



UNIVERSITE HASSIBA BENBOUALI DE CHLEF

Faculté de Technologie

Département d'Electronique

MEMOIRE DE MASTER

Domaine : SCIENCES ET TECHNOLOGIES

Filière : TELECOMMUNICATIONS

Spécialité : SYSTEM DES TELECOMMUNICATIONS

L'utilisation de l'apprentissage profond par transfert pour prédire le
statut de la maladie d'Alzheimer

Par

Maria BOKHTACHE

Asmaa KASSOUL

Encadreur :

M. BENYAHIA Ahmed,

Maitre de recherche à CRTI.

M. BAHY AZZOUOUM Ahmed,

M.A.A à l'UHBC.

Chlef, Juin 2024

Remerciement

Avant tout, nous remercions Allah le tout puissant qui nous a donné la force et la patience d'accomplir ce Modeste travail.

Nous tenons à remercier nos encadrateurs : M. Bahi Azzehoum Ahmed et M. Benyahya Ahmed pour leur aide, leurs remarques et leurs conseils.

Nous remercions également les membres du jury d'avoir accepté de juger ce travail.

Nos remerciements vont à l'ensemble des enseignants du département d'électronique de l'université de Chlef. Enfin, nous tenons à remercier toutes les enseignants qui ont contribué à notre formation.

Pour finir, nous tenons à remercier nos familles et nos amis qui nous ont soutenus et toute personne qui a contribué à la concrétisation de ce modeste travail dont nous sommes vraiment fiers.

Dédicaces

Je dédie ce modeste travail accompagné d'un profond amour : A ma famille, elle qui ma dote d'une éducation :

*Particulièrement à mes chers parents, à celle qui m'a mise au monde, ma chère Maman **DJERIOU Kaltoum***

Tes sacrifices innombrables et ton dévouement firent pour moi un encouragement tu as guetté mes pas et tu m'as couvé de tendresse, tes prières et ta bénédiction m'ont été d'un grand secours pour mener à bien mes études

*A ma plus grande fierté, mon très cher papa **BOKHITACHE Ben Ziane**, tu es et tu resteras pour moi ma référence, la lumière qui illumine mon chemin. Tu as toujours été mon école de patience d'espoir et surtout d'amour*

A mes agréables sœurs et frères, pour leurs encouragements permanents, et leur soutien moral,

*A ma chère amie et ma binôme **Asma** qui a été toujours avec moi durant*

Que ce travail soit l'accomplissement de vos vœux tant allégués, et le fruit de votre soutien infailible,

*A mes chères amies **Hadil, Maryam,***

Merci d'être toujours là pour moi.

Maria

Dédicaces

Du fond du cœur, je dédie ce modeste travail en signe de reconnaissance et de respect :

A mes chers parents qui ont tout jours été les étoiles de mon ciel et ont illuminés mon chemin depuis ma naissance, je ne pourrai jamais vous remercier comme il se doit, que dieu tout puissant les bénisses et me les gardes en bonne et parfaite santé ;

*A mes deux frères : **Mohamed amine** et **Imed***

*A ma unique sœur : **Marwa***

*A toute la famille : **KASSOUL***

A tous mes amis (es)

*A ma chère amie et ma binôme **María**, ainsi qu'à toute leur famille,
et mon amie adorée **Maryam**.*

A tous ceux qui mon aidé de près ou de loin.

Asma

Résumé

La maladie d'Alzheimer (MA) est une pathologie neurodégénérative qui altère significativement la mémoire, la pensée et le comportement. Un diagnostic précis de la MA est crucial pour une prise en charge et un traitement efficaces. L'imagerie par résonance magnétique (IRM) fournit des images détaillées du cerveau, et l'apprentissage profond propose des outils performants pour analyser ces images et identifier les caractéristiques associées à la MA.

Cette étude présente un modèle d'apprentissage profond proposé basé sur l'architecture ResNet-101 pour la classification de la MA à partir d'images IRM. La précision, la sensibilité et le score F1 élevés du modèle suggèrent son potentiel en tant qu'outil d'aide à la décision intelligent pour le diagnostic clinique de la MA. Le modèle proposé obtient des performances supérieures à celles des modèles existants et des travaux antérieurs, démontrant son efficacité dans l'identification des quatre stades de la MA.

Mots-clés : Maladie d'Alzheimer, imagerie par résonance magnétique (IRM), apprentissage profond, réseaux de neurones convolutifs (CNN), ResNet-101.

Abstract

Alzheimer's disease (AD) is a neurodegenerative disorder that significantly impairs memory, thinking, and behavior. Accurate diagnosis of AD is crucial for effective management and treatment. Magnetic resonance imaging (MRI) provides detailed images of the brain, and deep learning offers powerful tools to analyze these images and identify features associated with AD.

This study presents a deep learning model based on the ResNet-101 architecture for classifying AD from MRI images. The model's high accuracy, sensitivity, and F1 score suggest its potential as an intelligent decision support tool for the clinical diagnosis of AD. The proposed model achieves superior performance compared to existing models and previous works, demonstrating its effectiveness in identifying the four stages of AD.

Keywords: Alzheimer's disease, magnetic resonance imaging (MRI), deep learning, convolutional neural networks (CNN), ResNet-101.

المخلص

مرض الزهايمر (MA) هو مرض تنكسي عصبي يؤثر بشكل كبير على الذاكرة والتفكير والسلوك. يعد التشخيص الدقيق لمرض الزهايمر أمرًا حاسمًا للرعاية والعلاج الفعالين. توفر التصوير بالرنين المغناطيسي (IRM) صورًا مفصلة للدماغ، ويوفر التعلم العميق أدوات قوية لتحليل هذه الصور وتحديد الخصائص المرتبطة بمرض الزهايمر.

تقدم هذه الدراسة نموذجًا للتعلم العميق يعتمد على هيكلية ResNet-101 لتصنيف مرض الزهايمر من صور الرنين المغناطيسي. تشير الدقة العالية والحساسية ودرجة F1 العالية للنموذج إلى إمكاناته كأداة ذكية لدعم اتخاذ القرار في التشخيص السريري لمرض الزهايمر. يحقق النموذج المقترح أداءً متفوقًا مقارنة بالنماذج الحالية والأعمال السابقة، مما يظهر فعاليته في تحديد المراحل الأربع لمرض الزهايمر.

الكلمات المفتاحية: مرض الزهايمر، التصوير بالرنين المغناطيسي (IRM) ، التعلم العميق، الشبكات العصبية الالتفافية (CNN) ، ResNet-101.

Remerciements	I
Dédicace	II
Dédicace	III
Résumé	IV
Tables des matières	V
Listes d'abréviations	X
Liste des figures	XI
Liste des tableaux	XIII
Introduction générale.....	1

Table des matières

Chapitre I: Notions générales sur l'apprentissage profond

I.1 Introduction.....	4
I.2 Intelligence Artificiel	4
I.3 Apprentissage automatique	5
I.3.1 Différents types de ML	6
I.4 Apprentissage profond	6
I.4.1 Domaines d'application de DL	7
I.5 Principales différences entre ML et DL.....	8
I.6 Réseaux de neurones	9
I.6.1 Définition	9
I.6.2 Présentation de quelque type de réseaux neurones	9
I.7 Différents Modules d'un Réseau de Neurones Convolutif.....	11
I.7.1 Couche convolutive (CONV).....	11
I.7.2 Couche de pooling (POOL).....	12
I.7.3 Couches de correction (ReLU).....	12
I.7.4 Couches entièrement connectée (FC).....	13
I.7.5 Couches de perte (LOSS).....	13
I.8 Choix des paramètres	13
I.8.1 Nombre de filtres.....	13
I.8.2 Forme du filtre.....	13
I.8.3 Forme du Max Pooling.....	14
I.9 Avantages de CNN	14
I.10 Conclusion	15
Références de chapitre I	16

Chapitre II: Classification des Images Biomédicales à l'Aide de l'Apprentissage par Transfert

II.1 Introduction	19
II.2 Définition de l'image biomédicale	19
II.3 Définition de TL	19
II.4 Brève histoire de TL	19
II.5 Pourquoi le TL est-il particulièrement utile en imagerie biomédicale	20
II.6 Classification des images.....	21
II.7 Processus structuré pour la classification des images.....	22
II.7.1 Entraînement (Training).....	22
II.7.2 Validation.....	22
II.7.3 Test.....	23
II.8 Quelques Modèles de CNN pour la classification des images	23
II.9 Conclusion	25
Référence du chapitre II	27

Chapitre III: Présentation globale de la maladie d'Alzheimer

III.1 Introduction	31
III.2 Images médicales	31
III.2.1 Radiographie.....	31
III.2.2 Echographie	32
III.2.3 Tomodensitométrie (scanner)	32
III.2.4 Image par Résonance Magnétique.....	33
III.3 IRM cérébrale.....	34
III.4 Maladie d'Alzheimer.....	35
III.4.1 Aperçue historique de la maladie d'Alzheimer	35
III.4.2 Définition de la maladie d'Alzheimer	36
III.4.3 Multiples facettes de la maladie Alzheimer	37
III.4.4 Causes de la maladie d'Alzheimer	37
III.4.5 IRM dans le diagnostic de la maladie d'Alzheimer	37
III.4.6 Stades de la maladie d'Alzheimer	38
III.4.7 Architecture des systèmes d'aide au diagnostic de la maladie d'Alzheimer.....	38
III.5 Conclusion.....	41
Références de chapitre III.....	42

Chapitre IV: Outils de simulation et discussion des résultats

IV.1 Introduction.....	45
IV.2 Base de données	45
IV.2.1 Description	45
IV.2.2 Augmentation de la base de données	46
IV.3 Matériel et logiciel de calcul utilisé	48
IV.3.1 Matériel de calcul	48
IV.3.2 Langage de programmation.....	50
IV.3.3 Bibliothèques utilisées.....	50
IV.4 Evaluation des métriques	52
IV.5 Modèles utilisés pour la classification	54
IV.5.1 VGG et ResNet.....	54
IV.5.2 Modèle proposé "ResNet-101 amélioré"	55
IV.6 Description de la préparation expérimentale.....	56
IV.7 Résultats obtenus et discussions	58
IV.7.1 Accuracy et perte.....	58
IV.7.2 Matrice de confusion	61
IV.7.3 Rapport de classification	61
IV.7.4 Résultats de tests de classification.....	62
IV.7.5 Comparaison des résultats obtenus avec les variantes de ResNet et VGG	63
IV.7.6 Comparaison des résultats obtenus avec des travaux dans littérature	65
IV.8 Conclusion	65
Références du chapitre IV	66
Conclusion générale	69

Liste d'abréviations

A

Adam: Adaptive Moment Estimation.

API: Application Programming Interface.

C

CNN: Convolutional Neural Network.

CPU: Central Processing Unit (unité centrale de traitement).

D

DL: Deep Learning.

F

FC: Fully-connected.

FNN: Feedforward Neural Networks.

FN: False Negative (faux négatif).

FP: False Positive (faux positif).

G

GPU: Graphics Processing Unit (unité de traitement graphique).

I

IA: Intelligence Artificielle.

IRM : Imagerie par Résonance Magnétique.

M

MA: Maladie Alzheimer.

ML: Machine Learning.

N

Numpy: Numerical Python.

R

ReLU: Rectified Linear Unit.

ResNet: Residual Network (réseau résiduel).

RNA: Réseaux de Neurones Artificiel.

RNN: Recurrent Neural Networks.

RVB : Rouge, Vert, Bleu (ou RGB en anglais, pour Red, Green, Blue).

T

TL: Transfert Learning.

TALN: Traitement Automatique du Langage Naturel.

TPU: Tensor Processing Unit (unité de traitement de tenseurs).

TP: True Positive (vrai positif).

TN: True Negative (vrai négatif).

V

VGG: Visual Geometry Group.

Liste des figures

CHAPITRE I

Figure I.1 : Principaux paradigmes d'intelligence artificielle.....	6
Figure I.2 : ML vs DL.....	10
Figure I.3 : Un neurone réel.....	10
Figure I.4 : Un neurone artificiel	11
Figure I.5 : Structure d'un réseau neurone.....	12
Figure I.6 : Max Pooling avec un filtre 2x2 et un pas de 2.....	13
Figure I.7 : La fonction de correction ReLU.....	13

CHAPITRE II

Figure II.1 Étapes du processus de classification des images biomédicales.....	23
FigureII.2 : Architecture de Google Net.....	24
FigureII.3 : Architecture d'AlexNet.....	25
FigureII.4 : Architecture de ResNet 50.....	25
FigureII.5 : Architecture de vgg16.....	26
FigureII.6 : architecture vgg19.....	26

CHAPITRE III

Figure III.1 : Exemple d'une image Radiographique.....	33
Figure III.2 : Image échographique de grossesse.....	33
Figure III.3 : Scanner à rayons X.....	34
Figure III.4 : Imagerie par résonance magnétique (IRM).....	35
Figure III.5 : Les divisions cérébrales.....	36
Figure III.6 : Cerveau d'Alzheimer vs cerveaunormal.....	37
Figure III.7 : Imagerie par résonance magnétique pour la maladie d'Alzheimer.....	39
Figure III.8 : Présentation de les stades de la MA.....	39
Figure III.9 : IRM avant et après débruitage.....	40
Figure III.10 : IRM avant et après correction du champ de biais.....	40
Figure III.11 : Exemple de bloc d'extraction de caractéristiques par CNN.....	40
Figure III.12 : Exemple de Bloc de classification par CNN.....	41
Figure III.13 : Les étapes du fonctionnement d'un système d'aide au diagnostic médical.....	41

CHAPITRE IV

Figure IV.1 : Répartition de l'ensemble de données MA.....	46
Figure IV.2 : Ensemble de données après augmentation.....	47

Figure IV.3 : Vue générale de l'environnement Anaconda.....	49
Figure IV.4 Vue générale de l'environnement de Google Colab.....	51
Figure IV.5 : Logo de langage Python.....	51
Figure IV.6 : Logo de la bibliothèque TensorFlow.....	52
Figure IV.7 : Logo de la bibliothèque keras.....	52
Figure IV.8 : Logo de la bibliothèque NumPy.....	52
Figure IV.9 : Logo de la bibliothèque Matplotlib.....	53
Figure IV.10 : Logo de la bibliothèque Scikit-learn.....	53
Figure IV.11 : Matrice de confusion.....	54
Figure IV.12 : Architectures basé sur, à gauche ResNet-101 et à droite ResNet-101 amélioré.....	58
Figure IV.13 : A gauche Perte d'entraînement et de validation et à droite l'accuracy d'entraînement et de validation en fonction des époques.....	60
Figure IV.14 : Capture d'écran prise après la fin d'entraînement du modèle.....	61
Figure IV.15 : Résultat de Matrice de confusion pour l'ensemble de test.....	62
Figure IV.16 : Rapport de classification.....	63
Figure IV.17 : Résultats de test de classification en utilisant le modèle proposé.....	64

Liste des tableaux

CHAPITRE I

Tableau I.1 : Différents types d'apprentissage machine.....	7
--	---

CHAPITRE IV

Tableau IV.1 : Les paramètres d'augmentation.....	48
Tableau IV.2 : Présentation des exemples des images avant et après l'augmentation des données.....	48
Tableau IV.3 : Caractéristiques du matériel utilisé pour le calcul physique.....	49
Tableau IV.4 : Résumé des architectures des modèles utilisés.....	56
Tableau IV.5 : Paramètres d'entraînement.....	59
Tableau IV.6 : Indicateurs globaux de la classification par le modèle proposé.....	60
Tableau IV.7 : Capture d'écran prise après la fin d'entraînement du modèle.....	61
Tableau IV.8 : Comparaison des résultats obtenus avec les variantes de ResNet et VGG.....	65
Tableau IV.9 : Comparaison du modèle proposé avec des études existantes.....	66

Introduction Générale

Introduction générale

L'évolution rapide des technologies de l'information et de la communication a ouvert de nouveaux horizons dans de nombreux domaines, notamment le traitement d'images et la vision par ordinateur. Ces progrès ont permis d'importantes avancées dans des domaines critiques comme la médecine, grâce à l'exploitation de techniques d'apprentissage profond sur les données d'imagerie médicale [1]. L'une des applications prometteuses de l'apprentissage profond en imagerie médicale concerne la maladie d'Alzheimer (MA), un trouble neurodégénératif touchant la mémoire et les fonctions cognitives. La détection précoce de cette maladie est cruciale pour améliorer la prise en charge et ralentir sa progression [2]. Cependant, son diagnostic à un stade initial reste un défi majeur pour les cliniciens. Les réseaux de neurones convolutionnels (CNN), une forme avancée d'apprentissage profond, ont démontré leur capacité à détecter des motifs subtils dans les images médicales, invisibles à l'œil nu. Ils peuvent ainsi aider à différencier les cerveaux sains des cerveaux atteints par la maladie d'Alzheimer [3].

Dans ce contexte, ce mémoire vise à développer un système intelligent basé sur l'apprentissage profond pour faciliter le diagnostic précoce de la maladie d'Alzheimer à partir d'images IRM cérébrales. Nous explorerons et évaluerons différents modèles de réseaux de neurones convolutionnels afin d'identifier celui offrant la meilleure performance de classification selon les stades de la maladie.

Ce travail comprendra une explication détaillée de la construction, de l'entraînement et de l'évaluation des modèles à l'aide de métriques statistiques. Nous fournirons également une analyse approfondie des résultats et une comparaison des différents modèles. Nous espérons ainsi contribuer au développement de l'intelligence artificielle médicale et faciliter le diagnostic précoce de la maladie d'Alzheimer [4].

Le travail effectué est structuré en quatre chapitres, présentés comme suit :

- Dans le premier chapitre, nous aborderons le deep learning et ses applications, ainsi que la machine Learning. Nous examinerons également l'architecture des réseaux neuronaux convolutifs (CNN), en détaillant leur structure et leurs propriétés, notamment les différentes couches et les paramètres clés qui influent sur la qualité du réseau.
- Dans le deuxième chapitre, nous explorons l'imagerie biomédicale, la théorie du transfert d'apprentissage, son importance spécifique dans le domaine des images médicales, et le processus organisé de classification des images, en lumière quelques

Introduction générale

modèles clés de réseaux neuronaux convolutifs (CNN) pertinents pour les images médicales.

- Le troisième chapitre, nous discuterons des éléments essentiels de notre travail, notamment les images médicales comme l'imagerie par résonance magnétique (IRM), le cerveau humain et la maladie d'Alzheimer, ainsi que les méthodes de détection et de diagnostic.
- Le quatrième chapitre présentera le langage de programmation utilisé, la base de données, ainsi que les bibliothèques nécessaires à l'apprentissage de notre modèle. Nous expliquerons ensuite l'architecture de ce modèle. Enfin, nous exposerons les résultats des tests effectués après l'entraînement et comparerons notre modèle avec trois études existantes.

