

Cette fonction produit également deux courbes de précision et de perte en temps réel, pendant que le modèle fait l'apprentissage.

- **La précision** est une méthode de mesure des performances d'un modèle de classification. Il est généralement exprimé en pourcentage. La précision est le nombre de prédictions où la valeur prédite est égale à la valeur réelle. Il est binaire (vrai/faux) pour un échantillon particulier. La précision est souvent représentée graphiquement et surveillée pendant la phase d'entraînement, 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 [96].
- **La fonction de perte**, également appelée fonction de coût, prend en compte les probabilités ou l'incertitude d'une prédiction en fonction de l'écart entre la

prédiction et la valeur réelle. Contrairement à la précision, la perte n'est pas un pourcentage c'est une somme des erreurs commises pour chaque échantillon dans les ensembles d'apprentissage ou de validation [96].

Pendant le processus de l'entraînement, l'objectif est de minimiser cette valeur.

Nous avons essayé d'entraîner le réseau avec trois architectures, nous avons choisi l'architecture qui donne le meilleur résultat par rapport aux autres.

4.5.7 Résultats

Dans cette partie, nous présentons les différents résultats que nous avons obtenus avec les trois architectures.

🚦 Avec la première architecture (8 couches)

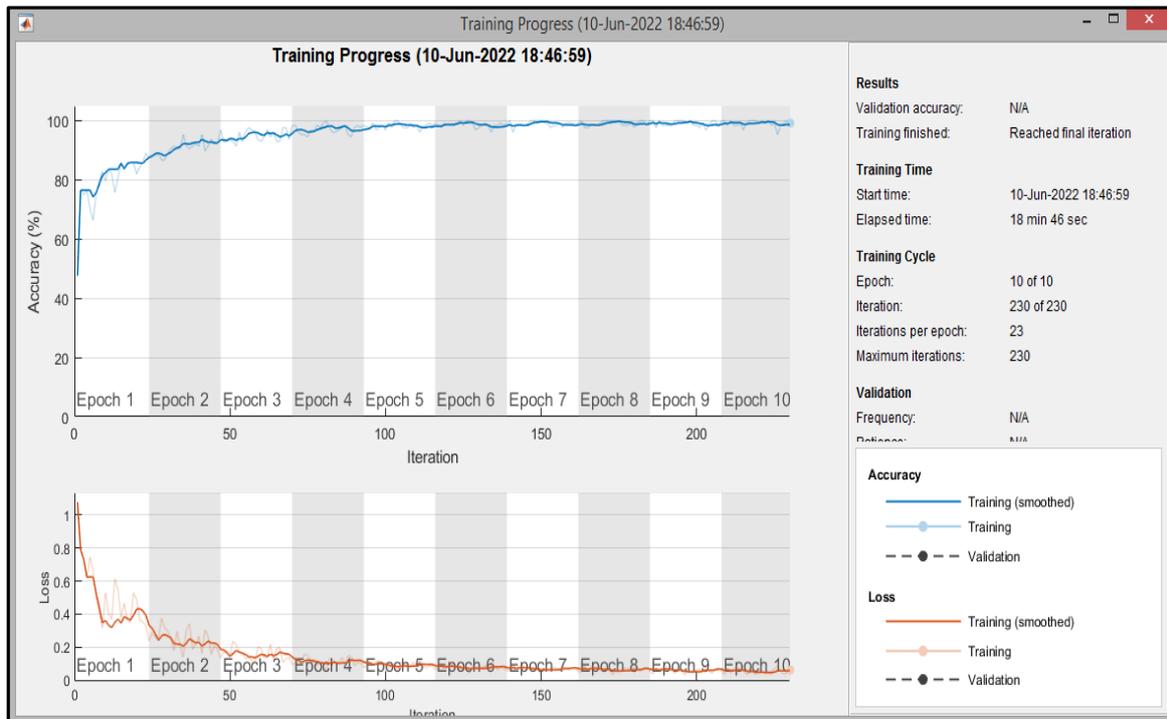


Figure 4.6: Résultat de l'entraînement du réseau avec la première architecture.

Epoque	Accuracy (précision)%	Loss (perte)
1	47.66	1.0758
5	96.88	0.1019
10	99.22	0.0586

Tableau 4-2: Résultats d'accuracy et de loss en fonction du nombre d'époques.

La figure 4-6 représente les courbes de précision et de perte de l'entraînement de la première architecture après 10 époques et un temps d'exécution d'approximativement d'une heure. D'après cette figure, nous observons que la précision d'entraînement augmente avec le nombre d'époques et la perte diminue.

Le tableau 4-2 représente les valeurs de précision et de perte en fonction du nombre d'époques. Pour l'époque 10, la précision d'entraînement atteint 99.22% et la valeur de perte est égale à 0.0586.

 Avec la deuxième architecture (12 couches)

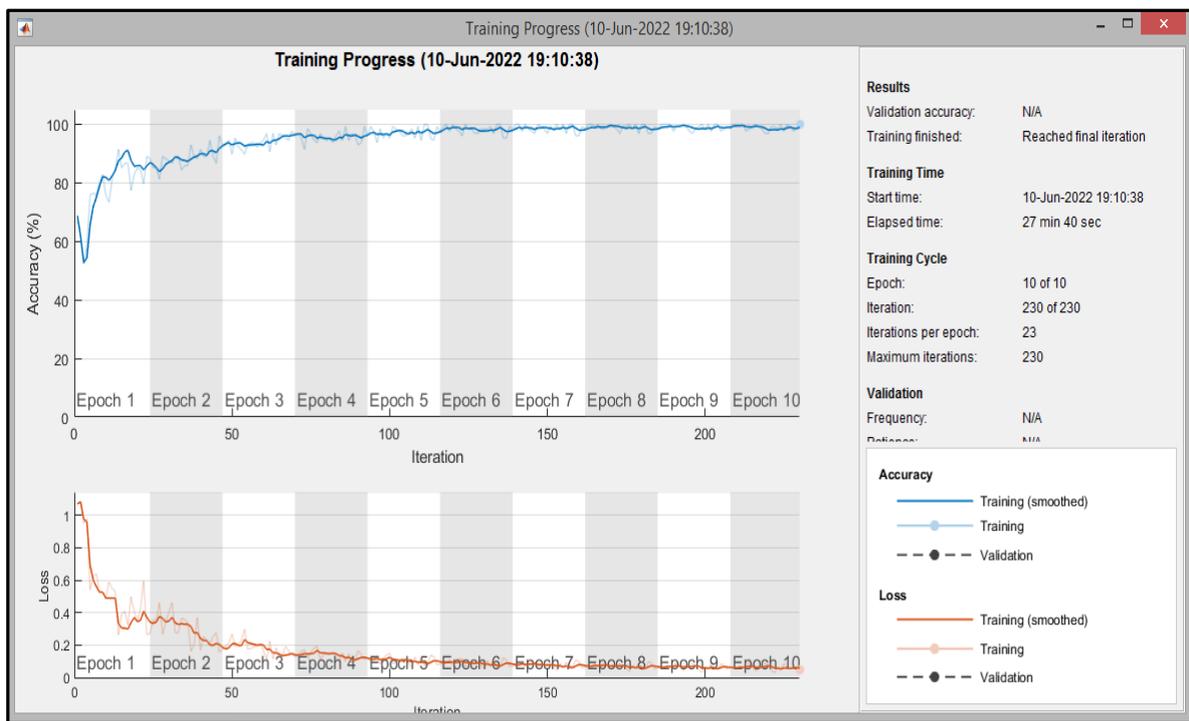


Figure 4.7: Résultat de l'entraînement du réseau avec la deuxième architecture.

Epoque	Accuracy (précision)%	Loss (perte)
1	68.75	1.0699
5	95.31	0.1498
10	100.00	0.0446

Tableau 4-3: Résultats d'accuracy et de loss en fonction du nombre d'époques.

La figure 4-7 représente les courbes de précision et de perte de l'entraînement de la deuxième architecture après 10 époques et un temps d'exécution d'approximativement d'une

heure. D’après cette figure, nous observons que la précision d’entraînement augmente avec le nombre d’époques et la perte diminue.

Le tableau 4-3 représente les valeurs de précision et de perte en fonction du nombre d’époques. Pour l’époque 10, la précision d’entraînement est de 100% et la valeur de perte égale à 0.0446.

