



Université Ibn Khaldoun-Tiaret
Faculté des Science de la Matière
Département de Physique

Mémoire

Présenté par :

OULD MOHAMED AMINA

SESSE KAOUTHER

Pour obtenir le diplôme de

Master

Spécialité : Physique Médicale

Sujet :

**Système d'aide au diagnostic pour la détection précoce de
la maladie d'Alzheimer**

Soutenu le :25 juin 2025

Devant le jury :

Mr. TURKI DJAMEL	Président	Professeur	UNIV.Tiaret
Melle. MOKEDDEM FATIMA	Examinatrice	MCB	UNIV.Tiaret
Mr. OUAMRI MOKHTAR	Examineur	MCB	UNIV.Tiaret
Mr. TRARI BENAÏSSA	Encadrant	MCA	UNIV.Tiaret
Melle. LATIFA HOURIA	Co_ Encadrante	Docteur	UNIV.Blida

ANNEE UNIVERSITAIRE 2024/2025

Remerciements

Nous remercions tout d'abord Dieu Tout-Puissant, qui nous a accordé la force, la patience et la volonté d'achever ce travail dans les meilleures conditions.

Nous exprimons notre profonde reconnaissance à notre encadrant, Monsieur TRARI BENAÏSSA , pour sa disponibilité, ses conseils judicieux, son suivi rigoureux et sa confiance tout au long de la réalisation de ce mémoire. Son encadrement scientifique et sa bienveillance ont été déterminants dans l'aboutissement de notre projet.

Nous adressons également nos sincères remerciements à Madame LATIFA HOURIA, notre co-encadrante, pour son accompagnement attentif, sa réactivité et son soutien constant. Sa contribution et son implication ont grandement enrichi notre travail.

Nous souhaitons également remercier le responsable de la spécialité :HALLES LADJELet l'ensemble des enseignants et enseignantes de la faculté, pour la qualité de l'enseignement qu'ils nous ont transmis durant ces années de formation, ainsi que le personnel administratif pour leur aide et leur disponibilité.

Nous remercions sincèrement les membres de jury Professeur TURKI.DJ, Docteur MOKKEDEM.F et Docteur OUAMRI.M.

Et nous remercions monsieur :SESSE YEHIA pour la touche particulière qu'il a apportée à ce mémoire .

Enfin, nous exprimons notre gratitude à nos camarades, collègues et amis, pour leur collaboration, leur soutien et les moments partagés tout au long de ce parcours universitaire.

إهداء

بسم الله الرحمن الرحيم

الحمد لله الذي علم بالقلم، علم الإنسان ما لم يعلم، الحمد له على نعمة العقل، وعلى توفيقه وتيسيره في كل خطوة، الحمد له في المبدأ والمنتهى، وفي كل لحظة تعبٍ تُكلَّلُ بالنجاح، وفي كل دعوة صادقةٍ استُجيبَت في الخفاء

إلى نفسي، التي عرفت في هذا الدرب معنى الصبر، وذاقت مرارة الإخفاق، لكنها أصرّت، وواصلت، ولم تتحني

إلى تلك النفس التي سهرت الليالي، وجاهدت في صمت، وسقطت مرات ووقفت من جديد... هذا الإهداء لك، لأنك لم تيأس، ولأنك آمنت أن بعد العسر يُولد الأمل

إلى أبي العزيز، الرجل الذي علمني أن الحياة لا تُمنح بل تُنتزع، وأن للكرامة ثمن، وأن العلم سلاح لا يُفترط فيه... شكراً لكل ما قدّمت، ولكل صبرٍ منك في صمت

إلى أمي الحبيبة، نبع الحنان الذي لا يجفّ، وسندي الذي لا يتبدّد... لك يا من كنت الدعاء الصادق، والصوت الذي يدعو لي في ظهر الغيب، والحضن الذي لا يعوّض، والروح التي أحيا بها

إلى إخوتي الأعزاء: صلاح الدين، نور الهدى، وسندس... كنتم النور حين أظلمت الطرق، والونس حين طغت الوحدة، والدافع الخفي وراء استمرارتي... وجودكم طمأنينة

وإلى روح خالتي الغالية حورية، رحمها الله، التي كانت تناديني دوماً بـ"كوثرتي"، وتستقبلني بعناقٍ لا يُنسى، وبقلبٍ أوسع من الدنيا... ستظلين حيّة في وجداني، وحنانك لا يُعوّض. هذا العمل أهديه أيضاً لروحك الطيبة

وإلى عمي العزيز يحيى، الذي لم يبخل عليّ بشيء، فكان السند والدعم في كل الظروف. فتح لي بيته قبل قلبه، وكان الكرم والدفء والترحيب عنوان كل لحظة قضيتها عنده. شكراً لك على كرمك، طيبتك، ومساندتك التي كانت لي عوناً حقيقياً في هذا العمل

وإلى صديقتي وشريكتي في هذا العمل، أمينة ولد محمد، التي كانت أكثر من زميلة، كانت أختاً وسنداً في كل خطوة. شكراً على روحك الجميلة، وعلى تقاسمك معي هذا المشوار بكل ما فيه من تعب وأمل. فخور بأننا أنجزنا هذا الطريق معاً

كما أشكر صديقتي العزيزة ميسّة، على تشجيعها الدائم، دعواتها الصادقة، ووجودها الذي كان مصدر دعم وراحة طيلة هذا المشوار

إلى زميلاتي وأخواتي في الدفعة، إلى كل من شاركت معهن الدروس، والمراجعة، والقلق، والابتسامة، والمساندة... أنتن أكثر من زميلات، أنتن جزء من ذاكرة هذا الطريق، ورفيقات مسيرة لن تُنسى

وإلى كل من دعمني بكلمة، أو نظرة ثقة، أو دعاء صامت في ظهر الغيب،

إلى كل من آمن بي في لحظة شك، إلى من قال لي "واصل"، ولو بكلمة بسيطة، ولكنها غيّرت الكثير

أهديكم هذا البحث، ثمرة سنوات من التعب، وجزءاً من حلمي الذي صار اليوم واقعاً. هو منّي، لكنّه يحمل منكم الكثير

كوثر

Dédicace

Je dédie ce travail, tout d'abord... à moi-même. À cette jeune fille qui a cru en son rêve, qui a préservée avec détermination et qui a avancé à pas sûrs vers la réussite. À celle qui n'a jamais abandonné, malgré tous les défis. Sois fière de tout ce que tu as accompli.

Puis, À l'âme de ma chère grand-mère, cette femme en or dans ma vie qui m'a offert un amour pur et qui a toujours été un refuge chaleureux pour moi. Tu es partie en corps, mais tu restes vivante dans mon cœur et ma mémoire.

À mes chers parents les piliers de ma vie, vous qui avez cru en moi même quand je doutais de moi-même. Merci pour votre amour inconditionnel, votre patience infinie, et vos sacrifices silencieux qui m'ont permis d'avancer. Ce travail est aussi le vôtre, car sans vous, rien n'aurait été possible.

À mes frères et sœurs, à mes amis, à ceux qui m'ont soutenue par une parole, un sourire ou une prière...

*À ma binôme **Kaouther**, merci d'avoir été plus qu'une partenaire de travail une alliée, une amie, une source de soutien dans chaque étape de ce parcours.*

A tous ceux que j'aime et qui m'aiment sincèrement.

Amina

Résumé

La maladie d'Alzheimer, forme la plus répandue de démence, constitue un enjeu majeur de santé publique en raison du vieillissement croissant de la population mondiale. Elle se manifeste par une dégénérescence progressive des fonctions cognitives, notamment la mémoire, le langage et l'orientation. Le diagnostic précoce représente un défi crucial pour ralentir la progression de la maladie et améliorer la qualité de vie des patients.

Ce mémoire explore l'apport de l'intelligence artificielle, en particulier des méthodes d'apprentissage profond (Deep Learning) et d'apprentissage automatisé (Machine Learning), dans la détection automatisée de la maladie d'Alzheimer à partir d'images IRM structurales pondérées en T1. Une revue de la littérature met en évidence l'efficacité des réseaux neuronaux convolutifs (CNN), des réseaux 3D et des approches hybrides, dans l'extraction de caractéristiques discriminantes et la classification des patients selon différents stades de la pathologie.

L'approche proposée repose sur un pipeline rigoureux intégrant le prétraitement des données (correction des artéfacts, normalisation spatiale via DARTEL, segmentation des tissus), la conversion des volumes 3D en coupes 2D informatives, et l'entraînement d'un modèle CNN pour la classification automatique des sujets en trois classes : Alzheimer (AD), Trouble Cognitif Léger (MCI) et témoins cognitivement normaux (CN). Les données utilisées proviennent de la base ADNI, reconnue pour la qualité et la richesse de ses annotations cliniques.

