



جامعة ابن طفيل
+oΘΛΠΣ+ ΣΘΙ ΕΞΗoΠ
Ibn Tofaïl University
Faculté des Sciences

Université Ibn Tofail
Faculté des Sciences, Kénitra
Mémoire de Projet de Fin d'Etudes
Master Intelligence Artificielle et Réalité Virtuelle

Représentation d'Images Médicales 3D pour le Diagnostic Assisté par Ordinateur

Établissement d'accueil : Institut de recherche Xlim, Université de Poitiers, France

Elaboré par : Mr. EL AFIA Mohamed

Encadré par : Mme. BEN AHMED Olfa (Xlim -Université de Poitiers)

Mr. NOURI Anass (Faculté des Science -UIT)

Soutenu le 24/09/2024, devant le jury composé de :

- *Mme* TOUAHNI Raja FS Kenitra (UIT)
- *Mme* EDDAROUICH Souad CRMEF Rabat
- *Mr* NOURI Anass FS Kenitra (UIT)
- *Mr* MESSOUSSI Rochdi FS Kenitra (UIT)
- *Mr* MOUMEN Idriss FS Kenitra (UIT)

Remerciements

Je tiens à exprimer ma profonde gratitude envers toutes les personnes qui m'ont accompagné et soutenu tout au long de ce projet de fin d'études, qui marque l'achèvement de mon Master en Intelligence Artificielle et Réalité Virtuelle.

Je commence par remercier Dieu, le tout-puissant, pour les innombrables bénédictions déversées tout au long de mon parcours académique et pour la force et la persévérance qu'Il m'a accordées.

Je suis particulièrement reconnaissant envers **Mme. Olfa Ben Ahmed**, mon encadrante de stage, pour sa précieuse guidance, ses conseils éclairés et son soutien inestimable tout au long de cette expérience enrichissante. Sa patience et son expertise ont été des atouts majeurs dans la réalisation de ce projet.

Je souhaite également exprimer ma gratitude à **M. Anass Nouri**, mon encadrant académique, dont les directives précises et l'encouragement constant m'ont aidé à mener à bien mes recherches et à affiner mon travail.

Mes remerciements vont aussi à toute l'équipe pédagogique du Master en Intelligence Artificielle et Réalité Virtuelle ainsi qu'à tous mes professeurs pour leur enseignement rigoureux et leur disponibilité. Leur contribution à ma formation a été essentielle et m'a préparé à relever les défis professionnels futurs.

Enfin, je remercie ma famille, mes amis et tous ceux qui m'ont encouragé et appuyé. Leur soutien moral a été un pilier dans mon parcours, et cette réussite est aussi la leur.

Dédicace

À celle qui s'est sacrifiée pour nous, qui nous a donné de son sang, de son âme et de sa vie avec amour. À celui qui a toujours été un pilier de soutien et d'amour inconditionnel, qui ont planté en nous l'amour du science et du savoir.

Ma chère mère et mon cher père.

À ceux dont la présence complète ma joie et qui m'ont toujours soutenu.

mes chères sœurs et mes chers frères.

À mes estimés professeurs, phare de la connaissance et des savants, et à mes chers amis, compagnons du chemin de la science et du savoir , qui n'ont jamais hésité à me tendre la main...

Votre soutien et votre amour m'ont porté jusqu'ici.

Introduction Générale

Dans le cadre de l'obtention du diplôme de Master en Intelligence Artificielle et Réalité Virtuelle, j'ai eu l'opportunité de réaliser mon stage de fin d'études au sein du laboratoire de recherche XLIM de l'Université de Poitiers, en France. Ce stage, qui s'inscrit dans un domaine en pleine expansion, vise à répondre à des problématiques scientifiques concrètes tout en exploitant les avancées récentes dans les domaines de l'intelligence artificielle, du traitement d'images et de l'apprentissage automatique.

Contexte du Stage

L'imagerie médicale constitue un enjeu majeur dans le diagnostic et la prise en charge des maladies neurologiques, notamment la maladie d'Alzheimer (MA). Avec l'accroissement de la population vieillissante, le nombre de cas diagnostiqués de la maladie d'Alzheimer ne cesse d'augmenter, rendant nécessaire le développement de méthodes automatiques et assistées par ordinateur pour améliorer la détection précoce et la classification des différentes phases de cette pathologie. L'utilisation des images médicales IRM dans ce contexte offre un potentiel considérable, notamment à travers l'analyse automatisée des données grâce à l'intelligence artificielle.

Le laboratoire XLIM, où j'ai réalisé ce stage, est spécialisé dans plusieurs domaines de pointe, incluant l'imagerie médicale, la modélisation et l'intelligence artificielle. Son objectif est de développer des technologies innovantes pour l'aide au diagnostic assisté par ordinateur (CAD), notamment dans le traitement et la représentation des images 3D médicales.

Problématique

L'identification précoce des signes avant-coureurs de la maladie d'Alzheimer est cruciale pour une prise en charge adéquate. Les images d'IRM, qui permettent de visualiser l'atrophie cérébrale associée à la MA, sont couramment utilisées dans ce cadre. Cependant, l'analyse manuelle de ces images par les radiologues est un processus long, fastidieux et sujet à des variations inter-experts.

La problématique principale de ce projet de fin d'études est donc la suivante : *comment développer des outils d'apprentissage automatique capables de représenter et de classifier efficacement les images IRM pour assister le diagnostic de la maladie d'Alzheimer et différencier ses différents stades (normal cognition, MCI, AD) ?* Cette problématique soulève plusieurs défis, notamment la sélection de caractéristiques pertinentes à partir d'images 3D, l'utilisation de techniques d'apprentissage profond adaptées et la gestion des volumes importants de données médicales.

Objectifs du Projet

L'objectif principal de ce projet est de proposer un modèle de représentation d'images médicales 3D pour l'aide au diagnostic de la maladie d'Alzheimer, en exploitant des techniques d'apprentissage automatique. Plus précisément, le projet se décline en plusieurs sous-objectifs :

- **Extraction et prétraitement des données IRM** : Collecter des images IRM à partir de bases de données existantes, telles que l'ADNI, et effectuer les étapes de prétraitement indispensables (normalisation, segmentation, sélection des tranches pertinentes).
- **Apprentissage supervisé** : Utiliser des modèles d'apprentissage automatique, en particulier des réseaux de neurones convolutifs (CNN), pour extraire automatiquement les caractéristiques importantes des images médicales et les utiliser pour la classification.
- **Classification multimodale** : Classifier les images en trois groupes (NC, MCI, AD) en utilisant des algorithmes d'apprentissage automatique tels que RandomForest et XG-Boost.
- **Validation des résultats** : Comparer les performances des différents modèles de classification et proposer des améliorations basées sur l'apprentissage par transfert et d'autres approches.

L'Organisme d'Accueil : Le Laboratoire XLIM

Le laboratoire XLIM (Laboratoire de Recherche en Informatique, Image et Interaction) de l'Université de Poitiers est une structure de recherche reconnue au niveau international pour ses travaux dans divers domaines, notamment l'imagerie médicale, l'électronique et les télécommunications. XLIM regroupe plusieurs équipes pluridisciplinaires et collabore avec des partenaires académiques et industriels.

Mon travail au sein de ce laboratoire s'inscrit dans le cadre de la collaboration avec l'équipe d'imagerie médicale, avec un accent particulier sur l'analyse des données d'imagerie IRM pour des applications cliniques. La supervision de mon stage a été assurée par **Mme Olfa Ben Ahmed**, spécialiste en imagerie médicale, et **M. Anass Nouri**, qui m'a guidé dans les aspects théoriques et méthodologiques de l'apprentissage automatique appliqué à l'imagerie.

Organisation du Rapport

Ce rapport de projet de fin d'études est structuré de la manière suivante :

- **Chapitre 1** : Présentation de la maladie d'Alzheimer, son évolution clinique et les méthodes de diagnostic couramment utilisées, notamment l'imagerie par résonance magnétique (IRM).
- **Chapitre 2** : Revue de l'état de l'art des méthodes d'apprentissage profond appliquées à l'analyse des images médicales, avec un focus sur les architectures CNN, les méthodes d'extraction des caractéristiques et les approches d'apprentissage par transfert.
- **Chapitre 3** : Description du processus de collecte et de prétraitement des données, en détaillant les étapes de normalisation, de segmentation, et de sélection des tranches les plus pertinentes.

- **Chapitre 4** : Présentation des résultats obtenus à partir des modèles d'apprentissage automatique appliqués aux images IRM, suivie d'une discussion sur les performances et les perspectives d'amélioration.
- **Chapitre 5** : Conclusion et perspectives de travaux futurs.

Table des matières

Remerciements	1
Dédicace	2
Introduction Générale	3
1 La maladie d'Alzheimer	13
1.1 Introduction	13
1.2 Définition et Histoire de la maladie	13
1.3 Statistiques	13
1.4 Évolution de la MA	14
1.4.1 Évolution clinique de la MA	14
1.4.2 Évolution anatomique de la MA : l'atrophie cérébrale	15
1.5 Diagnostic de la Maladie d'Alzheimer	16
1.5.1 Évaluation neuropsychologique	16
1.5.2 L'imagerie cérébrale	16
1.5.3 Tests biologiques et biomarqueurs	17
1.5.4 Biomarqueurs Sanguins	17
1.6 IRM dans le diagnostic de la maladie d'Alzheimer	17
1.6.1 Technique de l'IRM	17
1.6.2 Reconstructions multiplanaires (MPR)	18
1.6.3 IRM et mesure de l'atrophie cérébrale dans la maladie d'Alzheimer	18
1.7 Conclusion	19
2 État de l'art	20
2.1 Introduction	20
2.2 Architectures d'apprentissage profond pour l'analyse des images médicales	20
2.2.1 Convolutional Neural Networks (CNN)	20
2.2.2 ResNet50	20
2.2.3 InceptionV3	21
2.3 Approches d'extraction des caractéristiques pour l'analyse des images IRM par ordinateur	21
2.3.1 Méthodes d'extraction des caractéristiques par ResNet50	21
2.3.2 Méthodes d'extraction des caractéristiques par InceptionV3	22
2.3.3 Méthodes d'agrégation des caractéristiques pour l'analyse des images	22
2.3.4 Méthode d'Agrégation SPoC	22
2.3.5 Global Average Pooling (GAP)	23

2.3.6	Algorithmes de classification	23
2.4	Apprentissage par Transfert	24
2.5	Conclusion	25
3	Collecte et Prétraitement des Données	26
3.1	Introduction	26
3.2	Collection des Données	26
3.2.1	Description de l'ADNI " Alzheimer's disease Neuroimaging Initiative "	26
3.2.2	Téléchargement des images et définition du format NIFTI	28
3.2.3	Caractéristiques des images téléchargées	28
3.2.4	Composition des groupes et caractéristiques démographiques	29
3.2.5	Organisation du jeu de données	29
3.3	Prétraitement des Données	30
3.3.1	Définition de FSLeys	30
3.3.2	Normalisation des données	30
3.3.3	Segmentation des images	32
3.3.4	Sélection des tranches importantes du cerveau pour l'aide au diagnostic	33
3.4	Conclusion	34
4	Résultats et Discussion	35
4.1	Introduction	35
4.2	Extraction des caractéristiques et Méthodologie	35
4.2.1	Méthode ResNet	35
4.2.2	Méthode InceptionV3	35
4.3	Agrégation des caractéristiques avec Global Average Pooling	35
4.4	Classification Multimodale AD/NC/MCI	36
4.4.1	Classification avec Random Forest après Extraction des Features par ResNet50	36
4.4.2	Classification avec Random Forest après Extraction des Features par InceptionV3	37
4.4.3	Classification avec XGBoost après Extraction des Features par ResNet50	38
4.4.4	Classification avec XGBoost après Extraction des Features par InceptionV3	39
4.5	Comparaison des Performances Multimodales (ResNet50, InceptionV3)	40
4.5.1	Comparaison des performances avec Random Forest et XGBoost	40
4.5.2	Analyse des performances	41
4.5.3	Conclusion	41
4.6	Classification Binaire (AD/NC, AD/MCI, NC/MCI)	42
4.6.1	Classification avec Random Forest après Extraction des Features par ResNet50	42
4.6.2	Classification avec XGBoost après Extraction des Features par ResNet50	45
4.6.3	Classification avec Random Forest après Extraction des Features par InceptionV3	48
4.6.4	Classification avec XGBoost après Extraction des Features par InceptionV3	51
4.6.5	Comparaison des Performances Binaires (ResNet, InceptionV3)	54
4.7	Comparaison des Performances Binaires (ResNet50 vs InceptionV3)	54
4.7.1	Tableau comparatif des performances	54

4.7.2	Analyse des performances	54
4.8	Limitation et Perspectives	55
4.8.1	Limitations	55
4.8.2	Perspectives	55
4.8.3	Conclusion	55

Conclusion		56
-------------------	--	-----------

Table des figures

1.1	Histoire naturelle de la MA symptomatique.	14
1.2	Comparaison entre un cerveau sain (à gauche) et un cerveau atteint de la maladie d'Alzheimer (à droite).	16
1.3	Volume obtenu à partir d'une acquisition sur le crâne en IRM avec pondération T1. Ce volume permet d'analyser les structures cérébrales dans les trois plans de l'espace.	18
1.4	IRM cérébrale pour le diagnostic de la maladie d'Alzheimer. Les flèches indiquent la localisation des hippocampes. (A) Cerveau sain : absence d'atrophie hippocampique. (B) Patient Alzheimer : atrophie bilatérale des hippocampes.	19
2.1	L'architecture du model ResNet50.Medium	21
2.2	L'architecture du model Inception-V3.[30]	21
2.3	Schéma du Transfer Learning	24
3.1	Distribution des participants de l'étude ADNI par âge, groupe de recherche et genre	27
3.2	Image cérébrale avant la normalisation.	31
3.3	Image cérébrale après la normalisation.	32
3.4	Image cérébrale après enlèvement du crâne.	33
4.1	Matrice de confusion pour Random Forest après extraction des features avec ResNet50	36
4.2	Matrice de confusion pour Random Forest après extraction des features avec InceptionV3	38
4.3	Matrice de confusion pour XGBoost après extraction des features avec ResNet50	39
4.4	Matrice de confusion pour XGBoost après extraction des features avec InceptionV3	40
4.5	Matrice de confusion pour Random Forest sur CN vs MCI après extraction des features avec ResNet50	42
4.6	Matrice de confusion pour Random Forest sur AD vs MCI après extraction des features avec ResNet50	43
4.7	Matrice de confusion pour Random Forest sur AD vs CN après extraction des features avec ResNet50	44
4.8	Matrice de confusion pour XGBoost sur CN vs MCI après extraction des features avec ResNet50	45
4.9	Matrice de confusion pour XGBoost sur AD vs MCI après extraction des features avec ResNet50	46
4.10	Matrice de confusion pour XGBoost sur AD vs CN après extraction des features avec ResNet50	47

4.11	Matrice de confusion pour Random Forest sur CN vs MCI après extraction des features avec InceptionV3	48
4.12	Matrice de confusion pour Random Forest sur AD vs MCI après extraction des features avec InceptionV3	49
4.13	Matrice de confusion pour Random Forest sur AD vs CN après extraction des features avec InceptionV3	50
4.14	Matrice de confusion pour XGBoost sur CN vs MCI après extraction des features avec InceptionV3	51
4.15	Matrice de confusion pour XGBoost sur AD vs MCI après extraction des features avec InceptionV3	52
4.16	Matrice de confusion pour XGBoost sur AD vs CN après extraction des features avec InceptionV3	53