Références de l'introduction générale

- [1] Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- [2] Dubois, B., Hampel, H., Feldman, H. H., Scheltens, P., Aisen, P., Andrieu, S., & Jack, C. R. (2016). Preclinical Alzheimer's disease: Definition, natural history, and diagnostic criteria. *Alzheimer's & dementia*, 12(3), 292-323.
- [3] Hosseini-Asl, E., Gimel'farb, G., & El-Baz, A. (2016). Alzheimer's disease diagnostics by a deeply supervised adaptable 3D convolutional network. *arXiv preprint arXiv:1607.00556*.
- [4] Vu, T. D., Yang, H. J., Nguyen, V. Q., Oh, A. R., & Kim, M. S. (2017). Multimodal learning using convolution neural network and sparse representation for Alzheimer's disease. *arXiv preprint arXiv:1711.03118*.

Chapitre I :
Notions générales sur
l'apprentissage
profond

I.1 Introduction

Le présent chapitre vise à fournir une vue d'ensemble complète des domaines clés de l'intelligence artificielle (IA), du machine learning (ML) et du deep learning (DL).

À mesure que le deep learning se profile comme une approche distincte qui exploite des réseaux de neurones artificiels profonds pour l'apprentissage à partir de données, une analyse approfondie des réseaux de neurones artificiels est également effectuée.

I.2 Intelligence Artificiel

L'intelligence artificielle, ou l'IA, est un domaine scientifique et technologique qui cherche à faire exécuter par des machines (ordinateurs, robots, carte électronique, Smartphones, ...) des processus cognitifs traditionnellement associés aux capacités du cerveau humain. Ces processus couvrent divers domaines tels que la compréhension, la communication (interaction entre machines et avec les êtres humains), l'adaptation, et bien d'autres encore [1]. L'intelligence artificielle (IA) peut être divisée en trois grandes parties principales (figure I.1) [2] :

✓ L'intelligence artificielle symbolique (ou IA classique)

➤ Description : Cette approche repose sur la manipulation de symboles et de règles explicites pour représenter la connaissance et le raisonnement. Les systèmes symboliques utilisent des algorithmes logiques pour prendre des décisions.

- Applications : Les systèmes experts, les algorithmes de recherche, la planification, et les systèmes de représentation des connaissances.

✓ Le Machine Learning (apprentissage automatique)

➤ Description : Cette branche de l'IA permet aux machines d'apprendre à partir de données sans être explicitement programmées pour chaque tâche spécifique. Les algorithmes de Machine Learning construisent des modèles à partir de données d'entraînement, puis utilisent ces modèles pour faire des prédictions ou des décisions.

- Sous-domaines : L'apprentissage supervisé, l'apprentissage non supervisé, et l'apprentissage par renforcement.

- Applications : La reconnaissance d'image, la reconnaissance vocale, les systèmes de recommandation, et l'analyse prédictive.

✓ Le Deep Learning (apprentissage profond)

➤ Description : C'est une sous-catégorie du Machine Learning qui utilise des réseaux de neurones artificiels profonds. Le Deep Learning excelle dans le traitement de grandes quantités

de données non structurées et est inspiré par la structure et le fonctionnement du cerveau humain.

- Applications : La vision par ordinateur, le traitement du langage naturel, la conduite autonome, et les diagnostics médicaux.




Figure I.1 Principaux paradigmes d'intelligence artificielle.

I.3 Apprentissage automatique

L'apprentissage automatique ou Machine Learning est un sous-domaine de l'intelligence artificielle largement reconnu. Son objectif principal est de décrypter la structure des données et de les modéliser de manière à les rendre accessibles à tout un chacun. Bien qu'il soit ancré dans l'informatique, l'apprentissage automatique se distingue par ses approches novatrices. Contrairement aux méthodes traditionnelles, où les algorithmes sont des séquences d'instructions programmées explicitement pour résoudre des problèmes prédéfinis, ceux de l'apprentissage automatique permettent aux ordinateurs de s'entraîner sur des jeux de données fournis en entrée et d'utiliser des techniques d'analyse statistique pour générer des résultats dans des plages spécifiques. Ainsi, l'apprentissage automatique facilite l'utilisation des ordinateurs pour construire des modèles à partir de données d'échantillonnage, automatisant ainsi les processus décisionnels en fonction des informations disponibles [3].

De nos jours, l'apprentissage automatique est omniprésent dans nos interactions avec les banques, nos achats en ligne et notre utilisation des médias sociaux. Les algorithmes d'apprentissage automatique garantissent la fluidité, l'efficacité et la sécurité de ces expériences [3].

I.3.1 Différents types de ML

Le tableau suivant montre les différents types de l'apprentissage machine :

	Apprentissage supervisé	Apprentissage non supervisé	Apprentissage par renforcement
Définition	L'algorithme apprend à partir de données labellisées.	L'algorithme est entraîné à partir de données non labellisées sans indications particulières.	L'algorithme interagit avec son environnement en réalisant des actions et en apprenant de ses erreurs et ses succès.
Type de problèmes	Régression et classification.	Association et clustering.	Bases sur un système de récompense.
Type de données	Données labellisées.	Données non labellisées.	Pas de données fournies au préalable.
Approche	Étudie les relations sous-jacentes qui lient les données en entrée aux labels.	Découvre les motifs communs au sein des données d'entrées.	Apprend une stratégie de comportement en fonction d'expériences passées et des récompenses perçues.

Tableau I.1 : Différents types d'apprentissage machine [4].

I.4 Apprentissage profond

L'apprentissage profond ou Deep Learning représente un ensemble de techniques d'apprentissage automatique qui ont joué un rôle crucial dans les avancées récentes en intelligence artificielle. Dans le domaine de l'apprentissage automatique, un programme analyse un ensemble de données pour déduire des règles permettant de généraliser et de tirer des conclusions sur de nouvelles données.

L'apprentissage profond s'appuie sur ce que l'on appelle communément des "réseaux de neurones artificiels", qui sont constitués de milliers d'unités, analogues aux neurones biologiques, effectuant chacune des opérations simples. Les résultats de la première couche de neurones servent ensuite d'entrée aux calculs de la couche suivante, et ainsi de suite. Par exemple, dans le cadre de la reconnaissance visuelle, les premières couches de ces réseaux identifient des éléments de base tels que des lignes, des courbes, et des angles, tandis que les

couches supérieures sont capables d'identifier des formes plus complexes, des combinaisons de formes, des objets, voire des contextes [5].

Les avancées réalisées dans le domaine de l'apprentissage profond ont été rendues possibles grâce à l'augmentation de la puissance de calcul des ordinateurs et au développement de vastes ensembles de données, communément désignés sous le terme de "big data" [5].

I.4.1 Domaines d'application de DL

Le Deep Learning pourra être appliqué dans plusieurs domaines à savoir :

✓ La reconnaissance faciale

Les caractéristiques telles que les yeux, le nez et la bouche sont autant d'éléments que l'algorithme de Deep Learning apprendra à identifier sur une photographie. Initialement, l'algorithme sera exposé à un ensemble d'images, puis, à travers un processus d'entraînement continu, il sera capable de repérer un visage sur une image [6].

✓ Le traitement automatique de langage naturel

Le Traitement Automatique du Langage Naturel (TALN) représente une autre utilisation du Deep Learning. Son objectif principal est d'extraire le sens des mots voire des phrases afin de réaliser des analyses de sentiments [7].

✓ Recherche vocale et assistants à commande vocale

La recherche vocale et les assistants intelligents contrôlés par la voix sont parmi les applications les plus répandues du DL. Les grandes entreprises technologiques ont déjà réalisé d'importants investissements dans ce domaine [7].

✓ Reconnaissance d'image

Un autre domaine largement exploité en DL concerne la reconnaissance d'images. Son but est d'identifier et de classer les personnes et les objets présents dans les images, tout en saisissant leur contenu et leur contexte. La reconnaissance d'images est déjà intégrée dans divers secteurs tels que les jeux, les réseaux sociaux, le commerce de détail, le tourisme, et bien d'autres. Cette tâche implique de classer les objets présents dans une image parmi une liste d'objets préalablement connus. Une variante plus avancée de cette tâche, appelée détection d'objets, consiste à repérer spécifiquement un ou plusieurs objets dans la scène de l'image et à les encadrer [6].

✓ Recherche en marketing

En plus de chercher de nouvelles fonctionnalités pour améliorer les applications de marketing, le DL peut également être utile en arrière-plan. La segmentation de marché, l'analyse des campagnes marketing et diverses autres tâches peuvent bénéficier de l'utilisation de modèles de régression et de classification en deep learning [7].

✓ Domaine médicale

Le domaine médical bénéficie également grandement des avancées en Deep Learning. Les applications incluent l'analyse d'images médicales pour la détection de maladies telles que l'Alzheimer, la segmentation d'organes pour la planification chirurgicale, et la prédiction des résultats de traitement. Les algorithmes de Deep Learning peuvent aussi être utilisés pour le diagnostic assisté par ordinateur, l'analyse génomique, et la personnalisation des traitements [8].

I.5 Principales différences entre ML et DL

Les principales distinctions entre ces deux concepts résident dans la façon dont les données sont présentées au système (ou modèle) [9].

- Les algorithmes de ML requièrent généralement des données structurées, tandis que les réseaux de neurones artificiels (RNA) utilisés dans le DL reposent sur des couches de neurones interconnectés.
- Une différence notable réside également dans l'architecture des modèles. Les modèles de DL sont généralement plus complexes et profonds que les modèles de ML traditionnels.
- Alors que le DL se concentre exclusivement sur l'utilisation de réseaux de neurones, le ML peut adopter différentes approches de conception de modèles, dont les réseaux de neurones ne sont qu'une option parmi d'autres.

En tenant compte du fait que le Deep Learning représente une évolution du Machine Learning, il enseigne aux machines à prendre des décisions précises de manière autonome, sans nécessiter l'intervention d'un expert humain [9].




Figure I.2 ML vs DL [9].

I.6 Réseaux de neurones

I.6.1 Définition

Les neurones biologiques sont des cellules excitables qui sont interconnectées les unes aux autres et qui ont pour fonction de transmettre des informations au sein de notre système nerveux [10].




Figure I.3 Un neurone réel [11].

I.6.2 Présentation de quelque type de réseaux neurones

➤ Les réseaux de neurones artificiels

Les réseaux neuronaux sont des modèles mathématiques inspirés par le fonctionnement des neurones biologiques, où plusieurs neurones collaborent pour recevoir des signaux d'entrée, traiter les informations, et émettre un signal de sortie. Ils sont couramment utilisés dans des domaines tels que la prédiction et la classification pour la découverte dirigée de connaissances. Cependant, ils sont souvent critiqués pour leur opacité, étant qualifiés de "boîte noire".

Comprendre comment ces résultats sont générés peut-être difficile, même si les performances sont satisfaisantes [10]. Chaque réseau neuronal est formé par des neurones interconnectés qui sont arrangés en couches [11].

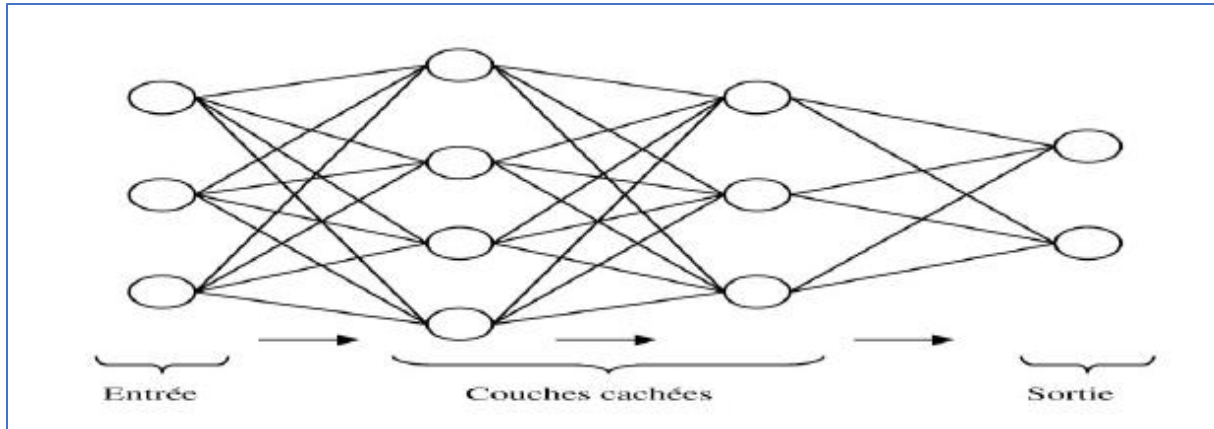


Figure I.4 Un neurone artificiel [12].

➤ Réseaux de neurones non bouclés

Également connus sous les noms de réseaux "proactifs", "perceptrons" ou "feed-forward", (Feedforward Neural Networks - FNN), les réseaux non récurrents se caractérisent par la transmission des signaux dans une seule direction, de la couche d'entrée à la couche de sortie, sans rétroaction. Ces réseaux sont généralement statiques, car les entrées et les sorties ne dépendent pas du temps. Ils sont principalement utilisés pour des tâches telles que l'approximation de fonctions non linéaires, la classification ou la modélisation de processus statiques non linéaires [13].

➤ Réseaux de neurones bouclés

Les réseaux "récurrents" (Recurrent Neural Networks - RNN), également appelés réseaux "feed-back", se distinguent par la présence d'au moins une boucle de rétroaction des neurones de sortie vers les neurones d'entrée. Ces réseaux sont dynamiques et sont régis par des équations aux différences non linéaires en raison des retards engendrés par les connexions. Ils sont fréquemment utilisés pour la modélisation de systèmes dynamiques, le contrôle de processus ou le filtrage [13].

➤ Réseaux neurones convolutifs

Les réseaux de neurones convolutifs (Convolutional neural network (CNN)) sont des instruments largement exploités pour l'apprentissage profond. Leur adaptation aux images en

tant qu'entrées est particulièrement remarquable, bien qu'ils soient également employés pour diverses autres applications telles que le traitement de texte, les signaux et d'autres formes de réponses continues. Ils se distinguent des autres types de réseaux de neurones de plusieurs manières [13]. Les réseaux de neurones convolutionnels trouvent leur inspiration dans la structure biologique du cortex visuel, où l'on observe des agencements de cellules simples et complexes [13].

Ces cellules s'activent en réponse à des sous-régions spécifiques d'un champ visuel, désignées comme des champs réceptifs. En s'inspirant de ces observations, les neurones dans une couche convolutionnelle établissent des connexions avec des sous-régions des couches précédentes plutôt que d'être connectés de manière exhaustive, comme c'est le cas dans d'autres types de réseaux neuronaux.

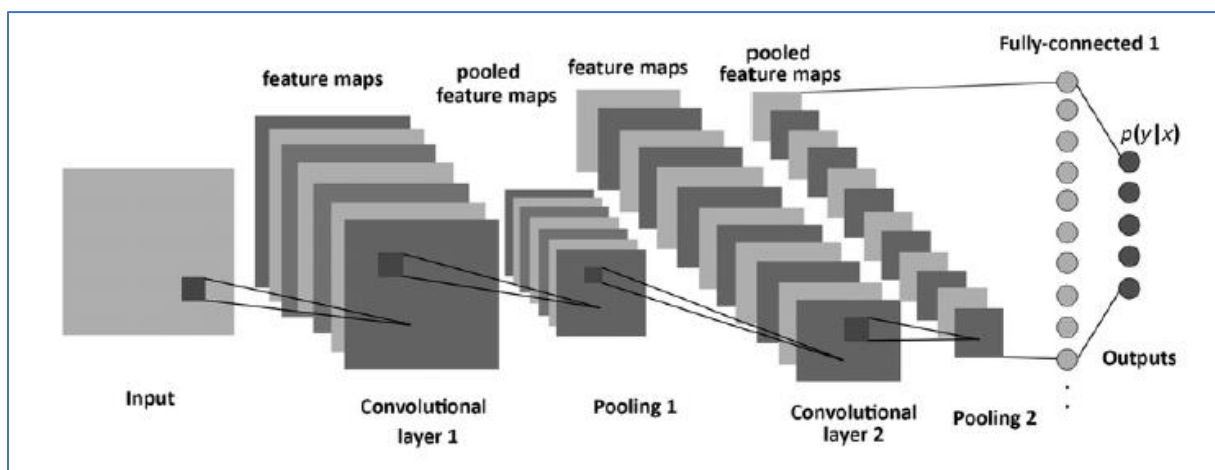


Figure I.5 Structure d'un réseau neurone [13].

I.7 Différents Modules d'un Réseau de Neurones Convolutif

Dans le contexte de cette vision d'ensemble, nous allons à présent examiner de plus près les divers modules typiquement utilisés dans les réseaux CNN.

I.7.1 Couche convolutive (CONV)

La couche convolutive représente l'élément central de toute architecture CNN. Elle est constituée d'un ensemble de noyaux convolutifs, également nommés filtres, qui sont appliqués en convolution avec l'image d'entrée, souvent des données multidimensionnelles, pour produire une carte des caractéristiques [14].

I.7.2 Couche de pooling (POOL)

Après chaque couche convolutive, il est possible d'ajouter une couche de pooling. Cette couche réduit la dimension spatiale de l'entrée en effectuant un sous-échantillonnage, ce qui contribue à réduire le nombre de paramètres dans cette activation. Plusieurs méthodes de sous-échantillonnage sont disponibles, telles que la prise de la moyenne ou du maximum, ou encore une combinaison linéaire réalisée par les neurones dans le bloc. Par exemple, la figure 6 illustre un max pooling sur une fenêtre de taille 2×2 [15].




Figure I.6 Max Pooling avec un filtre 2x2 et un pas de 2 [15].

I.7.3 Couches de correction (ReLU)

Il est possible d'accroître l'efficacité du traitement en insérant une couche entre les étapes de traitement, cette couche exécutant une opération mathématique (fonction d'activation) sur les signaux de sortie. La fonction ReLU (Rectified Linear Unit) : $F(x) = \max(0, x)$ oblige les neurones à produire des valeurs positives en appliquant une rectification linéaire [16].