Les résultats expérimentaux soulignent la pertinence de l'approche développée et démontrent le potentiel des techniques de Deep Learning pour le diagnostic assisté par ordinateur de la maladie d'Alzheimer, ouvrant ainsi la voie vers une médecine plus précise, personnalisée et **prédictive**.

Les mots clés: Maladie d'Alzheimer – IRM – Deep Learning – CNN – Diagnostic automatique

Abstract:

Alzheimer's disease, the most common form of dementia, represents a growing public health challenge due to the aging global population. It is characterized by a gradual decline in cognitive functions, including memory, language, and spatial orientation. Early diagnosis is essential to slow disease progression and improve patient quality of life.

This thesis investigates the potential of artificial intelligence, particularly deep learning and machine learning techniques, for the automatic detection of Alzheimer's disease using T1-weighted structural MRI images. A literature review highlights the effectiveness of Convolutional Neural Networks (CNNs), 3D networks, and hybrid approaches in extracting discriminative features and classifying patients across different stages of the disease.

The proposed approach is based on a structured pipeline involving image preprocessing (artifact correction, spatial normalization with DARTEL, tissue segmentation), conversion of 3D volumes into informative 2D slices, and CNN training to classify subjects into three categories: AD, MCI, CN

Keywords: Alzheimer's disease – MRI – Deep Learning – Convolutional Neural Networks – Automated Diagnosis

الملخص:

يعدّ مرض ألزهايمر، وهو أكثر أنواع الخرف شيوعاً، تحدياً صحياً عالمياً متزايداً بسبب التقدّم في العمر لدى السكان. يتمثل هذا المرض في تدهور تدريجي للوظائف المعرفية مثل الذاكرة واللغة والتوجه المكاني. ويُعتبر التشخيص المبكر عاملاً أساسياً في إبطاء تطوّر المرض وتحسين جودة حياة المريض.

يهدف هذا العمل إلى استكشاف إمكانيات الذكاء الاصطناعي، لا سيما تقنيات التعلم العميق (Deep Learning , Machine Learning)، في الكشف الآلي عن مرض ألزهايمر انطلاقاً من صور الرنين المغناطيسي الهيكلية (IRM T1) وقد أبرزت مراجعة الأدبيات فعالية الشبكات العصبية الالتفافية (CNN) ، والشبكات ثلاثية الأبعاد (3D CNN) ، والمقاربات الهجينة في استخراج الخصائص المميزة وتصنيف المرضى حسب مراحل المرض.

يعتمد النموذج المقترح على سلسلة منهجية دقيقة تشمل المعالجة القبلية للبيانات) تصحيح التشوهات، التسوية المكانية باستخدام خوارزمية DARTEL ، تجزئة الأنسجة(، تحويل الصور ثلاثية الأبعاد إلى مقاطع ثنائية الأبعاد، ثم تدريب نموذج CNN لتصنيف الحالات إلى ثلاث فئات: مرضى ألزهايمر (AD) ، اضطراب معرفي خفيف (MCI) ، وأشخاص أصحاء معرفياً (CN). وقد تم استخدام قاعدة بيانات ADNI نظراً لجودتها وغناها بالبيانات السريرية المصنفة بدقة.

أظهرت النتائج التجريبية فعالية المقاربة المعتمدة، مؤكدة قدرة تقنيات التعلم العميق على دعم تشخيص مرض ألزهايمر، مما يُمهّد نحو طبّ أكثر دقة وتخصيصاً وتنبؤاً.

الكلمات المفتاحية مرض الزهايمر – الرنين المغناطيسي – التعلم العميق – الشبكات العصبية الالتفافية – التشخيص الآلي

Listes des abréviations

AD: Alzheimer Disease, (Maladie d'Alzheimer)

MCI : Mild Cognitive Impairment, (Trouble cognitif léger)

EMCI : Early Mild Cognitive Impairment (trouble cognitif léger tôt)

LMCI : Late Mild Cognitive Impairment (trouble cognitif léger tard)

CN : Cognitively Normal (sujet cognitivement normaux)

MRI : Magnetic Resonance Imaging (Imagerie par Résonance magnétique)

sMRI : Structural Magnetic Resonance Imaging (Imagerie par Résonance magnétique)

RMN : Résonance magnétique nucléaire

FOV: Field of view (champ de vue)

ROI: Régions d'intérêt

TE : temps d'écho

TR : Temps de répétition

DNF : Dégénérescences neurofibrillaires

LCR : Liquide céphalo rachidien

IA : Intelligence artificielle

ML : Machine Learning

DP : Deep Learning

CNN : Convolutional Neural Network

ADNI : Alzheimer's Disease Neuroimaging

MMSE : Mini-Mental State Examination (mini-examen de l'état mental)

WM : White Matter (substance blanche)

GM: Gray Matter(Matière grise)

SPM: Statistical Parametric Mapping

DARTEL: Diffeomorphic Anatomical Registration Exponentiated Lie algebra

SVM: Support Vector Machine

KNN: K-Nearest Neighbors

RF: Random Forest

FC: Fully connected

Table des matières

Remerciements.....	1
اهداء.....	3
Dédicace.....	4
Résumé	5
Abstract:.....	6
الملخص:.....	7
Listes des abréviations	8
LISTE DES ILLUSTRATIONS GRAPHIQUES.....	15
LISTE DES ILLUSTRATIONS DES TABLEAUX	17
Chapitre 1.....	19
La Maladie d'Alzheimer	19
1.1. Introduction	20
1.2.La maladie d’Alzheimer.....	21
1.2.1Définition :	21
1.3.Motivation	22
1.4.Physiopathologie de la maladie.....	23
1.4.1.Les plaques amyloïdes.....	23
1.4.1.2.Les dégénérescences neurofibrillaires (DNF)	23
1.5.Évolution de la maladie et stades cliniques.....	24
1.5.1.Phase préclinique.....	24
1.5.2.Trouble cognitif léger (MCI - Mild Cognitive Impairment)	24
1.5.1.3Phase clinique de la maladie d’Alzheimer	24
1.6.Biomarqueurs de la Maladie d'Alzheimer.....	25
1.7.Marqueurs Topographiques	25
1.7.1Analyse volumétrique par IRM cérébrale :	25
1.7.1.1.Atrophie globale	25

1.7.1.2. Atrophie diffusée	25
1.7.1.3 Atrophie focale.....	25
1.7.2 Marqueurs isotopiques par tomographie par émission de positons (TEP) : ...	25
1.7.3 Marqueurs Physiopathologiques	26
1.8 Imagerie par Résonance Magnétique (IRM)	26
1.9 Principe physique de l'IRM.....	27
1.9.1 Relaxation longitudinale (T_1 ou relaxation spin-réseau)	29
1.9.2 Relaxation transversale (T_2 ou relaxation spin-spin)	29
1.10 Formation de l'image en IRM.....	29
1.10.1 Sélection de coupe.....	30
1.10.2 Encodage de fréquence	30
1.10.3 Encodage de phase	30
1.11 Pondération des Images en IRM	30
1.11.1 Le temps d'écho (TE)	31
1.11.2 Le temps de répétition (TR).....	31
1.11.3 Pondération T_1	31
1.11.4 Pondération T_2	31
1.11.5 Pondération en densité de protons (PD).....	31
1.12 Imagerie Structurale et Détection des Altérations Cérébrales.....	32
1.13 Conclusion.....	33
Chapitre 2.....	35
Détection automatique de la maladie d'Alzheimer par IRM : revue de la littérature.....	35
2.1 Introduction	36
2.2 L'Intelligence Artificielle et Son Impact en Imagerie Médicale	36
2.2.1 Le Machine Learning (ML) :	36
2.2.2 Le Deep Learning (DL) :	37
2.3 Revue des méthodes de classification de la maladie d'Alzheimer.....	38
2.4 Discussion	44
2.5 Rôle des bases de données	44
2.6 L'importance du prétraitement	44