Liste des tableaux

3.1	Caractéristiques démographiques des groupes d'étude (avec âges entre 65 et 85 ans)	29
4.1	Rapport de classification pour Random Forest après extraction des features avec ResNet50	36
4.2	Rapport de classification pour Random Forest après extraction des features avec InceptionV3	37
4.3	Rapport de classification pour XGBoost après extraction des features avec ResNet50	38
4.4	Rapport de classification pour XGBoost après extraction des features avec InceptionV3	39
4.5	Comparaison des performances multimodales (ResNet50 vs InceptionV3) avec Random Forest et XGBoost pour la classification AD/NC/MCI.	41
4.6	Rapport de classification pour Random Forest sur CN vs MCI après extraction des features avec ResNet50	42
4.7	Rapport de classification pour Random Forest sur AD vs MCI après extraction des features avec ResNet50	43
4.8	Rapport de classification pour Random Forest sur AD vs CN après extraction des features avec ResNet50	44
4.9	Rapport de classification pour XGBoost sur CN vs MCI après extraction des features avec ResNet50	45
4.10	Rapport de classification pour XGBoost sur AD vs MCI après extraction des features avec ResNet50	46
4.11	Rapport de classification pour XGBoost sur AD vs CN après extraction des features avec ResNet50	47
4.12	Rapport de classification pour Random Forest sur CN vs MCI après extraction des features avec InceptionV3	48
4.13	Rapport de classification pour Random Forest sur AD vs MCI après extraction des features avec InceptionV3	49
4.14	Rapport de classification pour Random Forest sur AD vs CN après extraction des features avec InceptionV3	50
4.15	Rapport de classification pour XGBoost sur CN vs MCI après extraction des features avec InceptionV3	51
4.16	Rapport de classification pour XGBoost sur AD vs MCI après extraction des features avec InceptionV3	52
4.17	Rapport de classification pour XGBoost sur AD vs CN après extraction des features avec InceptionV3	53

4.18	Comparaison des performances binaires (ResNet50 vs InceptionV3) avec Random Forest et XGBoost pour les classifications AD/NC, AD/MCI, et NC/MCI. . . .	54
------	--	----

Chapitre 1

La maladie d'Alzheimer

1.1 Introduction

Ce chapitre est consacré à la maladie d'Alzheimer (MA), la forme la plus courante de démence, touchant des millions de personnes dans le monde. Nous aborderons tout d'abord l'histoire et la définition de cette pathologie. Ensuite, des statistiques mondiales permettront de souligner l'ampleur croissante de la maladie, suivies d'une exploration détaillée de l'évolution clinique et anatomique de la MA, ainsi que des différentes phases de sa progression. Enfin, nous décrirons les méthodes actuelles de diagnostic, avec une attention particulière portée à l'imagerie par résonance magnétique (IRM), qui joue un rôle central dans l'évaluation des signes visibles de la maladie. L'objectif est de fournir une vue d'ensemble complète, allant des aspects historiques aux approches modernes de diagnostic, tout en mettant en lumière l'importance d'une prise en charge précoce et adéquate.

1.2 Définition et Histoire de la maladie

Le Dr Aloïs Alzheimer, un psychiatre et neuropathologiste allemand, a identifié la maladie qui porte désormais son nom en 1906 en étudiant le cas d'Auguste Deter, une femme présentant des troubles confusionnels et une perte de mémoire progressive. Il décrit la maladie comme une affection grave du cortex cérébral. Cliniquement, la maladie d'Alzheimer (MA) est une pathologie neurodégénérative entraînant des perturbations de la mémoire et des fonctions cognitives, souvent accompagnées de troubles comportementaux ou psychologiques, évoluant vers une perte d'autonomie [1]. Elle constitue la forme la plus courante de démence, représentant environ 70% des cas, selon l'Organisation Mondiale de la Santé, qui définit la démence comme un syndrome altérant significativement les fonctions cognitives au-delà des effets normaux du vieillissement. D'autres formes de démence incluent la démence vasculaire, la démence à corps de Lewy et la démence fronto-temporale[2].

1.3 Statistiques

Selon le Rapport Mondial sur l'Alzheimer de 2023, environ 50 millions de personnes étaient atteintes de démence dans le monde en 2020. Ce chiffre est projeté pour presque tripler d'ici 2050, la MA représentant la majorité de ces cas. Selon les principales études internationales, la MA toucherait environ 0,5% des personnes de moins de 65 ans et entre 2 et 4% de plus après 65

ans. Au-delà de 80 ans, ce pourcentage atteindrait 15%. Ces statistiques soulignent l'ampleur croissante du défi que la MA pose aux systèmes de santé mondiaux et mettent en lumière l'importance de poursuivre les efforts de recherche et d'intervention pour gérer cette épidémie en expansion[3].

1.4 Évolution de la MA

La MA évolue à travers plusieurs stades qui peuvent être observés de différentes manières : clinique (symptômes visibles), anatomique (changements dans le cerveau), neuropsychologique, biomarqueurs, génétique, et fonctionnelle. Chaque aspect permet d'évaluer l'évolution de la maladie. Nous allons d'abord nous concentrer sur deux de ces aspects : le stade clinique, qui montre les symptômes visibles chez les patients, et le stade anatomique, qui reflète les changements structurels dans le cerveau[4].

1.4.1 Évolution clinique de la MA

L'évolution clinique de la MA peut être suivie en fonction du nombre d'années écoulées depuis l'apparition des premiers symptômes, et est mesurée à l'aide du Mini-Mental State Examination (MMSE), un test évaluant les capacités cognitives des patients. Le score maximum au MMSE est de 30, un score élevé reflète des fonctions cognitives normales, tandis qu'un score bas indique une détérioration cognitive plus importante[6]. La figure 1.4 illustre les différentes phases de la progression symptomatique de la MA.

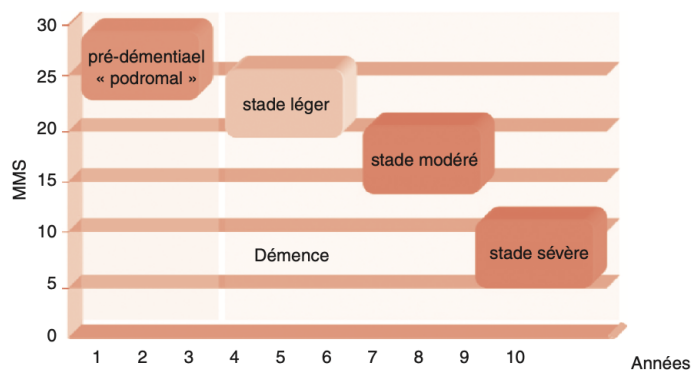


FIGURE 1.1 – Histoire naturelle de la MA symptomatique. [5]

Avant l'apparition des trois phases cliniques bien établies (légère, modérée, et sévère), une phase préliminaire, appelée phase prodromale ou trouble cognitif léger, se manifeste. À ce stade, le score MMSE est encore relativement élevé (autour de 25-30), et les symptômes cognitifs sont légers, souvent confondus avec les effets normaux du vieillissement. Le patient peut éprouver des pertes de mémoire occasionnelles ou des difficultés de concentration, mais ces signes passent souvent inaperçus.

La MA se caractérise par une progression en trois phases principales, correspondant à différents niveaux de détérioration cognitive [7][8] :

- **NC (Normal Cognitive)** : Ce terme fait référence aux personnes présentant une cognition normale, sans altération notable de la mémoire ou des capacités cognitives.

- **MCI (Mild Cognitive Impairment)** : Le stade de trouble cognitif léger (MCI) survient généralement avant l'apparition de la démence caractéristique de la maladie d'Alzheimer. À ce stade, les patients montrent des signes de déclin cognitif, mais conservent encore une relative indépendance pour les activités quotidiennes. Cependant, cette phase peut évoluer vers une démence plus sévère.
- **AD (Alzheimer's Disease)** : Il s'agit du stade où la maladie d'Alzheimer est pleinement développée, et qui peut être divisé en plusieurs sous-stades de progression :
 - **Stade léger (années 4 à 6)** : Le score MMSE diminue progressivement, atteignant environ 20. Les symptômes deviennent plus visibles, avec des troubles de la mémoire, des difficultés dans les tâches quotidiennes, et des problèmes d'orientation spatio-temporelle.
 - **Stade modéré (années 7 à 9)** : Au stade modéré, la maladie progresse plus rapidement. Le score MMSE chute entre 10 et 15. Le patient présente des troubles cognitifs importants, affectant gravement la mémoire, les fonctions exécutives, et la capacité de communication. L'individu devient de plus en plus dépendant pour les activités de la vie quotidienne.
 - **Stade sévère (années 9 à 10 et plus)** : À ce stade avancé, le score MMSE est inférieur à 10. Les patients sont gravement atteints, souvent incapables de reconnaître leurs proches, de parler ou de se rappeler des événements importants. Une aide constante est nécessaire pour les tâches de base.

1.4.2 Évolution anatomique de la MA : l'atrophie cérébrale

Sur le plan anatomique, la maladie d'Alzheimer est associée à une atrophie cérébrale progressive. Ce processus implique une réduction du volume cérébral et se manifeste par la perte des neurones dans différentes régions du cerveau[9].

- **Atrophie dans la phase précoce** : L'atrophie est limitée à des zones spécifiques, notamment l'hippocampe, responsable de la mémoire. À ce stade, les symptômes cliniques sont encore modérés.
- **Atrophie au stade modéré** : L'atrophie s'étend au cortex cérébral, affectant les régions responsables de la pensée, du langage et du raisonnement. Cela coïncide avec une aggravation des symptômes cliniques.
- **Atrophie au stade sévère** : Le cerveau subit un rétrécissement généralisé. Les zones corticales sont gravement touchées, entraînant une perte presque totale des fonctions cognitives et une dépendance complète.




FIGURE 1.2 – Comparaison entre un cerveau sain (à gauche) et un cerveau atteint de la maladie d’Alzheimer (à droite).

La figure 1.2 illustre clairement les effets de l’atrophie cérébrale causée par la maladie d’Alzheimer. À gauche, nous voyons un cerveau sain, avec des volumes cérébraux normaux et une structure bien conservée. À droite, le cerveau atteint de la maladie d’Alzheimer montre un rétrécissement important (atrophie). Cette réduction de la masse cérébrale est l’un des signes les plus visibles de l’impact de la maladie. L’atrophie cérébrale est l’un des principaux marqueurs visibles de l’évolution anatomique de la maladie et reflète directement la perte progressive des fonctions cognitives observée chez les patients.

1.5 Diagnostic de la Maladie d’Alzheimer

Le diagnostic de la maladie d’Alzheimer est un processus complexe qui s’appuie sur plusieurs techniques avancées. Parmi les approches les plus couramment utilisées, on trouve une combinaison d’évaluation neuropsychologique, de l’imagerie cérébrale, et de biomarqueurs analysés via des tests de fluides corporels et de sang. Ces méthodes sont essentielles pour identifier les signes précoces de la maladie et pour suivre l’évolution de ses effets sur le cerveau[10].

1.5.1 Évaluation neuropsychologique

Ces évaluations sont cruciales pour mesurer l’atteinte de la mémoire ainsi que d’autres fonctions cognitives, éléments essentiels dans le diagnostic de la maladie d’Alzheimer. Le test neuropsychologique le plus connu est le **Mini-Mental State Examination (MMSE)**, qui évalue la gravité des troubles cognitifs à travers un score maximum de 30 points. Un score faible reflète une détérioration plus marquée des fonctions cognitives [11].

1.5.2 L’imagerie cérébrale

Des techniques telles que l’Imagerie par Résonance Magnétique (IRM) et la Tomographie par Émission de Positrons (TEP) sont utilisées pour identifier les changements dans le cerveau associés à Alzheimer, tels que les plaques amyloïdes et les enchevêtrements neurofibrillaires. Une attention particulière sera accordée ultérieurement à la méthode de l’IRM, en explorant en détail son rôle et son efficacité dans le diagnostic de la maladie d’Alzheimer[12].

1.5.3 Tests biologiques et biomarqueurs

Les biomarqueurs dans le liquide céphalo-rachidien sont devenus une norme pour détecter les changements pathologiques précoces, mesurant des protéines comme l'amyloïde-bêta et la tau, indicatives de la pathologie d'Alzheimer [13].

1.5.4 Biomarqueurs Sanguins

L'utilisation de biomarqueurs sanguins, moins invasifs et moins coûteux, est en augmentation. Ils deviennent populaires pour détecter les stades précoces d'Alzheimer, avec une efficacité parfois comparable aux tests de LCR pour identifier les pathologies amyloïde et tau [14].

1.6 IRM dans le diagnostic de la maladie d'Alzheimer

1.6.1 Technique de l'IRM

L'imagerie par résonance magnétique (IRM) est une technique non invasive utilisée en médecine pour visualiser les structures internes du corps humain. Elle repose sur les propriétés des atomes d'hydrogène présents dans l'organisme. Voici comment fonctionne cette méthode :

Résonance magnétique : Lorsqu'un patient est placé dans un scanner IRM, il est exposé à un champ magnétique puissant et statique. Ce champ aligne les noyaux d'hydrogène présents en grande quantité dans le corps, en particulier dans l'eau (H_2O), selon la direction du champ magnétique[15].

Impulsions radiofréquence : Ensuite, des impulsions de radiofréquence sont envoyées dans ce champ, provoquant le basculement des noyaux d'hydrogène hors de leur alignement initial. Après excitation par les impulsions radiofréquence, les noyaux d'hydrogène retournent progressivement à leur état d'origine. Pendant ce processus, ils émettent des signaux détectables, dont la durée de relaxation varie en fonction du type de tissu, ce qui permet de distinguer différentes structures[16].

Acquisition des données : Le scanner IRM capte ces signaux émis par les noyaux d'hydrogène et les convertit en images à l'aide d'un ordinateur.

Création d'images : L'ordinateur génère ensuite des images tridimensionnelles des structures internes en fonction des signaux détectés. Selon la séquence des impulsions radiofréquence, différents types d'images peuvent être produits, tels que des images pondérées en densité protonique, en T1, en T2, ou encore en diffusion[17].

T1 : une séquence d'imagerie IRM dans laquelle les tissus riches en eau, tels que le liquide céphalo-rachidien (LCR), apparaissent en noir, tandis que les tissus comme la matière grise apparaissent en blanc.

T2 : une séquence d'imagerie IRM dans laquelle les tissus riches en eau apparaissent en blanc, tandis que les tissus comme la matière blanche apparaissent en noir.

1.6.2 Reconstructions multiplanaires (MPR)

L'IRM permet d'acquérir des images dans les trois plans de l'espace (axial, coronal, sagittal). Ces reconstructions multiplanaires (Multiplanar Reconstruction, MPR) permettent une analyse détaillée des structures cérébrales dans des vues perpendiculaires ou parallèles à chaque plan. La qualité des MPR dépend de la résolution spatiale longitudinale (c'est-à-dire perpendiculaire au plan de coupe). Une meilleure qualité est obtenue lorsque l'épaisseur des voxels et l'écart entre les coupes sont faibles. Un volume isotrope, avec une résolution égale sur les trois axes (ou voxel cubique), produit les meilleurs résultats. Cela est particulièrement important pour des applications comme l'analyse des structures cérébrales dans le contexte de la maladie d'Alzheimer[18].




FIGURE 1.3 – Volume obtenu à partir d'une acquisition sur le crâne en IRM avec pondération T1. Ce volume permet d'analyser les structures cérébrales dans les trois plans de l'espace.

1.6.3 IRM et mesure de l'atrophie cérébrale dans la maladie d'Alzheimer

L'IRM est un outil clé dans l'évaluation des régions cérébrales afin de détecter l'atrophie associée à la maladie d'Alzheimer (MA). L'atrophie de l'hippocampe, région essentielle pour la mémoire, est un marqueur important de la MA, comme l'ont montré plusieurs études, notamment celles de Frisoni et al.[19]. Dubois et al.[20] ont également démontré que la mesure de l'atrophie hippocampique par IRM peut aider à prévoir la progression de la maladie. L'hippocampe subit une réduction significative de sa taille et de son volume à mesure que la maladie progresse. Cette atrophie est souvent corrélée à une évolution rapide de la maladie et à une détérioration cognitive sévère.

Cependant, l'atrophie hippocampique détectée par l'IRM n'est pas un biomarqueur précoce, car elle n'apparaît qu'à des stades avancés de la maladie. Cela souligne l'importance de la recherche sur de nouveaux biomarqueurs pour améliorer la prise en charge clinique et les traitements thérapeutiques.