Avec la troisième architecture (15 couches)

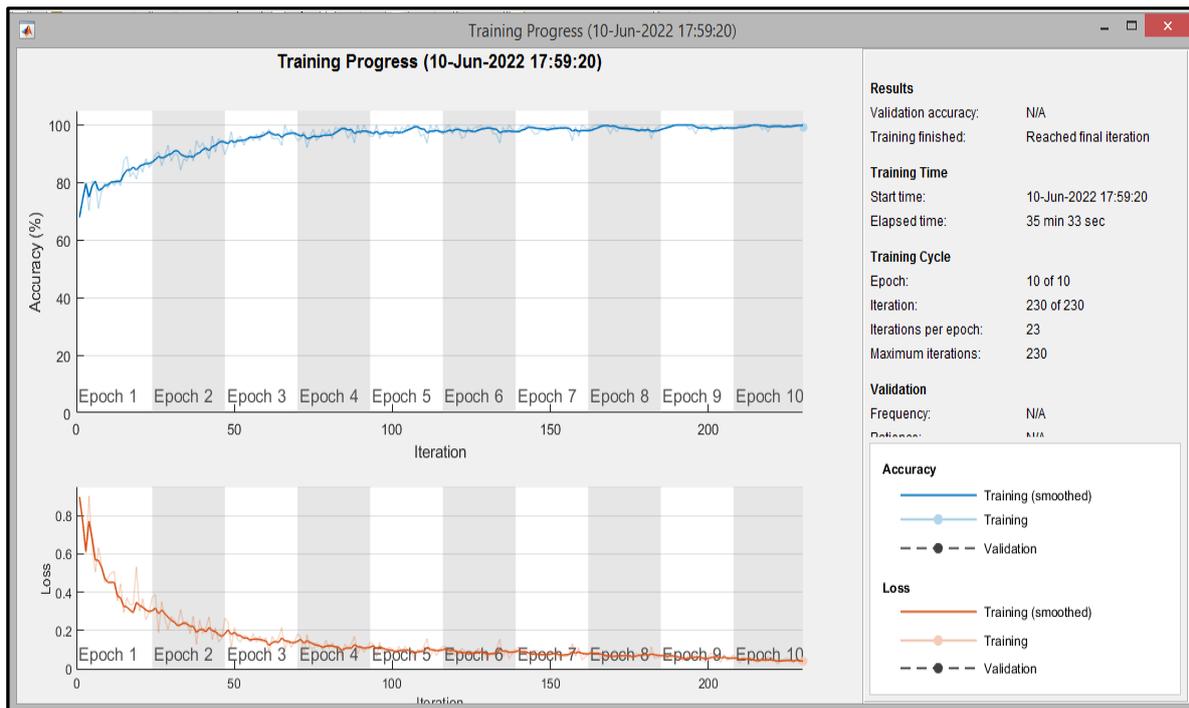


Figure 4.8: Résultat de l’entraînement du réseau avec la troisième architecture.

Epoque	Accuracy (précision)%	Loss (perte)
1	67.97	0.8966
5	96.09	0.0991
10	99.22	0.0425

Tableau 4-4: Résultats d’accuracy et de loss en fonction du nombre d’époques.

La figure 4-8 représente les courbes de précision et de perte de l’entraînement de la troisième architecture après 10 époques et un temps d’exécution d’approximativement d’une heure. D’après cette figure, nous observons que la précision d’entraînement augmente avec le nombre d’époques et la perte diminue.

Le tableau 4-4 représente les valeurs de précision et de perte en fonction du nombre d'époques. Pour l'époque 10, la précision d'entraînement est de 99.22% et la valeur de perte égale à 0.0425.

Interprétation

Nous observons dans les trois cas que la précision augmente avec la diminution de la perte, les deux semblent souvent être inversement proportionnels. Plus la précision augmente et plus la perte diminue, le modèle de classification fonctionne bien.

A travers les résultats obtenus, nous avons choisi la deuxième architecture qui contient 12 couches, la précision d'entraînement est de 100% et la valeur de perte est de 0.0446 pour l'époque 10.

Dans cette étape nous allons faire l'analyse de l'entraînement du réseau, nous utilisons pour cela la fonction analyzeNetwork(convnet) pour visualiser , comprendre l'architecture d'un réseau et vérifier que nous avons correctement défini l'architecture et détecter les problèmes qui concernent les couches. La figure 4.9 ci-dessous donne les informations concernant la deuxième architecture qui contient 12 couches.

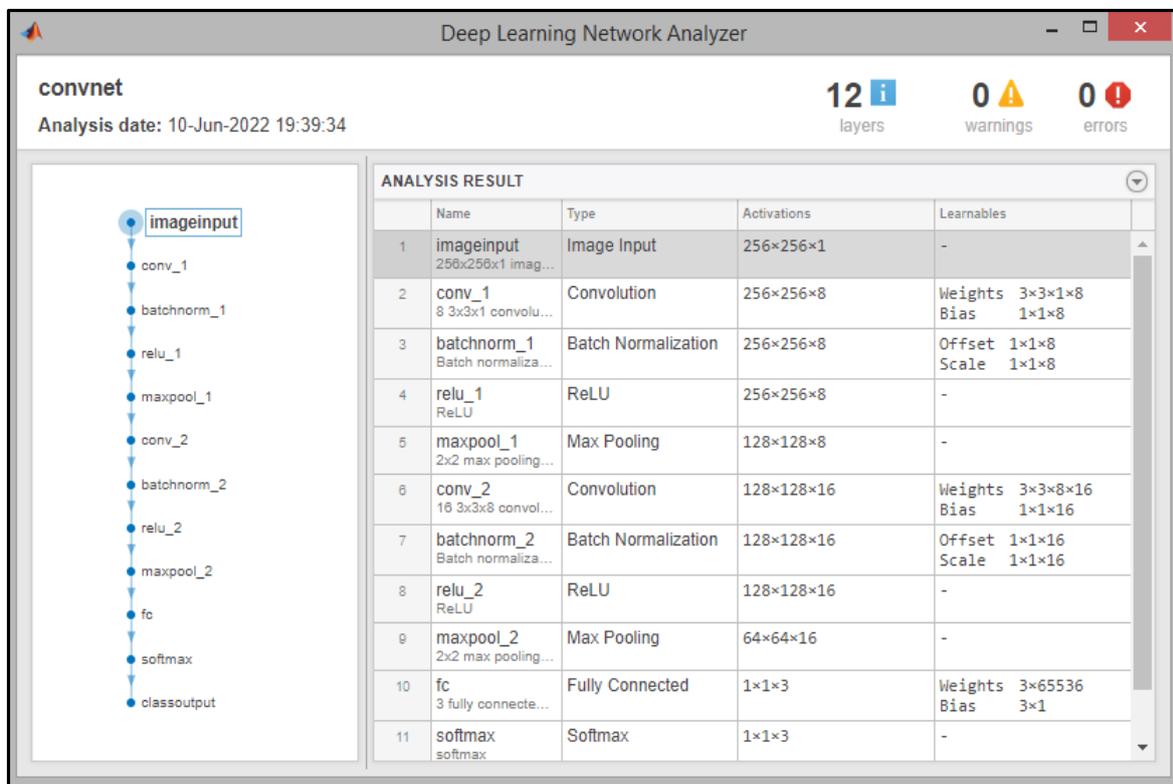


Figure 4.9: La deuxième architecture avec 12 couches.

4.5.8 Test de précision

Dans cette étape, nous allons utiliser les données de test pour calculer la précision. La deuxième architecture fonctionne avec une précision de 100 % sur l'ensemble de données d'entraînement, mais seulement de 73% sur l'ensemble de données de test.

4.5.9 Augmentation de données

Tout modèle d'apprentissage en profondeur nécessite une grande quantité de données d'entraînement pour avoir des résultats précis. Parmi les techniques qui permettent de résoudre ce problème c'est l'augmentation de données.

Les techniques d'augmentation de données sont divisés en deux, les transformations géométriques et les transformations diverses. Parmi les techniques de transformations géométriques, on a les rotations, réflexions, translations...etc (Figure 4.10).

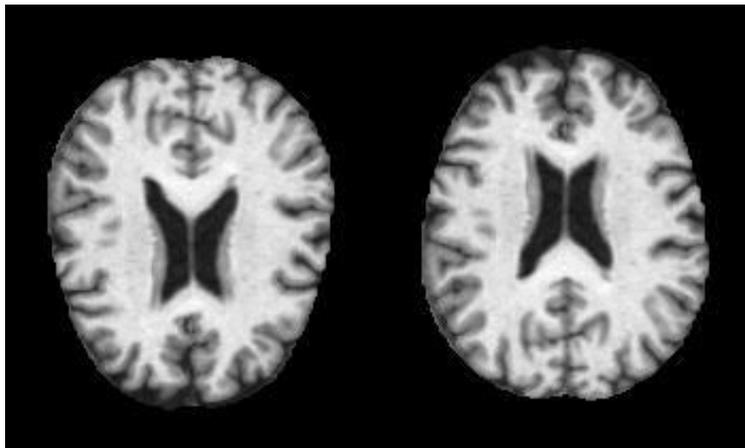


Figure 4.10: A gauche, image originale et à droite image après rotation.

Nous avons essayé de faire l'augmentation des données d'entraînement et avoir les résultats après augmentation. La figure 4-11 et le tableau 4-5 montrent les résultats obtenus suivants :



Figure 4.11: Courbe de précision et de perte après augmentation de données.

Epoque	Accuracy (précision)%	Loss (perte)	Accuracy (précision)% sans augmentation	Loss (perte) sans augmentation
1	55.47	0.9789	68.75	1.0699
5	84.38	0.3973	95.31	0.1498
10	81.25	0.4631	100.00	0.0446

Tableau 4-5: Résultats d'accuracy et de loss en fonction du nombre d'époques.