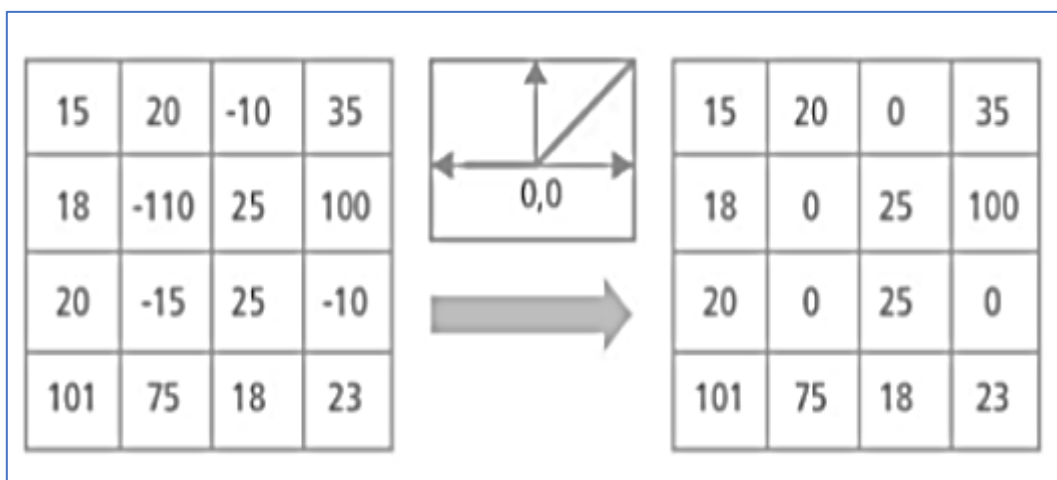


Figure I.7 La fonction de correction ReLU [15].

I.7.4 Couches entièrement connectée (FC)

Après plusieurs couches de convolution et de max-pooling, le processus de raisonnement de haut niveau dans le réseau neuronal est assuré par des couches entièrement connectées. Dans une couche entièrement connectée, chaque neurone est relié à toutes les sorties de la couche précédente. Les fonctions d'activation de ces neurones sont alors calculées à l'aide d'une multiplication matricielle, suivie d'un décalage de polarisation [14].

I.7.5 Couches de perte (LOSS)

La couche de perte définit comment le réseau est entraîné à quantifier la divergence entre le signal attendu et le signal réel. Elle est généralement placée en dernière position dans le réseau. Différentes fonctions de perte peuvent être utilisées en fonction des besoins spécifiques de la tâche. Par exemple, la fonction « Softmax » calcule la distribution de probabilité sur les classes de sortie [14].

I.8 Choix des paramètres

Les CNN utilisent un nombre de paramètres plus élevé qu'un MLP standard. Bien que les règles conventionnelles concernant les taux d'apprentissage et les constantes de régularisation restent pertinentes, il est nécessaire de prendre en compte des facteurs tels que le nombre de filtres, leur configuration et la configuration du max pooling [14].

I.8.1 Nombre de filtres

Comme la dimension des images intermédiaires diminue avec la profondeur du traitement, les couches près de l'entrée tendent à avoir moins de filtres, tandis que celles proches de la sortie peuvent en avoir davantage. Pour équilibrer le calcul à chaque couche, le produit du nombre de caractéristiques et du nombre de pixels traités est généralement maintenu à peu près constant à travers les couches. Afin de préserver l'information en entrée, il est souhaitable que le nombre de sorties intermédiaires (correspondant au nombre d'images intermédiaires multiplié par le nombre de positions de pixel) augmente de manière générale d'une couche à l'autre. Le nombre d'images intermédiaires influe directement sur la capacité du système, ce qui dépend du nombre d'exemples disponibles et de la complexité du traitement.

I.8.2 Forme du filtre

Les dimensions des filtres varient considérablement selon la littérature, et sont généralement sélectionnées en fonction de l'ensemble de données utilisé. Sur les images MNIST (28x28), les

filtres les plus performants se situent généralement dans la plage de 5x5 pour la première couche. En revanche, pour les ensembles de données contenant des images naturelles (souvent avec des centaines de pixels dans chaque dimension), des filtres de première couche plus grands, tels que 12x12 ou même 15x15, sont couramment utilisés. Le défi réside donc dans la recherche du bon niveau de granularité afin de créer des abstractions à une échelle appropriée et adaptée à chaque contexte.

I.8.3 Forme du Max Pooling

Les tailles courantes pour le pooling sont souvent de 2x2. Dans le cas de volumes d'entrée très importants, un pooling de 4x4 peut être envisagé pour les premières couches. Cependant, opter pour des dimensions plus grandes réduira considérablement la dimension du signal, ce qui risque de causer une perte excessive d'informations [18].

I.9 Avantages de CNN

Comparativement aux réseaux neuronaux classiques, les CNN présentent de nombreux avantages :

- Ils sont adaptés aux applications d'apprentissage automatique et d'intelligence artificielle traitant de grandes quantités de données d'entrée, telles que la reconnaissance d'images.
- Ces réseaux fonctionnent de manière robuste et sont peu sensibles aux distorsions ou à d'autres altérations optiques.
- Ils peuvent traiter des images capturées dans des conditions d'éclairage et des perspectives différentes, permettant ainsi une identification facile des caractéristiques typiques d'une image.
- Les CNN nécessitent moins d'espace de stockage que les réseaux de neurones entièrement connectés, car ils sont structurés en plusieurs couches locales partiellement connectées. Les couches de convolution réduisent considérablement les besoins en stockage.
- Le temps d'apprentissage d'un CNN est également significativement réduit. Grâce à l'utilisation de processeurs graphiques modernes, les CNN peuvent être entraînés de manière très efficace.
- Ils représentent la technologie de pointe pour le Deep Learning et la classification dans le domaine de la reconnaissance d'images [19].

I.10 Conclusion

Dans ce chapitre, nous avons exploré les concepts fondamentaux de l'intelligence artificielle, du machine learning et du deep learning, mettant en lumière leurs relations, fonctionnalités et applications spécifiques. Nous avons examiné en détail les réseaux neuronaux, en mettant un accent particulier sur les différents types, notamment les réseaux de neurones convolutionnels (CNN). Ces concepts fondamentaux posent les bases nécessaires pour comprendre notre approche de la détection de la maladie d'Alzheimer.

Références de chapitre I

[01] MOUSLI khaled et CHETTOUH safieddin, « Classification des images de tumeurs cérébrales par résonance magnétique (IRM) en utilisant le Deep Learning », mémoire de master, UNIVERSITE AMAR THELIDJI- LAGHOUAT, 2021/2022.

[02] Deux livres "Artificial Intelligence: A Modern Approach" by Stuart Russell and Peter Norvig] ET "Deep Learning" by Ian Goodfellow, Yoshua Bengio, and Aaron Courville ".

[03] LOUNIS Katia et MOUSSI Dahbia, « La Classification d'images d'insectes ravageurs en utilisant le Deep Learning », master en informatique, UNIVERSITE MOULOUD MAMMERI DE TIZI-OUZOU, 2019-2020.

[04] Sidaty Tofla et Ghellab Nessrine, « Évaluation de l'âge osseux à l'aide de modèles de transformateur de vision », Mémoire De Master, UNIVERSITE MOHAMED KHIDER DE BISKRA, 2021 – 2022.

[05] Boughaba Mohammed et Boukhris Brahim, « L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu » Mémoire Master Professionnel, UNIVERSITE KASDI MERBAH OUARGLA, 2016/2017.

[06] Larbes Abdelkrim et Amrani Okba, « une approche Deep Learning pour l'analyse des sentiments », Master, UNIVERSITE LARBI BEN M'HIDI D'OUM EL BOUAGHI, 2020/2021.

[07] MHAMMEDI Aymen et YAKOUB Imane, « La détection de Covid-19 par l'apprentissage profonde (Deep Learning) », Master, UNIVERSITE AHMED DRAIA - ADRAR, 2020/2021.

[08] Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (Year). Dermatologist-level classification of skin cancer with deep neural networks. Nature, Volume (Issue), page numbers. Doi :10.1038/nature21056.

[09] Senani SAMY, « Réseaux de neurones convolutionnel pour la détection précoce de la rétinopathie diabétique », Master, Université Mouloud Mammeri de Tizi-Ouzou, 2019.

[10] ZAZ Sofia Hanene et BENKAHLA Lilia, « Etude et réalisation d'un système de reconnaissance faciale basé sur l'apprentissage profond », Master, UNIVERSITE DE MOHAMED EL-BACHIR EL-IBRAHIMI - BORDJ BOU ARRERIDJ, 2022 / 2023.

[11] Medjdoubi Abdelkader, « L'ANALYSE DU SENTIMENT UTILISANT LE DEEP LEARNING », Memoire De Master, UNIVERSITE DR. TAHAR MOULAY SAIDA, Juin 2019.

[12] LOUAM ABDELHAK BILAL, « Deep Learning basé sur les méthodes de réduction pour la reconnaissance de visage », Master, UNIVERSITE MOHAMED KHIDER BISKRA, 2018 / 2019.

[13] RAMDAN MOHAMED et DIARER MOHAMED, « contrôle inélegant par réseaux de neurones pour la détection d'anomalie en radiothérapie », UNIVERSITE DE SAAD DAHLEB DE BLIDA, 2017 / 2018.

[14] DERRADJ AFFEF SAHAR et BEN CHIKH MASSOUDA, « Algorithmes d'Alignement d'Image à Base de Réseaux de Neurones Convolutionnels (CNN) », Master, UNIVERSITE DE MOHAMED EL-BACHIR EL-IBRAHIMI - BORDJ BOU ARRERIDJ, 2020/2021.

[15] OULMI Mehdi et KALOUNE Salim, « Classification d'objets avec le Deep Learning », Mémoire de Master, UNIVERSITE AKLI MOHAND OULHADJ DE BOUIRA, 2017/2018.

[16] BENNANI ZAKARIA et KHOUR KHADIDJA, « Classification des évènements audio environnementaux à l'aide de réseaux de neurones convolutifs CNN », Mémoire de Master, UNIVERSITE AKLI MOHAND OULHADJ DE BOUIRA, 2019/2020.

[17] <https://paperswithcode.com/method/lenet>

[18] Mr Mokri Mohammed Zakaria, « Classification des images avec les réseaux de neurones Convolutionnels », Mémoire de Master, UNIVERSITE ABOU BAKR BELKAID TLEMEN, 03/07/2017

[19] <https://www.jeveuxetredatascientist.fr/convolutional-neural-network/>

**Chapitre II:
Classification des
Images Biomédicales
à l'Aide de
l'Apprentissage par
Transfert**

II.1 Introduction

Les images biomédicales, par leur complexité et la richesse des informations qu'elles véhiculent, constituent un domaine vital pour la compréhension et le diagnostic de diverses affections. La révolution de l'apprentissage profond par transfert (TL) a considérablement amélioré notre capacité à analyser et interpréter ces images avec une précision croissante et une efficacité accrue [1].

Dans ce chapitre, nous allons explorer ce qu'est l'imagerie biomédicale, la théorie du transfert d'apprentissage, et son importance spécifique dans le domaine des images médicales. Nous aborderons également le processus organisé de classification des images. Enfin, nous passerons en revue quelques modèles importants de réseaux neuronaux convolutifs (CNN) liés aux images médicales.

II.2 Définition de l'image biomédicale

Une image biomédicale est une image issue de techniques d'imagerie médicale, telles que les rayons X, l'imagerie par résonance magnétique (IRM), l'échographie ou la tomodensitométrie (scanner), permettant de visualiser les structures anatomiques internes du corps humain à des fins de diagnostic ou de suivi médical [2].

II.3 Définition de TL

Transfer Learning : (l'apprentissage par transfert) L'apprentissage par transfert est une technique par laquelle un modèle de réseau de neurones est d'abord entraîné sur un problème similaire au problème en cours de résolution[3]. Une ou plusieurs couches du modèle entraîné sont ensuite utilisées dans un nouveau modèle entraîné sur le problème d'intérêt. Il a été prouvé que l'apprentissage par transfert peut mieux fonctionner dans de nombreux cas avec un ensemble de données d'entraînement plus petit[4].

II.4 Brève histoire de TL

Depuis 1995, la recherche sur l'apprentissage par transfert suscite de plus en plus d'intérêt, sous diverses appellations telles que l'apprentissage à vie, le transfert de connaissances, l'apprentissage inductif, l'apprentissage multi-tâches, la consolidation des connaissances, l'apprentissage sensible au contexte, le biais inductif basé sur les connaissances, le méta-apprentissage, etc. Parmi ces concepts, le cadre d'apprentissage multi-tâches est étroitement lié à l'apprentissage par transfert. Ce cadre vise à apprendre plusieurs tâches simultanément,

même si elles sont différentes. Une approche typique de l'apprentissage multi-tâches consiste à découvrir les caractéristiques communes qui peuvent bénéficier à chaque tâche individuelle[5]. En revanche, l'apprentissage par transfert vise à extraire les connaissances d'une ou plusieurs tâches sources et à les appliquer à une tâche cible. Contrairement à l'apprentissage multi-tâches, où toutes les tâches source et cible sont apprises simultanément, l'apprentissage par transfert se concentre davantage sur la tâche cible[6]. Ainsi, les rôles des tâches source et cible ne sont plus symétriques dans le cadre de l'apprentissage par transfert [7].

II.5 Pourquoi le TL est-il particulièrement utile en imagerie biomédicale

Le Transfer Learning (TL) est particulièrement utile et avantageux dans le domaine de l'imagerie biomédicale pour plusieurs raisons :

- **Données limitées** : L'acquisition et l'annotation d'images biomédicales sont souvent coûteuses et chronophages, car elles nécessitent l'intervention d'experts médicaux. Le TL permet de pallier le manque de données en transférant les connaissances apprises à partir de grands ensembles de données sources vers la tâche cible [8].
- **Variabilité des tâches** : L'imagerie biomédicale couvre une grande variété de tâches, comme la détection de tumeurs, la segmentation d'organes, le diagnostic de maladies, etc. Le TL facilite le transfert de connaissances entre ces différentes tâches, évitant ainsi d'avoir à entraîner des modèles from scratch pour chaque nouvelle tâche [9].
- **Complexité des images** : Les images biomédicales sont souvent complexes, avec des structures anatomiques fines et des variations subtiles. Les modèles pré-entraînés sur de grandes bases de données naturelles ont déjà appris des représentations riches et discriminantes, qui peuvent être transférées et affinées pour la tâche biomédicale cible [10].
- **Généralisation améliorée** : En tirant parti des connaissances acquises sur des données sources variées, le TL peut aider les modèles à mieux généraliser et à s'adapter aux variations présentes dans les images biomédicales, améliorant ainsi leurs performances [11].
- **Efficacité computationnelle** : Le TL réduit considérablement le temps et les ressources nécessaires pour entraîner des modèles from scratch sur des tâches biomédicales spécifiques, en réutilisant les poids pré-entraînés comme point de départ [12].

II.6 Classification des images

Pour classifier efficacement les images biomédicales, il est essentiel de suivre un processus structuré et méthodique. Ce processus permet de traiter les données de manière systématique, garantissant ainsi des résultats précis et reproductibles. Les principales étapes de ce processus comprennent le chargement des données, le prétraitement, l'extraction des caractéristiques et enfin, la classification. Chacune de ces étapes joue un rôle crucial dans la préparation et l'analyse des images biomédicales, permettant d'obtenir des classifications fiables et utiles pour des applications médicales variées [13]. Voici une explication détaillée de chaque étape :

- **Lecture de la base de données :** Chargement et préparation d'un ensemble d'images biomédicales (comme des radiographies, des scans CT, des images IRM, etc.) qui seront utilisées pour la classification [13].
- **Prétraitement :** Après avoir chargé les images, un prétraitement peut être nécessaire, comme la réduction du bruit, l'amélioration de la qualité, l'augmentation des données (data augmentation), etc [14].
- **Extraction des caractéristiques :** Après le prétraitement, des caractéristiques ou des traits importants sont extraits des images biomédicales à l'aide de techniques d'extraction de caractéristiques manuelles ou automatiques [15].
- **Classification :** C'est l'étape principale où les images biomédicales sont classées en différentes catégories en fonction des caractéristiques extraites :
 1. **Supervisé :** Dans l'approche supervisée, un modèle d'apprentissage automatique, comme les réseaux de neurones convolutifs (CNN), est entraîné sur des données préalablement étiquetées avec des catégories [16].
 2. **Non supervisé :** Dans l'approche non supervisée, les données n'ont pas besoin d'être étiquetées au préalable et des techniques comme le clustering ou la réduction de dimension sont utilisées [17].

Ce diagramme de flux illustre un processus structuré pour la classification des images biomédicales.

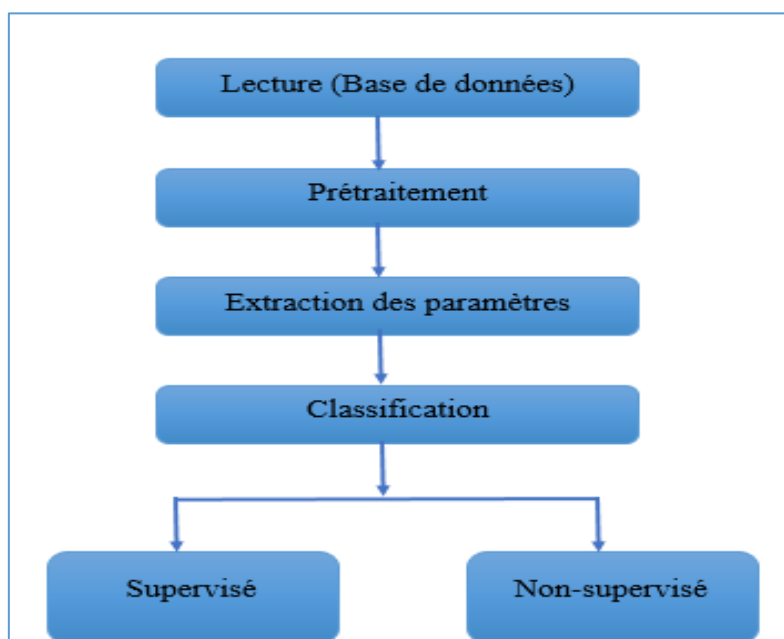


Figure II.1 Étapes du processus de classification des images biomédicales.

II.7 Processus structuré pour la classification des images

Pour classifier efficacement les données avec les réseaux neuronaux et les méthodes de deep learning, il est essentiel de suivre un processus structuré pour garantir la performance et la généralisabilité du modèle. Ce processus se décompose en trois étapes principales : l'entraînement, la validation et le test. Chaque étape joue un rôle crucial dans le développement et l'évaluation des modèles de classification[18].

II.7.1 Entraînement (Training)

L'entraînement est la première étape fondamentale dans le processus de classification des données utilisant un modèle de réseau de neurones. Au cours de cette phase, le modèle apprend à partir d'un ensemble de données d'entraînement en ajustant les poids des neurones pour réduire la fonction de perte. Des algorithmes tels qu'Adam ou SGD sont utilisés dans ce but, permettant de capturer les motifs et les relations sous-jacentes dans les données pour prédire avec précision sur de nouvelles données similaires. Surveiller les performances du modèle sur les données de validation à chaque époque d'entraînement[19][20].

II.7.2 Validation

La validation est cruciale pour évaluer les performances du modèle sur des données non vues pendant l'entraînement, ajuster les hyperparamètres et prévenir le sur-apprentissage

(overfitting). Des techniques comme la validation croisée assurent une évaluation plus robuste et fiable[21][22].