FIGURE 1.4 – IRM cérébrale pour le diagnostic de la maladie d’Alzheimer. Les flèches indiquent la localisation des hippocampes. (A) Cerveau sain : absence d’atrophie hippocampique. (B) Patient Alzheimer : atrophie bilatérale des hippocampes.

En conclusion, bien que l’IRM soit un outil performant pour la détection de l’atrophie hippocampique dans la MA, elle doit être complétée par d’autres approches pour améliorer la précision du diagnostic précoce et optimiser les traitements.

1.7 Conclusion

À travers ce chapitre, nous avons exploré la maladie d’Alzheimer sous plusieurs angles : son histoire, son évolution clinique et anatomique, ainsi que les méthodes de diagnostic qui sont utilisées pour détecter et suivre la progression de cette pathologie neurodégénérative. L’importance de la recherche sur cette maladie, qui touche principalement les personnes âgées, est soulignée par les statistiques alarmantes qui projettent une augmentation significative du nombre de cas dans les décennies à venir. L’utilisation de technologies avancées, telles que l’IRM, permet de mieux comprendre les mécanismes sous-jacents de l’atrophie cérébrale et d’améliorer les capacités de diagnostic.

Chapitre 2

État de l'art

2.1 Introduction

L'analyse des images médicales par apprentissage profond a connu un développement rapide ces dernières années, transformant de nombreuses pratiques dans le domaine de la santé. Les architectures de réseaux de neurones convolutifs se sont imposées comme des outils puissants pour l'extraction automatique de caractéristiques à partir d'images complexes. Ce chapitre présente un tour d'horizon des méthodes et algorithmes majeurs utilisés dans l'analyse des images médicales, et précisément les architectures CNN, telles que ResNet50 et InceptionV3, qui ont démontré leur efficacité dans divers domaines de la vision par ordinateur. Nous explorons également les approches d'extraction des caractéristiques, notamment les méthodes d'agrégation comme SPoC et GAP. Enfin, nous aborderons des techniques avancées comme l'apprentissage par transfert, particulièrement utiles dans les contextes où les données médicales sont limitées.

2.2 Architectures d'apprentissage profond pour l'analyse des images médicales

2.2.1 Convolutional Neural Networks (CNN)

Un réseau de neurones convolutifs (CNN) est un modèle d'apprentissage profond qui applique des filtres (ou noyaux) à des entrées pour apprendre des caractéristiques hiérarchiques. Contrairement aux réseaux de neurones traditionnels, les CNN exploitent la structure spatiale des données, ce qui leur permet de capturer efficacement les dépendances locales dans les images.

2.2.2 ResNet50

ResNet50 est une architecture de CNN qui a été introduite en 2015 par Kaiming He et ses collègues [29] dans le cadre de la recherche sur l'apprentissage profond. Cette architecture se distingue par sa capacité à former des réseaux très profonds, composés de 50 couches, tout en atténuant le problème de la dégradation des performances qui survient souvent dans les réseaux plus profonds. ResNet50 utilise des blocs résiduels, qui intègrent des connexions de contournement (skip connections), permettant au gradient de circuler plus efficacement lors de la rétropropagation. Cela facilite l'apprentissage en préservant les informations des couches

précédentes, ce qui est crucial pour la reconnaissance d'images complexes. Grâce à cette approche, ResNet50 a atteint des performances remarquables sur des ensembles de données tels qu'ImageNet, affichant un taux d'erreur de seulement 3,57% lors du défi ILSVRC 2015.

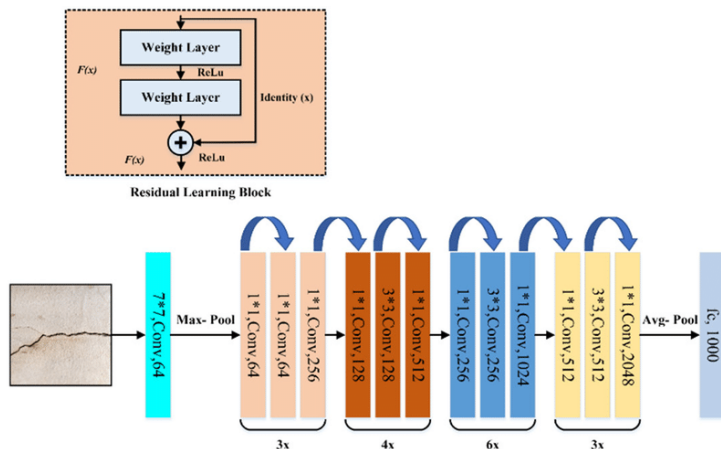


FIGURE 2.1 – L'architecture du model ResNet50.Medium

2.2.3 InceptionV3

InceptionV3 est un modèle CNN qui utilise une architecture complexe pour extraire des caractéristiques à plusieurs échelles. Il combine des convolutions de différentes tailles (1x1, 3x3, 5x5) et des opérations de pooling, permettant une représentation riche et détaillée des données d'entrée, telles que les IRM cérébrales.

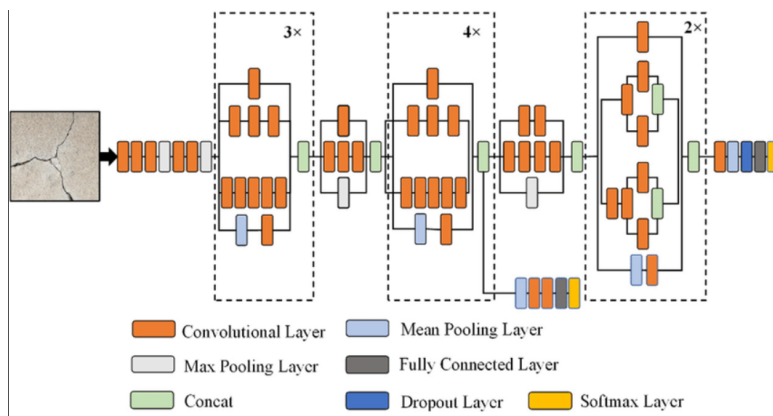


FIGURE 2.2 – L'architecture du model Inception-V3.[30]

2.3 Approches d'extraction des caractéristiques pour l'analyse des images IRM par ordinateur

2.3.1 Méthodes d'extraction des caractéristiques par ResNet50

L'article "A Novel Method for Diagnosing Alzheimer's Disease from MRI Scans using the ResNet50 Feature Extractor and the SVM Classifier"[28] propose une méthode innovante pour le diagnostic de la maladie d'Alzheimer à partir d'IRM cérébrales, en mettant l'accent sur

l'utilisation de ResNet50 pour l'extraction des caractéristiques. Le modèle ResNet50, qui est un réseau de neurones convolutifs pré-entraîné, est utilisé pour extraire automatiquement des caractéristiques discriminantes des images IRM. Cette approche permet de capter des détails complexes et subtils dans les images, essentiels pour différencier les stades de la maladie. Après l'extraction des caractéristiques, un classificateur SVM (Support Vector Machine) est appliqué pour effectuer la classification, atteignant une précision remarquable de 98,71%. Cette méthode démontre non seulement l'efficacité de ResNet50 dans le domaine de l'imagerie médicale, mais elle souligne également son potentiel pour améliorer le diagnostic précoce de la maladie d'Alzheimer, ce qui est crucial pour une intervention thérapeutique efficace.

2.3.2 Méthodes d'extraction des caractéristiques par InceptionV3

L'article "Detection of Alzheimer's Disease on Brain MRI using Inception V3 Network" [27] présente l'utilisation du modèle Inception V3 pour extraire des caractéristiques des images IRM cérébrales dans le but de détecter la MA. Ce modèle de réseau de neurones convolutifs (CNN) est capable de capturer des informations à différentes échelles grâce à sa structure multi-niveaux, ce qui est essentiel pour analyser les détails anatomiques des IRM. Avant l'extraction, les images subissent un prétraitement, incluant la normalisation et l'augmentation des données, afin d'améliorer leur qualité. Le modèle extrait automatiquement des caractéristiques pertinentes, ce qui simplifie le processus de diagnostic et augmente la précision. Les caractéristiques extraites sont ensuite utilisées pour classifier les images, atteignant une précision de 82,89% dans la détection de la maladie d'Alzheimer. Cette approche démontre l'efficacité d'Inception V3 comme outil automatisé et précis pour aider au diagnostic précoce de cette pathologie neurodégénérative.

2.3.3 Méthodes d'agrégation des caractéristiques pour l'analyse des images

2.3.4 Méthode d'Agrégation SPoC

L'article "Aggregating Local Deep Features for Image Retrieval" [32] présente une nouvelle méthode d'agrégation appelée SPoC (Sum-Pooled Convolutional features) pour construire des descripteurs d'images compacts à partir de caractéristiques de couches convolutives profondes. La méthode SPoC se distingue par sa simplicité et son efficacité, surpassant les approches d'agrégation plus sophistiquées.

- **Extraction des Caractéristiques Convolutives Profondes** Les caractéristiques sont extraites de la dernière couche convolutive d'un réseau de neurones convolutifs pré-entraîné. Chaque image I est représentée par un ensemble de vecteurs C -dimensionnels, où C est le nombre de cartes de caractéristiques dans la dernière couche convolutive.
- **Agrégation par Somme (Sum Pooling)** Le descripteur SPoC est construit en appliquant une simple agrégation par somme des caractéristiques convolutives locales :

$$\psi(I) = \sum_{x=1}^W \sum_{y=1}^H f(x, y)$$

où $f(x,y)$ est la caractéristique extraite à la position spatiale (x, y) dans l'image.

Cette somme correspond au noyau de correspondance le plus simple entre paires d’images, comme montré dans l’équation :

$$\text{sim}(I_1, I_2) = \langle \psi(I_1), \psi(I_2) \rangle = \sum_{f_i \in I_1} \sum_{f_j \in I_2} \langle f_i, f_j \rangle$$

- **Ajout d’un a priori de centrage (Center Prior)** Pour certains jeux de données, les objets d’intérêt sont souvent situés près du centre géométrique de l’image. Les auteurs proposent d’incorporer cet a priori de centrage en pondérant les caractéristiques en fonction de leur position spatiale :

$$\psi(I) = \sum_{x=1}^W \sum_{y=1}^H \alpha(x, y) f(x, y)$$

où les coefficients $\alpha_{(x,y)}$ suivent une loi gaussienne centrée sur le milieu de l’image.

- **Post-traitement** Le descripteur obtenu $\psi(I)$ subit ensuite les étapes de post-traitement suivantes :
 - Normalisation ℓ_2
 - Réduction de dimensionnalité et blanchiment par PCA :

$$\psi'(I) = \text{diag}(s_1, s_2, \dots, s_N)^{-1} M_{\text{PCA}} \psi(I)$$

- Normalisation ℓ_2 finale

En résumé, SPoC propose une méthode d’agrégation simple et efficace basée sur la somme des caractéristiques convolutives profondes, avec un post-traitement par PCA, surpassant les performances des méthodes d’agrégation plus complexes sur plusieurs jeux de données d’évaluation standard.

2.3.5 Global Average Pooling (GAP)

L’article ”Automatic Brain Tumor Segmentation and Classification using Convolutional Neural Networks” [32] décrit une méthode d’agrégation des caractéristiques qui utilise le Global Average Pooling (GAP) pour améliorer la segmentation et la classification des tumeurs cérébrales à partir d’images médicales.

Cette méthode consiste à réduire chaque carte de caractéristiques générée par les couches convolutives du réseau de neurones en calculant la moyenne de toutes les valeurs dans chaque carte. Cela produit un vecteur de caractéristiques global qui résume l’information spatiale contenue dans les cartes de caractéristiques.

GAP permet de conserver les informations essentielles tout en réduisant la dimensionnalité des données, ce qui facilite l’apprentissage et améliore la généralisation du modèle.

2.3.6 Algorithmes de classification

Random Forest

La méthode Random Forest est un algorithme d’apprentissage automatique basé sur l’assemblage de plusieurs arbres de décision. Chaque arbre est construit à partir d’un sous-ensemble

aléatoire des données d'entraînement, ce qui permet de réduire le risque de surapprentissage et d'améliorer la généralisation du modèle. Lorsqu'une prédiction est nécessaire, chaque arbre dans la forêt vote pour une classe, et la classe avec le plus de votes est choisie comme prédiction finale. Cette approche est particulièrement efficace pour les problèmes de classification et de régression, offrant une robustesse face aux données bruitées et une capacité à gérer des ensembles de données avec des caractéristiques manquantes [33].

XGBoost

XGBoost (Extreme Gradient Boosting) est un algorithme d'apprentissage automatique basé sur le gradient boosting, qui est utilisé pour la classification et la régression. Il est connu pour sa capacité à gérer des ensembles de données volumineux et complexes tout en offrant une grande précision. XGBoost se distingue par son efficacité en termes de calcul et sa capacité à éviter le surapprentissage grâce à des techniques telles que la régularisation L1 et L2. L'algorithme construit des arbres de décision de manière séquentielle, chaque nouvel arbre corrigeant les erreurs des arbres précédents. En optimisant les performances et en réduisant le temps d'entraînement, XGBoost est devenu un outil populaire dans les compétitions de science des données et les applications industrielles [34].

2.4 Apprentissage par Transfert

Transfer Learning est une technique d'apprentissage automatique qui permet de transférer des connaissances acquises d'une tâche source vers une tâche cible. Cette approche est particulièrement utile lorsque les données disponibles pour la tâche cible sont limitées. En pratique, un modèle pré-entraîné sur un grand ensemble de données (comme ImageNet) est ajusté ou affiné sur un ensemble de données plus petit et spécifique à la tâche. Cela permet non seulement d'accélérer le processus d'entraînement, mais aussi d'améliorer la performance du modèle en tirant parti des caractéristiques déjà apprises[35].

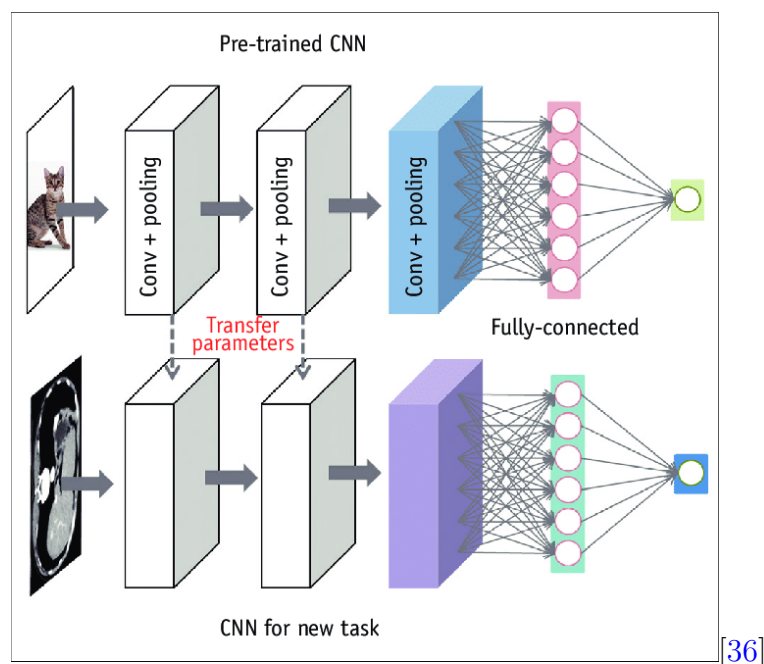


FIGURE 2.3 – Schéma du Transfer Learning

la figure 2.3 illustre un exemple du processus d'apprentissage par transfert où un modèle CNN pré-entraîné sur une tâche source (par exemple, la classification d'images de chats) est réutilisé pour une tâche cible (comme l'analyse d'images médicales). Les couches convolutives et de pooling du modèle pré-entraîné sont conservées, tandis que seules les couches entièrement connectées de la tâche cible sont ajustées, permettant ainsi de tirer parti des caractéristiques déjà apprises pour la nouvelle tâche.