2.7 Diversité des méthodes de classification.....	45
2.8 Classification.....	45
2.9 Performance et limites.....	45
2.10 Apports du Deep Learning	45
2.11 Conclusion.....	45
Chapitre 3.....	47
Approche proposée.....	47
3.1 Introduction :.....	48
2.3 Approche proposée.....	48
3.3 Collecte et description des données	50
3.3.1Data sets	50
3.3.2Description démographique des sujets :.....	51
3.4 Prétraitement des données IRM	52
3.5 Conversion des Images 3D en 2D et Sélection de Coupes Informatives.....	55
3.6 Classification par Réseaux Neuraux Convolutifs (CNN)	56
3.6.1 Introduction aux CNN	56
3.6.2 Optimisation	62
3.6.3 Régularisation.....	63
3.6.4 La modification de l'architecture du réseau	63
Architecture proposée	63
3.7Présentation des Classifieurs Utilisés	65
3.7.1 Support Vector Machine (SVM) :	65
3.7.2 K-Nearest Neighbors (KNN).....	66
3.7.3 Random Forest (RF)	66
3.8Conclusion.....	66
Chapitre 4.....	67
Résultats et Discussion	67
4.1 Introduction	68
4.2 Environnement de travail	68
4.3Évaluation de la performance du modèle	68

4.3.1 Rappel sur les métriques d'évaluation	68
4.3.2 Matrice de confusion	69
4.4 Expérience 1 : Classification avec CNN	70
4.4.1 Résultats	70
4.4.2 Discussion des résultats de la première expérimentation	72
4.5 Expérience 2 : Extraction de caractéristiques via CNN + Classifieurs classiques	73
4.5.1 Méthodologie	73
4.5.2 Résultats obtenus	73
4.5.2.1 Résultats pour la matière grise	74
4.5.2.3 Résultats pour le cerveau entier	76
4.5.3 Discussion des résultats de la deuxième expérimentation	78
4.6 Troisième expérimentation : Fusion des caractéristiques extraites par CNN	79
4.6.1 Méthodologie	79
4.7 Résultats expérimentaux	80
4.8 Discussion des résultats	85
4.9 Discussion globale des trois expériences	85
4.10 Conclusion	86
Conclusion générale	87
Annexe A : Anatomie Cérébrale	88
Introduction :	88
1. Le cerveau	88
1.1 Description du cerveau	88
1.2 Variabilité morphologique interindividuelle	91
1.3 Légitimité du recalage non rigide des images cérébrales	92
1.4 Les modalités d'observation du cerveau	95
1.5 Conclusion	96
Annexe B :	98
Autres Architectures populaire de CNN :	98
1. Le Net : un réseau neuronal convolutif simple	98
2. AlexNet :	99

3.VGG :	100
4.Google Net	100
5.ResNet	101
Références	102

LISTE DES ILLUSTRATIONS GRAPHIQUES

Figure 1.1 :Instance de rétrécissement cérébral pour deux sujets : (à gauche) - cerveau témoin normal et (à droite) - cerveau atteint de la maladie d'Alzheimer.....	21
Figure 1.2 :Évolution du pourcentage de certaines causes de décès entre 2000 et 2006 – National Center for Health Statistics.....	23
Figure 1.3 :Une vue en coupe du système d'imagerie par résonance magnétique (IRM).....	27
Figure1.4 : Effet d'un champ magnétique extérieur sur les spins. (a)absence de champs, (b) présence de champs.....	28
Figure 1.5 : Différentes modalités d'images cérébrales IRM : (a) pondération T1 ; (b) pondération T2 ; (c) pondération en densité de protons.....	32
Figure 2.1 :Relation entre l'intelligence artificielle, l'apprentissage automatique (Machine Learning) et l'apprentissage profond (Deep Learning).....	37
Figure 3.1 :Schéma général du pipeline méthodologique proposé pour la classification de la maladie d'Alzheimer à partir d'IRM structurelles	49
Figure 3.2 :Images des trois plans (coronale, sagittale et axiale) ; (a) T1w originales (b) après utilisation de VBM à l'espace natif (visualisé à l'aide de la fonction Check-Reg du logiciel SPM).....	54
Figure 3.3 :les images résultantes des trois plans prétraitées, segmentées et recalées dans l'espace MNI ; (a) Tw1, (b) la matière grise, (c) la matière blanche (visualisé à l'aide de la fonction Check-Reg du logiciel SPM).	55
Figure 3.4Un réseau neuronal simple et un réseau neuronal convolutif.	58
Figure 3.5 :une matrice 4x4 à zéro-padding.....	60
Figure 3.6 :Mécanisme de la fonction RELU.	60
Figure 3.7 :Exemple illustratif des différentes stratégies de pooling (max, moyen et somme) avec une fenêtre de taille 2×2 et un pas de déplacement identique.....	61
Figure 3.8 :Couche entièrement connectée sur une matrice.....	62
Figure 3.9 :Exemple de couche dropout (la probabilité de 50 % apparaît à droite).....	63
Figure 3.10 :architecture de modèle proposée	64
Figure 4.1 :Courbes d'apprentissage (Accuracy et loss) pour l'entraînement du modèle CNN sur les images IRM du cerveau entier	70
Figure 4.2 :Courbes d'apprentissage (Accuracy et loss) pour l'entraînement du modèle CNN sur les images IRM du matière grise.....	71

Figure 4.3 :Matrice de confusion de classification (MG) CNN+ : (a)KNN ; (b) SVM et (C) RF	75
Figure4.4:Matrice de confusion de classification (MB) CNN+ : (a)KNN ; (b) SVM et (C) RF	76
Figure 4.5 :Matrice de confusion de classification (MB) CNN+ : (a)KNN ; (b) SVM et (C) RF	77
Figure 4.6 :Évaluation comparative des classifieurs sur les différentes régions du cerveau" ..	78
Figure 4.7 :Matrice de confusion de classification (Fusion 1) CNN+ : (a)KNN ; (b) SVM et (C) RF.....	81
Figure 4.8 :Matrice de confusion de de classification (Fusion 2) CNN+ : (a)KNN ; (b) SVM et (C) RF.....	82
Figure 4.9 :Matrice de confusion de classification (Fusion 2) CNN+ : (a)KNN ; (b) SVM et (C) RF.....	83
Figure 4.10 :Matrice de confusion de classification (Fusion 2) CNN+ : (a)KNN ; (b) SVM et (C) RF.....	84
Figure 4.11 :Évaluation comparative des classifieurs sur les différentes fusions des régions cérébrale"	84.
<i>FigureA.1 :Anatomie cérébrale (illustrations modifiées d'après http://www.abieducation.com)</i>	90
<i>FigureA.2 :Développement embryonnaire de l'encéphale humain (illustration modifiée d'après [Marieb 93])</i>	93
<i>Figure A.3 ;illustre les conséquences du manque d'espace au sein de la boîte crânienne sur le développement de l'encéphale (illustration modifiée d'après [Marieb, 1993]).</i>	94
Figure B.1 : Un exemple de l'architecture LeNet.....	99
Figure B.2 :Architecture AlexNet.	100

LISTE DES ILLUSTRATIONS DES TABLEAUX

Table 2.1 :l'état de l'art.....	42
Table 3.2 :Données statistiques liées aux sujets	52
Table 3.3:Propriétés des couches pour l'architecture 2DCNN proposée.....	64
Table 4.4:Les performance pour matière grise.....	74
Table 4.5:Les performances de la matière blanche	75
Table 4.6 :Les performances du cerveau entier	76
Table 4.7:Les performances du Fusion 1.....	80
Table 4.8:Les performances du Fusion 2.....	81
Table 4.9:Les performances du Fusion 3.....	82
Table 4.10:Les performances du Fusion 4.....	83

Introduction Générale

La maladie d'Alzheimer (MA) représente aujourd'hui l'une des principales préoccupations de santé publique à l'échelle mondiale. Pathologie neurodégénérative chronique et progressive, elle affecte principalement les fonctions cognitives telles que la mémoire, le langage et l'orientation, conduisant inéluctablement à une perte d'autonomie. Le vieillissement de la population a considérablement accentué l'incidence de cette maladie, rendant indispensable le développement de stratégies diagnostiques précoces, fiables et automatisées.

Dans ce contexte, l'imagerie par résonance magnétique structurale (IRM) s'impose comme un outil de choix pour visualiser les altérations anatomiques cérébrales caractéristiques de la maladie. Toutefois, l'analyse manuelle des données IRM demeure complexe, lente et sujette à des biais subjectifs. Face à ces limitations, l'intégration de l'intelligence artificielle (IA), et plus spécifiquement des techniques d'apprentissage automatique (Machine Learning) et d'apprentissage profond (Deep Learning), constitue une voie prometteuse pour améliorer la détection et la classification des stades de la MA.