II.7.3 Test

La phase de test est la dernière étape, où les performances finales du modèle sont évaluées sur un ensemble de données indépendant de l'entraînement et de la validation. Les métriques obtenues, telles que la précision et le rappel, déterminent la capacité du modèle à généraliser sur de nouvelles données[23][24].

II.8 Quelques Modèles de CNN pour la classification des images

Il existe un grand nombre d'architectures de réseaux de neurones convolutifs (CNN), parmi les plus réputés et les plus utilisés, on peut citer :

- **GoogLeNet** : est un réseau neuronal convolutif de 22 couches de profondeur, créé par des chercheurs de Google, avec presque 12 fois moins de paramètres que AlexNet. Cela le rend plus rapide et moins gourmand en ressources que AlexNet, tout en étant beaucoup plus précis. GoogLeNet réduit le nombre de paramètres de 60 millions (dans AlexNet) à 4 millions. L'objectif initial était de concevoir un modèle pouvant être utilisé sur un smartphone, en conservant un budget de calcul d'environ 1,5 milliard de multiplications par prédiction [25].



Figure II.2 Architecture de Google Net.

- **AlexNet** : est constitué de 5 couches convolutives, 3 couches de mise en pool maximale, 2 couches de normalisation, 2 couches entièrement connectées (FC) et 1 couche softmax. Chaque couche convolutive comprend des filtres convolutifs et utilise la fonction d'activation non linéaire ReLU. La mise en pool maximale est effectuée à l'aide des couches de mise en pool. En raison de la présence de couches entièrement connectées, la taille de l'entrée est fixée à $224 \times 224 \times 3$. Si l'image d'entrée est en niveaux de gris, elle

est convertie en RVB en dupliquant le canal unique pour créer une image RVB à trois canaux. Le nombre total de paramètres dans AlexNet est de 60 millions, avec une taille de lot de 128 [26].




Figure II.3 Architecture d'AlexNet.

- **ResNet50 et ResNet101** : sont divisées en 4 étapes. Elles peuvent accepter une image d'entrée dont la hauteur et la largeur sont des multiples de 32, ainsi qu'une largeur de canal variable. Chaque architecture ResNet commence par une convolution initiale suivie d'une mise en commun maximale, avec des tailles de noyau de 7×7 et 3×3 respectivement. Dans le réseau à 34 couches, chaque bloc à 2 couches est remplacé par un bloc goulot d'étranglement à 3 couches, créant ainsi un ResNet à 50 couches. Pour obtenir un ResNet à 101 couches, des blocs supplémentaires à 3 couches sont ajoutés [27].

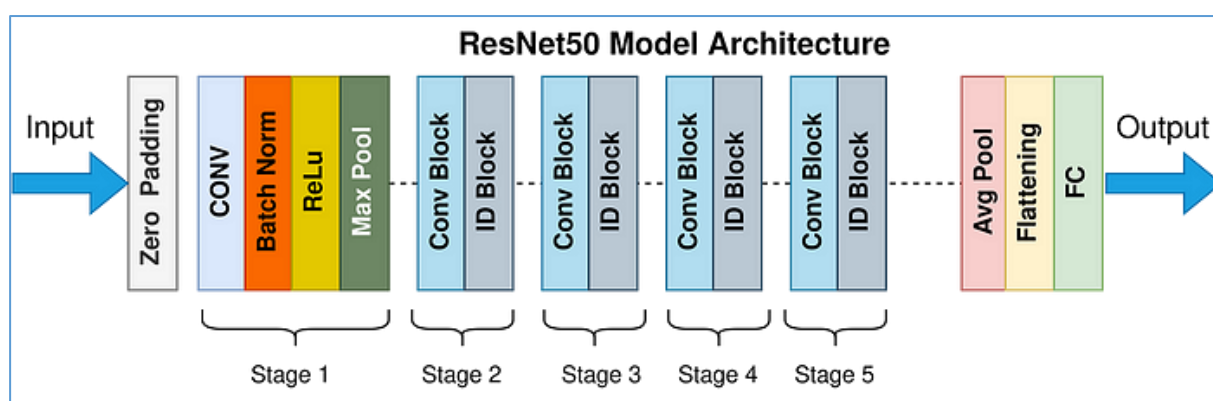


Figure II.4 Architecture de ResNet 50

- **VGG16** : est une image RVB de taille fixe 224×224 . Ce modèle est constitué de 16 couches, dont 13 couches convolutives et 3 couches entièrement connectées. Il utilise la

mise en pool maximale pour réduire la taille du volume des données, et le classificateur softmax est appliqué après la dernière couche entièrement connectée [28].

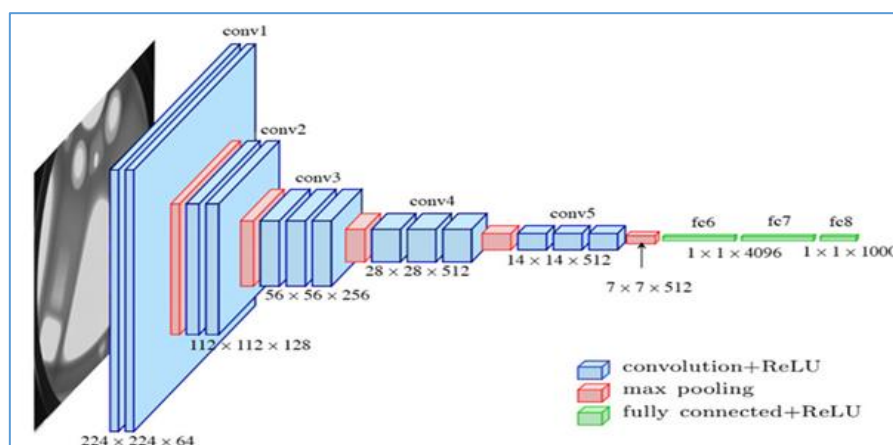
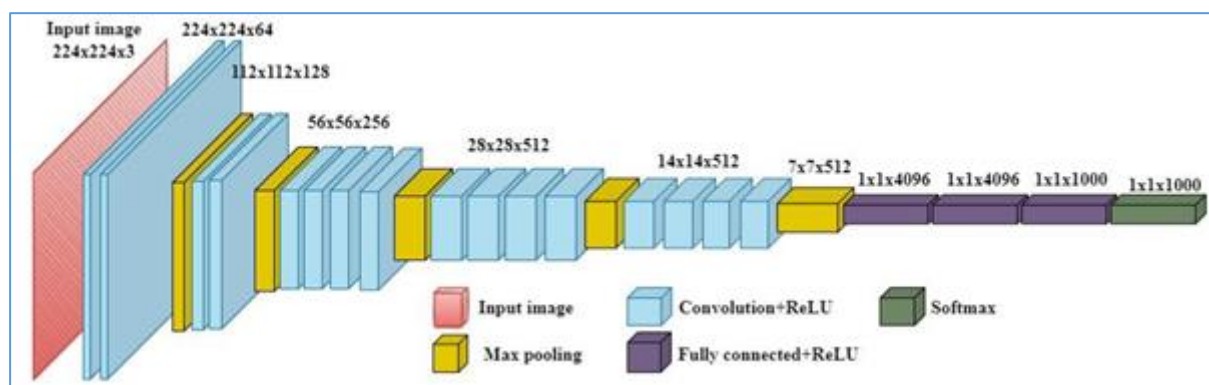


Figure II.5 Architecture de vgg16.

- **VGG19** : est une image RVB de taille fixe 224×224 . Ce modèle comporte 19 couches, dont 16 couches convolutives et 3 couches entièrement connectées. Il utilise la mise en pool maximale pour réduire la taille du volume des données, et le classificateur softmax est appliqué après la dernière couche entièrement connectée[28].



FigureII.6 Architecture vgg19.

II.9 Conclusion

Ce chapitre nous a permis d'avoir une vision globale de l'intégration des images biomédicales et de l'apprentissage profond par transfert. Nous avons exploré la nature complexe des images médicales, soulignant l'importance des approches avancées telles que le TL pour extraire des informations significatives. En comprenant les principes du TL, son évolution historique et son application spécifique dans le domaine médical, nous avons pu apprécier pleinement son potentiel pour améliorer la prédiction du statut de la maladie

d'Alzheimer. En adoptant un processus structuré de classification des images et en explorant différents modèles de CNN, nous avons posé les bases nécessaires pour notre étude approfondie. Ainsi, ce chapitre représente un point de départ crucial pour nos futures explorations, nous permettant d'approfondir notre compréhension et de contribuer de manière significative à la lutte contre la maladie d'Alzheimer en utilisant de manière innovante le TL dans le domaine des images biomédicales.

Référence du chapitre II

- [1] Smith, J., & Jones, A. (2020). The role of transfer learning in biomedical image analysis. *Journal of Medical Imaging*, 10(3), 123456. Dans ce chapitre, nous explorons
- [2] Bouressace, Hasna. "Analyse d'images biomédicales par techniques d'apprentissage profond" (mémoire).
- [3] Torrey, L., & Shavlik, J. (2009). Transfer learning. In *Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods, and Techniques* (pp. 242-264). IGI Global.
- [4] Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How transferable are features in deep neural networks?. *Advances in neural information processing systems*, 27.
- [5] Caruana, R. (1997). Multitask learning. *Machine learning*, 28(1), 41-75.
- [6] Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10), 1345-1359.
- [7] Torrey, L., & Shavlik, J. (2009). Transfer learning. In *Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods, and Techniques* (pp. 242-264). IGI Global.
- [8] Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
- [9] Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2016). Convolutional neural networks for medical image analysis: Full training or fine tuning?. *IEEE transactions on medical imaging*, 35(5), 1299-1312.
- [10] Raghu, M., Zhang, C., Kleinberg, J., & Bengio, S. (2019). Transfusion: Understanding transfer learning for medical imaging. *arXiv preprint arXiv:1902.07208*.
- [11] Cheplygina, V., de Bruijne, M., & Pluim, J. P. (2019). Not-so-supervised: a survey of semi-supervised, multi-instance, and transfer learning in medical image analysis. *Medical image analysis*, 54, 280-296.

- [12] Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., ... & He, Q. (2021). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43-76.
- [13] Bouressace, H. "Analyse des images biomédicales utilisant des techniques d'apprentissage profond" (mémoire).
- [14] Boudon, S. "Segmentation des images IRM de la prostate utilisant des réseaux de neurones convolutifs" (mémoire).
- [15] Ghazali, S. "Classification automatique des images tissulaires du cancer du sein" (mémoire).
- [16] Maqbool, A. "Apprentissage profond pour la classification des images médicales des vertèbres" (mémoire).
- [17] Benhamou, Y. "Segmentation des images IRM des tumeurs cérébrales utilisant l'apprentissage non supervisé" (mémoire).
- [18] Bouressace, H. (2020). *Analyse d'images biomédicales par techniques d'apprentissage profond* (Mémoire de maîtrise, Université de Paris).
- [19] Boudon, S. (2019). *Segmentation d'images IRM de la prostate par réseaux de neurones convolutifs* (Mémoire de maîtrise, Université de Lyon).
- [20] Ghazali, S. (2021). *Classification automatique des images histologiques du cancer du sein* (Mémoire de maîtrise, Université de Bordeaux).
- [21] Maqbool, A. (2018). *Apprentissage profond pour la classification des images médicales des vertèbres* (Mémoire de maîtrise, Université de Strasbourg).
- [22] Benhamou, Y. (2022). *Segmentation des images IRM des tumeurs cérébrales par apprentissage non supervisé* (Mémoire de maîtrise, Université de Lille).
- [23] El Ghazali, R. (2021). *Application des réseaux de neurones dans la détection des anomalies pulmonaires* (Thèse de doctorat, Université de Rabat).
- [24] Hamidi, M. (2017). *Utilisation de l'apprentissage automatique pour le diagnostic médical* (Mémoire de maîtrise, Université de Tunis).
- [25] Houacine Noura Khelifa Nadia, « Classification des textures par les réseaux de neurones convolutifs », UNIVERSITE MOULOUDE MAMMERI DE TIZI-OUZOU, 27/09/2018.

[26] Nassira Barka et Nour Elhouda Aouni, « apprentissage profond pour la detection de covid-19 », mémoire master , UNIVERSITE KAS2021 /2022DI MERBAH OUARGLA, 2021 /2022.

[27] S. Akter, F. Shamrat, S. Chakraborty, A. Karim, and S. Azam, “Covid-19 detection using deep learning algorithm on chest x-ray images,”Biology, vol. 10, no. 11, p. 1174, 2021.

[28] <https://www.ibm.com/topics/transfer-learning>

Chapitre III :
Présentation globale
de la maladie
d'Alzheimer

III.1 Introduction

L'augmentation des taux de prévalence des maladies neurodégénératives, en particulier la maladie d'Alzheimer, représente un défi majeur pour la santé publique à l'échelle mondiale. Les déficits cognitifs, qui sont une caractéristique du déclin cognitif et dont la maladie d'Alzheimer est une forme courante, affectent des millions de personnes dans le monde entier, mettant ainsi une pression considérable sur les systèmes de soins de santé et sur les familles. Cette maladie progressive ne se limite pas seulement à la perte de mémoire, mais elle impacte également les fonctions cognitives et comportementales, ce qui affecte la qualité de vie des patients et de leurs proches. Comprendre les détails des mécanismes sous-jacents de la maladie, ainsi que les facteurs de risque et les stratégies préventives, est d'une importance capitale pour atténuer son impact. Ce chapitre examine différents aspects de la maladie d'Alzheimer.

III.2 Images médicales

L'imagerie médicale regroupe un ensemble de techniques permettant de détecter et de visualiser différentes régions ou organes du corps. Ces techniques varient en fonction des zones à étudier. Parmi les différentes méthodes, on trouve la radiologie, qui utilise les rayons X pour examiner les os, les poumons, l'abdomen ou le système digestif. L'échographie, quant à elle, utilise des ultrasons pour explorer les organes pleins et permet notamment d'observer le fœtus pendant la grossesse. L'imagerie par résonance magnétique (IRM) produit des images en coupes du corps, tandis que le scanner offre également des images en coupe et permet la représentation en 3D des organes [1].

III.2.1 Radiographie

La radiographie consiste en la formation d'images par l'interaction des photons des rayons X avec un détecteur photonique, tel qu'un film à rayons X qui sera développé par la suite. L'image obtenue représente la projection des propriétés atténuantes selon le trajet emprunté par les rayons X [2].

La radiographie standard est principalement utilisée pour obtenir des images en deux dimensions des structures osseuses et articulaires.



Figure III.1 Exemple d'une image Radiographique [3].

III.2.2 Echographie

L'échographie (images ultrasonores) est une technique d'imagerie médicale qui utilise des ultrasons pour visualiser les organes internes. Les ultrasons, émis par une sonde placée sur la peau, rebondissent sur les organes et sont captés par la sonde, puis transformés en images par un ordinateur. Cette méthode est efficace pour examiner les organes pleins car les fluides, contrairement aux tissus osseux ou aériens, conduisent bien les ultrasons. Pendant la grossesse, l'échographie est largement utilisée pour surveiller le développement du fœtus et détecter d'éventuelles anomalies. Elle est également utile pour guider certaines interventions médicales, comme les biopsies [1].



Figure III.2 Image échographique de grossesse [4].

III.2.3 Tomodensitométrie (scanner)

Le scanner est une technique qui permet de produire une série d'images en "coupes" d'une zone scannée. Ces images sont créées à partir du traitement informatique des informations

reçues par les capteurs de l'appareil. Le scanner permet de visualiser les changements de volume et les anomalies structurelles des tissus ou des organes. Cette technique est utilisée dans divers domaines :

- En cancérologie pour détecter les nodules, suivre la réponse à la chimiothérapie et évaluer l'étendue des cancers (pulmonaires, bronchiques, pelviens, ORL),
- En chirurgie pour localiser précisément la zone à traiter,
- En traumatologie pour étudier les traumatismes et les fractures.

Le scanner continue de se développer afin d'améliorer les diagnostics médicaux [5].



Figure III.3 Scanner à rayons X.

III.2.4 Image par Résonance Magnétique

L'imagerie par résonance magnétique (IRM) est une technique d'imagerie médicale qui utilise des champs magnétiques puissants et des signaux radio pour créer des images détaillées des tissus et des organes du corps. Cette technologie permet aux médecins de visualiser les détails anatomiques à l'intérieur du corps, y compris les organes internes et les tissus mous tels que le cerveau, la moelle épinière, le foie et le cœur, avec une grande précision.

Lors d'une IRM, le patient est placé à l'intérieur d'un appareil d'IRM qui contient un aimant puissant et de l'émetteurs-récepteurs radio. Cet aimant est utilisé pour produire des images en coupe détaillées du corps en dirigeant des signaux radio vers les tissus du corps et en enregistrant les réponses qui en résultent.

L'IRM est utile pour diagnostiquer de nombreuses conditions médicales, telles que les tumeurs malignes, les anomalies structurelles, les lésions nerveuses et vasculaires, ainsi que pour surveiller la réponse aux différents traitements. Cette technologie fournit des images non

invasives et est considérée comme sûre pour la plupart des patients, à l'exception des cas où des informations médicales particulières sont présentes, comme la présence d'un stimulateur cardiaque implanté ou d'un corps étranger métallique dans le corps [2].




Figure III.4 Imagerie par résonance magnétique (IRM).

III.3 IRM cérébrale

L'imagerie par résonance magnétique (IRM) joue un rôle crucial dans la détection précoce et la compréhension de la maladie d'Alzheimer, une maladie neurodégénérative progressive [6]. Cette maladie entraîne des changements structuraux caractéristiques dans le cerveau, que l'IRM permet de visualiser [7]. Parmi les principaux changements observés à l'IRM chez les patients atteints d'Alzheimer, on peut citer l'atrophie (rétrécissement) du lobe occipital, une structure cérébrale cruciale pour la mémoire. On observe également une dilatation des ventricules, qui sont des cavités cérébrales contenant le liquide céphalo-rachidien, ainsi qu'une diminution globale du volume cérébral [8].

Ces changements sont liés à la mort progressive des neurones et à la perte de connexions entre eux, caractéristiques de la maladie d'Alzheimer. Ils se produisent initialement dans le lobe occipital et le cortex entorhinal, avant de s'étendre progressivement à d'autres régions du cerveau [9].

Le cerveau est composé de deux hémisphères (droit et gauche) reliés par le corps calleux. Chaque hémisphère est divisé en quatre lobes principaux [10], comme illustré dans la figure (III.5) [11]:

- Le lobe frontal, impliqué dans la pensée, le mouvement et les émotions.
- Le lobe pariétal, responsable de l'intégration sensori-motrice.
- Le lobe temporal, lié à l'audition et à la mémoire.