2.5 Conclusion

En conclusion, l'apprentissage profond a considérablement amélioré l'analyse des images médicales, offrant des solutions plus précises et efficaces pour des tâches telles que la classification et la segmentation des anomalies. Les architectures de réseaux de neurones convolutifs, avec des modèles comme ResNet50 et InceptionV3, ont montré leur potentiel dans l'extraction de caractéristiques complexes à partir d'images médicales. L'utilisation de méthodes d'agrégation, telles que SPoC et GAP, ainsi que l'adoption de l'apprentissage par transfert, ont permis de surmonter certaines des limitations liées aux données limitées dans ce domaine. Ces avancées ouvrent la voie à des applications cliniques plus performantes et à des outils de diagnostic assisté par ordinateur, rendant les processus d'analyse plus rapides et fiables pour les professionnels de santé.

Chapitre 3


Collecte et Prétraitement des Données

3.1 Introduction

Ce chapitre est consacré à la collecte et au prétraitement des données utilisées pour l'analyse et le diagnostic de la (MA). Il commence par une description de l'ADNI (Alzheimer's Disease Neuroimaging Initiative), une initiative de recherche dans le domaine de la neuroimagerie qui vise à mieux comprendre la progression de la MA grâce à des données cliniques, d'imagerie cérébrale et de biomarqueurs. Nous décrivons ensuite le processus de téléchargement et d'organisation des données, en expliquant le format standard utilisé pour les images IRM (NIfTI) ainsi que les caractéristiques techniques des images téléchargées. Par la suite, les étapes de prétraitement des données sont présentées, notamment la normalisation des images dans un espace standardisé (MNI) et la segmentation ou "skull stripping", essentielle pour extraire uniquement le cerveau des images. Enfin, nous abordons la sélection des tranches les plus pertinentes pour le diagnostic de la MA, une étape cruciale pour améliorer la précision des modèles de classification.

3.2 Collection des Données

3.2.1 Description de l'ADNI " Alzheimer's disease Neuroimaging Initiative "



L'étude ADNI soutient activement la recherche et le développement de traitements visant à ralentir ou arrêter la progression de la MA. Des chercheurs dans plus de 60 sites cliniques aux États-Unis et au Canada collectent des données pour étudier la progression de la MA dans

le cerveau humain, à travers le vieillissement normal, le trouble cognitif léger et la MA et la démence.

Le jeu de données ADNI est une collection complète et largement utilisée de données recueillies sur une longue période, permettant d’observer les changements et l’évolution au fil du temps. Il comprend divers types de données, notamment l’imagerie cérébrale structurale, fonctionnelle et moléculaire, des biomarqueurs biofluidiques, des évaluations cognitives, des données génétiques et des informations démographiques[21][22][23]. Parmi les principaux types de données dans l’ADNI, on trouve :

- **Données clinique** Les données cliniques recueillies par ADNI incluent des informations sur les participants, telles que leur âge, leur historique médical, leurs capacités cognitives et leurs diagnostics. Ces données sont collectées selon des protocoles rigoureux pour garantir une qualité uniforme dans tous les centres d’étude. Elles sont généralement recueillies au début de l’étude, puis mises à jour tous les six mois pendant toute sa durée.
- **Données d’imagerie cérébrale** Les données d’imagerie cérébrale collectées par ADNI incluent des images de scans IRM. Ces images fournissent une vue détaillée du cerveau, permettant aux chercheurs d’observer les changements dans sa structure et ses fonctions au fil du temps. Les données sont généralement collectées au début de l’étude, puis à intervalles réguliers pendant la période d’étude.

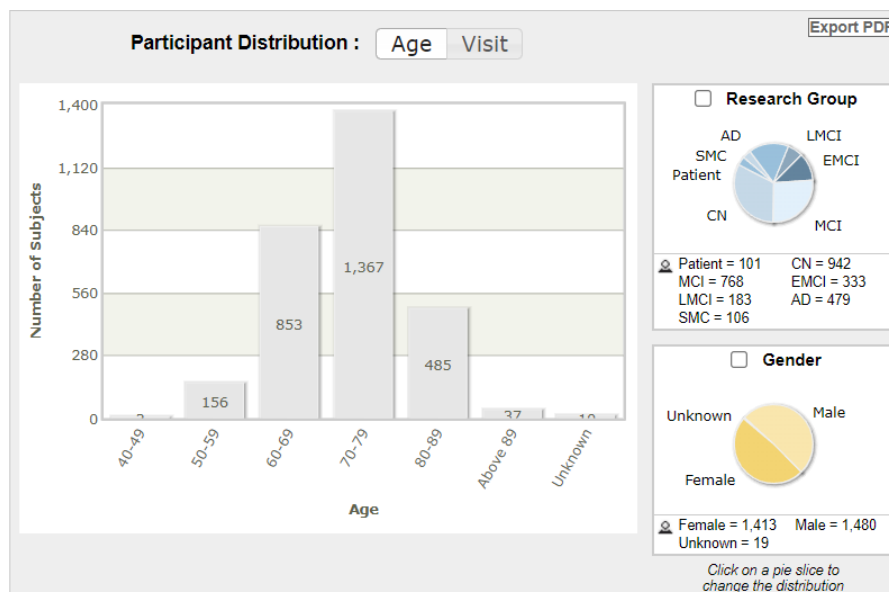


FIGURE 3.1 – Distribution des participants de l’étude ADNI par âge, groupe de recherche et genre

La figure ci-dessous illustre la distribution des participants de l’étude ADNI selon leur âge, leur groupe de recherche, et leur genre, offrant un aperçu de la diversité des données recueillies dans cette vaste étude.

Cette figure illustre la distribution des participants selon plusieurs critères. Le graphique principal montre une répartition des sujets par tranche d’âge, avec une majorité d’entre eux âgés de 70 à 79 ans. Le diagramme circulaire à droite présente les différents groupes de recherche :

- **CN (Cognition Normale)** : participants sans signes de troubles cognitifs.

- **MCI (Mild Cognitive Impairment)** : participants présentant des troubles cognitifs légers, souvent considérés comme une phase intermédiaire entre le vieillissement normal et la maladie d’Alzheimer.
- **EMCI (Early Mild Cognitive Impairment)** : participants avec des signes précoces de troubles cognitifs légers.
- **LMCI (Late Mild Cognitive Impairment)** : participants présentant des signes avancés de troubles cognitifs légers.
- **AD (Alzheimer’s Disease)** : participants atteints de la maladie d’Alzheimer.

Les personnes ayant une CN représentent le plus grand nombre. Enfin, la répartition par genre est également indiquée. Ces données reflètent l’engagement de l’étude ADNI dans le suivi d’une population diversifiée pour mieux comprendre la progression des troubles cognitifs et de la maladie d’Alzheimer.

3.2.2 Téléchargement des images et définition du format NIfTI

Dans le cadre de cette étude, j’ai téléchargé les images IRM au format NIfTI depuis l’archive IDA (Image Data Archive) accessible à l’adresse [IDA ADNI](#). Le format NIfTI (Neuroimaging Informatics Technology Initiative) est un format de fichier standardisé largement utilisé pour le stockage d’images neuroanatomiques volumétriques. Il permet de stocker non seulement les données d’image 3D ou 4D si une dimension temporelle est ajoutée, par exemple lors d’une imagerie fonctionnelle (fMRI), mais aussi des informations complémentaires telles que les dimensions de la grille et l’orientation spatiale, facilitant ainsi l’analyse neuroimagerie à grande échelle[24].

3.2.3 Caractéristiques des images téléchargées

Les images téléchargées sont caractérisées par les options suivantes : **T1**, **MPR-R**, **Gradwrap**, **B1 Correction**, et **N3**. Voici une brève explication de ces termes :

- **MPR-R (Multi-Planar Reconstruction - Repetition)** : Ce type d’acquisition permet de reconstruire les images dans plusieurs plans (axial, sagittal et coronal), assurant ainsi une haute résolution spatiale des coupes cérébrales.
- **Gradwrap** : Ce processus corrige les distorsions dues aux gradients non linéaires dans le système d’imagerie IRM, améliorant ainsi la précision spatiale des images.
- **B1 Correction** : Cette correction concerne l’inhomogénéité du champ magnétique B1 qui peut affecter la qualité de l’image. La correction B1 compense les variations d’intensité qui peuvent apparaître dans les images IRM.
- **N3 (Nonparametric Nonuniformity Normalization)** : Il s’agit d’un algorithme de correction de l’inhomogénéité dans les images IRM, particulièrement utile pour améliorer la qualité des images et les rendre plus uniformes en ajustant les variations d’intensité à travers le cerveau.

3.2.4 Composition des groupes et caractéristiques démographiques

Les participants ont été répartis en trois groupes principaux : MCI , AD et NC. Chaque groupe a été constitué selon des critères spécifiques, et les informations démographiques, notamment le nombre de participants, leur genre, leur âge et les intervalles de leurs scores MMSE , sont présentées dans le tableau ci-dessous.

Groupe	Genre	Intervalle MMSE
NC	12 femmes, 13 hommes	28 - 30
MCI	15 femmes, 15 hommes	21 - 27
AD	14 femmes, 16 hommes	16 - 24

TABLE 3.1 – Caractéristiques démographiques des groupes d'étude (avec âges entre 65 et 85 ans)

Le choix de cette répartition équilibrée entre les genres (femmes et hommes) et les groupes cognitifs (NC, MCI, AD) est essentiel pour garantir une diversité dans le jeu de données. Cette diversité est cruciale pour améliorer la robustesse des modèles d'apprentissage automatique. Un jeu de données bien équilibré permet d'éviter les biais qui pourraient influencer les performances du modèle de classification. En effet, une répartition homogène des différents groupes et une diversité de profils garantissent que le modèle soit mieux formé pour reconnaître des caractéristiques variées et éviter la sur-apprentissage sur un groupe particulier.

Cela se traduit par une meilleure généralisation du modèle lors des phases d'entraînement et de test, car il est exposé à des cas cognitifs et démographiques différents. Cette approche améliore la capacité du modèle à discriminer les différents niveaux de déficience cognitive, ce qui est fondamental pour des tâches de classification précises dans le contexte de la MA et des troubles cognitifs associés.

3.2.5 Organisation du jeu de données

J'ai organisé le jeu de données en trois groupes principaux : AD , NC et MCI. Chaque groupe contient plusieurs dossiers, chacun correspondant à un sujet unique. Les dossiers des sujets sont nommés selon un identifiant unique, par exemple "011_S_0053", où 011 représente le centre où les données ont été collectées, S indique que le participant fait partie de l'étude, et 0053 est l'identifiant du sujet au sein de cette étude.

À l'intérieur de chaque dossier de sujet, on trouve un sous-dossier nommé "MPR-R_GradWarp_B1_Correction_N3", qui indique que les images ont subi un ensemble spécifique de traitements : **MPR-R** (Multi-Planar Reconstruction), **GradWarp** (correction des distorsions de gradient), **B1 Correction** (correction de l'inhomogénéité du champ magnétique B1) et **N3** (correction d'inhomogénéité d'intensité).

Chaque sous-dossier contient ensuite un ou deux dossiers nommés par des dates, par exemple "2006-11-28_12.41.18.0". Ces dates correspondent aux moments où les scans IRM ont été réalisés. En général, les sujets sont suivis sur une période prolongée, avec un délai d'environ 6 mois entre deux prises de scan. Cela permet de suivre l'évolution des changements cognitifs et structurels dans le cerveau des participants au fil du temps.

Enfin, à l'intérieur de ces dossiers datés, on trouve des fichiers nommés comme "I31999", qui contiennent les données d'imagerie au format NIfTI.

Intérêt de cette organisation et du nommage

Cette organisation en dossiers bien structurés et nommés de manière cohérente présente plusieurs avantages. Premièrement, elle permet une gestion plus facile des données, en particulier lorsqu'il s'agit de suivre plusieurs scans pour un même sujet au fil du temps. Le nommage des dossiers selon la date de prise de scan permet de rapidement localiser les images correspondant à une période spécifique de l'étude.

Deuxièmement, la nomenclature détaillée des dossiers de traitement ("MPR-R_GradWarp_B1_Correction_N3") indique les étapes précises de prétraitement que chaque image a subies. Cela est particulièrement important dans le cadre de la reproductibilité des analyses, car les chercheurs peuvent rapidement identifier les traitements appliqués aux données.

Enfin, la standardisation du nommage des fichiers ("I31999") permet de manipuler les données de manière automatisée avec des scripts et des algorithmes, facilitant ainsi l'entraînement des modèles d'apprentissage automatique et la gestion des grands volumes de données.

Cette organisation rigoureuse contribue donc à améliorer l'efficacité et la fiabilité du processus d'analyse des données, tout en permettant un suivi longitudinal des participants à l'étude sur plusieurs années.

3.3 Prétraitement des Données

3.3.1 Définition de FSLeyes

FSLeyes (FSL image viewer) est un outil graphique interactif inclus dans la suite FSL (FMRIB Software Library), utilisé pour visualiser et analyser des images médicales en trois dimensions, telles que des IRM ou des images de diffusion. Il prend en charge une variété de formats d'images, y compris les fichiers NIfTI et DICOM, et permet de visualiser des données volumétriques en coupes axiales, coronales et sagittales.

FSLeyes offre plusieurs fonctionnalités avancées, notamment :

- La superposition de différentes images pour la comparaison, par exemple des images anatomiques avec des cartes fonctionnelles.
- La visualisation et l'analyse de données d'imagerie structurelle et fonctionnelle.
- L'intégration de masques, d'annotations et de tracés pour faciliter l'analyse des régions d'intérêt.
- La possibilité d'afficher des cartes statistiques et d'appliquer des seuils pour examiner les résultats d'analyses.

Cet outil est particulièrement utile pour les chercheurs travaillant en neuroimagerie, car il permet une inspection rapide des images, des traitements et des résultats dérivés des analyses FSL.

3.3.2 Normalisation des données

La normalisation des images cérébrales est une étape cruciale dans l'analyse des données de neuroimagerie. Elle consiste à transformer les images individuelles dans un espace stan-

standardisé afin de permettre des comparaisons directes entre les sujets. Cette procédure est particulièrement utile pour les études multi-sujets ou les analyses de groupe, car elle permet d'aligner les structures anatomiques de différents cerveaux dans un espace commun, facilitant ainsi la détection de différences ou de similarités inter-sujets.

Outils utilisés et paramètres

Pour normaliser les images, j'ai utilisé l'outil **FLIRT** (FMRIB's Linear Image Registration Tool) de la suite logicielle FSL. Cet outil permet d'effectuer des recalages linéaires entre les images, en ajustant des transformations rigides et non rigides.

Les paramètres suivants ont été utilisés pour la normalisation :

- **Modèle standard** : `MNI152_T1_1mm.nii.gz`. Ce modèle représente un cerveau standardisé basé sur les IRM pondérées en T1 de 152 sujets sains, avec une résolution isotrope de 1 mm^3 .
- **Fonction de coût** : `cost_func='corratio'`. Le ratio de corrélation est particulièrement adapté pour le recalage intermodal, comme entre des images T1 anatomiques et d'autres types d'images fonctionnelles ou structurales. Il permet de tenir compte des différences d'intensité entre les deux images tout en trouvant le meilleur ajustement.
- **Degrés de liberté (dof)** : `dof=12`. Ce paramètre permet d'ajuster les translations, rotations, échelles et cisaillements dans les trois dimensions de l'espace, garantissant un alignement précis avec le modèle MNI.

Ces choix de paramètres garantissent que les images sont non seulement alignées avec le modèle standard MNI, mais également optimisées pour minimiser les distorsions tout en préservant les caractéristiques anatomiques des images d'origine.

Résultats avant et après normalisation

Les figures ci-dessous illustrent une comparaison visuelle d'une image cérébrale avant et après la normalisation. On peut observer que l'image normalisée (Figure 3.3) est alignée avec le modèle MNI, permettant ainsi une comparaison directe avec d'autres sujets ou groupes.




FIGURE 3.2 – Image cérébrale avant la normalisation.




FIGURE 3.3 – Image cérébrale après la normalisation.

La normalisation garantit que les caractéristiques anatomiques des cerveaux sont alignées avec précision, permettant des comparaisons inter-sujets fiables. Cette étape est essentielle pour les analyses de groupe et les études multi-sujets dans le cadre de la neuroimagerie.