4.5.10 Interprétation après augmentation de données

Nous pouvons remarquer que les résultats obtenus ne sont pas satisfaisant avec augmentation de données par rapport à ceux obtenus sans augmentation, la précision de l'entraînement diminue. Par exemple pour l'époque 10, la précision est égale à 81.25% et la valeur de perte 0.4631 et pour les données de test, la précision est égale à 64.67%.

4.6 Classification par AlexNet

AlexNet est un type de réseau de neurone convolutionnel qui peut classer les images en 1000 catégories d'objets (telles que clavier, tasse à café, crayon et de nombreux animaux) [97].

AlexNet contient 5 couches convolutives et 3 couches entièrement connectées (Figure 4.12). La couche Relu est appliquée après les couches de convolution et la couche entièrement connectée. La couche dropout est appliquée avant les première et deuxième couches entièrement connectées [98].

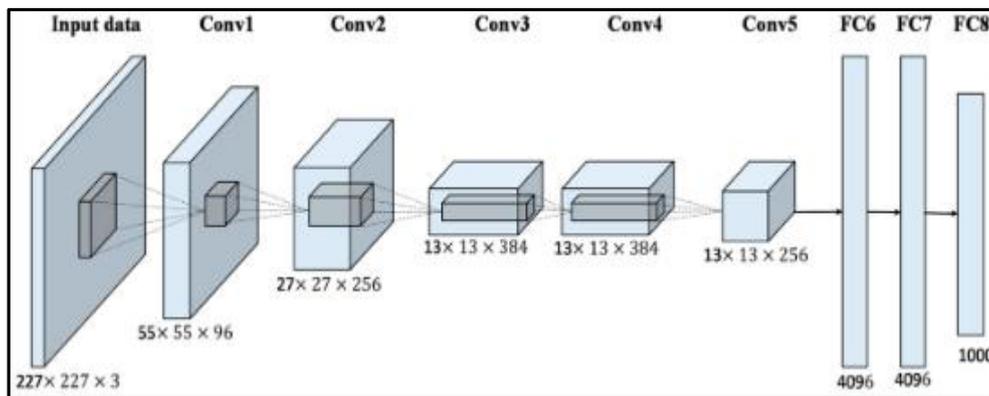


Figure 4.12: Visualisation de l'architecture AlexNet [98].

Pour réaliser notre algorithme de réseau AlexNet, nous allons suivre les étapes qui sont représentées dans l'organigramme suivant (Figure 4.13) :

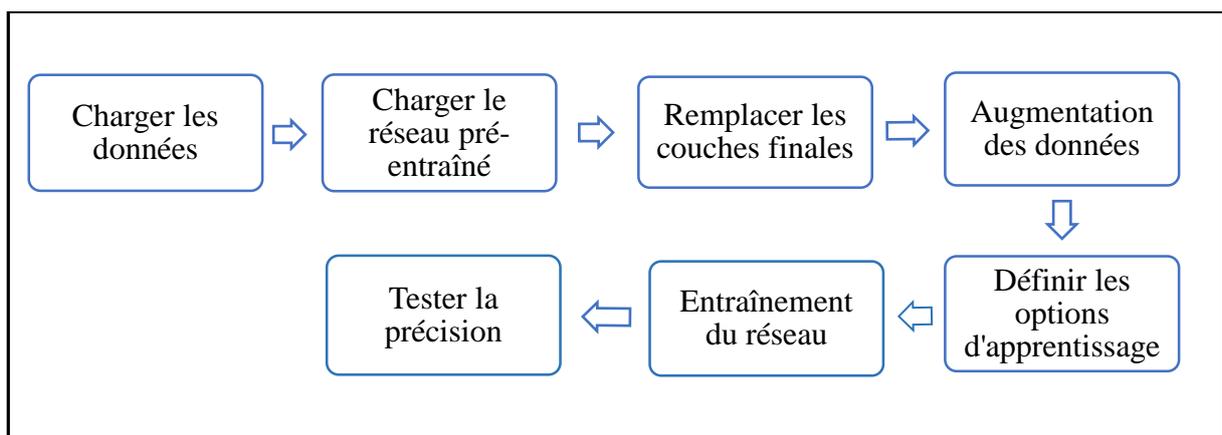


Figure 4.13: Les étapes d'implémentation de réseau AlexNet.

L'implémentation du réseau AlexNet est similaire à l'implémentation du réseau de neurone convolutionnels CNN, sauf dans les deux étapes de l'augmentation de données et du remplacement des couches finales.

➤ **Remplacement des couches finales**

La structure du réseau reste la même à l'exception des trois dernières couches. Ces trois dernières couches sont remplacées par une couche entièrement connectée, une couche softmax et une couche de sortie de classification. Nous avons spécifié les options de la nouvelle couche entièrement connectée, en fonction des nouvelles données en la définissant pour qu'elle ait la même taille que le nombre de classes, dans la nouvelle architecture, nous l'avons donc configuré pour 3 classes [97].

➤ **Augmentation des données**

Le réseau nécessite des images d'entrée de taille $227 \times 227 \times 3$, mais notre base de données contient des images de tailles différentes en niveaux de gris. Nous avons utilisé l'augmentation de données pour redimensionner automatiquement les images d'entraînement, et nous avons spécifié les opérations d'augmentation supplémentaires à effectuer sur les images d'entraînement [97].

Résultats

L'implémentation de réseau AlexNet donne les résultats montrés ci-dessous :

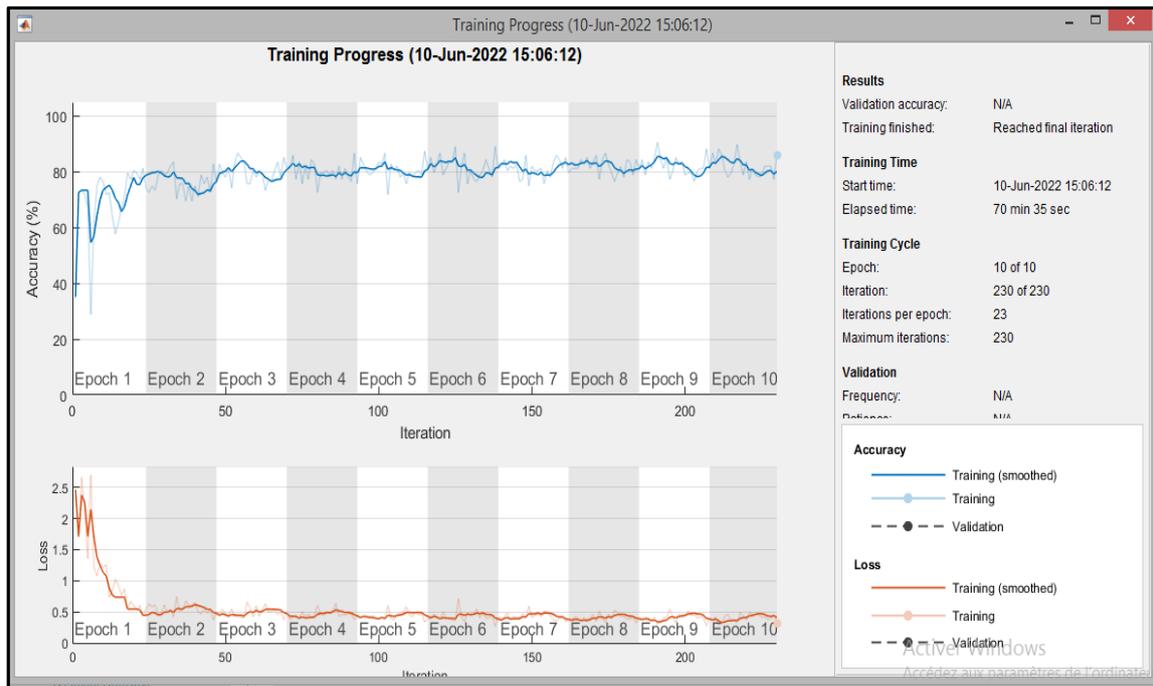


Figure 4.14: Résultats d'entraînement de réseau AlexNet.

Epoque	Accuracy (précision)%	Loss (perte)
1	35.16	2.4596
5	83.59	0.3874
10	85.94	0.3163

Tableau 4-6: Résultats d'accuracy et de loss en fonction du nombre d'époques.

La figure 4-14 représente les courbes de précision et de perte d'entraînement du réseau AlexNet après 10 époques et un temps d'exécution d'approximativement une heure. D'après cette figure, nous observons que la précision d'entraînement augmente avec le nombre d'époques et la perte diminue.

Le tableau 4-6 représente les valeurs de précision et de perte en fonction du nombre d'époques. Pour l'époque 10, la précision d'entraînement est 85.94% et la valeur de perte égale à 0.3163.

Nous avons testé notre modèle sur les données de test et nous avons trouvé une précision de test égale à 84.14%.

4.7 Evaluation des performances

La matrice de confusion est un outil de mesure de la performance des modèles de classification à 2 classes ou plus. La matrice de confusion est un tableau à 4 valeurs représentant les différentes combinaisons de valeurs réelles et valeurs prédites comme le montre la figure 4.15 [99].