- Le lobe occipital, dédié à la vision.




Figure III.5 Les divisions cérébrales.

III.4 Maladie d'Alzheimer

III.4.1 Aperçu historique de la maladie d'Alzheimer

La découverte de cette pathologie remonte à 1901 et est attribuée au médecin bavarois Aloïs Alzheimer (1864-1915), également psychiatre. Après avoir achevé ses études, il a intégré le service des maladies mentales et épileptiques à Francfort, puis est devenu l'assistant de Kraepelin à Heidelberg. Pendant cette période, il a suivi le cas d'une patiente de 51 ans nommée Auguste D, jusqu'à son décès en 1906. Cette patiente présentait des symptômes de détérioration intellectuelle et de trouble psycho comportementale. Après le décès de cette patiente, Aloïs Alzheimer a récupéré son dossier médical ainsi que son cerveau pour pratiquer une autopsie. Il a utilisé une technique histologique d'imprégnation organique pour examiner les coupes du cerveau, découvrant ainsi dans le cortex des lésions particulières, caractérisées par une dégénérescence neuro fibrillaire, soit une accumulation de filaments anormaux dans les neurones. En 1903, il a continué ses recherches à Munich, et en 1912, il a fondé une école de neuropathologie. En 1907, il a publié un article sous-titré "Une maladie caractéristique grave du cortex cérébral", détaillant la maladie d'Alzheimer. En 1910, il a individualisé cette maladie en lui donnant le nom qui la distingue aujourd'hui, Aloïs Alzheimer [12].

III.4.2 Définition de la maladie d'Alzheimer

La maladie d'Alzheimer altère le fonctionnement du cerveau en provoquant une dégénérescence et une mort progressives des cellules nerveuses. Au fil du temps, cette

maladie évoluée, touchant de nouvelles zones cérébrales et entraînant la détérioration de certaines fonctions mentales.

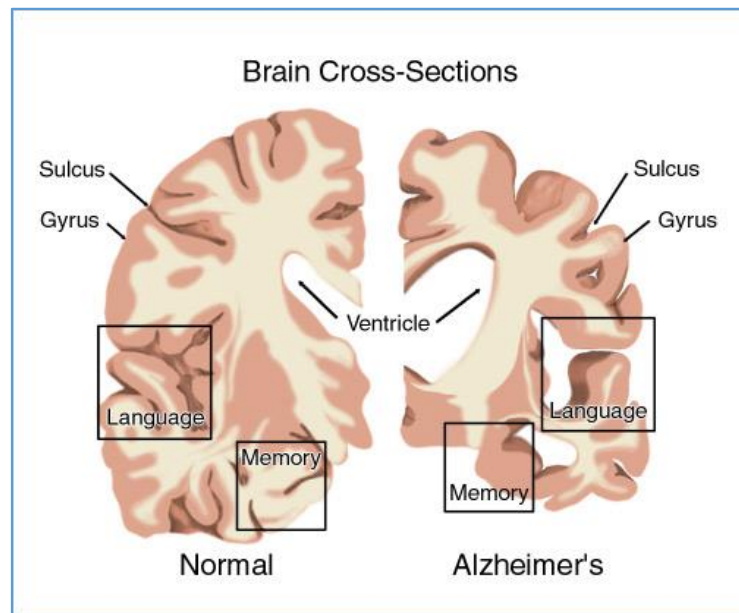


Figure III.6 Cerveau d'Alzheimer vs cerveau normal [13].

On qualifie cette maladie de dégénérative neuronale car elle entraîne une perte progressive des neurones. Sa prévalence augmente avec l'âge. La maladie d'Alzheimer est la principale cause des syndromes démentiels et représente 77 % de tous les cas de démence. Les autres causes fréquentes de démence sont non dégénératives : la démence vasculaire, la démence à corps de Lewy, la démence liée à la maladie de Parkinson et la dégénérescence lobaire fronto-temporale [14].

III.4.3 Multiples facettes de la maladie Alzheimer

La maladie d'alzheimer se révèle être un phénomène aux multiples facettes, impactant profondément les individus, les familles et la société dans son ensemble. Ces facettes peuvent se résumer comme suit:

- **Une affection cérébrale** : étant donné qu'elle est liée à des lésions ou des atteintes cérébrales qui perturbent le fonctionnement du cerveau.

- **Une maladie familiale** : remettant en question l'organisation familiale, elle altère entre les générations et modifie les rôles familiaux.

- **Une maladie individuelle** : du fait que l'atteinte cérébrale entraîne des troubles psychologiques chez le malade dans sa relation avec lui-même et même avec les autres.

• **Une maladie sociale** : en raison de l'insuffisance d'accueil et de l'augmentation significative du nombre de patients, ce sera un défi pour la santé publique et nécessitera même l'élaboration d'une politique sociale et sanitaire adaptée et cohérente [12].

III.4.4 Causes de la maladie d'Alzheimer

Les causes de la maladie d'Alzheimer restent inconnues à ce jour. Cependant, certains facteurs de risque ont été identifiés comme favorisant le développement de cette maladie.

▪ **Age** : Il s'agit du facteur de risque le plus significatif, une cause de la maladie d'Alzheimer sur laquelle personne n'a de contrôle. En effet, le risque de développer cette pathologie augmente avec l'âge : elle se manifeste généralement vers l'âge de 60 à 70 ans. Les femmes sont plus fréquemment touchées, peut-être en raison d'une espérance de vie plus longue que celle des hommes.

▪ **Facteur génétique (les antécédents familiaux)** : Dans seulement 5 à 10 % des cas de cette démence, la science a démontré l'implication de la génétique. Bien que les antécédents familiaux ne soient pas une cause directe de la maladie d'Alzheimer, ils représentent un facteur de risque significatif du point de vue de la recherche. Le fait d'avoir un parent atteint augmente le risque de développer la maladie soi-même, et les mécanismes héréditaires sont encore en cours d'étude.

▪ **Santé mentale** : Le stress, la dépression et l'isolement sont des éléments qui peuvent contribuer à de nombreux problèmes de santé et favoriser également l'apparition de la maladie d'Alzheimer. Par ailleurs, des études menées aux États-Unis ont révélé qu'une attitude optimiste, joyeuse, confiante et sereine pourrait constituer une forme de protection contre cette maladie. En effet, les interactions sociales ainsi que les activités physiques et intellectuelles sont considérées comme des facteurs protecteurs [15].

III.4.5 IRM dans le diagnostic de la maladie d'Alzheimer

L'IRM joue un rôle important dans le diagnostic de la maladie d'Alzheimer en fournissant des images détaillées du cerveau et en aidant à identifier les lésions caractéristiques de la maladie. Elle permet également de différencier la maladie d'Alzheimer d'autres causes de troubles cognitifs et d'évaluer le stade de la maladie. Cependant, l'IRM doit être utilisée en conjonction avec d'autres approches diagnostiques pour établir un diagnostic précis [16].




Figure III.7 Imagerie par résonance magnétique pour la maladie d'Alzheimer.

III.4.6 Stades de la maladie d'Alzheimer

Les stades de la maladie d'Alzheimer sont généralement classés en stade léger (Mild Demented), stade modéré (Moderate Demented) et stade sévère (Very Mild Demented) [17]. Dans le stade léger, les individus présentent des troubles de la mémoire et une légère altération cognitive, mais ils peuvent généralement vivre de manière autonome. Dans le stade modéré, les troubles de la mémoire et cognitifs s'aggravent, ce qui affecte les activités quotidiennes. Quant au stade sévère, les individus ont besoin d'une assistance complète pour la plupart des activités quotidiennes [18][19].




Figure III.8 Présentation de les stades de la MA.

III.4.7 Architecture des systèmes d'aide au diagnostic de la maladie d'Alzheimer

L'architecture d'un système d'aide au diagnostic de la maladie d'Alzheimer se compose principalement de trois blocs principaux :

❖ **Bloc de prétraitement** : Ce bloc traite les images brutes en leur appliquant des prétraitements pour améliorer leur qualité, tels que le dé bruitage, la normalisation, la correction du champ de biais et l'application de filtres.




Figure III.9 IRM avant et après débruitage.




Figure III.10 IRM avant et après correction du champ de biais.

❖ **Bloc d'extraction de caractéristiques** : Ce bloc est au cœur de la qualité du système, car il prend les images prétraitées et extrait les caractéristiques utilisées pour leur classification, en utilisant des méthodes statistiques classiques ou basées sur l'apprentissage profond.

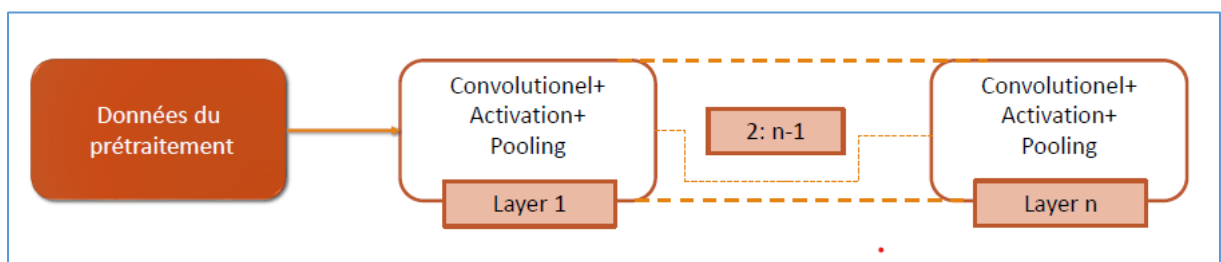


Figure III.11 Exemple de bloc d'extraction de caractéristiques par CNN.

❖ **Bloc de classification** : Ce bloc prend en entrée le vecteur de caractéristiques extrait par le bloc précédent et se charge de la classification, soit par des algorithmes classiques, soit par apprentissage automatique, pour donner en sortie la classe de l'image d'entrée.

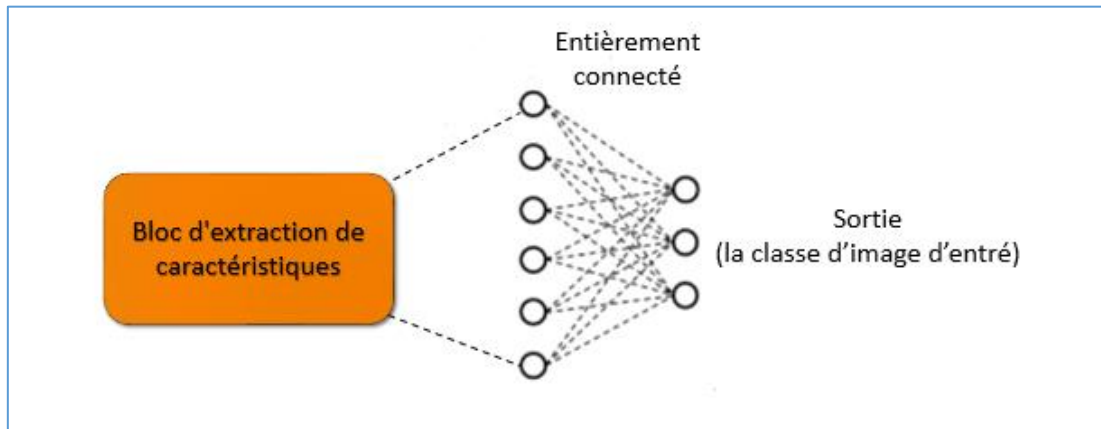


Figure III.12 Exemple de Bloc de classification par CNN.

La figure (III.13) résume ce que nous avons mentionné précédemment. Elle illustre les étapes du fonctionnement d'un système d'aide au diagnostic médical, commençant par l'image IRM, passant par le prétraitement, puis l'extraction des caractéristiques, jusqu'à la classification et la classe finale.

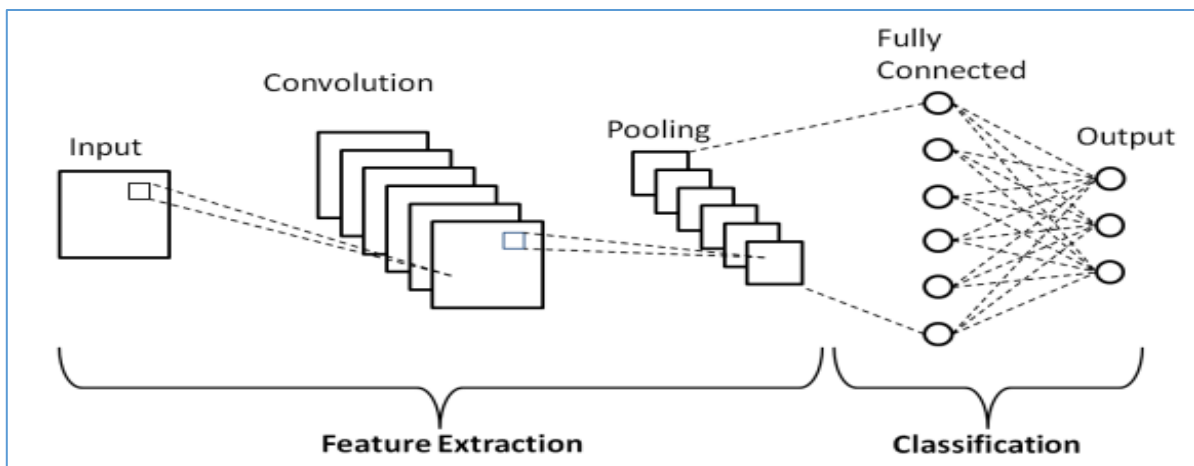


Figure III.13 Les étapes du fonctionnement d'un système d'aide au diagnostic médical.

III.5 Conclusion

Dans ce chapitre, nous avons abordé divers aspects liés à notre étude, tels que l'IRM cérébrale et sa relation avec le cerveau humain, en mettant en évidence les maladies pouvant être détectées par cette technique. Nous avons également présenté un aperçu de la maladie d'Alzheimer, en retraçant son historique, en détaillant ses causes, ses manifestations cliniques

et ses différents stades. Enfin, nous avons discuté de l'architecture des systèmes d'aide au diagnostic de la maladie d'Alzheimer.

Ainsi, ce chapitre a permis de démontrer l'importance de l'IRM dans le diagnostic précoce et le suivi de la maladie d'Alzheimer, tout en fournissant un cadre pour l'application des systèmes de diagnostic assisté.

Dans le prochain chapitre, nous explorerons l'utilisation d'une base de données d'IRM cérébrales de Kaggle pour détecter la maladie d'Alzheimer et analyserons les résultats des modèles CNN.

Références de chapitre III

- [1] Chirost. Radiographie. Retrieved from (<https://chirost.com/blogue/radiographie>).
- [2] Centre d'Échographie. Retrieved from (<https://www.centre-echographie.fr/details>).
- [3] Ghezali, H., & Charif, O. Une étude comparative sur les différents types des images médicales. Thèse de master, Université Mohamed Boudiaf, Département d'Électronique, M'Sila. (2017–2018).
- [4] Hampel, H., Vergallo, A., Aguilar, L. F., Benda, N., Broich, K., Cuello, A. C., ... & Lista, S. Precision pharmacology for Alzheimer's disease. *Pharmacological Research*, 158, 104870. (2020).
- [5] Dupont, A. Neuroimagerie de la maladie d'Alzheimer. Mémoire de master, Université de Paris. (2020).
- [6] García, B. Changements structurels cérébraux dans la maladie d'Alzheimer. Mémoire de master, Université de Barcelone. (2019).
- [7] Ivanov, P. Progression de la pathologie d'Alzheimer dans le cerveau. Mémoire de master, Université de Moscou. (2018).
- [8] Jiang, L. Architecture cérébrale et fonctions cognitives. Mémoire de master, Université de Pékin. (2017).
- [9] Journal des Femmes. Retrieved from (<https://img3.journaldesfemmes.fr/>).
- [10] Allem, T., & Amara, K. Les performances en mémoire épisodique chez des personnes atteintes de la maladie d'Alzheimer et des personnes ayant un vieillissement normal. Mémoire de master, Université Mouloud Mammeri de Tizi-Ouzou. (2019–2020).
- [11] Medical Islam. Retrieved from (<https://medicalislam.com/index.php/>).
- [12] Grandjean, S. Prise en charge de la maladie d'Alzheimer à l'officine. Mémoire de master, Université d'Aix-Marseille, Faculté de Pharmacie. (2018).
- [13] Cap Retraite. Les causes de la maladie d'Alzheimer. Retrieved from (<https://www.capretraite.fr/prevenir-dependance/maladie-d-alzheimer/les-causes-de-la-maladie-d-alzheimer/>).
- [14] GRANDJEAN, S. Prise en charge de la maladie d'Alzheimer à l'officine. Mémoire de master, Université d'Aix-Marseille, Faculté de Pharmacie. (2018).

[15] Al-Jabri, K. Évolution clinique de la maladie d'Alzheimer. Mémoire de master, Université de Damas, Faculté de Médecine. (2022).

[16] Hassan, M. Prise en charge des différents stades de la démence : une étude de cas sur la maladie d'Alzheimer. Mémoire de master, Université du Caire, Département de Psychologie, Faculté des Lettres. (2021).

[17] Khalil, O. Symptômes et progression de la maladie d'Alzheimer : une étude longitudinale sur les patients en Jordanie. Mémoire de master, Université de Jordanie, Département des Sciences Médicales, Faculté des Sciences. (2020).

[18] Dalmau Bueno, A., Gómez-Vilaró, C., Arévalo-Garcia, R. (2020). Quantitative EEG in the Mild Cognitive Impairment Stage of Alzheimer's Disease: A Systematic Review and Meta-Analysis. *Brain Sciences*, 10(9), 585. <https://doi.org/10.3390/brainsci10090585>

[19] Cohen, A.D., Sundararajan, L., Hominda, D.M. et al. (2021). Longitudinal Associations Between Daily Walking and Subsequent Cognitive, Functional, and Structural Brain Changes in Older Adults with Mild Alzheimer's Disease Dementia. *Journal of Alzheimer's Disease*, 79(4), 1525-1539. <https://doi.org/10.3233/JAD-200981>

Chapitre IV :
Outils de simulation
et discussion des
résultats

IV.1 Introduction

Ce chapitre examine l'utilisation d'une base de données d'IRM cérébrales pour détecter la maladie d'Alzheimer. La base de données, provenant de Kaggle, comprend 6400 images réparties en quatre catégories. Cette base de données souffre de problèmes de déséquilibre. En raison du nombre limité d'images dans certaines catégories, nous avons appliqué des techniques d'augmentation de données pour générer de nouvelles images à partir de celles existantes. Cela nous a permis d'enrichir notre ensemble de données, de le rendre plus équilibré et d'améliorer les performances des modèles d'apprentissage profond utilisés. Nous avons utilisé les variantes des célèbres modèles de CNN ResNet et VGG pour la classification. Une version modifiée de ResNet-101 a également été utilisée pour la classification. Les résultats obtenus sont exposés en détail dans ce chapitre.