3.3.3 Segmentation des images

Après l'étape de la normalisation, il est crucial d'effectuer la segmentation des images cérébrales, également appelée skull stripping en anglais. Cette étape consiste à retirer toutes les structures non cérébrales, telles que le crâne, les tissus mous et le cou, pour ne conserver que le cerveau dans l'image. Cette procédure est essentielle pour se concentrer exclusivement sur le cerveau lors des analyses ultérieures, notamment dans l'étape de classification.

Intérêt et rôle de la segmentation

Le principal objectif du skull stripping est d'améliorer la précision des analyses en excluant les structures anatomiques qui ne sont pas pertinentes pour l'étude du cerveau. En particulier, cette étape est fondamentale pour :

- **Réduire les artefacts** : En éliminant le crâne et les tissus environnants, on réduit les artefacts et les variations d'intensité qui pourraient fausser les analyses de l'image.
- **Optimiser la segmentation cérébrale** : En conservant uniquement le cerveau, on facilite la segmentation des différentes régions cérébrales et l'extraction de caractéristiques anatomiques spécifiques.
- **Améliorer les performances des modèles d'apprentissage automatique** : Les modèles de machine learning peuvent se concentrer uniquement sur les structures cérébrales, réduisant ainsi les erreurs de classification liées à des régions non pertinentes.

Application de la segmentation avec FSL BET

Pour effectuer cette segmentation, nous utilisons la fonction **BET (Brain Extraction Tool)** de la bibliothèque FSL. BET est un outil simple et efficace qui permet d'extraire le cerveau en ajustant le degré d'enlèvement grâce à un paramètre appelé `frac` (fractional intensity threshold).

Voici la commande utilisée pour appliquer la segmentation :

```
bet {input_image} {output_image} -f 0.3 -B
```

- `{input_image}` : Image d'entrée (fichier NIFTI) à traiter.
- `{output_image}` : Image de sortie où seule la structure cérébrale est conservée.

- **-f 0.3** : Ce paramètre contrôle le degré d'enlèvement du crâne. Après plusieurs essais, nous avons fixé la valeur à 0.3, ce qui a produit les meilleurs résultats pour nos images. Une valeur plus faible correspond à une extraction plus conservatrice, tandis qu'une valeur plus élevée retire plus de tissus autour du cerveau.
- **-B** : Cette option permet de retirer également les parties inférieures, comme le cou et les structures situées sous le cerveau. Cela permet une segmentation plus précise en éliminant les parties du cou.



FIGURE 3.4 – Image cérébrale après enlèvement du crâne.

3.3.4 Sélection des tranches importantes du cerveau pour l'aide au diagnostic

En se basant sur les connaissances médicales concernant le diagnostic de la maladie d'Alzheimer, nous avons restreint notre traitement aux tranches du cerveau les plus pertinentes pour le diagnostic. Ces tranches sont celles qui contiennent un maximum d'informations sur les régions d'intérêt visibles impliquées dans la (MA).

Tranches sélectionnées par projection

Les meilleures tranches pour chaque projection, identifiées en fonction de la présence des régions d'intérêt [25], sont les suivantes :

- **Projection sagittale** : Les tranches entre 54 et 70 et entre 114 et 127 ont été jugées les plus pertinentes pour la détection de la maladie d'Alzheimer.
- **Projection coronale** : Les tranches entre 95 et 145 contiennent de l'information utile, avec une concentration particulière d'informations entre les tranches 112 et 115.
- **Projection axiale** : Les tranches entre 55 et 74 sont informatives, notamment les tranches 62 à 66, qui montrent des détails importants pour le diagnostic.

Ces sélections permettent de focaliser le traitement sur les zones cérébrales les plus pertinentes, améliorant ainsi la capacité du modèle à distinguer un cerveau atteint de la MA d'un cerveau sain.

Extraction des images 2D

Suite à cette sélection, j'ai réalisé l'extraction des tranches identifiées afin de créer des images 2D tout en conservant la même organisation que notre jeu de données d'origine. Chaque tranche a été extraite de manière à préserver la structure des dossiers par sujet et par projection, ce qui facilite l'intégration des nouvelles données dans le pipeline d'analyse.

Ces images 2D extraites seront utilisées pour l'extraction des caractéristiques, étape cruciale pour alimenter les modèles de classification qui permettent de diagnostiquer la MA en se basant sur les informations visuelles extraites des régions d'intérêt.

3.4 Conclusion

Ce chapitre a permis de détailler les étapes essentielles du collecte et du prétraitement des données dans le cadre de la recherche sur la MA. En s'appuyant sur l'ADNI, nous avons collecté et organisé des données des images IRM, pour constituer un jeu de données robuste et équilibré. Les processus de normalisation et de segmentation ont été essentiels pour préparer les images de manière à ce qu'elles puissent être utilisées dans des modèles d'apprentissage automatique. Enfin, la sélection des tranches pertinentes a permis de concentrer l'analyse sur les zones cérébrales les plus touchées par la MA, améliorant ainsi la qualité et la précision du diagnostic assisté par les technologies de l'IA.

Chapitre 4

Résultats et Discussion

4.1 Introduction

Rappel des objectifs de l'étude. Présentation des différentes approches utilisées : extraction des features avec ResNet et InceptionV3, et transfert d'apprentissage à partir du modèle Brain Tumor Detection (basé sur ResNet50). Justification du re-entraînement des modèles Axial, Coronal et Sagittal pour la classification des images AD, NC, et MCI.

4.2 Extraction des caractéristiques et Méthodologie

4.2.1 Méthode ResNet

Pour extraire les caractéristiques des images médicales, j'ai utilisé le modèle ResNet50 pré-entraîné. Afin d'adapter ce modèle à mon projet, j'ai supprimé les dernières couches fully-connected et de global pooling pour conserver uniquement les couches convolutives. J'ai ensuite appliqué le Global Average Pooling (GAP) à la sortie du modèle, qui réduit chaque feature map à une seule valeur moyenne.

4.2.2 Méthode InceptionV3

Dans le cadre de mon projet, j'ai également utilisé le modèle InceptionV3 pré-entraîné pour l'extraction des caractéristiques. Afin d'adapter ce modèle, j'ai supprimé la dernière couche fully-connected, ce qui permet de conserver uniquement les couches convolutives pour l'extraction des features. J'ai ensuite appliqué le Global Average Pooling (GAP) à la sortie du modèle, afin de réduire chaque feature map à une seule valeur moyenne.

4.3 Agrégation des caractéristiques avec Global Average Pooling

Dans mon projet, chaque dossier contient plusieurs images (Axial, Coronal, Sagittal). L'objectif de l'application du Global Average Pooling (GAP) est de représenter chaque dossier d'images par un seul vecteur. En prenant la moyenne des features extraites de toutes les images dans un dossier, le GAP me permet de créer une représentation compacte et informative de

l'ensemble des images, ce qui simplifie leur utilisation pour la classification dans les classes AD, NC, et MCI.

4.4 Classification Multimodale AD/NC/MCI

4.4.1 Classification avec Random Forest après Extraction des Features par ResNet50

Class	Precision	Recall	F1-Score	Support
AD	0.48	0.72	0.58	18
CN	0.33	0.40	0.36	10
MCI	0.42	0.22	0.29	23
Accuracy			0.43	51
Macro Avg	0.41	0.45	0.41	51
Weighted Avg	0.42	0.43	0.40	51

TABLE 4.1 – Rapport de classification pour Random Forest après extraction des features avec ResNet50

Le tableau 4.1 montre les performances du modèle Random Forest après extraction des caractéristiques avec ResNet50. Les résultats indiquent que le modèle a une précision et un rappel variés selon les classes. La classe "AD" est la mieux prédite avec un F1-score de 0.58, tandis que la classe "MCI" montre des performances plus faibles avec un F1-score de 0.29, suggérant une difficulté à la distinguer des autres classes. L'exactitude globale de 43 % montre que le modèle présente des limites dans sa capacité à classer correctement les échantillons, en particulier pour les classes "CN" et "MCI", qui ont des rappels plus faibles.

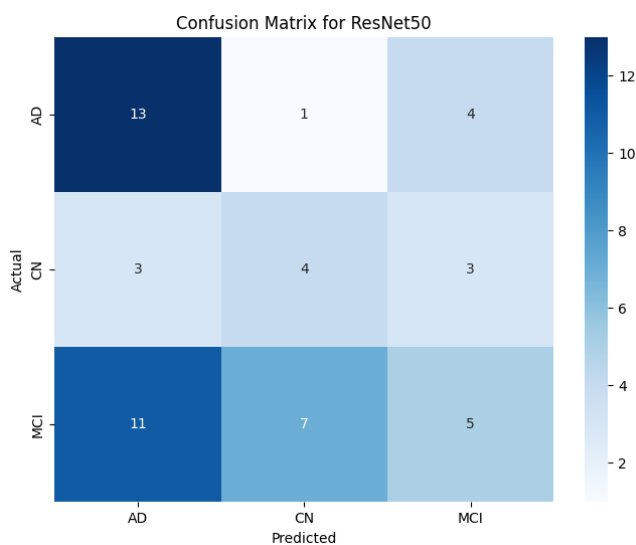


FIGURE 4.1 – Matrice de confusion pour Random Forest après extraction des features avec ResNet50

La matrice de confusion 4.1 visualise les erreurs de classification entre les classes "AD", "CN", et "MCI". Le modèle montre une bonne performance pour la classe "AD" avec 13 échantillons correctement classés, mais il confond souvent les classes "MCI" et "AD", avec 11 échantillons "MCI" incorrectement classés comme "AD". Cette confusion indique que le modèle a des difficultés à différencier efficacement ces deux conditions, ce qui pourrait être lié à la similarité des caractéristiques extraites pour ces classes.

4.4.2 Classification avec Random Forest après Extraction des Features par InceptionV3

Class	Precision	Recall	F1-Score	Support
AD	0.54	0.39	0.45	18
CN	0.35	0.70	0.47	10
MCI	0.50	0.39	0.44	23
Accuracy			0.45	51
Macro Avg	0.46	0.49	0.45	51
Weighted Avg	0.48	0.45	0.45	51

TABLE 4.2 – Rapport de classification pour Random Forest après extraction des features avec InceptionV3

Le tableau 4.2 présente les performances du modèle Random Forest après extraction des caractéristiques par InceptionV3. La précision et le rappel varient selon les classes. La classe "CN" (Cognitively Normal) se distingue par un rappel élevé de 0.70, indiquant que la plupart des échantillons de cette classe sont correctement classés, bien que sa précision soit plus basse (0.35). En revanche, la classe "AD" (Alzheimer's Disease) a une précision légèrement plus élevée (0.54) mais un rappel plus faible (0.39), montrant que le modèle confond souvent cette classe avec d'autres. La performance globale du modèle reste modeste avec une exactitude de 0.45, et les moyennes pondérées des scores F1 (0.45) reflètent les difficultés à classer les échantillons avec un bon équilibre entre précision et rappel.

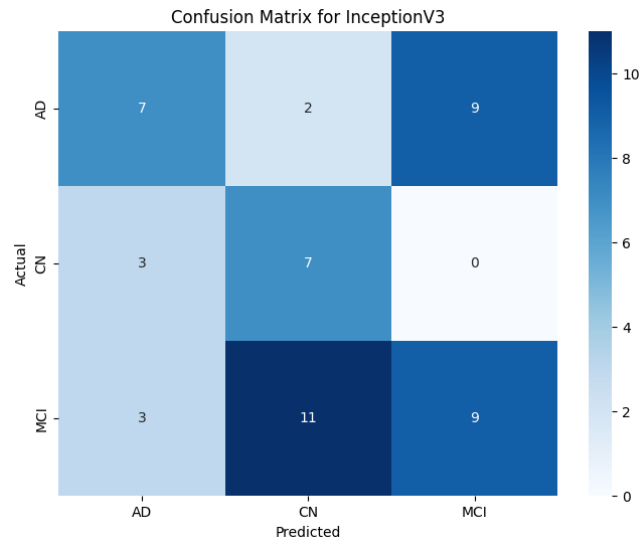


FIGURE 4.2 – Matrice de confusion pour Random Forest après extraction des features avec InceptionV3

La matrice de confusion 4.2 visualise la capacité du modèle à prédire correctement les classes "AD", "CN", et "MCI" (Mild Cognitive Impairment). On remarque que la classe "AD" est confondue avec "MCI" dans 9 cas sur 18, ce qui explique son rappel plus faible. De même, la classe "MCI" est souvent mal classée, avec 11 échantillons mal identifiés comme "CN". Cependant, le modèle réussit à classer correctement 7 échantillons sur 10 pour la classe "CN", confirmant son rappel élevé. Ces résultats montrent une difficulté générale à distinguer précisément les conditions "AD" et "MCI".

4.4.3 Classification avec XGBoost après Extraction des Features par ResNet50

Class	Precision	Recall	F1-Score	Support
AD	0.40	0.56	0.47	18
CN	0.38	0.50	0.43	10
MCI	0.38	0.22	0.28	23
Accuracy			0.39	51
Macro Avg	0.39	0.42	0.39	51
Weighted Avg	0.39	0.39	0.37	51

TABLE 4.3 – Rapport de classification pour XGBoost après extraction des features avec ResNet50

Le tableau 4.3 présente les performances du modèle XGBoost après extraction des caractéristiques à l'aide de ResNet50. La classe "AD" obtient une précision de 0.40 et un rappel de 0.56, indiquant que plus de la moitié des échantillons "AD" sont correctement classés, bien que près de 60 % des prédictions soient incorrectes. Pour la classe "CN", la précision est légèrement meilleure avec 0.38, mais son rappel est de 0.50, montrant une performance similaire à celle de la classe "AD". La classe "MCI", cependant, est plus problématique avec un F1-score de

0.28 et un faible rappel de 0.22, indiquant que le modèle a du mal à identifier correctement cette classe. L'exactitude globale est de 39 %, ce qui souligne des difficultés importantes dans la classification.

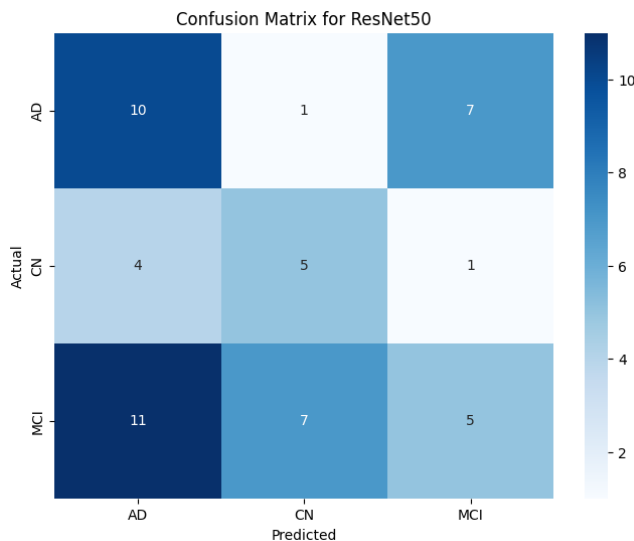


FIGURE 4.3 – Matrice de confusion pour XGBoost après extraction des features avec ResNet50

La matrice de confusion 4.3 montre les erreurs et les succès du modèle XGBoost pour chaque classe. Pour la classe "AD", 10 échantillons ont été correctement classés, mais 8 ont été confondus avec les classes "CN" et "MCI". La classe "CN" montre également une certaine confusion, avec seulement 5 échantillons correctement classés et une part significative mal classée comme "AD" ou "MCI". La classe "MCI" est celle qui souffre le plus de la confusion avec les autres classes, en particulier avec "AD", ce qui explique son faible rappel. Cette matrice illustre les difficultés générales du modèle à distinguer correctement les trois classes.