		Classe réelle	
		-	+
Classe prédite	-	True Negatives <i>(vrais négatifs)</i>	False Negatives <i>(faux négatifs)</i>
	+	False Positives <i>(faux positifs)</i>	True Positives <i>(vrais positifs)</i>

Figure 4.15: Matrice de confusion [99].

Pour calculer une matrice de confusion, il est nécessaire de disposer d'un ensemble de données de test (test dataset) ou d'un ensemble de données de validation (validation dataset) ainsi que les valeurs des résultats attendues [100].

Les résultats d'une matrice de confusion sont classés en quatre grandes catégories : les vrais positifs, les vrais négatifs, les faux positifs et les faux négatifs.

- **TP** : les cas où la prédiction est positive, et où la valeur réelle est effectivement positive [100].
- **TN** : les cas où la prédiction est négative, et où la valeur réelle est effectivement négative [100].
- **FP** : les cas où la prédiction est positive, mais où la valeur réelle est négative [100].
- **FN** : les cas où la prédiction est négative, mais où la valeur réelle est positive [100].

Cette matrice est indispensable pour définir les différentes métriques de classification telles que la précision, la spécificité et la sensibilité.

➤ **La précision**

C'est la proportion de prédictions correctes parmi les points que l'on a prédits positifs, calculé par l'équation ci-dessous [99] :

$$P = \frac{TP}{TP + FP} \times 100$$

➤ **La sensibilité**

La sensibilité est le taux de vrais positifs, c'est à dire la proportion de positifs que l'on a correctement identifiés, calculé par l'équation ci-dessous [99] :

$$S = \frac{TP}{TP + FN} \times 100$$

➤ **La spécificité**

Est le taux d'individus négatifs correctement prédits par le modèle, calculé par l'équation ci-dessous [99] :

$$Sp = \frac{TN}{FP + TN} \times 100$$

Elle mesure la capacité du modèle à détecter l'ensemble des individus négatifs.



Figure 4.16: Matrice de confusion de CNN pour l'ensemble de test.

La figure 4.16 représente la matrice de confusion de CNN pour l'ensemble de test. Cette matrice montre les bonnes prédictions sur sa diagonale tout en donnant le nombre et le pourcentage de bonnes prédictions.

Avec le réseau CNN, nous avons trouvé un taux de précision égal à 73% et un taux d'erreur de 27%.

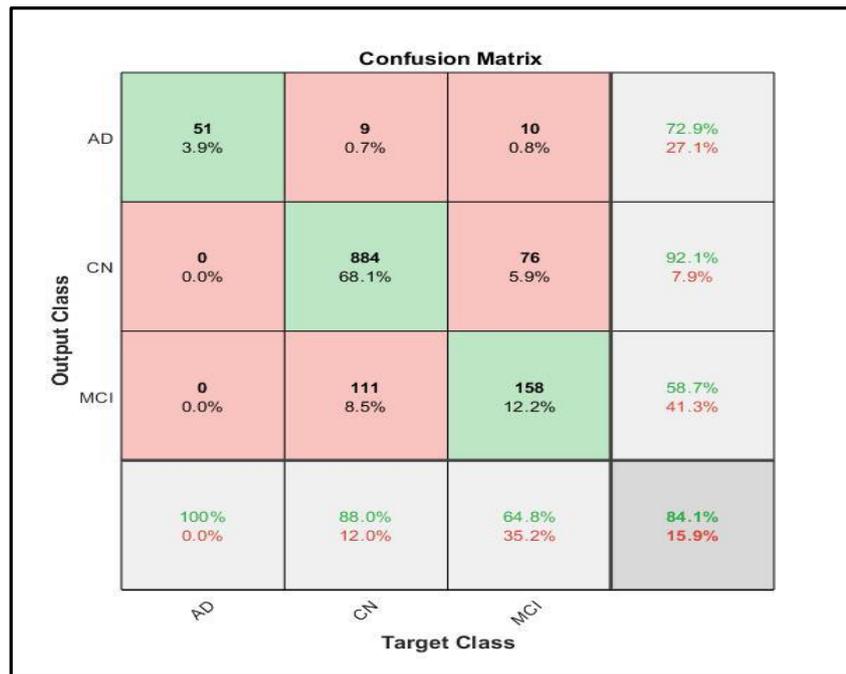


Figure 4.17: Matrice de confusion de réseau AlexNet pour l'ensemble de test.

La figure 4.17 représente la matrice de confusion d'AlexNet pour l'ensemble de test. Avec le réseau AlexNet, nous avons trouvé un taux de précision égal à 84.1% et un taux d'erreur de 15.9%.

➤ **Comparaison des résultats entre CNN et AlexNet**

Le tableau 4-7 ci-dessous, résume les résultats qui nous avons obtenu avec les deux modèles CNN et AlexNet et en même fait la comparaison entre les deux.

	Précision d'entraînement	Précision de test	Précision	Sensibilité	Spécificité	Taux d'erreur
CNN sans augmentation de données	100%	73%	AD 100% CN 78.59% MCI 39.59%	AD 26%, CN 89% MCI 29%	AD 100%, CN 35.43% MCI 88.44%	27%
AlexNet	86%	84.1%	AD 73%, CN 92.08% MCI 59%	AD 100%, CN 98% MCI 65%	AD 98.47%, CN 74.23% et MCI 89.47%	15.9%

Tableau 4-7: Comparaison entre CNN et AlexNet.

D'après le tableau 4-7, on remarque que le modèle Alexnet donne de meilleurs résultats que le CNN pour les différents indicateurs de performances. Par exemple, pour la classe MCI, il donne une précision de 59%, une sensibilité de 65% et une spécificité de 89.47% contre 9.59%, 29% et 88.44% pour le réseau CNN.

La classification des trois stades de l'Alzheimer par AlexNet est meilleure qu'avec le réseau CNN à cause du résultat de l'entraînement et de test. Le modèle AlexNet donne une précision d'entraînement de 86% et de test est de 84.1%, l'écart entre eux est petit. Au contraire pour le CNN, la précision d'entraînement est de 100% et de test de 73%, donc l'écart est grand à cause de problème connu dans l'apprentissage profond, qui est le surapprentissage.

Pour évaluer notre modèle de classification et vérifier son fonctionnement, nous comparons notre méthode (AlexNet) avec quelques méthodes citées dans l'état de l'art.

Auteurs	Précision	Sensibilité	Spécificité
H.A. Helaly, M. Badawy, A.Y. Haikal	Précision de 93.61% et 95.17% pour les classifications d'étages AD multi-classes (AD, EMCI et LMCI et CN)	/	/
k. Aderghal	AD 33.82% CN 52.12% MCI 62.80%	/	/
Notre méthode	AD 73% CN 92.08% MCI 59%	AD 100% CN 98% MCI 65%	AD 98.47% CN 74.23% MCI 89.47%

Tableau 4-8: Performances de notre méthode par rapport d'autres méthodes.

D'après le tableau 4-8, on remarque que la méthode de classification proposée, basée sur AlexNet, a donnée des résultats satisfaisants.

4.8 Présentation de l'interface

Une interface graphique est un affichage graphique permettant à l'utilisateur d'effectuer des tâches interactives, rendant compte des résultats de l'interaction avec l'utilisateur et contenant des objets graphiques : menus, barre d'outils, boutons, liste déroulante, axes.... [101].

Dans notre travail, nous présentons notre d'interface graphique avec le langage MATLAB R2019a qui a pour but de classer les différents stades de la maladie d'Alzheimer.

L'interface graphique se compose de deux boutons poussoirs, le premier pour charger l'image et l'autre pour classer l'image en CN, AD ou MCI, et ainsi que d'une fenêtre d'affichage où l'on visualise l'image.

La figure 4.18 ci-dessous représente notre d'interface graphique réalisée avec le langage MATLAB.