IV.2 Base de données

IV.2.1 Description

La base de données utilisée provient du jeu de données "Alzheimer's Dataset" disponible sur Kaggle [1]. Il s'agit d'une collection de 6400 images IRM du cerveau liées à la maladie d'Alzheimer, réparties en quatre classes : démence légère (896 images), démence modérée (64 images), absence de démence (3200 images) et démence très légère (2240 images), comme l'illustre la figure (IV.1). Toutes les images ont été redimensionnées à une taille de 176 x 208 pixels.

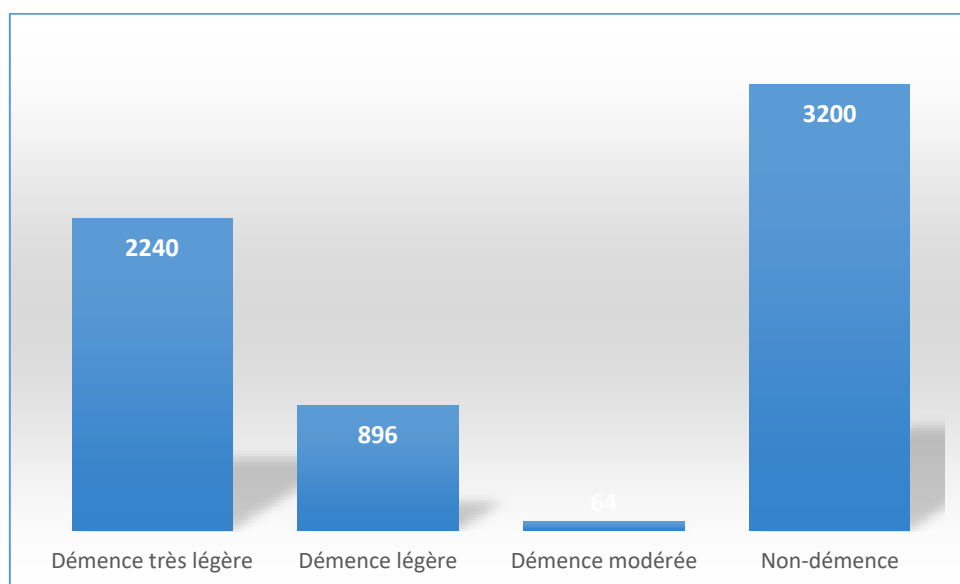


Figure IV.1 Répartition de l'ensemble de données MA.

IV.2.2 Augmentation de la base de données

En neuro-imagerie pour la maladie d'Alzheimer, un grand problème est le manque de données disponibles, avec seulement quelques centaines d'images de patients accessibles. Les modèles d'intelligence artificielle fonctionnent mieux avec un grand volume de données d'entraînement, mais dans le domaine médical, l'accès aux grandes bases de données est limité en raison de la confidentialité des données. Ce petit nombre d'images entraîne un sur-apprentissage des modèles, ce qui nuit à leur performance. Pour améliorer la précision de notre modèle, un plus grand ensemble de données est nécessaire [2].

Pour pallier ce manque, l'augmentation des données est utilisée. Cette technique consiste à accroître la taille d'un ensemble en ajoutant des copies légèrement modifiées des données existantes ou des données synthétiques générées à partir de celles-ci. Similaire au sur-échantillonnage en analyse de données, elle agit comme une régularisation, aidant à réduire le sur-apprentissage lors de l'entraînement des modèles d'apprentissage automatique. En fournissant plus de données variées, elle permet d'améliorer la précision des modèles [3].

Dans cette étude, la technique d'augmentation des données a été appliquée uniquement aux deux premières classes : la démence légère (augmentant de 896 à 2680 images) et la démence modérée (augmentant de 64 à 2552 images). Après cette augmentation, le nombre total d'images est passé à 10672, comme illustré dans la figure (IV 2).

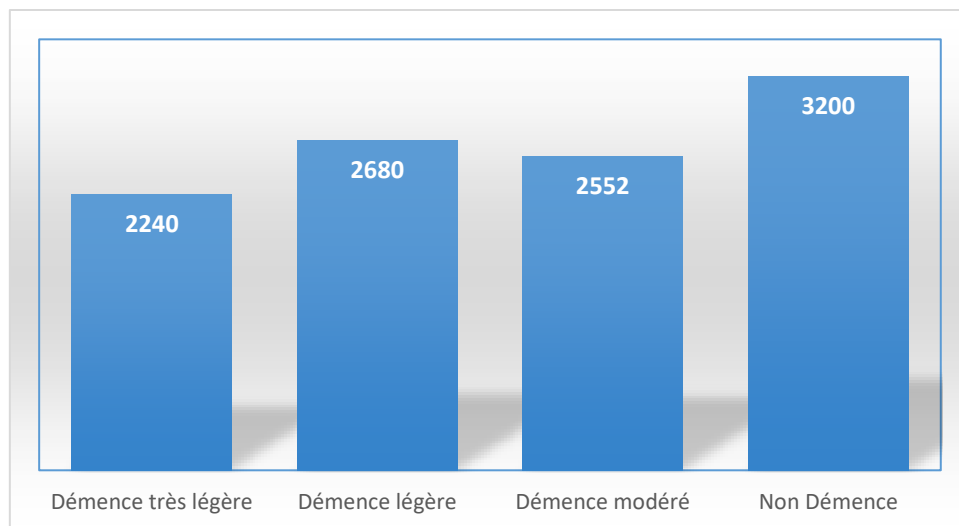


Figure IV.2 Ensemble de données après augmentation.

L'augmentation des données a été réalisée à l'aide de plusieurs paramètres comme montre le tableau (IV.1).

Paramètres	Valeur	Description
ZOOM	[0.98, 1.02]	Zoom avant/arrière de l'image jusqu'à 2 maximum
BRIGHT_RANGE	[0.8, 1.2]	Augment /diminué la luminosité l'image jusqu'à 20 maximum
HORZ_FLIP	True	Retourne l'image horizontalement
FILL_MODE	Constant	Remplit les zones vides avec une valeur constante
DATA_FORMAT	Channels_last	Ordre des canaux de l'image
ROTATION_RANGE	10	Fait pivoter l'image jusqu'à 10 degrés maximum
SHEAR_RANGE	0.1	Déforme l'image horizontalement jusqu'à 10
WIDTH_SHIFT_RANGE	0.1	Décale l'image horizontalement jusqu'à 10 jusqu'à 10 de sa largeur maximum
HEIGHT_SHIFT_RANGE	0.1	Décale l'image verticalement jusqu'à 10 de sa hauteur maximum

Tableau IV.1 Les paramètres d'augmentation.

Le tableau (IV.2) présente des exemples d'images issues de l'ensemble d'entraînement de cette base de données avant et après l'augmentation.

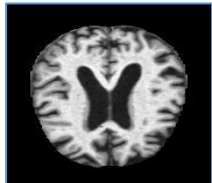
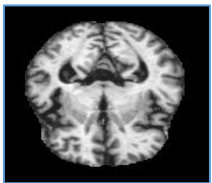
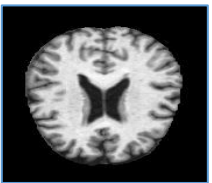

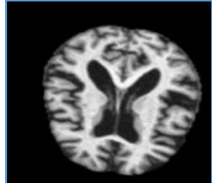
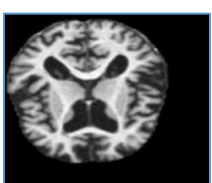

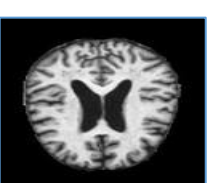
	Démence légère	Démence modérée	Non-Démence	Démence très légère
Avant l'augmentation				
Après Augmentation				

Tableau IV.2 Présentation des exemples des images avant et après l'augmentation des données.

IV.3 Matériel et logiciel de calcul utilisé

IV.3.1 Matériel de calcul

Pour mener à bien ce travail, nous avons mis en œuvre un calcul physique en utilisant un ensemble de matériels présentant les caractéristiques dans le tableau (IV.3) et des environnements virtuels disponibles sur Internet ont été également exploités.

Pc	HP
Processeur	Intel(R) Core(TM) i5-6300U CPU @ 2.40GHz 2.50 GH
La RAM	4Go
Système d'exploitation	64 bits, processeur x64 Microsoft Windows 10
Génération de processeur	6-ème

Tableau IV.3 Caractéristiques du matériel utilisés pour le calcul physique

Au départ, nous avons utilisé Anaconda, nous utilisons l'éditeur Spyder inclus dans Anaconda pour coder. Cependant, nous avons ensuite changé d'environnement de développement par Google Colab, car Google Colab offre la possibilité de se connecter gratuitement à l'aide de GPU. Nous avons ainsi pu bénéficier de cette fonctionnalité pour accélérer les traitements de notre projet basé sur le deep learning.

- **Anaconda** : Anaconda est une distribution libre de l'environnement Python destinée aux applications de science des données. Elle intègre plus de 300 bibliothèques spécialisées dans la machine learning, le deep learning et d'autres domaines liés aux données. Avec cet important écosystème de packages préconfigurés, Anaconda s'impose comme un choix optimal pour les programmeurs souhaitant travailler de manière efficace sur des projets de data science. Son large éventail d'outils et de bibliothèques tout-en-un facilite grandement le développement et le déploiement de solutions d'analyse de données, d'apprentissage automatique ou de calcul scientifique sous Python [4].

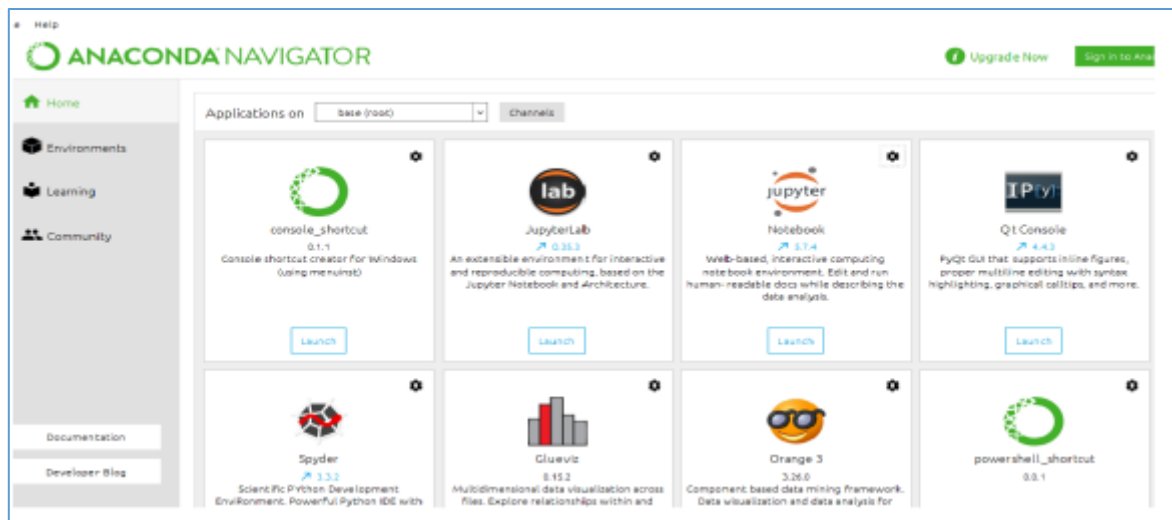


Figure IV.3 Vue générale de l'environnement Anaconda.

- **Google Colab** : également connu sous le nom de « Colaboratory » ou Colab, est une plateforme offerte gratuitement par Google qui permet d'écrire et d'exécuter du code Python via un navigateur web. Fondé sur Jupyter Notebook, il est principalement utilisé dans le domaine de la formation et de la recherche en apprentissage automatique.

Cette plateforme offre la possibilité d'entraîner des modèles de Machine Learning directement dans le Cloud.

Les fonctionnalités de Colab incluent :

- Améliorer les compétences de codage en Python.
- Développer des applications en Deep Learning en utilisant des bibliothèques populaires telles que Keras, TensorFlow et OpenCV.
- Utiliser un environnement de développement (Jupyter Notebook) sans aucune configuration requise.

Ce qui distingue Colab des autres services est son accès gratuit à un processeur graphique (GPU), ce qui est particulièrement avantageux pour les tâches intensives en calcul, comme l'entraînement de modèles de Deep Learning [5].

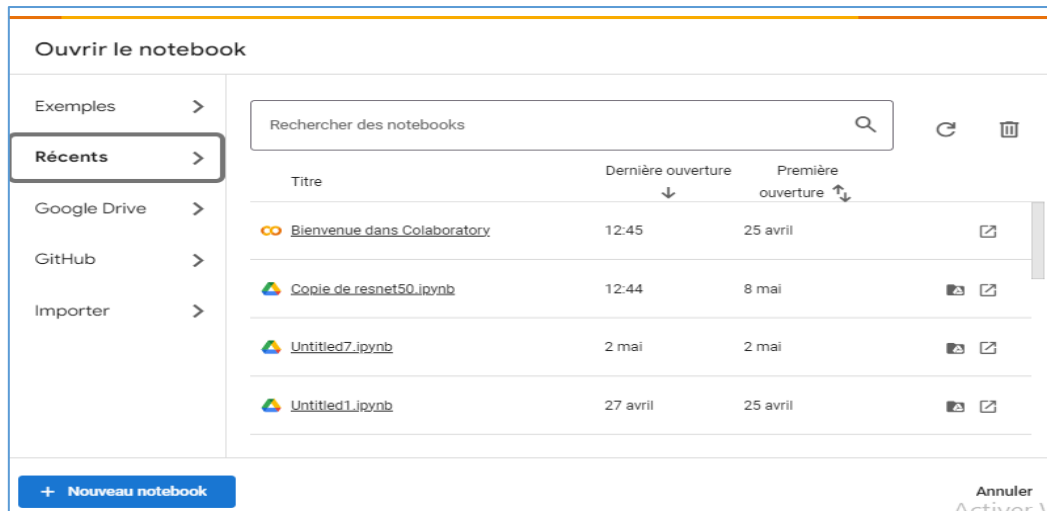


Figure IV.4 Vue générale de l'environnement de Google Colab.

IV.3.2 Langage de programmation

❖ **Python** : Python est un langage de programmation de haut niveau, caractérisé par une philosophie de conception axée sur la lisibilité du code et une structure syntaxique permettant aux programmeurs d'exprimer des concepts en quelques lignes de code. Python a été développé sous une licence open source approuvée par l'OSI, ce qui le rend utilisable et distribuable librement, même à des fins commerciales. Il a été utilisé avec succès dans de nombreux cas réels et professionnels à travers le monde, y compris dans des systèmes critiques et importants [6]. Python est plus rapide qu'avec d'autres langages [5].



Figure IV.5 Logo de langage Python.

IV.3.3 Bibliothèques utilisées

- ✓ **Pandas** : C'est une bibliothèque écrite pour le langage python permet la manipulation et l'analyse de données [6].
- ✓ **TensorFlow** : TensorFlow est une bibliothèque open source pour l'apprentissage automatique et profond. Elle a été développée par Google et permet d'utiliser facilement les CPU, GPU et TPU. TensorFlow est flexible, puissante et largement utilisée dans de nombreux domaines [7].




Figure IV.6 Logo de la bibliothèque TensorFlow.

- ✓ **Keras** : Nous avons utilisées cette bibliothèque pour faciliter la création de réseaux de neurones artificiels. L'objectif de Keras est de permettre une construction rapide de réseaux neuronaux. Keras n'est pas un framework complet mais plutôt une interface de programmation qui se connecte à différents frameworks d'apprentissage automatique existants [8].



Figure IV.7 Logo de la bibliothèque keras.

- ✓ **NumPy** : NumPy est un outil essentiel pour le calcul scientifique avec Python. Il fournit les "ndarray" qui permettent de représenter facilement les vecteurs, matrices et tableaux multidimensionnels. Ces ndarray sont différents et plus adaptés que les listes Python pour ce type de calculs [7].



Figure IV.8 Logo de la bibliothèque NumPy.

- ✓ **Matplotlib** : Matplotlib s'avère particulièrement précieuse pour les individus qui manipulent du code Python ou NumPy. Elle trouve notamment sa place sur les serveurs d'applications web, dans les environnements de développement interactifs (shells) et les

scripts Python. Grâce à ses interfaces de programmation (API), les développeurs peuvent aisément intégrer des graphiques dans des applications à interface graphique [7].



Figure IV.9 Logo de la bibliothèque Matplotlib.

- ✓ **Scikit-learn** : Scikit-learn est une bibliothèque Python essentielle pour les projets de machine learning (apprentissage automatique). Elle se concentre sur les outils de machine learning, comprenant des algorithmes mathématiques, statistiques et généralistes qui forment la base de nombreuses technologies d'apprentissage automatique. En tant qu'outil gratuit, Scikit-learn est extrêmement importante pour le développement de divers types d'algorithmes liés à la machine learning et aux technologies associées [9].



Figure IV.10 Logo de la bibliothèque Scikit-learn.

IV.4 Evaluation des métriques

Notre problème de classification implique des classes déséquilibrées, une situation typique dans le domaine biomédical. Pour mesurer réellement la qualité du modèle, le choix des métriques est crucial. Par exemple, la métrique la plus utilisée dans le domaine de l'apprentissage automatique est « Accuracy ». Cependant, en raison du déséquilibre des classes, nous allons opter pour d'autres métriques plus adaptées afin de mieux évaluer la qualité de notre modèle.

❖ La matrice de confusion

La matrice de confusion est un tableau qui résume les prédictions d'un modèle de classification. Elle met en lumière les prédictions correctes et incorrectes pour chaque classe,

ce qui permet de comprendre comment le modèle se comporte et quelles erreurs il commet [3]. C'est un outil essentiel pour évaluer la performance d'un modèle de classification, en particulier pour les modèles à deux classes ou plus. La matrice de confusion se présente sous la forme d'un tableau à quatre valeurs, illustrant les différentes combinaisons entre les valeurs réelles et les valeurs prédites, comme illustré dans la figure (IV.11) [10].

		Vraies classes	
		Positif	Négatif
Classes prédites	Positif	VP	FP
	Négatif	FN	VN

Figure IV.11 Matrice de confusion.

Voici les quatre types de résultats possibles lors de l'évaluation des performances d'un modèle de classification :

- **TP (True positives)** : Quand on prédit correctement qu'une valeur réelle est vrai.
- **TN (True negatives)** : Quand on prédit correctement qu'une valeur réelle est faux.
- **FP (False positives)** : Quand on prédit positivement, mais que la réalité est négative.
- **FN (False negatives)** : Quand on prédit négativement, mais que la réalité est positive.