4.4.4 Classification avec XGBoost après Extraction des Features par InceptionV3

Class	Precision	Recall	F1-Score	Support
AD	0.50	0.56	0.53	18
CN	0.41	0.70	0.52	10
MCI	0.57	0.35	0.43	23
Accuracy			0.49	51
Macro Avg	0.49	0.53	0.49	51
Weighted Avg	0.51	0.49	0.48	51

TABLE 4.4 – Rapport de classification pour XGBoost après extraction des features avec InceptionV3

Le tableau 4.4 montre les performances du modèle XGBoost après extraction des caractéristiques par InceptionV3. La classe "AD" présente une précision de 0.50 et un rappel de 0.56, indiquant que le modèle réussit raisonnablement bien à identifier cette classe, mais

laisse encore de la place à l'amélioration. La classe "CN" montre une meilleure performance en termes de rappel (0.70), suggérant que la majorité des échantillons de cette classe sont correctement classés, bien que la précision reste modeste à 0.41. Pour la classe "MCI", le modèle a une meilleure précision (0.57), mais un rappel plus faible (0.35), ce qui reflète une difficulté à bien capturer cette classe. L'exactitude globale est de 49 %, ce qui montre que le modèle a une performance légèrement supérieure à l'aléatoire mais encore perfectible.




FIGURE 4.4 – Matrice de confusion pour XGBoost après extraction des features avec InceptionV3

La matrice de confusion 4.4 illustre les prédictions du modèle pour les différentes classes. Pour la classe "AD", 10 échantillons ont été correctement classés, tandis que 6 ont été confondus avec "MCI", ce qui explique la performance modérée en termes de précision. Pour la classe "CN", 7 échantillons ont été correctement classés, avec seulement 3 confusions avec "AD". En revanche, la classe "MCI" montre une distribution plus équilibrée entre les trois classes, avec 8 échantillons correctement identifiés mais 7 confondus avec "AD" et 8 avec "CN". Ces résultats reflètent une difficulté du modèle à bien séparer les différentes classes, en particulier entre "MCI" et les autres.

4.5 Comparaison des Performances Multimodales (ResNet50, InceptionV3)

4.5.1 Comparaison des performances avec Random Forest et XGBoost

La table ci-dessous présente une comparaison des performances de deux modèles de réseaux de neurones profonds, ResNet50 et InceptionV3, pour la classification multimodale (AD/NC/MCI) avec les algorithmes Random Forest et XGBoost.

Modèle	Algorithme	Classe AD			Classe CN			Classe MCI			Exactitude Globale
		Précision	Rappel	F1-Score	Précision	Rappel	F1-Score	Précision	Rappel	F1-Score	
ResNet50	Random Forest	0.48	0.72	0.58	0.33	0.40	0.36	0.42	0.22	0.29	0.43
InceptionV3	Random Forest	0.54	0.39	0.45	0.35	0.70	0.47	0.50	0.39	0.44	0.45
ResNet50	XGBoost	0.40	0.56	0.47	0.38	0.50	0.43	0.38	0.22	0.28	0.39
InceptionV3	XGBoost	0.50	0.56	0.53	0.41	0.70	0.52	0.57	0.35	0.43	0.49

TABLE 4.5 – Comparaison des performances multimodales (ResNet50 vs InceptionV3) avec Random Forest et XGBoost pour la classification AD/NC/MCI.

4.5.2 Analyse des performances

Bien que les modèles de réseaux de neurones profonds ResNet50 et InceptionV3 obtiennent des résultats acceptables pour la classification des classes AD et NC, la classification multimodale montre des performances globales limitées, en particulier pour la classe MCI.

— Modèles utilisant Random Forest :

- InceptionV3 obtient de meilleures performances globales que ResNet50, avec une meilleure précision et rappel pour la classe NC.
- Cependant, les deux modèles ont des difficultés à bien classer la classe MCI, avec des F1-Scores relativement faibles (0.29 pour ResNet50 et 0.44 pour InceptionV3).

— Modèles utilisant XGBoost :

- InceptionV3 avec XGBoost surpasse ResNet50 pour la classe NC et MCI, mais les résultats restent médiocres pour la classe MCI avec des F1-Scores de 0.28 pour ResNet50 et 0.43 pour InceptionV3.

— Difficulté à classer la classe MCI :

- La classe MCI est difficile à classer dans cette approche multimodale. Cela pourrait être dû à la similarité entre les images de MCI et celles des autres classes, ou à la variabilité intra-classe.
- Les faibles F1-Scores pour MCI dans tous les modèles et algorithmes (0.29 à 0.44) indiquent que cette classe est la plus complexe à discriminer correctement.

— Exactitude Globale :

- InceptionV3 obtient une exactitude globale légèrement supérieure à celle de ResNet50, particulièrement lorsqu'il est couplé à XGBoost (0.49 contre 0.39).
- Toutefois, même avec cette amélioration, la performance globale reste limitée pour cette tâche multimodale, avec une classification loin d'être parfaite, notamment pour la classe MCI.

4.5.3 Conclusion

Les résultats montrent que la classification multimodale AD/NC/MCI reste un défi, en particulier pour la classe MCI, qui est difficile à classer avec précision. Même avec l'utilisation de modèles avancés comme ResNet50 et InceptionV3, et d'algorithmes puissants comme Random Forest et XGBoost, les performances sur la classe MCI sont faibles, indiquant un besoin d'améliorations pour cette tâche spécifique. InceptionV3, couplé à XGBoost, semble être la combinaison la plus performante, mais des recherches supplémentaires sont nécessaires pour améliorer la classification de la classe MCI.

4.6 Classification Binaire (AD/NC, AD/MCI, NC/MCI)

4.6.1 Classification avec Random Forest après Extraction des Features par ResNet50

ResNet50 CN vs MCI

Class	Precision	Recall	F1-Score	Support
CN	0.50	0.47	0.48	15
MCI	0.58	0.61	0.59	18
Accuracy			0.55	33
Macro Avg	0.54	0.54	0.54	33
Weighted Avg	0.54	0.55	0.54	33

TABLE 4.6 – Rapport de classification pour Random Forest sur CN vs MCI après extraction des features avec ResNet50

Le tableau 4.6 montre les performances du modèle Random Forest appliqué aux classes CN (Cognitively Normal) et MCI (Mild Cognitive Impairment) après l'extraction des caractéristiques avec ResNet50. Les résultats indiquent une précision de 0.50 pour la classe "CN" et de 0.58 pour la classe "MCI", avec des F1-scores de 0.48 et 0.59 respectivement. Cela montre que le modèle a de meilleures performances sur la classe "MCI" par rapport à la classe "CN". L'exactitude globale est de 0.55, ce qui suggère que le modèle a une capacité modérée à distinguer entre les deux classes. La macro-moyenne des métriques est de 0.54, ce qui reflète un équilibre moyen des performances sur les deux classes.




FIGURE 4.5 – Matrice de confusion pour Random Forest sur CN vs MCI après extraction des features avec ResNet50

La matrice de confusion ?? montre comment le modèle Random Forest a classé les échantillons "CN" et "MCI". On observe que 7 échantillons "CN" ont été correctement classés, tandis que 8 ont été mal classés comme "MCI". De même, 11 échantillons "MCI" ont été correctement classés, tandis que 7 ont été incorrectement prédits comme "CN". Cette confusion relativement

importante entre les deux classes reflète les défis rencontrés par le modèle pour bien différencier ces deux états cognitifs, malgré une performance légèrement meilleure pour la classe "MCI".

ResNet50 AD vs MCI

Class	Precision	Recall	F1-Score	Support
AD	0.50	0.44	0.47	18
MCI	0.50	0.56	0.53	18
Accuracy			0.50	36
Macro Avg	0.50	0.50	0.50	36
Weighted Avg	0.50	0.50	0.50	36

TABLE 4.7 – Rapport de classification pour Random Forest sur AD vs MCI après extraction des features avec ResNet50

Le tableau 4.7 présente les performances du modèle Random Forest appliqué aux classes AD (Alzheimer's Disease) et MCI (Mild Cognitive Impairment) après extraction des caractéristiques avec ResNet50. Les résultats montrent que les performances pour les deux classes sont similaires, avec une précision de 0.50 pour chaque classe. Cependant, la classe "AD" a un rappel légèrement inférieur (0.44) par rapport à "MCI" (0.56), ce qui indique que le modèle est plus apte à détecter les cas de "MCI" que ceux de "AD". L'exactitude globale de 0.50 reflète la difficulté du modèle à distinguer clairement entre les deux classes, et les moyennes pondérées des métriques indiquent une performance équilibrée, bien que modeste.

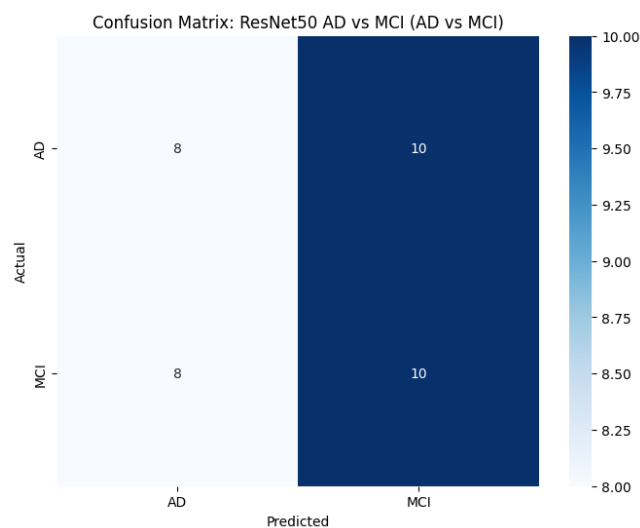


FIGURE 4.6 – Matrice de confusion pour Random Forest sur AD vs MCI après extraction des features avec ResNet50

La matrice de confusion 4.6 montre la répartition des prédictions du modèle pour les classes "AD" et "MCI". Sur les 18 échantillons de la classe "AD", 8 ont été mal classés comme "MCI", tandis que 10 ont été correctement identifiés. Pour la classe "MCI", 10 échantillons ont été correctement prédits, mais 8 ont été incorrectement classés comme "AD". Ces résultats révèlent une confusion relativement élevée entre ces deux classes, reflétant les limites du modèle dans sa capacité à différencier entre "AD" et "MCI".

ResNet50 AD vs CN

Class	Precision	Recall	F1-Score	Support
AD	0.71	0.94	0.81	18
CN	0.89	0.53	0.67	15
Accuracy			0.76	33
Macro Avg	0.80	0.74	0.74	33
Weighted Avg	0.79	0.76	0.74	33

TABLE 4.8 – Rapport de classification pour Random Forest sur AD vs CN après extraction des features avec ResNet50

Le tableau 4.8 présente les résultats de classification du modèle Random Forest appliqué aux classes AD (Alzheimer’s Disease) et CN (Cognitively Normal) après extraction des caractéristiques à l’aide de ResNet50. La classe ”AD” obtient une précision de 0.71 et un rappel élevé de 0.94, ce qui signifie que presque tous les cas d’”AD” sont correctement identifiés. En revanche, la classe ”CN” montre une précision plus élevée (0.89) mais un rappel inférieur (0.53), suggérant que presque la moitié des échantillons ”CN” sont mal classés. L’exactitude globale est de 0.76, indiquant que le modèle performe raisonnablement bien pour distinguer ces deux classes, bien que les échantillons ”CN” soient parfois confondus avec ceux de ”AD”.

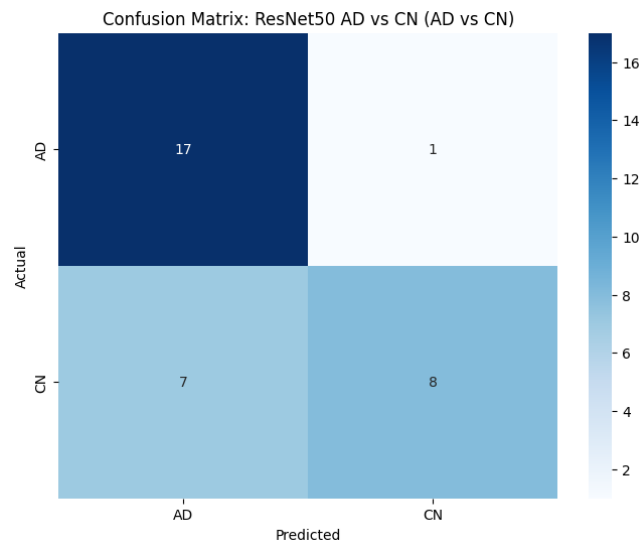


FIGURE 4.7 – Matrice de confusion pour Random Forest sur AD vs CN après extraction des features avec ResNet50

La matrice de confusion 4.7 montre que sur les 18 échantillons de la classe ”AD”, 17 ont été correctement classés, tandis qu’un seul a été mal classé comme ”CN”. Pour la classe ”CN”, sur les 15 échantillons, 8 ont été mal classés comme ”AD” et 7 ont été correctement prédits. Cela montre une tendance à surclasser les échantillons dans la catégorie ”AD”, même lorsque ceux-ci sont ”CN”, ce qui est cohérent avec le rappel relativement faible observé pour ”CN”.

4.6.2 Classification avec XGBoost après Extraction des Features par ResNet50

XGBoost ResNet50 CN vs MCI

Class	Precision	Recall	F1-Score	Support
CN	0.56	0.60	0.58	15
MCI	0.65	0.61	0.63	18
Accuracy			0.61	33
Macro Avg	0.60	0.61	0.60	33
Weighted Avg	0.61	0.61	0.61	33

TABLE 4.9 – Rapport de classification pour XGBoost sur CN vs MCI après extraction des features avec ResNet50

Le tableau 4.9 présente les performances du modèle XGBoost appliqué à la classification entre les classes CN (Cognitively Normal) et MCI (Mild Cognitive Impairment) après extraction des caractéristiques avec ResNet50. La classe "CN" obtient une précision de 0.56 et un rappel de 0.60, tandis que la classe "MCI" montre une meilleure précision (0.65) avec un rappel de 0.61. L'exactitude globale de 0.61 montre que le modèle est raisonnablement performant dans la différenciation entre ces deux classes. Le F1-score moyen (0.60) suggère un bon équilibre entre précision et rappel pour les deux classes.




FIGURE 4.8 – Matrice de confusion pour XGBoost sur CN vs MCI après extraction des features avec ResNet50

La matrice de confusion 4.8 montre que 9 échantillons de la classe "CN" ont été correctement classés, tandis que 6 ont été mal classés comme "MCI". Pour la classe "MCI", 11 échantillons ont été correctement prédits, et 7 ont été incorrectement classés comme "CN". Bien que le modèle parvienne à classer une majorité d'échantillons correctement, il y a encore une certaine confusion entre les deux classes, ce qui est cohérent avec l'exactitude modérée observée dans le tableau.

XGBoost ResNet50 AD vs MCI

Class	Precision	Recall	F1-Score	Support
AD	0.37	0.39	0.38	18
MCI	0.35	0.33	0.34	18
Accuracy			0.36	36
Macro Avg	0.36	0.36	0.36	36
Weighted Avg	0.36	0.36	0.36	36

TABLE 4.10 – Rapport de classification pour XGBoost sur AD vs MCI après extraction des features avec ResNet50

Le tableau 4.10 présente les résultats de classification du modèle XGBoost pour les classes AD (Alzheimer’s Disease) et MCI (Mild Cognitive Impairment) après extraction des caractéristiques avec ResNet50. Le modèle montre des performances limitées, avec une précision de 0.37 pour la classe ”AD” et de 0.35 pour la classe ”MCI”, et des F1-scores respectifs de 0.38 et 0.34. Ces résultats reflètent une grande difficulté du modèle à distinguer correctement entre les deux classes. L’exactitude globale de 0.36 montre que le modèle ne dépasse que de peu les performances d’une classification aléatoire, indiquant une confusion importante entre ”AD” et ”MCI”.