Ce travail s'inscrit dans cette dynamique et vise à développer un système automatisé de classification des patients à partir d'IRM structurales pondérées en T1. L'approche adoptée repose sur la construction d'un pipeline complet, depuis la collecte et le prétraitement des données, jusqu'à la mise en œuvre de modèles de classification, en passant par l'extraction de caractéristiques discriminantes.

Trois expériences principales ont été réalisées :

1. Une première approche end-to-end basée sur des réseaux de neurones convolutifs (CNN), exploitant les images 2D issues de trois régions cérébrales (matière grise, matière blanche, cerveau entier).
2. Une deuxième approche hybride combinant l'extraction de caractéristiques par CNN et la classification via des classifieurs traditionnels (SVM, KNN, Random Forest).
3. Une troisième expérimentation basée sur la fusion des caractéristiques issues des différentes régions cérébrales, visant à renforcer la robustesse de la classification.

À travers ce mémoire, nous présentons de manière rigoureuse les fondements théoriques, les choix méthodologiques et les résultats expérimentaux obtenus. Ce travail met en évidence la contribution potentielle des techniques de Deep Learning dans le domaine du diagnostic assisté de la maladie d'Alzheimer, et propose une analyse comparative des performances obtenues selon les différentes configurations testées.

Chapitre 1

La Maladie d'Alzheimer

1.1. Introduction

La maladie d'Alzheimer (MA) représente la forme la plus fréquente de démence, affectant des millions de personnes dans le monde. Il s'agit d'une pathologie neurodégénérative progressive, dont les répercussions cognitives, fonctionnelles et comportementales engendrent une perte d'autonomie significative chez les patients. Cette maladie se manifeste principalement par des troubles de la mémoire, du langage, de l'orientation, ainsi que par des altérations du jugement et du comportement. À mesure qu'elle évolue, elle entraîne une désorganisation progressive du fonctionnement cérébral, jusqu'à l'incapacité totale du patient à mener une vie indépendante.

Face à l'augmentation de l'espérance de vie, la prévalence de la maladie d'Alzheimer ne cesse de croître, constituant ainsi un défi de santé publique majeur à l'échelle mondiale. Le diagnostic précoce constitue un enjeu crucial, puisqu'il permet non seulement de ralentir l'évolution de la maladie grâce à des traitements symptomatiques et à des stratégies de prise en charge personnalisées, mais aussi de soutenir les proches aidants dans la gestion au quotidien.

Dans ce contexte, les avancées en neuroimagerie ont permis de mieux caractériser les modifications cérébrales associées à la maladie. Parmi les techniques disponibles, **l'imagerie par résonance magnétique structurelle (IRM)** occupe une place centrale. Elle permet d'observer avec une grande précision les changements morphologiques du cerveau, notamment l'atrophie de l'hippocampe, la perte de volume de la matière grise et les anomalies corticales. Ces altérations, souvent visibles avant même l'apparition des symptômes cliniques marqués, font de l'IRM un outil essentiel pour le suivi de la progression de la maladie et pour l'identification de ses différents stades.

Ce chapitre vise ainsi à fournir une vue d'ensemble sur la maladie d'Alzheimer. Il abordera d'abord les fondements **physiopathologiques** de la maladie, ses **stades cliniques**, ainsi que les **biomarqueurs biologiques et neuroanatomiques** les plus utilisés dans le cadre du diagnostic. Une attention particulière sera portée à l'intérêt de l'IRM structurelle dans la détection des atteintes cérébrales, afin de mieux comprendre son rôle dans l'évaluation et le suivi de cette pathologie complexe.

1.2. La maladie d'Alzheimer

1.2.1 Définition :

La maladie d'Alzheimer (MA) est une maladie cérébrale irréversible et dégénérative qui disparaît progressivement. Endommage la mémoire et les capacités de réflexion. Bien qu'elle soit incurable, la maladie d'Alzheimer provoque des douleurs importantes et des difficultés financières pour les patients et leurs familles. Cependant, les médicaments sont les plus efficace lorsqu'il est administré au début de la maladie et un diagnostic précoce est crucial dans le traitement de la MA pour limiter sa progression. [1]




Figure 1.1 : Instance de rétrécissement cérébral pour deux sujets : (à gauche) - cerveau témoin normal et (à droite) - cerveau atteint de la maladie d'Alzheimer [2].

1.3.Motivation

La maladie d'Alzheimer touche 10 % des personnes de plus de 65 ans et plus de 50 % des personnes de plus de 80 ans, les troubles cognitifs liés à l'âge touchant 10 fois plus de personnes. Le risque de développer la maladie d'Alzheimer double environ tous les 5 ans entre 65 et 85 ans et, par conséquent, à mesure que la génération des baby-boomers vieillit, on estime que dans 30 ans, 15 à 20 millions de personnes âgées dans tout le pays pourraient souffrir d'un handicap cognitif. [2]

La maladie d'Alzheimer représente entre **60 % et 70 %** des cas de démence à l'échelle mondiale, selon le **World Alzheimer Report 2019**. D'après l'**Alzheimer's Disease International (ADI)**, plus de **50 millions** de personnes étaient atteintes de démence en 2019, un chiffre qui pourrait atteindre **152 millions d'ici 2050**. Actuellement, une personne développe une démence toutes les **trois secondes**, et le coût annuel de sa prise en charge est estimé à **1 billion de dollars**, un montant qui devrait **doubler d'ici 2030**.

Par ailleurs, selon les statistiques publiées par l'Organisation Mondiale de la Santé (OMS) en 2020, la maladie d'Alzheimer était responsable de 3,04 % des décès en Algérie.[3]

Les données démographiques du vieillissement suggèrent donc qu'il est essentiel de diagnostiquer avec précision la maladie d'Alzheimer et de la distinguer spécifiquement des nombreuses autres causes possibles de troubles cognitifs.[2]




Figure 1.2 : Évolution du pourcentage de certaines causes de décès entre 2000 et 2006 – National Center for Health Statistics [4].

1.4. Physiopathologie de la maladie

Cependant, le diagnostic de cette maladie repose actuellement sur des critères cliniques appréciables à un stade relativement avancé de la maladie où les troubles cognitifs et la perte neuronale sont déjà importants.

Actuellement, le diagnostic de la maladie d'Alzheimer repose principalement sur des critères cliniques, généralement détectables à un stade avancé, lorsque la dégénérescence neuronale et les troubles cognitifs sont déjà significatifs. [4]

La **physiopathologie** de la maladie d'Alzheimer (MA) est principalement marquée par deux types de lésions neuropathologiques majeures : [5]

1.4.1. Les plaques amyloïdes : ce sont des dépôts **extracellulaires** de peptides **β -amyloïdes (A β)** qui s'accumulent anormalement dans le cerveau, perturbant la communication neuronale et déclenchant des réactions inflammatoires toxiques.

1.4.1.2. Les dégénérescences neurofibrillaires (DNF) : elles correspondent à l'accumulation **intracellulaire** de la protéine **Tau hyperphosphorylée**, entraînant une désorganisation du cytosquelette neuronal et la mort progressive des neurones.

Sur le plan structurel, **ces lésions microscopiques** provoquent une perte progressive des neurones, entraînant **une diminution de l'activité cérébrale, une atrophie corticale, réduction du volume total du cerveau, élargissement des sillons corticaux et une dilatation des ventricules cérébraux** visible à l'échelle **macroscopique** notamment dans les régions impliquées dans la mémoire et les fonctions cognitives, comme l'hippocampe et le cortex entorhinal.. [4]

1.5.Évolution de la maladie et stades cliniques

L'évaluation de la progression de la maladie d'Alzheimer (MA) révèle que le patient traverse trois phases distinctes avant d'atteindre un stade où la pathologie est considérée comme probable. Toutefois, divers outils et méthodes de diagnostic permettent d'évaluer le degré de gravité de la maladie à différents stades. Un diagnostic précoce est essentiel, car il offre aux cliniciens la possibilité d'initier des traitements visant à préserver l'autonomie des patients et à ralentir l'évolution des symptômes.[6]

Ainsi, l'évolution de la maladie d'Alzheimer peut être divisée en trois phases cliniques principales :

1.5.1.Phase préclinique : À ce stade, les patients ne présentent aucun symptôme apparent de troubles cognitifs. Cependant, des changements structuraux peuvent déjà survenir dans certaines régions spécifiques du cerveau, ainsi que dans le sang et le liquide céphalo-rachidien (LCR). Cette phase est particulièrement difficile à détecter, car la dégénérescence neuronale associée à la maladie d'Alzheimer peut débuter plusieurs années, voire des décennies, avant l'apparition des premiers signes cliniques.[7]