À partir de la matrice de confusion, on peut obtenir plusieurs mesures de performance :

❖ Accuracy

La précision mesure la proportion de prédictions positives correctes parmi toutes les prédictions positives [11].

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

❖ Précision

La précision représente le pourcentage de prédictions positives correctes parmi toutes les prédictions positives [11].

$$\text{Précision} = \frac{TP}{TP + FP}$$

❖ Sensitivité (Recall)

La sensibilité ou le rappel (Recall) est une mesure du nombre de prédictions positives correctes parmi toutes les données réellement positives [11].

$$\text{Recall} = \frac{TP}{TP + FN}$$

❖ F1-score

Le score F1 est une mesure harmonique de la précision et du rappel. Il est calculé comme le double du produit de la précision et du rappel, divisé par leur somme [11].

$$F1 - score = \frac{2 \cdot \text{Précision} \cdot \text{Recall}}{\text{Précision} + \text{Recall}}$$

IV.5 Modèles utilisés pour la classification

IV.5.1 VGG et ResNet

Afin de classifier l'ensemble de données de la maladie d'Alzheimer provenant de Kaggle, nous avons utilisé la technique de l'apprentissage par transfert (transfer learning). Pour ce faire, nous avons choisi d'utiliser les modèles de CNN ResNet et VGG. Les cinq variantes suivantes ont été employées : VGG-16, VGG-19, ResNet-50, ResNet-101 et ResNet-152. De plus, une modification du modèle ResNet-101 a été proposée pour améliorer les performances.

Le tableau suivant résume les différentes architectures de VGG-16, VGG-19, ResNet-50, ResNet-101 et ResNet-152.

Modèle	Nombre de couches	Architecture	Détails
VGG-16	16	5 blocs convolutifs + 3 couches entièrement connectées	<ul style="list-style-type: none"> • Bloc 1 : 2 conv (64 filtres, 3x3) + Pooling • Bloc 2 : 2 conv (128 filtres, 3x3) + Pooling • Bloc 3 : 3 conv (256 filtres, 3x3) + Pooling • Bloc 4 : 3 conv (512 filtres, 3x3) + Pooling • Bloc 5 : 3 conv (512 filtres, 3x3) + Pooling • FC : 2 couches (4096 neurones) + Sortie (1000 neurones)
VGG-19	19	5 blocs convolutifs + 3 couches entièrement connectées	<ul style="list-style-type: none"> • Bloc 1 : 2 conv (64 filtres, 3x3) + Pooling • Bloc 2 : 2 conv (128 filtres, 3x3) + Pooling • Bloc 3 : 4 conv (256 filtres, 3x3) + Pooling • Bloc 4 : 4 conv (512 filtres, 3x3) + Pooling • Bloc 5 : 4 conv (512 filtres, 3x3) + Pooling • FC : 2 couches (4096 neurones) + Sortie (1000 neurones)
ResNet-50	50	Blocs convolutifs résiduels + Pooling moyen global + FC	<ul style="list-style-type: none"> • Conv (64 filtres, 7x7) + BN + ReLU + Pooling • Bloc 1 : 3 conv résiduels (64 filtres, 3x3) • Bloc 2 : 4 conv résiduels (128 filtres, 3x3) • Bloc 3 : 6 conv résiduels (256 filtres, 3x3) • Bloc 4 : 3 conv résiduels (512 filtres, 3x3) • Pooling moyen global • FC (1000 neurones)
ResNet-101	101	Blocs convolutifs résiduels + Pooling moyen global + FC	<ul style="list-style-type: none"> • Conv (64 filtres, 7x7) + BN + ReLU + Pooling • Bloc 1 : 3 conv résiduels (64 filtres, 3x3) • Bloc 2 : 4 conv résiduels (128 filtres, 3x3) • Bloc 3 : 23 conv résiduels (256 filtres, 3x3) • Bloc 4 : 3 conv résiduels (512 filtres, 3x3) • Pooling moyen global • FC (1000 neurones)
ResNet-152	152	Blocs convolutifs résiduels + Pooling moyen global + FC	<ul style="list-style-type: none"> • Conv (64 filtres, 7x7) + BN + ReLU + Pooling • Bloc 1 : 3 conv résiduels (64 filtres, 3x3) • Bloc 2 : 8 conv résiduels (128 filtres, 3x3) • Bloc 3 : 36 conv résiduels (256 filtres, 3x3) • Bloc 4 : 3 conv résiduels (512 filtres, 3x3) • Pooling moyen global • FC (1000 neurones)

Tableau IV.4 Résumé des architectures des modèles utilisés.

IV.5.2 Modèle proposé "ResNet-101 amélioré"

Nous avons pris le modèle de base ResNet-101 et y avons apporté des modifications pour améliorer ses performances sur notre dataset de MA. Ces modifications incluent la décongélation de certaines couches, l'ajout de couches de dropout et de batch normalisation,

ainsi que l'ajustement des hyper paramètres de l'optimiseur. Nous pouvons résumer ces modifications comme suit :

- **Décongélation des dernières couches du modèle de base** : Permettre un ajustement plus fin des poids pour mieux s'adapter aux nouvelles données.
- **Ajout de couches de dropout** : Réduire le surapprentissage en désactivant aléatoirement des neurones pendant l'entraînement.
- **Ajout de couches de batch normalization** : Stabiliser et accélérer l'entraînement en normalisant les activations.
- **Utilisation d'un scheduler de taux d'apprentissage** : Ajuster dynamiquement le taux d'apprentissage pour une convergence plus stable.
- **Optimiseur Adam avec un taux d'apprentissage plus faible** : Permettre des ajustements plus fins pendant l'entraînement.

En combinant ces modifications, nous avons créé une version améliorée de ResNet-101, qu'on peut appeler "ResNet-101 amélioré".

IV.6 Description de la préparation expérimentale

Cette préparation expérimentale suit plusieurs étapes. L'ensemble de données est d'abord divisé en trois parties : 80 % pour l'entraînement, et les 20 % restants sont divisés également en validation et test, chacun représentant 10 % des données initiales.

Les images d'entrée sont de taille 128x128 pixels avec 3 canaux de couleur (RGB). Un Image Data Generator est utilisé pour augmenter et prétraiter les données, incluant la normalisation et le retournement horizontal. Des générateurs sont créés pour les ensembles d'entraînement, de validation et de test avec une taille du lot (batch size) a été fixée à 64.

Le modèle de base, pré-entraîné sur ImageNet avec des poids gelés, est intégré dans un modèle séquentiel. Des couches supplémentaires sont ajoutées, incluant une couche de flattening, des couches de normalisation par lots et des couches denses avec des activations ReLU. La couche finale utilise une activation softmax pour classer en quatre catégories.

Le modèle est compilé avec l'optimiseur Adam, la perte de catégorie croisée catégorique et la précision comme métrique. Des callbacks de sauvegarde et d'arrêt anticipé sont définis pour enregistrer le meilleur modèle et éviter le surapprentissage. Le modèle est ensuite entraîné pendant 100 époques.

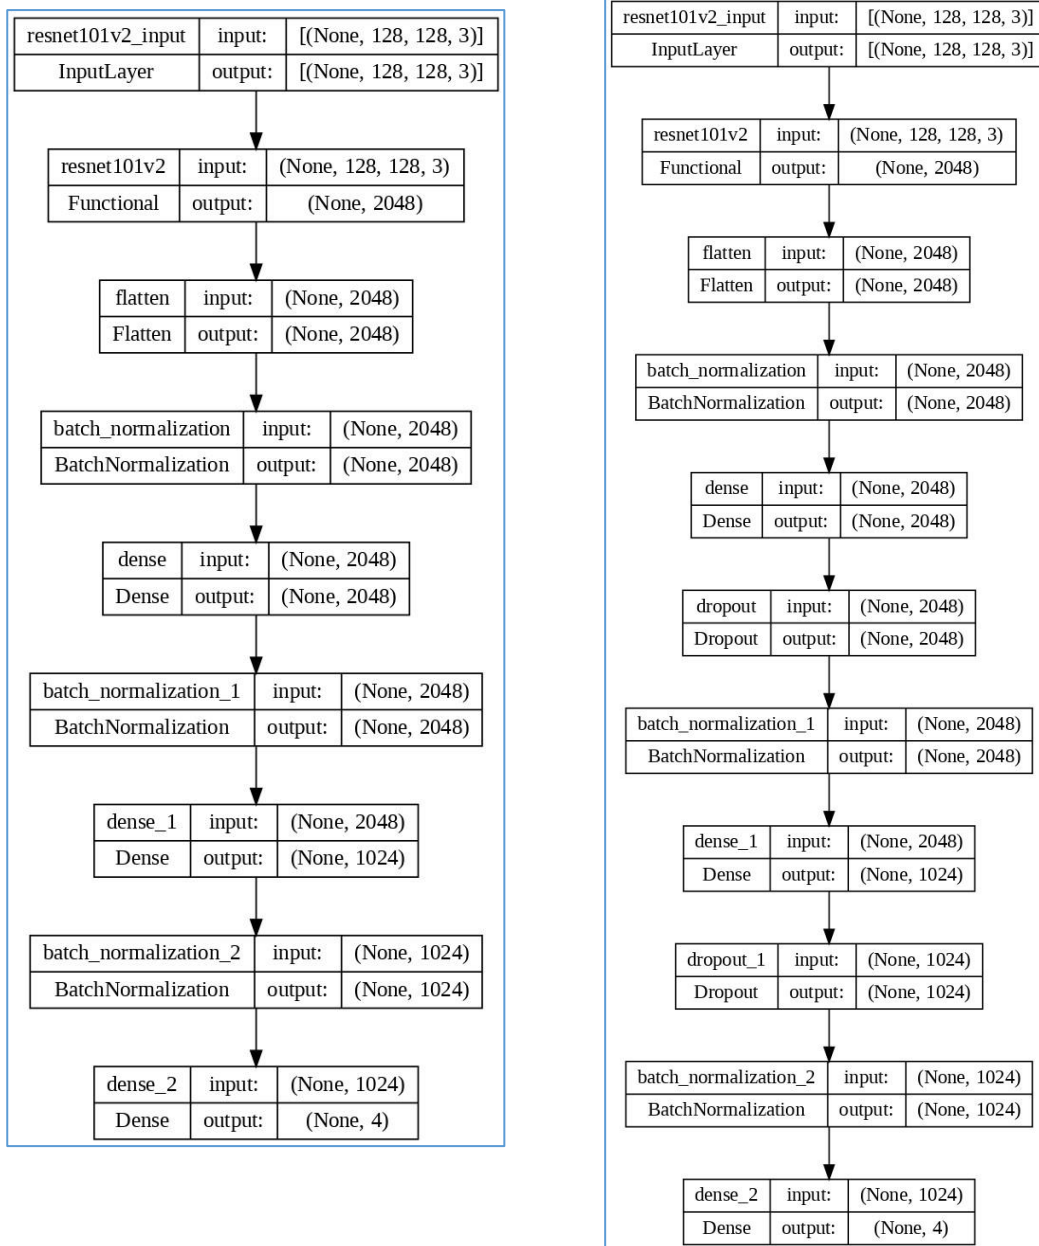


Figure IV.12 Architectures basé sur, à gauche ResNet-101 et à droite ResNet-101 amélioré.

Paramètre	Valeur.
Entraînement	8537 images
Validation	1068 images
Test	1067 images
Nombre des époques	100
La taille du lot « batch size »	64
Nombre d'itérations	134

Tableau IV.5 Paramètres d'entraînement.

IV.7 Résultats obtenus et discussions

IV.7.1 Accuracy et perte

Le modèle proposé a été évalué en utilisant l'ensemble de test, où il a atteint une précision de test (Test Accuracy) de 99,81 %, correspondant à une erreur de classification de seulement 0,0036%. Ces résultats témoignent de la fiabilité du modèle en tant que système intelligent de détection automatique des patients atteints de la maladie d'Alzheimer, basé sur des images IRM.

La valeur de perte de 0,0036 représente la perte moyenne par instance calculée par le modèle lors de l'entraînement ou de l'évaluation. Elle mesure la proximité entre les probabilités prédites par le modèle et les véritables étiquettes de classe. Une valeur de perte plus faible indique une meilleure performance, indiquant que les prédictions du modèle sont plus proches des étiquettes réelles des classes.

Une Test Accuracy de 99,81 % est une mesure de la performance globale du modèle dans la distinction entre les différentes classes. Dans le contexte d'une classification multi-classes, une valeur de Test Accuracy plus élevée indique une meilleure capacité du modèle à discriminer entre les classes, reflétant ainsi sa précision accrue.

Ces résultats confirment que le modèle se comporte bien en classifiant avec précision les différents stades de la maladie d'Alzheimer. En effet, les indicateurs globaux tels que l'accuracy, la Balanced Accuracy, la Sensitivity (Recall) et le F1 score atteignent respectivement les valeurs illustrées dans le tableau (IV.6).

Indicateurs	Valeur
Accuracy	0.9971910112359551
Balanced Accuracy	0.99765625
Sensitivity (Recall)	0.9971910112359551
F1 Score	0.9971937391974192

Tableau IV.6 Indicateurs globaux de la classification par le modèle proposé.

Ces résultats globaux renforcent la performance élevée du modèle dans la prédiction précise des différents stades de la maladie d'Alzheimer.




Figure IV.13 A gauche Perte d'entraînement et de validation et à droite l'accuracy d'entraînement et de validation en fonction des époques.

D'après la figures (IV.13), on remarque de manière générale que quelle que soit la base de données (entraînement ou validation), l'Accuracy augmente avec le nombre d'époques, tandis que la perte (Loss) diminue. Ces deux paramètres semblent souvent être inversement proportionnels. Plus la précision augmente, plus la perte diminue, ce qui indique que le modèle de classification fonctionne bien. Cela peut être justifié par le fait que, à chaque époque, le modèle apprend davantage d'informations, et aussi par la capacité de notre modèle à apprendre à partir des données d'entraînement et de validation. Dès l'époque 40, on observe que les courbes d'entraînement et de validation, tant pour la perte que pour la précision (l'accuracy), se rapprochent et convergent quasi totalement. Cela indique que le modèle a effectivement appris les caractéristiques pertinentes sans sur-apprentissage sur l'ensemble d'entraînement. L'entraînement du modèle s'arrête après 70 époques, signe que la technique

d'arrêt prématuré "Early Stopping" s'est activée à la 20ème époque. Le tableau (IV.7) présente les valeurs de perte (Loss), d'Accuracy, de perte de validation (Val_Loss) et d'Accuracy de validation (Val_Accuracy) pour les 13 dernières époques.

Epoque	Loss	Accuracy	Val_Loss	Val_Accuracy
58	0.00014100212138146162	1.0	0.007157941814512014	0.9981256127357483
59	0.00010499859490664676	1.0	0.002924638334661722	0.9990627765655518
60	0.00014604878379032016	1.0	0.0027354652993381023	0.9990627765655518
61	7.043955702101812e-05	1.0	0.002564921509474516	0.9990627765655518
62	7.440220360876992e-05	1.0	0.0031089188996702433	0.9990627765655518
63	0.0006817147950641811	0.9998828768730164	0.006018581800162792	0.9971883893013
64	0.000845187169034034	0.9998828768730164	0.00791226513683796	0.9981256127357483
65	0.00026894756592810154	0.9998828768730164	0.007652929052710533	0.9981256127357483
66	0.0010083906818181276	0.9997657537460327	0.016744030639529228	0.9943767786026001
67	0.00022731930948793888	1.0	0.010066652670502663	0.9962511658668518
68	0.0001111341844080016	1.0	0.008732875809073448	0.9962511658668518
69	0.00011637852730927989	1.0	0.0058378614485263824	0.9990627765655518
70	8.868993609212339e-05	1.0	0.00949297845363617	0.9981256127357483

Tableau IV.7 Loss, Accuracy, Val_Loss et Val_Accuracy pour les derniers 13 époques.

```

Epoch 52/100
134/134 [=====] - 53s 394ms/step - loss: 4.4035e-04 - accuracy: 0.9999 - val_loss: 0.0036 - val_accuracy: 0.9981 - lr: 1.0000e-05
Epoch 53/100
134/134 [=====] - 53s 392ms/step - loss: 2.5058e-04 - accuracy: 1.0000 - val_loss: 0.0055 - val_accuracy: 0.9981 - lr: 1.0000e-05
Epoch 54/100
134/134 [=====] - 53s 392ms/step - loss: 4.1233e-04 - accuracy: 1.0000 - val_loss: 0.0030 - val_accuracy: 0.9991 - lr: 1.0000e-05
Epoch 55/100
134/134 [=====] - 54s 401ms/step - loss: 2.3440e-04 - accuracy: 1.0000 - val_loss: 0.0073 - val_accuracy: 0.9981 - lr: 1.0000e-05
Epoch 56/100
134/134 [=====] - 53s 396ms/step - loss: 1.6643e-04 - accuracy: 1.0000 - val_loss: 0.0067 - val_accuracy: 0.9972 - lr: 1.0000e-05
Epoch 57/100
134/134 [=====] - 53s 395ms/step - loss: 3.4656e-04 - accuracy: 0.9999 - val_loss: 0.0040 - val_accuracy: 0.9991 - lr: 1.0000e-05
Epoch 58/100
134/134 [=====] - 52s 391ms/step - loss: 6.0694e-04 - accuracy: 0.9996 - val_loss: 0.0040 - val_accuracy: 0.9991 - lr: 1.0000e-05
Epoch 59/100
134/134 [=====] - 53s 393ms/step - loss: 1.4100e-04 - accuracy: 1.0000 - val_loss: 0.0072 - val_accuracy: 0.9981 - lr: 1.0000e-05
Epoch 60/100
134/134 [=====] - 54s 400ms/step - loss: 1.0500e-04 - accuracy: 1.0000 - val_loss: 0.0029 - val_accuracy: 0.9991 - lr: 1.0000e-05
Epoch 61/100
134/134 [=====] - 53s 399ms/step - loss: 1.4605e-04 - accuracy: 1.0000 - val_loss: 0.0027 - val_accuracy: 0.9991 - lr: 1.0000e-05
Epoch 62/100
134/134 [=====] - 53s 395ms/step - loss: 7.0440e-05 - accuracy: 1.0000 - val_loss: 0.0026 - val_accuracy: 0.9991 - lr: 1.0000e-05
Epoch 63/100
134/134 [=====] - 52s 390ms/step - loss: 7.4402e-05 - accuracy: 1.0000 - val_loss: 0.0031 - val_accuracy: 0.9991 - lr: 1.0000e-05
Epoch 64/100
134/134 [=====] - 53s 393ms/step - loss: 6.8171e-04 - accuracy: 0.9999 - val_loss: 0.0060 - val_accuracy: 0.9972 - lr: 1.0000e-05
Epoch 65/100
134/134 [=====] - 52s 391ms/step - loss: 8.4519e-04 - accuracy: 0.9999 - val_loss: 0.0079 - val_accuracy: 0.9981 - lr: 1.0000e-05
Epoch 66/100
134/134 [=====] - 53s 395ms/step - loss: 2.6895e-04 - accuracy: 0.9999 - val_loss: 0.0077 - val_accuracy: 0.9981 - lr: 1.0000e-05
Epoch 67/100
134/134 [=====] - 53s 395ms/step - loss: 0.0010 - accuracy: 0.9998 - val_loss: 0.0167 - val_accuracy: 0.9944 - lr: 1.0000e-05
Epoch 68/100
134/134 [=====] - 52s 390ms/step - loss: 2.2732e-04 - accuracy: 1.0000 - val_loss: 0.0101 - val_accuracy: 0.9963 - lr: 1.0000e-05
Epoch 69/100
134/134 [=====] - 53s 394ms/step - loss: 1.1113e-04 - accuracy: 1.0000 - val_loss: 0.0087 - val_accuracy: 0.9963 - lr: 1.0000e-05
Epoch 70/100
134/134 [=====] - 53s 393ms/step - loss: 1.1638e-04 - accuracy: 1.0000 - val_loss: 0.0058 - val_accuracy: 0.9991 - lr: 1.0000e-05
Epoch 71/100
134/134 [=====] - 53s 392ms/step - loss: 8.8690e-05 - accuracy: 1.0000 - val_loss: 0.0095 - val_accuracy: 0.9981 - lr: 1.0000e-05
    
```

Figure IV.14 Capture d'écran prise après la fin d'entraînement du modèle.