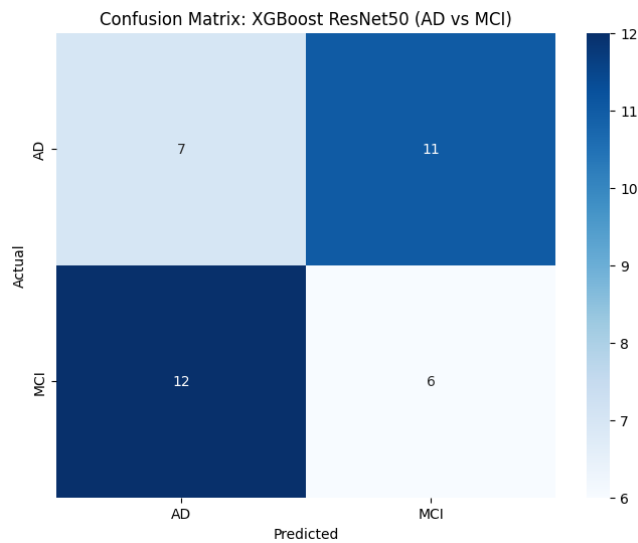


FIGURE 4.9 – Matrice de confusion pour XGBoost sur AD vs MCI après extraction des features avec ResNet50

La matrice de confusion 4.9 montre que sur les 18 échantillons de la classe ”AD”, seulement 7 ont été correctement classés, tandis que 11 ont été incorrectement prédits comme ”MCI”. Pour la classe ”MCI”, 6 échantillons ont été correctement identifiés, mais 12 ont été mal classés comme ”AD”. Ces résultats soulignent la forte confusion entre les deux classes, ce qui est cohérent avec les faibles scores de précision et de rappel observés dans le tableau. Le modèle a clairement du mal à faire la distinction entre ces deux conditions cognitives.

XGBoost ResNet50 AD vs CN

Class	Precision	Recall	F1-Score	Support
AD	0.71	0.94	0.81	18
CN	0.89	0.53	0.67	15
Accuracy			0.76	33
Macro Avg	0.80	0.74	0.74	33
Weighted Avg	0.79	0.76	0.74	33

TABLE 4.11 – Rapport de classification pour XGBoost sur AD vs CN après extraction des features avec ResNet50

Le tableau 4.11 présente les performances du modèle XGBoost appliqué à la classification entre AD (Alzheimer’s Disease) et CN (Cognitively Normal) après extraction des caractéristiques avec ResNet50. Le modèle montre une excellente performance pour la classe ”AD” avec une précision de 0.71 et un rappel très élevé de 0.94, ce qui indique que presque tous les échantillons ”AD” sont correctement identifiés. En revanche, la classe ”CN” présente une précision plus élevée (0.89) mais un rappel plus faible (0.53), ce qui signifie que près de la moitié des échantillons ”CN” sont mal classés. L’exactitude globale du modèle est de 0.76, indiquant une bonne performance pour la distinction entre ces deux classes.




FIGURE 4.10 – Matrice de confusion pour XGBoost sur AD vs CN après extraction des features avec ResNet50

La matrice de confusion 4.10 montre que sur les 18 échantillons ”AD”, 17 ont été correctement classés, avec seulement un échantillon mal classé comme ”CN”. Pour la classe ”CN”, sur les 15 échantillons, 8 ont été correctement classés, tandis que 7 ont été mal prédits comme ”AD”. Ces résultats soulignent une forte capacité du modèle à détecter la classe ”AD”, bien que des améliorations soient nécessaires pour réduire la confusion avec la classe ”CN”.

4.6.3 Classification avec Random Forest après Extraction des Features par InceptionV3

InceptionV3 CN vs MCI

Class	Precision	Recall	F1-Score	Support
CN	0.58	0.47	0.52	15
MCI	0.62	0.72	0.67	18
Accuracy			0.61	33
Macro Avg	0.60	0.59	0.59	33
Weighted Avg	0.60	0.61	0.60	33

TABLE 4.12 – Rapport de classification pour Random Forest sur CN vs MCI après extraction des features avec InceptionV3

Le tableau 4.12 présente les résultats de classification pour Random Forest appliqué à la distinction entre les classes CN (Cognitively Normal) et MCI (Mild Cognitive Impairment) après extraction des caractéristiques à l'aide de InceptionV3. La classe "CN" a une précision de 0.58 et un rappel de 0.47, indiquant une certaine difficulté à bien capturer tous les échantillons de cette classe. En revanche, la classe "MCI" est mieux identifiée, avec une précision de 0.62 et un rappel de 0.72, ce qui montre que le modèle est plus performant pour cette classe. L'exactitude globale est de 0.61, ce qui indique des performances globalement satisfaisantes, bien qu'il y ait une marge d'amélioration, particulièrement pour la classe "CN".




FIGURE 4.11 – Matrice de confusion pour Random Forest sur CN vs MCI après extraction des features avec InceptionV3

La matrice de confusion 4.11 montre la répartition des prédictions du modèle. Pour la classe "CN", sur les 15 échantillons, 7 ont été correctement classés, tandis que 8 ont été mal classés comme "MCI". Pour la classe "MCI", 11 échantillons sur 18 ont été correctement identifiés, tandis que 7 ont été mal classés comme "CN". Ces résultats mettent en lumière une confusion

significative entre les deux classes, ce qui explique les scores modérés de précision et de rappel, surtout pour la classe "CN".

InceptionV3 AD vs MCI

Class	Precision	Recall	F1-Score	Support
AD	0.42	0.44	0.43	18
MCI	0.41	0.39	0.40	18
Accuracy			0.42	36
Macro Avg	0.42	0.42	0.42	36
Weighted Avg	0.42	0.42	0.42	36

TABLE 4.13 – Rapport de classification pour Random Forest sur AD vs MCI après extraction des features avec InceptionV3

Le tableau 4.13 présente les résultats de classification pour le modèle Random Forest appliqué aux classes AD (Alzheimer's Disease) et MCI (Mild Cognitive Impairment) après extraction des caractéristiques avec InceptionV3. Les performances du modèle sont modérées, avec une précision de 0.42 pour la classe "AD" et de 0.41 pour la classe "MCI". Le rappel est similaire pour les deux classes, autour de 0.44 pour "AD" et 0.39 pour "MCI", ce qui montre que le modèle a du mal à distinguer les deux classes. L'exactitude globale du modèle est de 0.42, indiquant que le modèle n'est que légèrement meilleur qu'une prédiction aléatoire.

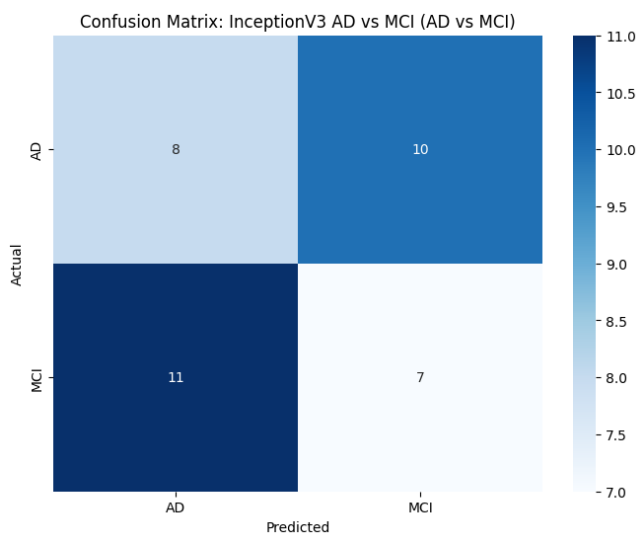


FIGURE 4.12 – Matrice de confusion pour Random Forest sur AD vs MCI après extraction des features avec InceptionV3

La matrice de confusion 4.12 montre que, sur les 18 échantillons "AD", 8 ont été correctement classés, tandis que 10 ont été mal classés comme "MCI". Pour la classe "MCI", 10 échantillons ont été correctement identifiés, tandis que 8 ont été incorrectement classés comme "AD". Cette répartition montre une forte confusion entre les deux classes, ce qui est cohérent avec les faibles scores de précision et de rappel observés dans le tableau. Le modèle a clairement des difficultés à différencier entre "AD" et "MCI".

InceptionV3 AD vs CN

Class	Precision	Recall	F1-Score	Support
AD	0.65	0.94	0.77	18
CN	0.86	0.40	0.55	15
Accuracy			0.70	33
Macro Avg	0.76	0.67	0.66	33
Weighted Avg	0.75	0.70	0.67	33

TABLE 4.14 – Rapport de classification pour Random Forest sur AD vs CN après extraction des features avec InceptionV3

Le tableau 4.14 présente les performances du modèle Random Forest pour la classification entre AD (Alzheimer’s Disease) et CN (Cognitively Normal) après extraction des caractéristiques avec InceptionV3. Le modèle montre de très bonnes performances pour la classe ”AD”, avec une précision de 0.65 et un rappel élevé de 0.94, ce qui signifie que la majorité des échantillons ”AD” sont correctement identifiés. En revanche, la classe ”CN” présente une précision élevée (0.86) mais un rappel plus faible (0.40), indiquant que le modèle a du mal à identifier une part significative des échantillons ”CN”. L’exactitude globale de 0.70 indique des performances raisonnables mais avec une marge d’amélioration, notamment pour mieux capturer la classe ”CN”.




FIGURE 4.13 – Matrice de confusion pour Random Forest sur AD vs CN après extraction des features avec InceptionV3

La matrice de confusion 4.13 montre que sur les 18 échantillons de la classe ”AD”, 17 ont été correctement classés, avec seulement un échantillon mal classé comme ”CN”. En revanche, sur les 15 échantillons de la classe ”CN”, seulement 6 ont été correctement classés, tandis que 9 ont été mal classés comme ”AD”. Cette confusion importante entre ”CN” et ”AD” explique le faible rappel pour la classe ”CN” et les bonnes performances globales pour la classe ”AD”.

4.6.4 Classification avec XGBoost après Extraction des Features par InceptionV3

XGBoost InceptionV3 CN vs MCI

Class	Precision	Recall	F1-Score	Support
CN	0.56	0.60	0.58	15
MCI	0.65	0.61	0.63	18
Accuracy			0.61	33
Macro Avg	0.60	0.61	0.60	33
Weighted Avg	0.61	0.61	0.61	33

TABLE 4.15 – Rapport de classification pour XGBoost sur CN vs MCI après extraction des features avec InceptionV3

Le tableau 4.15 présente les performances du modèle XGBoost appliqué à la classification entre les classes CN (Cognitively Normal) et MCI (Mild Cognitive Impairment) après extraction des caractéristiques avec InceptionV3. Le modèle montre des performances équilibrées, avec une précision de 0.56 pour la classe "CN" et de 0.65 pour la classe "MCI". Le rappel est de 0.60 pour "CN" et de 0.61 pour "MCI", indiquant que le modèle parvient à identifier la majorité des échantillons des deux classes. L'exactitude globale est de 0.61, ce qui est satisfaisant mais montre que le modèle peut encore être amélioré, surtout dans la distinction entre les deux classes.




FIGURE 4.14 – Matrice de confusion pour XGBoost sur CN vs MCI après extraction des features avec InceptionV3

La matrice de confusion 4.14 montre la répartition des prédictions pour les classes "CN" et "MCI". Pour la classe "CN", sur les 15 échantillons, 9 ont été correctement classés et 6 ont été mal classés comme "MCI". Pour la classe "MCI", 11 échantillons ont été correctement identifiés et 7 ont été mal classés comme "CN". Cette confusion, bien que modérée, montre que le modèle a des difficultés à séparer les deux classes de manière parfaitement nette, d'où les scores de précision et de rappel autour de 0.60.

XGBoost InceptionV3 AD vs MCI

Class	Precision	Recall	F1-Score	Support
AD	0.37	0.39	0.38	18
MCI	0.35	0.33	0.34	18
Accuracy			0.36	36
Macro Avg	0.36	0.36	0.36	36
Weighted Avg	0.36	0.36	0.36	36

TABLE 4.16 – Rapport de classification pour XGBoost sur AD vs MCI après extraction des features avec InceptionV3

Le tableau 4.16 montre les performances du modèle XGBoost appliqué à la classification entre AD (Alzheimer’s Disease) et MCI (Mild Cognitive Impairment) après extraction des caractéristiques avec InceptionV3. Le modèle présente des performances faibles, avec une précision de 0.37 pour la classe "AD" et de 0.35 pour la classe "MCI". Les rappels sont également bas, respectivement de 0.39 pour "AD" et 0.33 pour "MCI", ce qui signifie que le modèle ne parvient pas à correctement identifier une majorité des échantillons de ces classes. L’exactitude globale est de 0.36, ce qui est proche des résultats aléatoires et montre que le modèle a des difficultés à distinguer les deux classes.

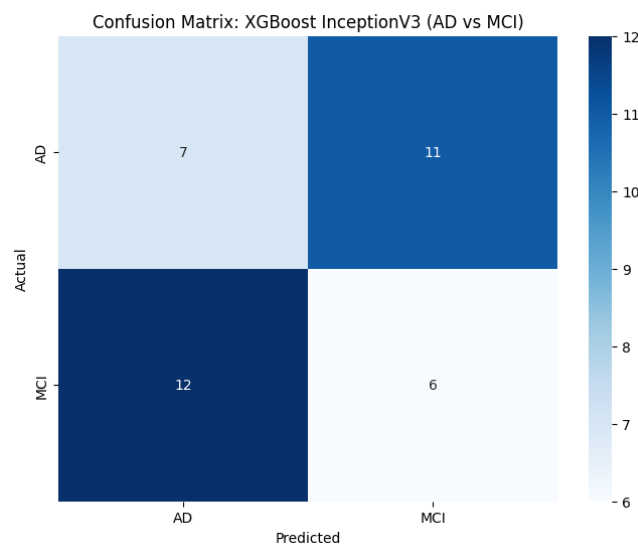


FIGURE 4.15 – Matrice de confusion pour XGBoost sur AD vs MCI après extraction des features avec InceptionV3

La matrice de confusion 4.15 montre que sur les 18 échantillons "AD", seulement 7 ont été correctement classés, tandis que 11 ont été incorrectement classés comme "MCI". Pour la classe "MCI", 6 échantillons ont été correctement identifiés, et 12 ont été mal classés comme "AD". Cela révèle une forte confusion entre les deux classes, ce qui explique les faibles scores de précision, de rappel et de F1 observés dans le tableau. Le modèle a clairement des difficultés à différencier efficacement entre "AD" et "MCI".

XGBoost InceptionV3 AD vs CN

Class	Precision	Recall	F1-Score	Support
AD	0.71	0.94	0.81	18
CN	0.89	0.53	0.67	15
Accuracy			0.76	33
Macro Avg	0.80	0.74	0.74	33
Weighted Avg	0.79	0.76	0.74	33

TABLE 4.17 – Rapport de classification pour XGBoost sur AD vs CN après extraction des features avec InceptionV3

Le tableau 4.17 présente les performances du modèle XGBoost appliqué à la classification entre AD (Alzheimer’s Disease) et CN (Cognitively Normal) après extraction des caractéristiques avec InceptionV3. Le modèle montre de très bonnes performances pour la classe ”AD”, avec une précision de 0.71 et un rappel de 0.94, indiquant que la majorité des échantillons de cette classe sont correctement classés. Pour la classe ”CN”, bien que la précision soit élevée à 0.89, le rappel est plus faible à 0.53, suggérant que le modèle ne parvient pas toujours à identifier correctement les échantillons de cette classe. L’exactitude globale est de 0.76, ce qui démontre une bonne performance générale, même si des améliorations sont nécessaires pour mieux capturer les échantillons de la classe ”CN”.

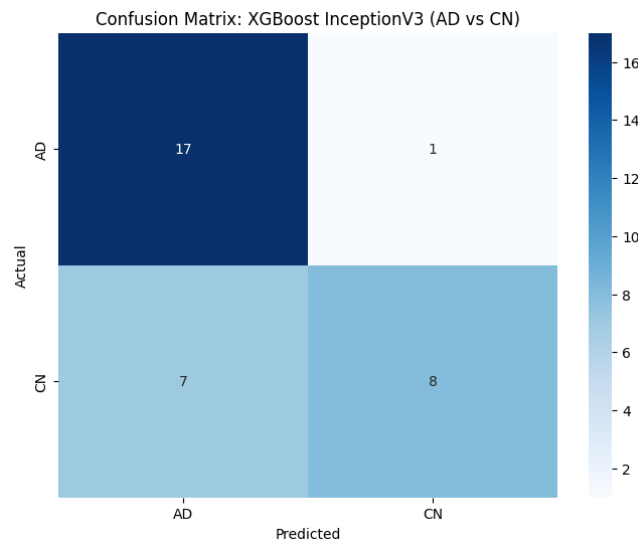


FIGURE 4.16 – Matrice de confusion pour XGBoost sur AD vs CN après extraction des features avec InceptionV3

La matrice de confusion 4.16 montre que sur les 18 échantillons ”AD”, 17 ont été correctement classés, avec seulement un échantillon mal classé comme ”CN”. En revanche, sur les 15 échantillons ”CN”, 8 ont été correctement classés, tandis que 7 ont été mal classés comme ”AD”. Ces résultats montrent une forte capacité du modèle à détecter les échantillons ”AD”, mais une certaine confusion persiste dans la classification des échantillons ”CN”, ce qui explique le faible rappel pour cette classe.