1.5.2.Trouble cognitif léger (MCI - Mild Cognitive Impairment) : Avec l'avancée en âge, certains individus développent des troubles de la mémoire plus marqués que la normale. Dans le cadre de la maladie d'Alzheimer, ces patients peuvent être en phase de MCI, qui constitue une période de transition entre le vieillissement cognitif normal et la maladie déclarée. Durant cette étape, un déclin progressif des fonctions cognitives, notamment la mémoire et la réflexion, est observé, bien que l'autonomie dans la vie quotidienne soit encore préservée.[8]

1.5.1.3Phase clinique de la maladie d'Alzheimer : Il s'agit du stade avancé où les symptômes deviennent évidents et significatifs. Les patients souffrent d'une altération progressive des capacités cognitives, comportementales et fonctionnelles. Cette

dégradation est due à la dégénérescence accrue des cellules cérébrales, particulièrement dans les zones critiques touchées par la maladie. À ce stade, l'impact sur la vie quotidienne est majeur, nécessitant une prise en charge adaptée.[7]

1.6. Biomarqueurs de la Maladie d'Alzheimer

Le diagnostic biologique de la maladie d'Alzheimer (MA) repose sur l'identification de marqueurs ayant démontré leur pertinence dans la détection des altérations cérébrales associées à la pathologie. Ces **marqueurs biologiques** permettent d'évaluer la progression de la maladie, notamment lorsqu'un trouble cognitif léger (MCI – Mild Cognitive Impairment) est observé. Ces marqueurs peuvent être classés en deux grandes catégories : **topographiques** et **physiopathologiques**. [9]

1.7. Marqueurs Topographiques : Ces marqueurs sont basés sur l'imagerie cérébrale et permettent de visualiser les modifications structurelles et fonctionnelles du cerveau liées à la MA : [10]

1.7.1 Analyse volumétrique par IRM cérébrale :

1.7.1.1. Atrophie globale : évaluation de la morphométrie basée sur les voxels et les tenseurs, notamment pour mesurer **l'élargissement des ventricules cérébraux**.

1.7.1.2. Atrophie diffusée : étude de la diminution de la **matière grise** à travers le cortex cérébral, en particulier par l'analyse de **l'épaisseur corticale**.

1.7.1.3 Atrophie focale : mesure du volume dans des **régions spécifiques**, telles que **l'hippocampe** et le **cortex entorhinal**, zones fortement affectées par la maladie.

L'IRM structurelle permet de mesurer la réduction du volume de ces structures, ce qui constitue un critère diagnostique important.

1.7.2 Marqueurs isotopiques par tomographie par émission de positons (TEP) :

La TEP au fluorodésoxyglucose (FDG-TEP) permet d'évaluer l'activité métabolique cérébrale. Une hypométabolisme est souvent observé dans les régions temporopariétales et le gyrus cingulaire postérieur des patients atteints de MA.

La TEP amyloïde permet de visualiser directement l'accumulation des plaques amyloïdes dans le cerveau à l'aide de traceurs spécifiques (ex. : Pib, Florbetapir).

1.7.3 Marqueurs Physiopathologiques

Ces marqueurs sont issus de l'analyse biochimique des fluides biologiques et reflètent les processus pathologiques sous-jacents de la maladie :[10]

Diminution du peptide amyloïde $\beta 42$ ($A\beta 42$) : ce peptide est un composant majeur des plaques amyloïdes et sa concentration diminue dans le LCR en raison de son accumulation excessive dans le cerveau.

Augmentation des protéines Tau et Tau phosphorylée (p-Tau) : ces protéines sont libérées par les neurones en dégénérescence et leur concentration dans le LCR est significativement élevée dans la MA.

Facteurs génétiques :

La présence d'antécédents familiaux peut être un indicateur de risque, notamment en cas de mutations autosomiques dominantes sur les gènes APP, PSEN1 ou PSEN2, responsables de formes précoces de la MA.

Le gène APOE $\epsilon 4$, bien que non spécifique, est un facteur de susceptibilité reconnu pour la MA sporadique.[11]

Le diagnostic de MA repose sur une combinaison d'évaluations cliniques, de tests neuropsychologiques et de biomarqueurs biologiques et d'imagerie. Parmi les techniques d'imagerie médicale, l'Imagerie par Résonance Magnétique (IRM) occupe une place essentielle dans l'étude et le suivi de la maladie. Grâce à sa capacité à fournir des images détaillées du cerveau sans recours aux radiations ionisantes, l'IRM permet d'évaluer les altérations structurelles précoces, telles que l'atrophie hippocampique, qui constitue un marqueur clé de la progression de la maladie d'Alzheimer. L'intégration de l'IRM dans le processus diagnostique offre ainsi une meilleure compréhension des mécanismes sous-jacents de la maladie et contribue au développement de stratégies de prise en charge adaptée

1.8 Imagerie par Résonance Magnétique (IRM)

L'Imagerie par Résonance Magnétique (IRM) est une technique d'imagerie médicale non invasive, développée il y a environ deux décennies. Elle repose sur le principe de la **résonance magnétique nucléaire (RMN)**, un phénomène physique découvert dans les années 1940. Cette technologie exploite les propriétés des noyaux atomiques soumis à un champ magnétique puissant et à des ondes radiofréquences, permettant ainsi d'obtenir des images détaillées des structures internes du corps humain, en particulier du cerveau.[12]




Figure 1.3 :Une vue en coupe du système d'imagerie par résonance magnétique (IRM)[13].

1.9 Principe physique de l'IRM

L'**Imagerie par Résonance Magnétique (IRM)** repose sur le principe de la **résonance magnétique nucléaire (RMN)**, un phénomène physique découvert en 1946 par **Felix Bloch** (Stanford) et **Edward Mills Purcell** (Harvard). Ce phénomène concerne les noyaux atomiques possédant un moment magnétique intrinsèque, appelé **spin nucléaire**. [13]

En l'absence de champ magnétique externe, les spins des noyaux sont orientés de manière aléatoire, entraînant une aimantation nette nulle du système (Figure I.4a). Lorsqu'un champ magnétique externe $\mathbf{B}_0$ est appliqué, ces spins adoptent deux orientations distinctes : l'une parallèle au champ $\mathbf{B}_0$ et l'autre antiparallèle (Figure I.4b), générant ainsi une aimantation macroscopique $\mathbf{M}_0$ non nulle. [14]




Figure 1.4 : Effet d'un champ magnétique extérieur sur les spins. (a)absence de champs, (b) présence de champs[14].

Dans cette configuration, les spins entrent en **précession** autour de l'axe du champ $\vec{B}_0$ avec une fréquence appelée **fréquence de Larmor** (ω_0), définie par l'équation :

$$\omega_0 = \gamma B_0 \dots\dots\dots (1.1)$$

Où

γ : représente le **rapport gyromagnétique** spécifique à chaque type de noyau.

Pour l'atome d'hydrogène (^1H), qui est le plus couramment utilisé en IRM en raison de son abondance dans les tissus biologiques, cette fréquence de précession est particulièrement bien adaptée à l'imagerie médicale.

L'application d'une onde radiofréquence à cette fréquence entraîne une excitation des spins, qui absorbent de l'énergie et passent à un état de plus haute énergie. Lorsque cette excitation cesse, les spins retournent progressivement à leur état d'équilibre en émettant un signal mesurable, qui est ensuite transformé en images par des algorithmes de reconstruction avancés.[15]

Lorsqu'un champ magnétique radiofréquence $\vec{B}_1$ de même fréquence que la **fréquence de Larmor** est appliqué aux spins, un phénomène de **résonance magnétique** se produit. Ce phénomène entraîne une absorption totale de l'énergie de la radiofréquence, perturbant ainsi l'équilibre du système des spins. L'aimantation macroscopique $\vec{M}_0$ bascule alors d'un angle θ ,

ce qui engendre l'apparition d'une **aimantation transversale M_{xy}** dans le plan XY et une réduction de l'**aimantation longitudinale M_z** .[\[15\]](#)

Lorsque le champ radiofréquence **B_1** est interrompu, le système des spins libère l'énergie absorbée et retourne progressivement à son état d'équilibre initial. Ce processus, appelé **relaxation**, permet à l'aimantation globale **M_0** de retrouver sa valeur et son orientation d'origine selon le champ statique **B_0** .

On distingue deux types de relaxation :

1.9.1 Relaxation longitudinale (T_1 ou relaxation spin-réseau) : elle décrit le retour progressif de l'aimantation **M_z** vers son état d'équilibre initial. Ce retour suit une loi exponentielle caractérisée par la constante de temps **T_1** , qui dépend de l'interaction entre les spins nucléaires et leur environnement moléculaire.