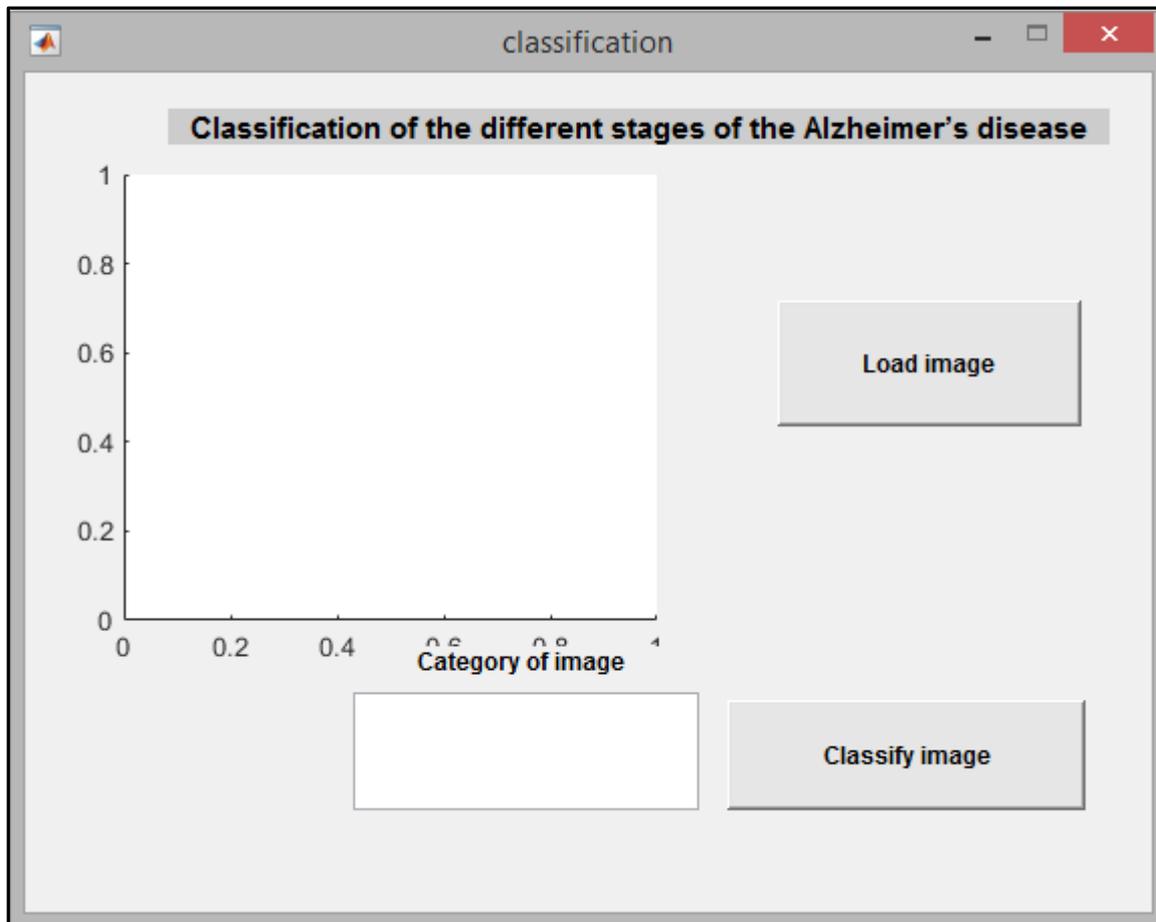


Figure 4.18: Interface graphique.

- **Affichage du résultat**

Les figures 4.19 et 4.20 ci-dessous, présente les résultats de l'interface graphique avec la classe de l'image.

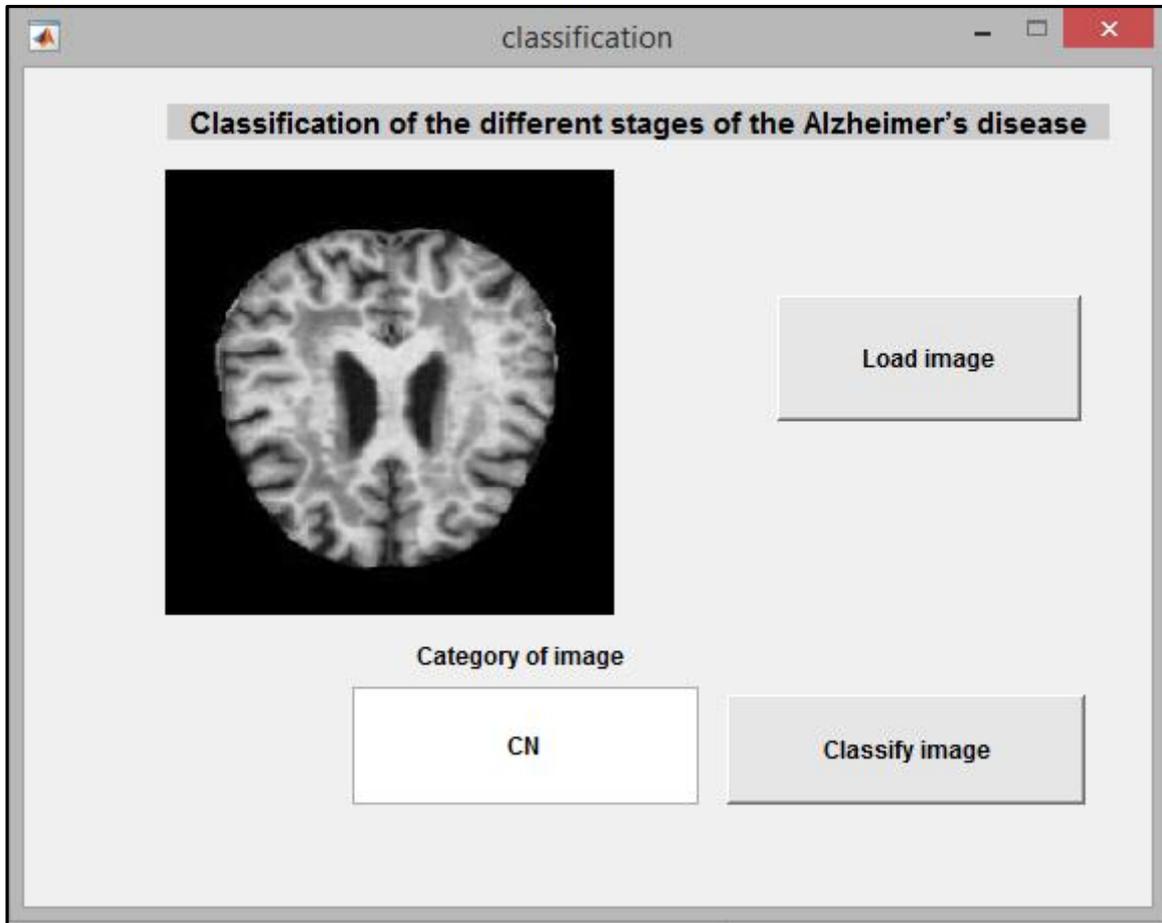


Figure 4.19: Résultat de l'interface graphique pour sujet sain.

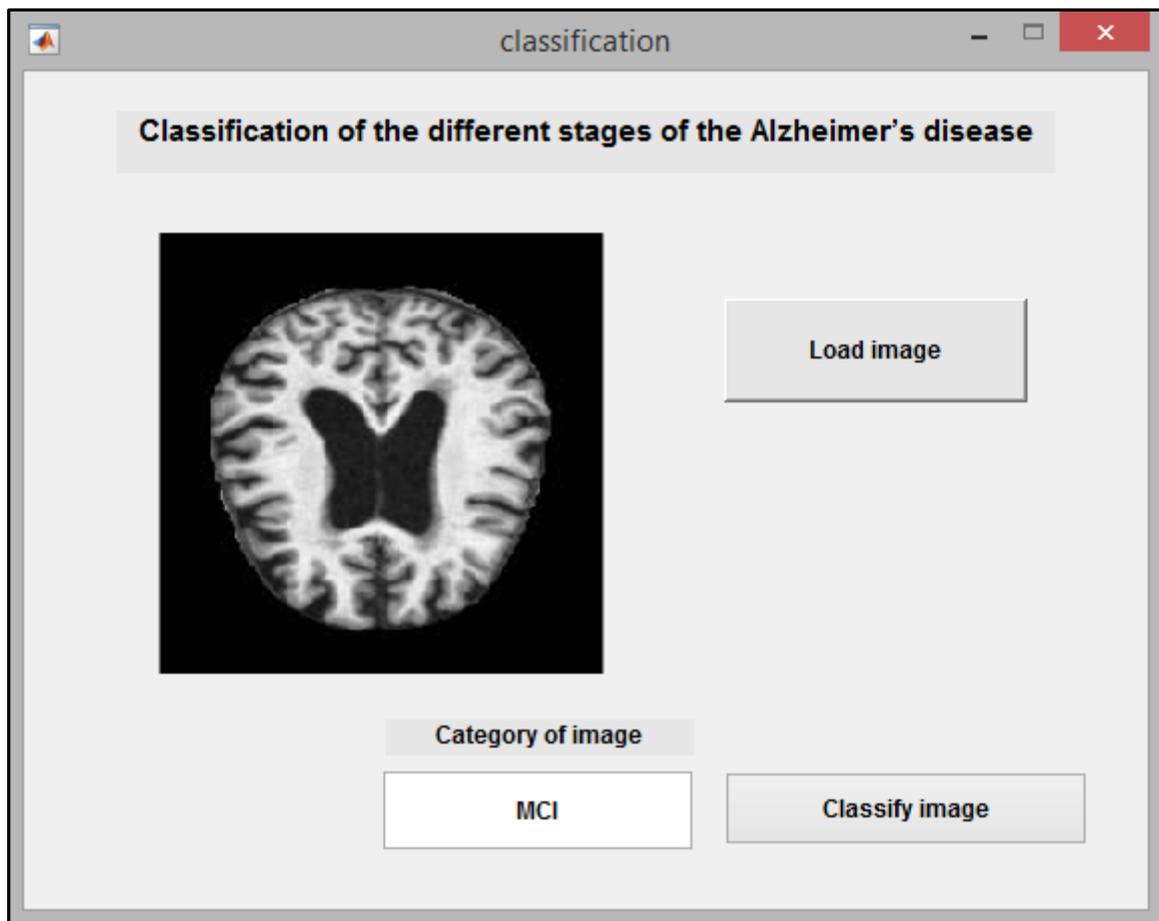


Figure 4.20: Résultat de l'interface graphique pour sujet atteint de troubles cognitifs légers.