4.6.5 Comparaison des Performances Binaires (ResNet, InceptionV3)

4.7 Comparaison des Performances Binaires (ResNet50 vs InceptionV3)

Cette section présente une comparaison des performances des modèles ResNet50 et InceptionV3 pour la classification binaire (AD/NC, AD/MCI, NC/MCI) en utilisant les algorithmes Random Forest et XGBoost.

4.7.1 Tableau comparatif des performances

Modèle	Algorithme	Comparaison Binaire	Précision	Rappel	F1-Score	Exactitude Globale
ResNet50	Random Forest	CN vs MCI	0.50	0.47	0.48	0.55
		AD vs MCI	0.50	0.44	0.47	0.50
		AD vs CN	0.71	0.94	0.81	0.76
	XGBoost	CN vs MCI	0.56	0.60	0.58	0.61
		AD vs MCI	0.37	0.39	0.38	0.36
		AD vs CN	0.71	0.94	0.81	0.76
InceptionV3	Random Forest	CN vs MCI	0.58	0.47	0.52	0.61
		AD vs MCI	0.42	0.44	0.43	0.42
		AD vs CN	0.65	0.94	0.77	0.70
	XGBoost	CN vs MCI	0.56	0.60	0.58	0.61
		AD vs MCI	0.37	0.39	0.38	0.36
		AD vs CN	0.71	0.94	0.81	0.76

TABLE 4.18 – Comparaison des performances binaires (ResNet50 vs InceptionV3) avec Random Forest et XGBoost pour les classifications AD/NC, AD/MCI, et NC/MCI.

4.7.2 Analyse des performances

— NC vs MCI :

— InceptionV3 montre une meilleure performance par rapport à ResNet50 pour la comparaison NC vs MCI avec Random Forest, atteignant une exactitude de 0.61 contre 0.55 pour ResNet50.

— Pour XGBoost, les deux modèles montrent des performances similaires, tous deux atteignant une exactitude de 0.61.

— AD vs MCI :

— Les performances sont proches pour les deux modèles avec XGBoost, chacun ayant un F1-Score de 0.38 et une exactitude de 0.36.

— Avec Random Forest, ResNet50 a un avantage avec une exactitude de 0.50 et un F1-Score de 0.47, contre 0.42 pour InceptionV3.

— AD vs NC :

— Pour la classification AD vs NC, les deux modèles obtiennent des performances similaires avec XGBoost, avec un F1-Score de 0.81 et une exactitude de 0.76.

— Avec Random Forest, ResNet50 montre de meilleures performances avec un F1-Score de 0.81 contre 0.77 pour InceptionV3.

4.8 Limitation et Perspectives

4.8.1 Limitations

Performance des Modèles : Les résultats obtenus avec les modèles ResNet50 et InceptionV3 montrent des performances globales limitées, en particulier pour la classification de la classe MCI. Les F1-Scores pour cette classe varient entre 0.29 et 0.44, indiquant une difficulté significative à discriminer correctement cette catégorie.

Variabilité des Données : La variabilité intra-classe dans les images de MCI pourrait contribuer à la complexité de la classification. Les images de cette classe présentent souvent des caractéristiques similaires à celles des autres classes, rendant leur distinction plus difficile.

Approche Multimodale : Bien que l'approche multimodale ait été mise en œuvre, elle n'a pas permis d'améliorer significativement les performances, notamment pour la classe MCI. Cela suggère que d'autres méthodes d'extraction ou de prétraitement des données pourraient être nécessaires pour optimiser les résultats.

4.8.2 Perspectives

Amélioration des Modèles : Des recherches futures pourraient explorer l'intégration de modèles plus avancés ou hybrides qui combinent plusieurs architectures pour améliorer la classification, notamment en utilisant des techniques d'ensemble qui pourraient renforcer les performances sur les classes difficiles comme MCI.

Augmentation des Données : L'application de techniques d'augmentation de données pourrait aider à enrichir le jeu de données, en créant des variations supplémentaires des images existantes pour mieux entraîner les modèles sur les classes moins représentées.

Exploration de Nouvelles Méthodes : L'exploration de nouvelles méthodologies d'apprentissage, telles que l'apprentissage par transfert plus sophistiqué ou l'apprentissage auto-supervisé, pourrait offrir des améliorations significatives dans la précision de classification.

4.8.3 Conclusion

Les résultats montrent que InceptionV3 est légèrement meilleur que ResNet50 pour la classification NC vs MCI, tandis que ResNet50 obtient de meilleures performances dans les comparaisons AD vs MCI et AD vs NC, surtout avec l'algorithme Random Forest. Les performances sont similaires pour les deux modèles avec XGBoost, suggérant que le choix entre les deux réseaux dépend du type de classification binaire et de l'algorithme utilisé.

Conclusion

En conclusion, ce projet de fin d'études a permis d'explorer et de mettre en œuvre des techniques avancées d'apprentissage automatique pour le diagnostic assisté de la maladie d'Alzheimer à partir d'images IRM. L'utilisation des modèles ResNet50 et InceptionV3 pour l'extraction des caractéristiques, ainsi que des algorithmes de classification comme Random Forest et XGBoost, a permis de montrer le potentiel de l'intelligence artificielle pour automatiser et améliorer la détection des différentes phases de la maladie.

Les résultats obtenus montrent que la classification binaire entre les groupes AD et NC a donné les meilleures performances, avec des taux de précision et de rappel relativement élevés, en particulier avec l'algorithme Random Forest appliqué aux caractéristiques extraites par ResNet50. Cependant, la classification multimodale et la distinction entre les groupes MCI et les autres groupes (NC et AD) restent un défi, probablement en raison de la nature intermédiaire et variable des caractéristiques de ce groupe.

Le choix entre ResNet50 et InceptionV3 dépend du type de classification et de l'algorithme de classification utilisé. InceptionV3 a montré de meilleures performances pour la comparaison NC vs MCI, tandis que ResNet50 est plus performant dans les classifications AD vs NC et AD vs MCI.

Ce travail ouvre la voie à plusieurs perspectives d'amélioration. D'une part, il serait intéressant d'explorer des architectures plus complexes ou des techniques d'optimisation comme l'apprentissage auto-supervisé, qui pourrait permettre aux modèles d'extraire des représentations plus robustes des images médicales en l'absence d'annotations explicites. L'apprentissage auto-supervisé, en exploitant les informations inhérentes aux données, pourrait s'avérer particulièrement bénéfique dans des contextes où l'étiquetage manuel est coûteux ou limité, tout en améliorant la capacité du modèle à distinguer les phases de la maladie. De plus, l'intégration de l'apprentissage fédéré ou continu pourrait permettre une meilleure gestion de la variabilité des images et améliorer les résultats pour la classe MCI. D'autre part, l'augmentation des données et l'ajout de nouvelles vues (axiale, coronale, sagittale) enrichiraient les modèles et augmenteraient leur capacité de généralisation.

Enfin, l'intégration de ces modèles dans un outil de diagnostic assisté par ordinateur pourrait offrir une réelle valeur ajoutée aux professionnels de la santé, en facilitant la détection précoce de la maladie et en améliorant la prise en charge des patients.

Bibliographie

- [1] France Alzheimer, *Premiers repères sur la maladie d'Alzheimer*, disponible sur : [francealzheimer](https://francealzheimer.org/)
- [2] World Health Organization, *Dementia*, disponible sur : [who.int/news-room/dementia](https://www.who.int/news-room/dementia)
- [3] Alzheimer's Disease International. World Alzheimer Report 2023 : Reducing dementia risk : never too early, never too late. London (England) : Alzheimer's Disease International ; 2023.
- [4] Alzheimer's Disease International. World Alzheimer Report 2023 : Reducing dementia risk : never too early, never too late. London (England) : Alzheimer's Disease International ; 2023. Chapter 1, The epidemiology and impact of dementia ; p. 11-25.
- [5] CEN Neurologie. Confusion, troubles cognitifs et démence [Internet]. Paris (France) : CEN Neurologie ; 2023. Available from : <https://www.cen-neurologie.fr/second-cycle/confusion-troubles-cognitifs-demence>
- [6] Tombaugh TN, McIntyre NJ. The Mini-Mental State Examination : A comprehensive review. *J Am Geriatr Soc.* 1992 ;40(9) :922-935.
- [7] Alzheimer's Disease International. World Alzheimer Report 2023 : Reducing dementia risk : never too early, never too late. London, England : Alzheimer's Disease International ; 2023.
- [8] Mayo Clinic. Alzheimer's stages : How the disease progresses [Internet]. . Disponible sur : [mayoclinic.org](https://www.mayoclinic.org)
- [9] Pini L, Pievani M, Bocchetta M, Altomare D, Bosco P, Cavedo E, et al. Brain atrophy in Alzheimer's Disease and aging. *Alzheimers Dement.* 2016 ;12(1) :1-10. doi :10.1016/j.jalz.2015.05.001.
- [10] Author(s). Diagnostic Tools for Alzheimer's Disease : A Narrative Review Based on Our Own Research Experience. *Journal Name.* Year ;Volume(Issue) :Pages. doi :DOI.
- [11] Folstein MF, Folstein SE, McHugh PR. "Mini-mental state". A practical method for grading the cognitive state of patients for the clinician. *J Psychiatr Res.* 1975 ;12(3) :189-198. doi :10.1016/0022-3956(75)90026-6.
- [12] Dubois B, Slachevsky A, Litvan I, Pillon B. Clinical diagnosis of Alzheimer's disease : recommendations of the International Working Group. *Lancet Neurol.* 2007 ;6(12) :1145-1153. doi :10.1016/S1474-4422(07)70283-5.
- [13] Nature. Blood test could predict Alzheimer's disease years before symptoms arise. *Nature.* 2024. Disponible sur : [Nature](https://www.nature.com).
- [14] Nature. Blood test could predict Alzheimer's disease years before symptoms arise. *Nature.* 2024 . Disponible sur : [Nature](https://www.nature.com).
- [15] Vidal. IRM (imagerie par résonance magnétique nucléaire) [Internet]. 2017 [cité le 20 sept. 2024]. Disponible sur : <https://www.vidal.fr/sante/examens-tests-analyses-medicales/irm-imagerie-resonance-magnetique.html>.

- [16] Imagerie par résonance magnétique. Wikipedia. [cité le 20 sept. 2024]. Disponible sur : [wikipedia](#)
- [17] Elster AD. Gradient echo imaging : techniques and acronyms. *Radiology*. 1993;186(1) :1-8. doi :10.1148/radiology.186.1.8416546.
- [18] CNP-MN. Les fondamentaux : Chapitre 10 - Traitement de l'image reconstruite [Internet]. Disponible sur : [www.cnp-mn.fr](#)
- [19] Frisoni GB, Fox NC, Jack CR, Scheltens P, Thompson PM. The clinical use of structural MRI in Alzheimer disease. *Nat Rev Neurol*. 2010;6(2) :67-77. doi :10.1038/nrneurol.2009.216.
- [20] Dubois B, Hampel H, Feldman HH, et al. Preclinical Alzheimer's disease : definition and diagnostic criteria. *Alzheimers Dement*. 2016;12(3) :292-298. doi :10.1016/j.jalz.2016.02.002.
- [21] Weiner MW, Aisen PS, Bain LJ, et al. The Alzheimer's Disease Neuroimaging Initiative : Progress and Plans. *Alzheimers Dement*. 2010;6(3) :202-211. doi :10.1016/j.jalz.2010.03.005.
- [22] Jack CR Jr, Bennett DA, Blennow K, et al. A/T/N framework for Alzheimer's disease : a report of the National Institute on Aging-Alzheimer's Association workgroups on diagnostic guidelines for Alzheimer's disease. *Alzheimers Dement*. 2016;12(3) :292-297. doi :10.1016/j.jalz.2016.09.001.
- [23] Petersen RC, Aisen PS, Beckett LA, et al. Current concepts in mild cognitive impairment. *Arch Neurol*. 2010;67(3) :298-304. doi :10.1001/archneurol.2009.333.
- [24] Neuroimaging Informatics Technology Initiative (NIFTI). Wikipedia. [cité 2024 Sep 20]. Disponible sur : [wikipedia](#)
- [25] La neuro-imagerie au service de la maladie d'Alzheimer - Imagerie et cognition. *Med Sci (Paris)*. 2011;27(2) :193-198. doi :10.1051/medsci/2011272193.
- [26] *BioMed Central*. [biomedcentral](#)
- [27] Shanmuga Skandh V, Shahina A, Nayeemulla Khan A. *Detection of Alzheimer's Disease on Brain MRI using Inception V3 Network*. *International Journal of Engineering Research and Technology (IJERT)*, 2020. [ijert](#)
- [28] Slam F, Rahman MH, Nurjahan, Hossain MS, Ahmed S. *A Novel Method for Diagnosing Alzheimer's Disease from MRI Scans using the ResNet50 Feature Extractor and the SVM Classifier*. *International Journal of Engineering Research and Technology (IJERT)*, 2023;14(6) :1-5. Disponible sur : [thesai.org](#)
- [29] He K, Zhang X, Ren S, Sun J. *Deep Residual Learning for Image Recognition*. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016;770-778.
- [30] Auteur F, Auteur S, Auteur T. *Performance Evaluation of Deep CNN-Based Crack Detection and Localization Techniques for Concrete Structures*. *Journal/Conference Name*, 2023. Disponible sur : [researchgate](#)
- [31] Babenko A, Lempitsky V. Aggregating Local Deep Features for Image Retrieval. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. 2015; 1-9.
- [32] Babenko A, Lempitsky V. Aggregating Local Deep Features for Image Retrieval. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. 2015; 1-9.
- [33] Breiman L. Random forests. *Machine Learning*. 2001; 45(1) : 5-32.

- [34] Chen T, Guestrin C. XGBoost : A Scalable Tree Boosting System. In : Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, CA ; 2016. p. 785-794.
- [35] Pan S, Yang Q. A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*. 2010 ; 22(10) : 1345-1359.
- [36] Do S, Song KD, Chung JW. Basics of Deep Learning : A Radiologist's Guide to Understanding Published Radiology Articles on Deep Learning.

Résumé

Ce rapport de stage explore l'utilisation des techniques d'apprentissage profond pour le diagnostic assisté par ordinateur de la maladie d'Alzheimer, en se concentrant sur l'analyse des images IRM. Réalisé au sein du laboratoire XLIM, l'étude applique les modèles ResNet50 et InceptionV3 pour l'extraction des caractéristiques des images cérébrales, suivis d'une classification utilisant les algorithmes Random Forest et XGBoost. Les résultats obtenus montrent une amélioration significative de la précision dans la détection des différents stades de la maladie, permettant ainsi une aide précieuse pour le diagnostic précoce. L'accent est mis sur l'importance de l'automatisation dans l'analyse des images médicales, en vue de rendre les processus plus rapides et fiables.

Abstract

This internship report explores the use of deep learning techniques for computer-aided diagnosis of Alzheimer's disease, focusing on MRI image analysis. Conducted at the XLIM laboratory, the study applies ResNet50 and InceptionV3 models for the extraction of brain image features, followed by classification using Random Forest and XGBoost algorithms. The results show a significant improvement in the accuracy of detecting the different stages of the disease, thus providing valuable support for early diagnosis. Emphasis is placed on the importance of automation in medical image analysis, aiming to make the processes faster and more reliable.