1.9.2 Relaxation transversale (T_2 ou relaxation spin-spin) : elle traduit la décroissance de l'aimantation transversale **M_{xy}** due aux interactions entre les spins eux-mêmes. Cette décroissance suit également une loi exponentielle, définie par la constante de relaxation **T_2** , généralement plus courte que **T_1** .[\[15\]](#)

Le signal de **résonance magnétique nucléaire (RMN)** est enregistré après la relaxation du système. L'énergie restituée par les spins est émise sous forme d'ondes radiofréquence, captées par une antenne réceptrice. Ce signal est ensuite analysé à l'aide de la **transformation de Fourier**, permettant d'extraire des informations essentielles telles que la **fréquence**, **l'amplitude et la durée du signal**, qui reflètent les propriétés physiques et biologiques des tissus étudiés.[\[16\]](#)

1.10 Formation de l'image en IRM

Le **champ de vue** (Field of View, FOV) représente la région du volume anatomique que l'on souhaite imager. Ce volume est subdivisé en unités élémentaires appelées **voxels** (éléments de volume), dont la taille influence directement la résolution de l'image obtenue. Une réduction de la taille des voxels améliore la finesse de l'image, mais peut également entraîner une diminution du signal reçu, ce qui nécessite un compromis entre résolution spatiale et qualité du signal.[\[17\]](#)

L'acquisition des images en **IRM** repose sur l'utilisation de **gradients de champ magnétique**, générés par des électro-aimants intégrés dans l'aimant principal de l'appareil. Ces gradients permettent d'encoder spatialement le signal dans les trois directions de l'espace :[17]

1.10.1 Sélection de coupe : Un **gradient de coupe** est appliqué dans une direction spécifique (par exemple, selon l'axe Z) afin d'exciter uniquement les noyaux situés dans un plan précis. Ce gradient ajuste la fréquence de résonance des spins en fonction de leur position, garantissant que seule une coupe de tissu soit excitée par l'impulsion radiofréquence appliquée.

1.10.2 Encodage de fréquence : Une fois la coupe sélectionnée, un gradient est appliqué dans une direction donnée (ex. axe X) pour modifier légèrement la **fréquence de précession** des protons en fonction de leur position. Ainsi, chaque voxel de cette direction possède une fréquence unique, facilitant la différenciation spatiale du signal.

1.10.3 Encodage de phase : Un second gradient, perpendiculaire au premier (ex. axe Y), est utilisé pour introduire un déphasage progressif des spins. Chaque voxel situé le long de cette direction partage la même fréquence de précession, mais présente un déphasage spécifique par rapport aux voxels voisins, permettant leur identification.

L'ensemble du signal acquis provient de l'ensemble du volume analysé et contient des informations codées sur toute la région d'intérêt. La reconstruction de l'image repose alors sur une technique mathématique appelée **transformée de Fourier**, qui décompose le signal brut en ses différentes composantes fréquentielles, permettant ainsi de reconstituer l'image finale avec une distribution spatiale précise des intensités de signal.[18]

1.11 Pondération des Images en IRM

L'acquisition des images en IRM repose sur plusieurs paramètres physiques influençant le signal de résonance magnétique nucléaire (RMN). Ce signal dépend principalement de trois caractéristiques fondamentales : la **densité de protons (ρ)**, le **temps de relaxation longitudinale (T_1)** et le **temps de relaxation transversale (T_2)**. En ajustant certains paramètres d'acquisition, il est possible de privilégier l'influence de l'un de ces facteurs afin d'obtenir des images mettant en évidence des contrastes spécifiques entre les différents tissus.[18]

Deux paramètres essentiels influencent cette pondération :

Chapitre 1

1.11.1 Le temps d'écho (TE) : durée entre l'impulsion radiofréquence (RF) initiale et la mesure du signal RMN.

1.11.2 Le temps de répétition (TR) : intervalle entre deux impulsions RF successives.

L'intensité du signal RMN peut être approximée par la relation suivante :

$$S \propto \rho (1 - e^{(-\frac{TR}{T1})}) e^{(-\frac{TE}{T2})} \dots\dots\dots (I.2)$$

Bien que cette équation soit une simplification des phénomènes complexes de relaxation et d'interaction des spins, elle illustre le principe général de la pondération des images en IRM.

Ainsi, selon les valeurs choisies de **TE** et **TR**, différentes pondérations d'images sont obtenues: [\[19\]](#)

1.11.3 Pondération T1 : permet une meilleure différenciation des tissus en fonction de leur temps de relaxation longitudinale.

1.11.4 Pondération T2 : met en évidence les variations du temps de relaxation transversale, notamment pour détecter les zones riches en eau, comme les lésions inflammatoires.

1.11.5 Pondération en densité de protons (PD) : optimise le contraste en fonction de la concentration en protons, souvent utilisée en imagerie cérébrale et ostéo-articulaire.

La figure 1.5 illustre ces différentes pondérations et montre comment le choix des paramètres d'acquisition influence le contraste des images, permettant ainsi de mieux distinguer les structures cérébrales telles que la substance blanche, la substance grise et le liquide céphalorachidien.




Figure 1.5 : Différentes modalités d'images cérébrales IRM : (a) pondération T1 ; (b) pondération T2 ; (c) pondération en densité de protons[18]

1.12 Imagerie Structurale et Détection des Altérations Cérébrales

L'imagerie par résonance magnétique structurale (IRM structurale) constitue aujourd'hui un outil de référence incontournable dans le domaine de la neurologie et de la neuropsychiatrie. Cette technique d'imagerie médicale repose sur la mesure du signal généré par la résonance des protons d'hydrogène présents dans les tissus biologiques, soumis à un champ magnétique puissant et à des ondes radiofréquences. Contrairement à l'IRM fonctionnelle qui analyse l'activité cérébrale, l'IRM structurale permet d'obtenir des images à haute résolution des structures anatomiques du cerveau, en mettant en évidence les contrastes naturels entre les différents types de tissus, tels que la matière grise, la matière blanche et le liquide céphalorachidien.[20]

Dans le contexte des pathologies neurodégénératives, et en particulier de la maladie d'Alzheimer, l'IRM structurale joue un rôle essentiel pour l'identification des altérations morphologiques précoces, souvent invisibles cliniquement aux premiers stades. Elle permet notamment de détecter l'**atrophie de l'hippocampe**, la **réduction du volume cortical**, ou encore des **modifications de la symétrie et de l'épaisseur corticale**, éléments fréquemment observés chez les patients atteints. Ces marqueurs morphologiques, lorsqu'ils sont détectés précocement, peuvent être intégrés dans des protocoles de suivi longitudinal pour évaluer la progression de la maladie et mesurer l'efficacité des interventions thérapeutiques.

L'analyse des images IRM structurales peut être réalisée de manière qualitative par un expert radiologue, mais aussi de manière quantitative à l'aide d'outils informatiques d'analyse

automatisée. Des méthodes telles que la **Voxel-Based Morphometry (VBM)**, la **segmentation volumétrique des régions d'intérêt (ROI)**, ou encore les approches basées sur des **modèles statistiques** permettent de quantifier avec précision les variations de volume ou d'épaisseur de certaines régions cérébrales entre groupes pathologiques et témoins.

L'IRM structurelle s'impose comme une modalité de choix pour l'étude des modifications cérébrales liées aux maladies neurodégénératives. Elle offre une base objective et reproductible pour le diagnostic, le suivi longitudinal et la recherche sur les mécanismes pathologiques sous-jacents, tout en constituant un support privilégié pour l'intégration de méthodes avancées d'analyse automatisée dans le cadre de la médecine personnalisée.

1.13 Conclusion

L'exploration approfondie de la maladie d'Alzheimer dans ce chapitre a permis de dresser un cadre scientifique et médical rigoureux autour de cette pathologie neurodégénérative complexe. Nous avons examiné ses fondements physiopathologiques, ses principales manifestations cliniques ainsi que les différents stades de sa progression. Ces éléments sont essentiels pour comprendre les enjeux actuels liés à son diagnostic, notamment dans les stades précoces où l'intervention thérapeutique peut avoir le plus d'impact.

Parmi les outils diagnostiques disponibles, **l'imagerie par résonance magnétique structurelle (IRM structurelle)** occupe une place de choix. Grâce à sa capacité à fournir des images détaillées du cerveau, elle permet de visualiser des altérations anatomiques spécifiques telles que l'atrophie de l'hippocampe, la réduction du volume cortical ou les changements dans la substance blanche. Toutefois, ces observations demeurent souvent difficiles à interpréter de manière objective, en raison de la complexité des données générées et de la variabilité interindividuelle liée à l'âge, au sexe, ou encore aux comorbidités.