Discussion

Dans ce chapitre, nous avons présenté deux algorithmes de classification, les étapes de leur implémentation, et les résultats obtenus pour chaque étape. Au début, nous avons réalisé la classification par un réseau de neurone convolutionnel CNN avec et sans augmentation de données. Par la suite, nous avons appliqué l'un des modèles de CNN connu sous le nom AlexNet. Selon les résultats obtenus, le modèle AlexNet est meilleur que CNN pour la classification de notre base de données.

Finalement, nous avons réalisé une interface graphique qui sert à classer le patient soit en CN, AD ou MCI.

Conclusion générale

Conclusion générale

Ces dernières années, les chercheurs se sont davantage intéressés à l'apprentissage profond et à ses modèles pour parvenir à la classification des images médicales, et à la segmentation des images cérébrales, pour l'aide au diagnostic de certaines maladies, telles que celles qui affectent le cerveau.

Le but de notre travail était de réaliser la classification de la maladie d'Alzheimer, à partir d'images IRMs cérébrales en utilisant l'apprentissage profond en particulier les réseaux de neurones convolutionnels. Les réseaux de neurones convolutionnels sont à ce jour les modèles les plus performants pour classer des images par rapport à d'autres modèles de l'apprentissage automatique.

Dans notre étude, nous avons réalisé la classification de trois stades de la maladie d'Alzheimer AD, CN et MCI avec deux architectures. La première architecture représente un CNN qui contient 12 couches et la deuxième architecture représente un modèle de CNN pré-entraîné connu, AlexNet qui contient 25 couches. Nous avons implémenté les deux architectures avec le langage MATLAB R2019a. Nous avons remarqué que l'implémentation des deux architectures est similaire, sauf dans le remplacement des couches finales pour AlexNet, ainsi que le fait que ce réseau ne nécessite pas d'augmentation de données.

Nous avons exécuté les deux architectures sur l'environnement CPU avec les mêmes options d'apprentissage. Selon les résultats obtenus, le modèle AlexNet est plus performant pour la classification que CNN, nous avons obtenu un taux de précision égal à 84.1%, un taux d'erreur 15.9%, avec augmentation de données.

En termes de perspectives, notre travail peut être amélioré, afin d'obtenir des résultats plus performants selon les recommandations suivantes :

- L'utilisation d'une base de données plus importante que celle que nous avons utilisée.
- L'utilisation d'autre modèle de CNN comme ResNet et googleNet.
- L'utilisation d'autre modèle de l'apprentissage profond comme RNN.
- L'utilisation de l'environnement GPU pour l'exécution au lieu CPU.

Bibliographie

- [1] Visible Body, « Cerveau et nerfs : cinq clés pour comprendre le système nerveux ». 2022. < <https://www.visiblebody.com/fr/learn/nervous/system-overview> > (Consulté le 11/05/2022).
- [2] Larousse, « Système nerveux ».2018. <https://www.larousse.fr/encyclopedie/divers/systeme_nerveux/73116> (Consulté le 11/05/2022).
- [3] Société canadienne du cancer, « L'encéphale et la moelle épinière». [https://cancer.ca/fr/cancer-information/cancer-types/brain-and-spinal-cord/what-is-a-brain-or-spinal-cord#:~:text=L%27encéphale%20est%20le%20centre,signaux%20fondés%20sur%20ces%20informations](https://cancer.ca/fr/cancer-information/cancer-types/brain-and-spinal-cord/what-is-a-brain-or-spinal-cord-tumour/the-brain-and-spinal-cord#:~:text=L%27encéphale%20est%20le%20centre,signaux%20fondés%20sur%20ces%20informations)(Consulté le 12/05/2022).
- [4] Carnets2psycho, « La définition de Encéphale ». <https://carnets2psycho.net/dico/sens-de-encephale.html>(Consulté le 13/05/2022).
- [5] Institut national de cancer, « Les différentes parties ».<<https://www.e-cancer.fr/Patients-et-proches/Les-cancers/Tumeurs-du-cerveau/Le-cerveau/Les-differentes-parties>>(Consulté le 13/05/2022).
- [6] Fédération pour la recherche sur le cerveau, « Anatomie de cerveau de système nerveux ». < <https://www.frcneurodon.org/comprendre-le-cerveau/a-la-decouverte-du-cerveau/anatomie-du-cerveau-et-du-systeme-nerveux/#:~:text=Le%20lobe%20frontal%20est%20impliqué,de%20la%20formation%20des%20émotions> > (Consulté le 13/05/2022)..
- [7] A.F.Z. Yahiaoui, I. Azzaz, « Analyse des images IRM pour l'étude de la sclérose en plaque », Mémoire de master en Génie Biomédical, Université Abou Bakr Belkaid, Tlemcen, Algérie, 2013.
- [8] A. Benabdallah, « Mise en œuvre d'une technique automatique de segmentation de sillons corticaux», Mémoire de Magister en Informatique, Université Abou Bakr Belkaid, Tlemcen, Algérie, 2011. < <http://dspace.univ-tlemcen.dz/bitstream/112/1022/1/BENABDALLAH-Ali.pdf>> (Consulté le 14/05/2022).
- [9] Connaître les syndromes cérébelleux, « Qu'est-ce que le cervelet? Quel est son rôle ? ».2013. < <https://www.csc.asso.fr/article/connaître/49/> > (Consulté le 14/05/2022).
- [10] Journal des femmes santé, « Tronc cérébrale : définition, schéma ».2022. < <https://sante.journaldesfemmes.fr/fiches-anatomie-et-examens/2796385-tronc-cerebral-definition-schema/>> (Consulté le 14/05/2022).
- [11] Y. Cherfa. « Instrumentation d'exploration fonctionnel ».Master 2 Génie Biomédicale, Université Saad Dahleb Blida 1, Algérie, 2022.

Bibliographie

- [12] Kartable, « Compléter le schéma de la moelle épinière ». <<https://www.kartable.fr/ressources/svt/exercice-de-connaissances/compléter-le-schema-de-la-moelle-epiniere/19369/132581>> (Consulté le 15/05/2022).
- [13] Institut du cerveau. « Comprendre le cerveau, son développement, son fonctionnement, sa plasticité et ses pathologies », Juillet2020,
< [https : //institutducerveau-icm.org/fr/actualite/comprendre-le-cerveau-et-son-fonctionnement/](https://institutducerveau-icm.org/fr/actualite/comprendre-le-cerveau-et-son-fonctionnement/)> (Consulté le 23/12/2021).
- [14] « Définition : Ganglions de la base | Psychomédia », <https://www.psychomedia.qe.ca/lexique/définition/ganglions-de-la-base> (Consulté le 23/12/2021).
- [15] Parkinson et Huntington, « Les ganglions de la base ». < <http://uf-mi.u-bordeaux.fr/ter-2016/pastureau-labarchede/ganglions-intro.php>> (Consulté le 16/05/2022).
- [16] D. Duchemin. « Atrophie hippocampique : conséquence, liens avec Alzheimer, traitement ». In : Journal des femmes.<<https://sante.journaldesfemmes.fr/fiches-maladies/2678699-atrophie-hippocampique-hippocampe-cerveau-consequences-liens-alzheimer-traitement/>>(Consulté le 23/12/2021).
- [17] carnets2psycho. « La définition de Hippocampe ». < <https://carnets2psycho.net/dico/sens-de-hippocampe.html>>(Consulté le 16/052022).
- [18] Futura santé, « Maladie neurodégénérative : qu'est-ce que c'est ? ». <<https://www.futura-science.com/sante/definitions/medecine-maladie-neurodegenerative-12214/>>(Consulté le 28/05/2022).
- [19] Ministère des solidarités et de la santé, « La maladie d'Alzheimer ».2021. <<https://solidarites-sante.gouv.fr/soins-et-maladies/maladies/maladies-neurodegeneratives/article/la-maladie-d-alzheimer>> (Consulté le 16/05/2022).
- [20] Medical Student, « Comparaison entre un cerveau normal et du cerveau d'un patient atteint d'un MA ». < <https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcTTKyXR6WfKr-IR2AaBHfr1pggEQgHibHH1Tb2YRsg1-x4vgjFO&s> > (Consulté le 28/05/2022).
- [21] Passeport santé, « La maladie d'Alzheimer ».2021. < https://www.passeportsante.net/fr/Maux/Problemes/Fiche.aspx?doc=alzheimer_pm/> (Consulté le 16/05/2022).
- [22] Cap retraite, « Tout savoir sur les 7 stades de la maladie d'Alzheimer ».2021. <<https://www.capretraite.fr/blog/maladie-alzheimer/savoir-7-stades-de-maladie-dalzheimer/>>(Consulté le 16/05/2022).