IV.7.2 Matrice de confusion

Une matrice de confusion a été calculée comme le montre la Figure (IV.15), qui fournit des valeurs significatives calculées sur la base d'images IRM classées avec précision et inexactitude. Ces valeurs sont communément appelées vrai positif (TP), vrai négatif (TN), faux positif (FP) et faux négatif (FN).

MildDemented -	1	0	0	0
ModerateDemented -	0	1	0	0
NonDemented -	0	0	0.990625	0.009375
VeryMildDemented -	0	0	0	1
	MildDemented	ModerateDemented	NonDemented	VeryMildDemented

Figure IV.15 Résultat de Matrice de confusion pour l'ensemble de test.

La figure (IV.15) présente la matrice de confusion pour l'ensemble de test. Cette matrice affiche les bonnes prédictions sur sa diagonale (Dans notre cas, les prédictions sont exprimées en pourcentages).

L'analyse de la matrice de confusion révèle une performance remarquable du modèle de classification de la démence. Les classes "Démence Légère" (MildDemented), "Démence Modérée" (ModerateDemented) et "Démence Très Légère" (VeryMildDemented) présentent un taux de prédiction correct de 100%, indiquant une absence totale d'erreurs de classification pour ces catégories. Concernant la classe "Non Démence" (NonDemented), le modèle affiche un taux de réussite de 99%, avec une 1% d'erreur a été classée à tort comme "Démence Très Légère". Ces résultats indiquent une capacité remarquable du modèle à distinguer les différents stades de la maladie d'Alzheimer.

IV.7.3 Rapport de classification

Les valeurs présentées dans la Figure (IV.16) témoignent de la fiabilité du modèle proposé en termes de précision, de sensibilité et de F-mesure. Ce modèle peut être utilisé comme un système d'aide à la décision pour détecter les stades de la maladie d'Alzheimer et apporter une assistance précieuse aux médecins dans leur diagnostic.

	precision	recall	f1-score	support
MildDemented	1.00	1.00	1.00	268
ModerateDemented	1.00	1.00	1.00	256
NonDemented	1.00	0.99	1.00	320
VeryMildDemented	0.99	1.00	0.99	224
accuracy			1.00	1068
macro avg	1.00	1.00	1.00	1068
weighted avg	1.00	1.00	1.00	1068

Figure IV.16 Rapport de classification.

Ce rapport de classification présente les performances d'un modèle capable de distinguer différents stades de la maladie d'Alzheimer. Les résultats sont très encourageants, avec un score parfait (1,00) pour trois des quatre classes sur les mesures de précision, de rappel et de F1-score. Cela indique une excellente capacité du modèle à classifier ces classes avec justesse. La quatrième classe, "Non Démence" (NonDemented), a une précision élevée (1,00) mais un rappel légèrement inférieur (0,99). Cela signifie que le modèle se trompe rarement en classant d'autres classes comme "Non Démence", mais manque une petite fraction des cas "Non Démence" réels. Dans l'ensemble, ce rapport suggère une très bonne performance du modèle pour la classification de la démence.

IV.7.4 Résultats de tests de classification

La figure (IV.17) présente les résultats de tests de classification de la démence réalisés à l'aide du modèle proposé. Le test est effectué sur 16 images aléatoires de l'ensemble de tests, chacune correspondant à un cas de test individuel. Chaque résultat comporte :

- L'indication du diagnostic réel (Actual) du patient et la prédiction du modèle (Predicted). Les valeurs sont accompagnées d'un score de confiance (Confidence) exprimé en pourcentage.

En examinant les résultats des cas de test, on peut observer que le modèle proposé a correctement classé les patients dans tous les cas. Ces résultats démontrent que le modèle proposé est capable de classer avec précision les patients atteints de démence à partir d'images IRM de leur cerveau.

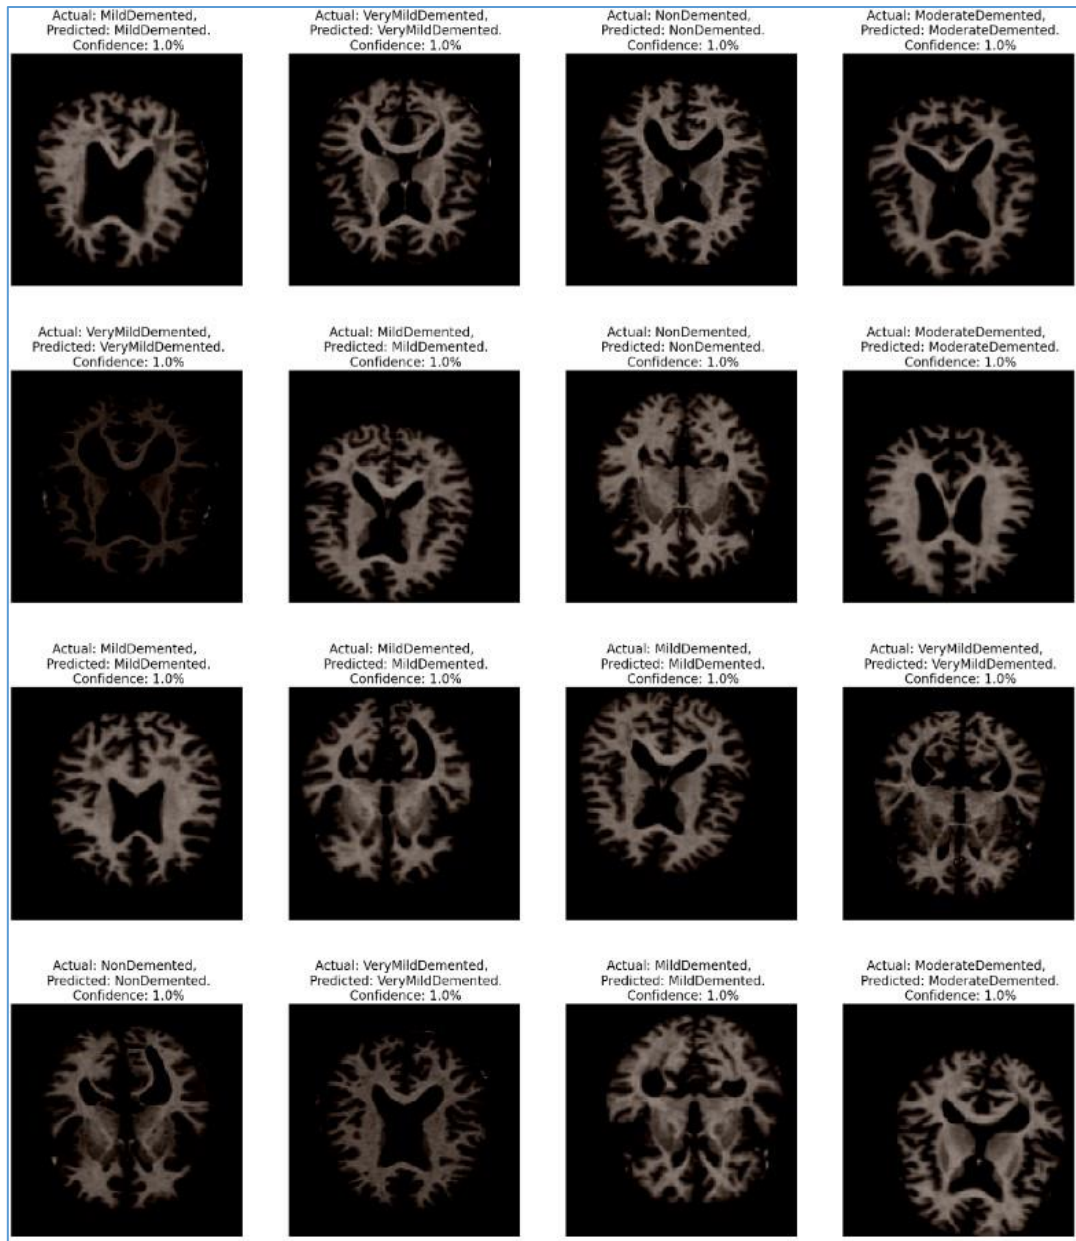


Figure IV.17 Résultats de test de classification en utilisant le modèle proposé

IV.7.5 Comparaison des résultats obtenus avec les variantes de ResNet et VGG

Afin de démontrer l'efficacité du modèle proposé, une comparaison est effectuée avec d'autres modèles établis. Pour garantir une comparaison équitable entre les différents modèles, l'évaluation a été réalisée en utilisant le même ensemble de données et les mêmes paramètres d'entraînement pour tous les modèles. Cette approche permet d'isoler les performances intrinsèques de chaque modèle et d'éliminer tout biais potentiel résultant de variations dans les données ou les paramètres d'apprentissage.

Modèle	Accuracy (%)	Précision (%)	Recall (%)	F1-score (%)	Temps d'entraînement pour chaque époque (second)
VGG-16	95.97	96.06	95.97	95.98	13
VGG-19	98.31	98.38	98.31	98.31	16
ResNet-50	94.47	94.43	94.47	94.49	16
ResNet-101	94.75	94.28	94.75	94.71	17
ResNet-152	95.13	94.88	95.13	95.12	17
ResNet-101 amélioré	99.17	99.76	99.71	99.71	53

Tableau IV.8 Comparaison des résultats obtenus avec les variantes de ResNet et VGG.

Le tableau (IV.8) compare les performances de classification de cinq modèles présentant les variantes de VGG (VGG-16 et VGG-19) et de ResNet (ResNet-50, ResNet-101 et ResNet-152) et le modèle proposé dans ce travail pour la détection de la maladie d'Alzheimer. Les modèles sont évalués selon cinq métriques : l'Accuracy, la précision (Precision), le rappel (Recall), le F1-score et le temps d'entraînement pour chaque époque.

Sur la base des résultats présentés dans le tableau (IV.8), tous les modèles étudiés semblent performants pour la classification de la maladie d'Alzheimer. Cependant, le modèle ResNet-101 amélioré se démarque des autres en obtenant des scores légèrement supérieurs sur les quatre métriques d'évaluation, on observe que le modèle ResNet-101 amélioré obtient les meilleurs résultats dans l'ensemble. Il atteint un score quasi parfait avec une précision de 99,71 %, une précision de 99,76 % et un score F1 de 99,71 %. Les autres modèles présentent également des performances élevées, avec des précisions et des rappels supérieurs à 94 %.

Le temps d'entraînement par époque est indiqué dans la dernière colonne du tableau (IV.8). Il est intéressant de noter que le temps d'entraînement est généralement plus long pour les modèles atteignant des performances plus élevées. Par exemple, le modèle ResNet-101 amélioré, qui obtient les meilleurs scores de précision, nécessite également le plus de temps d'entraînement par époque (53 secondes). En revanche, des modèles comme VGG-16 et ResNet-50 présentent des temps d'entraînement par époque beaucoup plus courts (respectivement 13 et 16 secondes). Cela suggère qu'il existe un compromis entre la précision du modèle et le temps de calcul nécessaire pour l'entraîner.

IV.7.6 Comparaison des résultats obtenus avec des travaux dans littérature

Le tableau (IV.9) compare la performance du modèle proposé avec des études publiées antérieurement. Les modèles sont évalués en fonction de quatre métriques : la précision (Accuracy), la précision (Precision), le rappel (Recall) et le score F1 (F1-score).

Etude	Année	Accuracy (%)	Précision (%)	Recall (%)	F1-score (%)
Murgan et al. [12]	2021	95.23	96	95	95.27
Mohammed et al. [13]	2021	94.80	—	93	—
Mostefaoui et Taleb [14]	2023	98.30	98.36	98.20	98.27
Modèle proposé	2024	99.17	99.76	99.71	99.71

Tableau IV.9 Comparaison du modèle proposé avec des études existantes.

En examinant le tableau, on constate que le modèle proposé affiche systématiquement des performances supérieures à celles des modèles de la littérature sur les quatre métriques. Le modèle proposé atteint une précision de 99,17 %, une précision de 99,76 %, un rappel de 99,71 % et un score F1 de 99,71 %. L'écart de performance le plus important est observé pour la précision, où le modèle proposé devance le deuxième meilleur modèle (Mostefaoui et Taleb, 2023) de près de 1,4 %.

IV.8 Conclusion

Dans ce chapitre, nous avons d'abord présenté les différents outils et langages utilisés pour implémenter notre code de classification. Ensuite, nous avons décrit notre modèle proposé pour la classification de la maladie d'Alzheimer, basé sur l'architecture ResNet-101. Nous avons présenté les résultats obtenus et les avons comparés à ceux de modèles établis et de travaux antérieurs publiés dans la littérature. Notre modèle a obtenu des performances élevées en termes de précision, de sensibilité et de score F1. Ces résultats démontrent la fiabilité du modèle proposé pour la détection des quatre stades de la maladie d'Alzheimer à partir de la base de données Kaggle. Cela suggère qu'il pourrait être utilisé comme un outil intelligent d'aide à la décision pour le diagnostic clinique de la maladie.

Références du chapitre IV

- [1] "Alzheimer's Dataset", Kaggle, <https://www.kaggle.com/datasets/tourist59/alzheimers-dataset-4-class-of-images>.
- [2] Boudali.A, Benchaib.A, « Détection précoce de la maladie d'Alzheimer sur les images IRM, Mémoire de master, Université Ibn KHaldoun, Tiaret, 2021/2022.
- [3] NENNOUCHE Mohamed et ATCHI Abdel Malek, « Fusion de caractéristiques pour la classification des différents niveaux de démence de la maladie d'Alzheimer », mémoire PFE, École nationale polytechnique, 2022.
- [4] Mohamed Abd Elmoumen DJABELLAH, « système de prédiction de la consommation d'énergie basé deep learning », mémoire de master, Université de 8 Mai 1945 -GUELMA-, septembre 2021.
- [5] Ait Hammou Hamza Korichi Badreddine, « Développements des mécanismes basés sur l'apprentissage automatique pour la gestion du trafic routier dans les intersections » mémoire de master, UNIVERSITE IBN KHALDOUN – TIARET, 2020-2021.
- [6] BELAID Boualem, « Prédiction des manifestations publiques à l'aide de réseaux de neurones artificiels », mémoire de master, Université de Mohamed El Bachir El Ibrahimi de Borj Bou Arréridj, 2020/2021.
- [7] AMEUR HMAIDA « Analyse des opinions basées sur l'apprentissage en profondeur » mémoire master, Université Mohamed Khider – BISKRA, 2020/2021.
- [8] <https://www.ionos.fr/digitalguide/web-marketing/search-engine-marketing/quest-ce-que-keras/>
- [9] <https://www.techopedia.com/definition/33860/scikit-learn>
- [10] Benali Khodja Khaoula & Guennaz Amel, « Analyse d'Images Médicales pour la Détection et le Suivi des Pathologies du Cerveau », Mémoire de Master, Université SAAD DAHLAB de BLIDA, 2021-2022.
- [11] Messaour Imane & uellil Yasmine, « Privacy-preserving classification », Mémoire de master, Université AMO de Bouira, 2021/2022.

[12] S. Murugan, C. Venkatesan, M. G. Sumithra, X. Z. Gao, B. Elakkiya *et al.*, “DEMNET: A deep learning model for early diagnosis of Alzheimer diseases and dementia from mrimages,” *IEEE Access*, vol. 9, pp. 90319–90329, 2021.

[13] B. A. Mohammed, E. M. Senan, T. H. Rassem, N. M. Makbol, A. A. Alanazi *et al.*, “Multimethod analysis of medical records and mri images for early diagnosis of dementia and Alzheimer’s disease based on deep learning and hybrid methods,” *Electronics*, vol. 10, pp. 120, 2021.

[14] Fatima Zahra Mostefaoui et Nawal Taleb, « Détection et classification de la maladie d’Alzheimer à l’aide de deep learning », mémoire de master, UNIVERSITE HASSIBA BENBOUALI DE CHLEF, Juin 2023.

Conclusion

générale

Conclusion générale

Ces dernières années, l'intérêt des chercheurs pour l'apprentissage profond et ses modèles n'a cessé de croître, notamment pour la classification des images médicales et la segmentation des images cérébrales, dans le but de faciliter le diagnostic des maladies, en particulier celles affectant le cerveau. Dans notre étude, nous avons visé à classifier la maladie d'Alzheimer en utilisant des images IRM du cerveau et en appliquant l'apprentissage profond, plus précisément les réseaux de neurones convolutionnels (CNN).

Notre étude explore un modèle proposé pour la classification de la maladie d'Alzheimer, basé sur l'architecture ResNet-101. Le modèle proposé a obtenu des performances élevées en termes de précision, de sensibilité et de score F1, démontrant sa fiabilité dans la détection des quatre stades de la maladie d'Alzheimer à partir d'images IRM. Ces résultats surpassent ceux de modèles établis et de travaux antérieurs publiés dans la littérature, soulignant l'efficacité du modèle proposé. Ces performances suggèrent que le modèle pourrait être utilisé comme un outil d'aide à la décision intelligent pour le diagnostic clinique de la maladie d'Alzheimer.

L'implémentation a été réalisée en Python en utilisant des bibliothèques pour faciliter le développement et l'entraînement sur Google Colab avec GPU. Ces résultats ouvrent la voie à de futures recherches sur l'utilisation de CNN pour le diagnostic de la maladie d'Alzheimer, notamment dans le cadre d'applications en temps réel ou en utilisant des modèles pré-entraînés.