Dans ce contexte, **l'intelligence artificielle (IA)**, et plus particulièrement les techniques d'**apprentissage automatique (Machine Learning)** et d'**apprentissage profond (Deep Learning)**, se présentent comme des solutions innovantes pour relever ces défis. En automatisant le traitement des images IRM et en extrayant des caractéristiques discriminantes complexes, ces approches permettent non seulement de renforcer la précision du diagnostic mais aussi de prédire plus efficacement l'évolution de la maladie.

Chapitre 1

La synergie entre l'imagerie médicale et l'intelligence artificielle constitue aujourd'hui un axe de recherche majeur, avec pour objectif de passer d'une évaluation subjective à une analyse quantitative, reproductible et personnalisée du cerveau. Le chapitre suivant s'inscrit dans cette dynamique en présentant les fondements théoriques de l'IA, ses applications en traitement d'images médicales, ainsi que les méthodes les plus avancées utilisées pour la classification de la maladie d'Alzheimer à partir des données IRM.

Chapitre 2

Détection automatique de la maladie d'Alzheimer par IRM : revue de la littérature

2.1 Introduction

L'imagerie par résonance magnétique (IRM) est une modalité clé dans l'étude des maladies neurodégénératives, car elle permet d'observer avec précision les altérations structurelles du cerveau, telles que l'atrophie hippocampique et la perte neuronale. Toutefois, l'interprétation manuelle de ces images reste complexe et sujette à la variabilité humaine. C'est dans ce contexte que l'intelligence artificielle (IA), jouent un rôle fondamental en facilitant l'extraction automatique des caractéristiques cérébrales et en optimisant la classification des patients.

Ce chapitre s'intéresse à la contribution de l'intelligence artificielle dans le diagnostic de la maladie Alzheimer, en mettant l'accent sur l'apprentissage automatique (machine Learning) et le Deep Learning. Nous aborderons brièvement les méthodes existantes dans la littérature ayant démontré leur efficacité dans la détection et le diagnostic de la maladie d'Alzheimer.

2.2 L'Intelligence Artificielle et Son Impact en Imagerie Médicale

L'intelligence artificielle révolutionne le domaine médical en offrant des outils avancés pour l'analyse et l'interprétation des données complexes, notamment en imagerie médicale. Parmi les techniques les plus prometteuses, l'apprentissage automatique (Machine Learning) et l'apprentissage profond (Deep Learning) permettent d'automatiser et d'améliorer le diagnostic de nombreuses pathologies, dont la maladie d'Alzheimer.

2.2.1 Machine Learning (ML) :

Est une branche de l'intelligence artificielle qui repose sur le développement d'algorithmes capables d'apprendre des données et d'effectuer des prédictions sans être explicitement programmés (voir figure II.1).

Dans le domaine de **l'imagerie médicale et de la radiologie**, le ML est utilisé pour analyser les images, détecter les anomalies et assister les professionnels de santé dans le processus diagnostique. Toutefois, son efficacité est conditionnée par la **qualité des données d'entraînement**, le respect des **normes médicales** et la capacité des modèles à fournir des résultats **interprétables et fiables**. Un enjeu majeur de son intégration en clinique réside dans **l'acceptabilité des décisions automatisées**, nécessitant une validation par les radiologues avant leur adoption dans la pratique diagnostique.[\[21\]](#)

2.2.2 Deep Learning (DL) :

Ou apprentissage profond, est une branche avancée du Machine Learning fondée sur l'utilisation de réseaux neuronaux artificiels profonds, constitués de plusieurs couches successives permettant d'extraire automatiquement des caractéristiques complexes à partir de vastes ensembles de données (voir figure.1). Cette approche se distingue par sa capacité à identifier des motifs subtils dans des données non structurées, ce qui la rend particulièrement adaptée à l'analyse des images médicales, notamment les IRM cérébrales, facilitant ainsi la classification des patients en fonction de leur état de santé.[21]

Le Deep Learning présente une limite majeure liée à son manque de transparence et d'interprétabilité. Contrairement aux radiologues, dont les décisions diagnostiques reposent sur une expertise médicale explicite et des connaissances cliniques établies, les modèles d'apprentissage profond réalisent des prédictions basées sur des calculs internes difficilement interprétables, souvent qualifiés de "boîte noire". Cette opacité soulève des enjeux en matière d'acceptabilité et d'intégration clinique, car un diagnostic médical doit être compréhensible et justifiable avant d'être adopté dans la pratique médicale. Le développement de méthodes d'explicabilité des modèles constitue donc un axe de recherche essentiel pour renforcer la fiabilité et l'adoption du Deep Learning en imagerie médicale.[22]




Figure 2.1 :Relation entre l'intelligence artificielle, l'apprentissage automatique (Machine Learning) et l'apprentissage profond (Deep Learning)/[23].

Les méthodes de Deep Learning sont rapidement devenues la méthodologie la plus populaire dans de nombreuses applications du domaine médical. Elles englobent différents types de modèles tels que [23]:

Les réseaux de neurones convolutifs (CNN),

Les réseaux de neurones récurrents (RNN),

L'apprentissage par renforcement (Reinforcement Learning).

Parmi ces modèles, les CNN représentent une branche essentielle du Deep Learning, largement utilisée pour la classification d'images, la reconnaissance de motifs, et la segmentation intelligente d'images. Ils ont démontré une performance incontournable pour résoudre divers problèmes complexes, notamment les problèmes de prise de décision.

Contrairement aux approches nécessitant une extraction manuelle de caractéristiques (basées sur le ML), les architectures basées sur les CNN ne requièrent aucune ingénierie de caractéristiques, car les premières couches convolutionnelles jouent le rôle d'extracteurs de caractéristiques via des filtres entraînaables.

Les dernières couches des CNN profonds correspondent à des classifieurs de réseaux de neurones entièrement connectés (MLP — voir section 3.3.3). Ainsi, le processus d'extraction des caractéristiques et leur classification est réalisé dans une architecture complète de bout en bout (end-to-end) [23].

Cependant, la contrainte principale de l'utilisation des méthodes de Deep Learning réside dans le fait qu'elles nécessitent un grand nombre d'échantillons pour l'entraînement, ce qui est rarement disponible dans le domaine médical.[24]

2.3 Revue des méthodes de classification de la maladie d'Alzheimer

Dans cette section, nous passons en revue les travaux les plus intéressants exploitant les méthodes d'apprentissage profond. Nous présentons diverses stratégies d'implémentation ainsi que leurs performances pour la détection de la maladie d'Alzheimer, incluant à la fois les méthodes basées sur le volume et celles basées sur la surface.

L'étude [25] s'intéresse à l'impact du prétraitement des images IRM structurales ainsi qu'au choix du modèle d'apprentissage profond dans le cadre de la classification de la maladie d'Alzheimer. Les chercheurs ont utilisé la base de données **Alzheimer's Disease Neuroimaging Initiative ADNI** (<http://www.adni-info.org>), incluant des images acquises à

des champs magnétiques de 1.5T et 3T. Afin d'assurer une meilleure homogénéité entre les données et d'améliorer la comparabilité inter-sujets, la méthode de normalisation VBM-DARTEL a été appliquée. Par la suite, cinq architectures différentes de réseaux de neurones convolutionnelles (CNN) préentraînés ont été évaluées sur plusieurs sous-ensembles de données. Les résultats obtenus ont montré des performances élevées, atteignant un taux de précision maximal de 97,15 % pour classer (AD vs CN), soulignant l'efficacité de ces approches dans la détection automatisée de la maladie d'Alzheimer à partir d'IRM structurelles.

Dans cette étude [26], les auteurs proposent une méthode de détection de la maladie d'Alzheimer à partir d'images IRM cérébrales en utilisant un réseau de neurones profond (DNN). Basée sur les données de la base OASIS(<http://www.oasis-brains.org/>), l'approche intègre des étapes de segmentation, d'extraction des contours ventriculaires et de sélection d'attributs géométriques et statistiques. Ces caractéristiques sont ensuite exploitées pour entraîner un classificateur DNN. Les résultats obtenus montrent une précision de 96,6 % (AD vs CN), surpassant d'autres techniques classiques comme les machines à vecteurs de support (SVM), confirmant l'efficacité du DNN pour le diagnostic automatisé d'Alzheimer.