Bibliographie

- [23] Fondation pour la recherche médicale. « Les enjeux d'un diagnostic précoce ». < <http://www.frm.org/recherches-maladies-neurologiques/maladie-d-alzheimer/recherches-maladies-neurologiques/maladie-d-alzheimer/maladie-alzheimer-enjeux-diagnostic-precoce>> (Consulté le 28/05/2022).
- [24] Y. Cherfa. « Instrumentation d'imagerie médical ». Master 2 Génie Biomédical, Université Saad Dahleb Blida 1, Algérie, 2022.
- [25] Centre d'Investigation Clinique Innovation Technologique de Nancy, « Qu'est-ce que L'IRM ». <<http://www.cic-it-nancy.fr/fr/quest-ce-que-lirm/#:~:text=excitation%20%3A%20lorsqu%27on%20ajoute%20une,qu%27on%20utilise%20une%20antenne>> (Consulté 18/05/2022).
- [26] Info-radiologie.ch, « Précession et équation de Larmor ». < <https://www.info-radiologie.ch/precession-larmor.php#:~:text=L%27équation%20de%20Larmor&text=où%20ω%20est%20la%20vitesse,ou%20f%20est%20la%20fréquence.&text=Si%20B0%20augmente%2C%20la,précession%20augmente%20et%20vice-versa>> (Consulté 18/05/2022).
- [27] IMAIOS, « Phase d'excitation ». < <https://www.imaios.com/fr/e-Cours/e-MRI/RMN/excitation-rmn> > (Consulté 18/05/2022).
- [28] IMAIOS, « Phase de relaxation et temps T1 et T2 ». < <https://www.imaios.com/fr/e-Cours/e-MRI/RMN/relaxation-rmn> > (Consulté 18/05/2022).
- [29] Société française de radiologie, « Les produits de contraste utilisés en imagerie exponentiels à des risques ». < <http://www.sfrnet.org/sfr/presse/3-materiel-de-presse/interviews-d-experts/article.phtml?id=rc%2Forg%2Fsfrnet%2Fhtm%2FArticle%2F2011%2F20110523-125704-109> > (Consulté 19/05/2022).
- [30] Info-radiologie.ch, « Imagerie par résonance magnétique ». < https://www.info-radiologie.ch/resonance_magnetique.php > (Consulté 18/05/2022).
- [31] F Shi, T Jiang, Y Wang et al. « Hippocampal shape analysis of Alzheimer disease based on machine learning methods ». In: American journal of Neuroradiology. 2007. Vol 28, N°7, pp 1339-1345.
- [32] N. Belmokhter, N. Benamrane. « Classification of Alzheimer's disease from 3d structural MRI data ». In: Computer Applications. 2012. Vol 47, N°3, pp 40-44.
- [33] H. Suk, D. Shen. « Deep Learning-Based Feature Representation for AD/MCI Classification ». In: medical image computing and computer-assisted intervention. 2013. Vol 8150, pp 583-590.

Bibliographie

- [34] F. Liu, Ch. Shen. « Learning Deep Convolutional Features for MRI Based Alzheimer's Disease Classification ». In: Computer Science. 2014. Vol 2.
- [35] Z. Yu-Dong, W. Shuihua, D. Zhengchao. « Classification of Alzheimer Disease Based on Structural Magnetic Resonance Imaging by Kernel Support Vector Machine Decision Tree ». In Electromagnetics Research, Vol. 144, 171-184, 2014.
- [36] S. Saman, T. Ghassem. « Deep learning-based pipeline to recognize Alzheimer's disease using fMRI data ». In: 2016 Future technologies conference (FTC). 2016. pp 816-820.
- [37] K.A.N.N.P Gunawardena, R.N.Rajapakse, N.D.Kodikara et al. « Applying convolutional neural networks for pre-detection of alzheimer's disease from structural MRI data ». In: Mechatronics and Machine Vision in Practice (M2VIP). 2017. pp 1-7.
- [38] M. Hon, N.M. Khan. « Towards Alzheimer's disease classification through transfer learning ». In: Bioinformatics and biomedicine (BIBM). 2017. pp 1166-1169.
- [39] I. Jyoti, Y. Zhang. « A Novel Deep Learning Based Multi-class Classification Method for Alzheimer's Disease Detection Using Brain MRI Data ». In: Brain Informatics. 2017. pp 213-222.
- [40] N. Amoroso, D. Diacono, A. Fanizzi et al. « Deep learning reveals Alzheimer's disease onset in MCI subjects: Results from an international challenge ». In: Journal of neuroscience methods. 2018. Vol 302, pp 3-9.
- [41] F. Lia, M. Liu. « Alzheimer's disease diagnosis based on multiple cluster dense convolutional networks ». In: Computerized Medical Imaging and Graphics. 2018. Vol 70, pp 101-110.
- [42] I. Jyoti, Z. Yanqing. « Brain MRI analysis for Alzheimer's disease diagnosis using an ensemble system of deep convolutional neural networks ». In: Brain Informatics. 2018, Vol 5, N°2.
- [43] T. Jo, K. Nho, A.J. Saykin. « Deep Learning in Alzheimer's Disease: Diagnostic Classification and Prognostic Prediction Using Neuroimaging Data ». In: Frontiers in aging neuroscience. 2019. Vol 11, pp 220.
- [44] F. Lia, M. Liu. « A hybrid Convolutional and Recurrent Neural Network for Hippocampus Analysis in Alzheimer's Disease ». In: Neuroscience methods. 2019. Vol 323, pp 108-118.
- [45] H. Wang, Y. Shen, S. Wang et al. « Ensemble of 3D densely connected convolutional network for diagnosis of mild cognitive impairment and Alzheimer's disease ». In: Neurocomputing. 2019. Vol 333, pp 145-156.

Bibliographie

- [46] M. Shahbaz, A. Shahzad, A. Guergachi et al. « Classification of Alzheimer's Disease using Machine Learning Techniques ». In: Proceedings of the 8th International Conference on Data Science.2019.pp 296-303.
- [47] P.C. Alejandro, F.B. Enrique, P. Alejandro et al. « Automatic assessment of Alzheimer's disease diagnosis based on deep learning techniques ». In: Computers in Biology and Medicine. 2020. Vol 120, pp 103764.
- [48] H. Parmar, B. Nutter, R. Long et al. « Spatiotemporal feature extraction and classification of Alzheimer's disease using deep learning 3D-CNN for fMRI data ». In: Medical Imaging. 2020. Vol 7, N° 5, pp 056001.
- [49] J.X. Fong; M.I. Shapiai; Y.Y. Tiew et al. « Bypassing MRI Pre-processing in Alzheimer's Disease Diagnosis using Deep Learning Detection Network ». In: Colloquium on Signal Processing & Its Applications (CSPA). 2020. pp 219-224.
- [50] T.A. Tuan, T.B. Phamb, J.Y. Kim et al. « Alzheimer's diagnosis using deep learning in segmenting and classifying 3D brain MR images ». In: Neuroscience. 2020. pp 1-10.
- [51] S.S. Kundaram, K.C. Pathak. « Deep Learning-Based Alzheimer Disease Detection ».In: Microelectronics, Computing and Communication Systems. 2021. pp 587-597.
- [52] M. Atif, B. Muzaffar, M. Muazzam et al. « A Deep Siamese Convolution Neural Network for Multi-Class Classification of Alzheimer Disease ». In : Brain sciences. 2020, Vol 10, N°2.
- [53] M. Liu, M. Xu, K. Wanq et al. « A multi-model deep convolutional neural network for automatic hippocampus segmentation and classification in Alzheimer's disease ».In: Neuroimage. 2020, Vol 208, pp 116459.
- [54] A. Rehmat, M. Usman, F. Ramzan et al. « A deep learning approach for automated diagnosis and multi-class classification of Alzheimer's disease stages using resting-state fMRI and residual neural networks ». In: medical systems.2020, Vol 44, N°2, pp 1-16.
- [55] H. Nawaz, M. Maqsood, S. Afzal et al. « A deep feature-based real-time system for Alzheimer disease stage detection ». In: Multimedia Tools and Applications. 2021. Vol 80, N° 28, pp 35789-35807.
- [56] M. Tanveer, R.U. Khan, R.B. Pachori. « A novel method for the classification of Alzheimer's disease from normal controls using magnetic resonance imaging ». In: Expert Systems.2021, Vol 38, N°, pp e12566.
- [57] H.A. Helaly, M. Badawy, A.Y. Haikal. « Deep Learning Approach for Early Detection of Alzheimer's Disease ». In: Cognitive Computation. 2021. pp 1-17.

Bibliographie

- [58] K. Aderghal, « Classification of multimodal MRI images using Deep Learning: Application to the diagnosis of Alzheimer's disease ». Thèse de doctorat, Université Ibn Zohr Agadir. 2021.
- [59] J. Venugopalan, L. Tong, H.R. Hassanzadeh et al. « Multimodal deep learning models for early detection of Alzheimer's disease stage ». In: Scientific reports. 2021. Vol 11, N°1, pp 1-13.
- [60] F. Zhang, B. Pan, P. Shao et al. « An explainable two-dimensional single model deep learning approach for Alzheimer's disease diagnosis and brain atrophy localization ». In: Electrical Engineering and Systems Science. 2021. Vol 1.
- [61] B. Lu, H.X. Li. « A Practical Alzheimer Disease Classifier via Brain Imaging-Based Deep Learning on 85,721 Samples: A Multicentre, Retrospective Cohort Study ». In: SSRN .2021. pp 48.
- [62] A. Abida, N. Saeeda, P. Mukesh et al. « Deep transfer learning for Alzheimer neurological disorder detection ». In: Multimedia Tools and Applications. 2021, Vol80, N°20, pp 30117-30142.
- [63] M. Golrokkh, A. Hojjat. « Machine learning techniques for diagnosis of Alzheimer disease, mild cognitive disorder, and other types of dementia ». In: Science Direct.2022, Vol 72, Part A.
- [64] L.F. Samhan, A.H. Alfarra, S.S. Abu-naser. « Classification of Alzheimer's Disease Using Convolutional Neural Networks ». In: Academic Information Systems Research (IAISR). 2022, Vol 6, N°3.
- [65] M. Odusami, R. Maskeliunas, S. Misra et al. « ResD Hybrid Model Based on Resnet18 and Densenet121 for Early Alzheimer Disease Classification ». In: Intelligent Systems Design and Applications. 2022. pp 296-305.
- [66] H.M. Kamrul, Z.S. Binish, A. Sagheer et al. « Alzheimer disease detection empowered with transfer learning ». In: tech science press. 2022. Vol 70, N°3, pp 5005-5019.
- [67] P. Bhaskaran, J.V. Shanmugam. « Alzheimer's disease classification using pre-trained deep networks ». In: Biomedical Signal Processing and Control. 2022. Vol 71, Part B, pp 103217.
- [68] Futura Tech. « Deep Learning : qu'est-ce que c'est ? ». < <https://www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/> > (Consulté le 28/05/2022).

Bibliographie

- [69] D.E. Yagoub, « Analyse d'images médicales, application à la catégorisation des types de tuberculose pulmonaire », Mémoire de Master en informatique, Université Abdelhamid Ibn Badis , Mostaganem, Algérie, 2017.
- [70] Wikilivre, « Comment fonctionnent les réseaux de neurones », le 4 Mai 2022. < <https://wikilivre.org/wiki/comment-fonctionnent-les-reseaux-de-deurones/> > (Consulté le 04/06/2022).
- [71] clevy, « Introduction aux réseaux de neurones -2/3 : Neurone biologique et neurone formel ». 2019. < <https://blog.clevy.io/nlp-et-ia/introduction-aux-reseaux-de-neurones-2-3-neurone-biologique-et-neurone-formel/> > (Consulté le 28/05/2022).
- [72] Natural solutions, « Histoire du Deep Learning ». 2018. < <https://www.natural-solutions.eu/blog/histoire-du-deep-learning> > (Consulté le 28/05/2022).
- [73] Digital Guide IONOS, « Réseau de neurones artificiels : quelles sont leurs capacités ? ». 2020. < <https://www.ionos.fr/digitalguide/web-marketing/quest-ce-quun-reseau-neuronal-artificiel-> > (Consulté le 28/05/2022).
- [74] Javat point, « Artificial neural network ». < <https://www.javatpoint.com/artificial-neural-network> > (Consulté le 28/05/2022).
- [75] N. Mekhaldi « Analyse des images médicales par des techniques hybrides : applications à la détection des kystes rénaux », Magister en informatique, Université Mohamed Boudiaf, Oran, Algérie, 2013.
- [76] M.Z Mokri, « Classification des images avec les réseaux de neurones convolutionnels », Mémoire de Master en Informatique, Université Tlemcen, Algérie, 2017.
- [77] DataScientest, « Convolutional neural network ». 2020. < <https://datascientest.com/convolutional-neural-network> > (Consulté le 29/05/2022).
- [78] Open classrooms, « Découvrez les différentes couches d'un CNN ». 2021. < <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn> > (Consulté le 29/05/2022).
- [79] Research gate, « Example of max pooling and average pooling operations ». < https://www.researchgate.net/figure/Example-of-max-pooling-and-average-pooling-operations-In-this-example-a-4x4-image-is_fig4_332092821 > (Consulté le 29/05/2022).
- [80] Data Science Today, « Les réseaux de neurones convolutifs ». 2018. < <https://www.datasciencetoday.net/index.php/en-us/deep-learning/173-les-reseaux-de-neurones-covolutifs> > (Consulté le 29/05/2022).
- [81] Ml4a, « Les réseaux de neurones ». < <https://ml4a.github.io/images/figures/sigmoid.png> > (consulté le 29/05/2022).

Bibliographie

- [82] Y. S Obam, « Comprendre les Réseaux de Neurones Convolutifs (CNN) ».2019 . <
<https://yannicksergeobam.medium.com/comprendre-les-réseaux-de-neurones-convolutifs-cnn-d5f14d963714> > (Consulté le 29/05/2022).
- [83] CS 230, « Pense-bête de réseaux de neurones convolutionnels ». <
<https://stanford.edu/~shervine/1/fr/teaching/cs-230/pense-bete-reseau-neurones-convolutionnels> > (Consulté le 30/05/2022).
- [84] retengr, « Deep Learning : définition, applications, avantages et inconvénients ». <
<https://www.retengr.com/2021/01/22/deep-learning-definitions-applications-avantages-inconvénients/> > (Consulté le 30/05/2022).
- [85] Data scientist, « Qu'est-ce qu'un convolutional neural network ? ». <
<https://www.jeveuxetredata scientist.fr/convolutional-neural-network/> > (Consulté le 30/05/2022).
- [86] M. Kasdi , « L'apprentissage profond (Deep Learning) pour la classification et la recherche d'imagerie par le contenu », Mémoire de Master en Informatique, Université de Ouargla , Algérie, 2017.
- [87] Open Genus, «Disadvantages of CNN models ». <
<https://iq.opengenus.org/disadvantages-of-cnn/> > (Consulté le 30/05/2022).
- [88] Math Works, « Training Options ADAM ». <
<https://ch.mathworks.com/help/deeplearning/ref/nnet.cnn.trainingoptionsadam.html> >.
(Consulté le 30/05/2022).
- [89] Jedha Bootcamp, « La vraie différence entre CPU et GPU ». 2021. <
<https://www.jedha.co/blog/vraie-difference-cpu-gpu> > (Consulté le 30/05/2022).
- [90] A. Géron, 2017. Hands-On_Machine_Learning_with_Scikit-learn and tensorflow. USA : O'Reilly Media.
- [91] M.A. Bechar. « Informatique médical ».L3 Génie Biomédicale, Université Saad Dahleb Blida 1, Algérie, 2019.
- [92] R.C. Petersen, P.S. Aisen, L.A. Beckett et al, « Alzheimer's Disease Neuroimaging Initiative (ADNI) », Neurology, pp: 201-209, 2010.
- [93] S. Uddin, « Convolutional Neural Network (CNN) in MATLAB », University of Engineering and Technology, 2021.
- [94] « Normalisation des bases de données | moins de redondance-IONOS », <
<https://www.ionos.fr/digitalguide/hebergement/aspects-techniques/normalisation-base-de-donnees/>> (Consulté le 4/6/2022)
- [95] Mathworks, « Create simple Deep Learning Network for classification », 2022

Bibliographie

<<https://www.mathworks.com/help/deeplearning/ug/create-simple-deep-learning-network-for-classification.html> > (Consulté le 4/6/2022)

[96] AI wiki, « Accuracy and Loss »,

<<https://machine-learning.paperspace.com/wiki/accuracy-and-loss>> (Consulté le 4/6/2022)

[97] Mathworks, « alexnet »,2022

<<https://www.mathworks.com/help/deeplearning/ref/alexnet.html;jsessionid=e2aa153c3cb6c42953810e322d61>> (Consulté le 4/6/2022)

[98] K. Lounis, D. Moussi, « La classification d'images d'insectes ravageurs en utilisant de Deep Learning », Master en systèmes informatiques, université Mouloud Mammeri,Tizi Ouzou, Algérie, 2019.

[99] Kobia, « Partie 2 : Matrice de confusion, la grande confusion », le 16 novembre 2021

<<https://kobia.fr/classification-metrics-matrice-de-confusion/>> (Consulté le 4/6/2022)

[100] lebigdata, « Confusion Matrix : l'outil de mesure de performances du Machine learning »,2018.

<<https://www.lebigdata.fr/confusion-matrix->

definition#:~:text=Une%20Confusion%20Matrix%20(matrice%20de,dans%20des%20probl%C3%A8mes%20de%20classification> (Consulté le 4/6/2022).

[101] Matlabbourtous, « Les interfaces graphiques »,2022.

< <https://matlabbourtous.com/formation/course/les-interfaces-graphiques-dans-matlab/> > (Consulté le 4/6/2022).