Dans l'étude [27], Les chercheurs ont exploité la base **ADNI** qui contient des images IRM structurelles acquises de manière longitudinale, afin d'analyser l'évolution morphologique de certaines régions cérébrales d'intérêt (ROI). L'approche adoptée repose sur la mesure des volumes de ces régions au fil du temps, dans le but de détecter les changements anatomiques associés à la progression de la maladie. Un modèle d'apprentissage automatique basé sur le SVM a été utilisé pour classifier les sujets atteints de MCI en deux catégories : ceux qui vont évoluer vers la maladie d'Alzheimer (MCI convertis) et ceux qui resteront stables. Cette méthode a permis d'atteindre un taux de précision de 98,06 %, démontrant ainsi son efficacité dans la prédiction précoce de l'évolution vers une démence de type Alzheimer.

Dans le cadre de cette étude [28], les chercheurs ont opté pour la conversion d'images cérébrales tridimensionnelles (3D) en représentations bidimensionnelles (2D), dans le but d'entraîner un réseau de neurones convolutifs 2D à reconnaître les différents stades de la maladie d'Alzheimer citez (AD CN MCI). Cette transformation a permis de simplifier l'analyse tout en conservant les caractéristiques discriminantes essentielles. L'approche proposée a démontré une efficacité notable, les résultats obtenus confirmant son potentiel

pour la détection précoce de la maladie et la classification des patients en fonction de l'évolution de leur état cognitif.

Une recherche récente [29], s'est penchée sur l'utilisation des réseaux de neurones convolutifs tridimensionnels (3D CNN) pour améliorer la détection précoce de la maladie d'Alzheimer à partir d'images IRM structurales. Contrairement aux modèles bidimensionnels, cette approche exploite pleinement les volumes d'imagerie en trois dimensions, ce qui permet de conserver l'ensemble des informations spatiales essentielles à l'analyse. L'expérimentation menée sur deux bases de données distinctes a démontré une capacité encourageante du modèle à différencier les sujets atteints de la maladie de ceux en bonne santé avec une précision de **73,4%**, soulignant le potentiel de cette méthode dans un cadre clinique.

L'étude [30] a exploré le potentiel des Vision Transformers (ViT), dans le cadre du diagnostic précoce de la maladie d'Alzheimer, à partir d'images IRM structurales tridimensionnelles. En tirant parti de la capacité des ViT, à traiter les données visuelles de manière séquentielle, les chercheurs ont conçu un modèle capable d'extraire automatiquement des informations discriminantes pertinentes, pour la classification de la maladie d'Alzheimer . Les performances obtenues ont montré une nette amélioration par rapport aux méthodes classiques, avec des taux de précision particulièrement élevés atteignant **99,048 %** en classification binaire et **99,014 %** en classification multi classe, mettant en évidence l'efficacité de cette approche novatrice.

Dans le cadre de la modélisation et de la classification de la maladie d'Alzheimer, des chercheurs [31] ont mis au point un réseau de neurones convolutifs spécifiquement conçu pour cibler les effets de la neurodégénérescence, appelé SNeurodCNN. Ce modèle a été appliqué à l'analyse d'images IRM cérébrales, afin d'identifier les altérations structurales caractéristiques de la pathologie. Les résultats obtenus ont révélé une performance remarquable, avec des précisions de classification générale de la maladie d'Alzheimer atteignant **97,8 %** pour les images en coupe sagittale et **98,1 %** pour celles en coupe sagittale médiane , surpassant ainsi les approches traditionnelles.

Dans le contexte du diagnostic précoce de la maladie d'Alzheimer, une approche innovante [32] a été développée, en combinant les réseaux de neurones convolutifs (CNN) issus de l'apprentissage profond avec l'algorithme d'apprentissage automatique XGBoost. Cette méthode permet d'exploiter à la fois la capacité des CNN à extraire des caractéristiques

complexes des images IRM et la puissance de XGBoost pour la classification. Les résultats obtenus démontrent une très haute précision de **98,7 %**, mais ne permet pas de classer les stades cliniques de la maladie d'Alzheimer se limitant à une classification binaire, ouvrant ainsi la voie à des solutions plus efficaces pour la détection anticipée de la maladie.

Dans une optique d'amélioration du diagnostic de la maladie d'Alzheimer [33], une approche fondée sur l'intelligence artificielle a été explorée, reposant sur un modèle d'apprentissage profond modifié basé sur l'architecture EfficientNet en 3D. Ce modèle intègre ViT, qui se distingue par leur capacité à extraire des informations détaillées à partir des images IRM structurales. Les performances obtenues se révèlent particulièrement prometteuses, avec un taux de précision extrêmement élevé dans la classification des patients atteints de la maladie d'Alzheimer ce qui confirme le potentiel de cette méthode dans le cadre d'une détection fiable et précoce de la pathologie.

Dans l'étude récente [34], les auteurs ont exploré le potentiel de l'apprentissage profond pour la détection automatisée de la maladie d'Alzheimer à partir d'images IRM cérébrales. Conscients de l'importance d'un diagnostic précoce, ils ont mis en œuvre deux modèles de Deep Learning, Squeeze Net et ResNet-50, afin de comparer leurs performances dans la classification de patients selon quatre stades de démence : non dément, très léger, léger et modéré. Les données utilisées proviennent d'un ensemble de 6400 images issues de la plateforme Kaggle, prétraitées pour améliorer la qualité des entrées. Après un entraînement rigoureux, les résultats ont démontré que le modèle Squeeze Net obtenait une précision remarquable de **99 %**, surpassant les autres architectures telles que DenseNet169 et VGG19.

L'étude [35] a proposé un système automatisé basé sur l'apprentissage profond pour la classification multi-classes de la pathologie à partir d'images IRM cérébrales. L'approche développée repose sur l'utilisation de l'apprentissage par transfert appliqué à un réseau de Deep Learning capable de classer les patients selon quatre stades cliniques : CN, EMCI, MCI et LMCI. Les résultats expérimentaux ont démontré une précision de classification de 91,70 %, ce qui représente une amélioration notable par rapport aux méthodes précédentes. Ce modèle montre ainsi le potentiel des techniques de Deep Learning pour une détection précoce et fiable de la maladie, en apportant un soutien automatisé aux professionnels de santé.

Dans l'étude [36], les auteurs proposent un modèle de classification automatisée de la maladie d'Alzheimer à partir d'images IRM cérébrales, en s'appuyant sur une architecture CNN. Contrairement aux approches traditionnelles qui se limitent souvent à des sous-

Chapitre 2

ensembles spécifiques de données (selon l'âge, le sexe, ou des critères cliniques), cette méthode utilise uniquement les données visuelles issues de la base OASIS . Cette approche atteint une précision de 80 % pour classer (stades), les auteurs suggèrent que l'augmentation du volume de données d'apprentissage pourrait améliorer significativement les performances du modèle. Cette approche souligne ainsi la capacité des CNN à traiter efficacement des tâches complexes de classification dans le domaine de l'imagerie médicale, tout en réduisant la dépendance aux informations externes.

Shukla et al. (2023) [37] ont présenté une revue des méthodes automatiques de détection de la maladie d'Alzheimer, mettant en avant l'utilisation de l'imagerie médicale (IRM, PET, DTI) et des approches d'apprentissage automatique. L'étude souligne l'efficacité des pipelines tels que SPM, FSL et FreeSurfer pour le prétraitement et l'extraction de caractéristiques, avec des précisions supérieures à 95 % pour la classification binaire. Les approches hybrides combinant Deep Learning (CNN, 3D-CNN) et machine learning (SVM, ANN) se sont révélées particulièrement prometteuses, notamment pour le diagnostic précoce et la classification multiclassées, bien que cette dernière reste un défi majeur.

Table 2.1 :l'état de l'art

Référence	Base de données	Modalité Et pondération	Méthode	Accuracy
[6] Chen et al.,2020	ADNI	les séquences IRM structurales pondérées en T1	CNN (5 architectures) + VBM-DARTEL	97,15 % pour classer les patients atteints d'Alzheimer et les sujets sains
[7]Gulhare et al.,2017	OASIS	collection longitudinale des images IRM	DNN avec segmentation et extraction de	96,6 %

Chapitre 2

			caractéristiques	
[8]Zhang et al.,2020	ADNI	Images IRM pondérées en T1	SVM sur ROI longitudinal	98,06 %
[9]YİĞİT et Z. Işık,2020	ADNI	Images IRM pondérées en T1	CNN 2D sur images 3D	Non spécifié
[10]Yagis, E., et al.2020	Images IRM (OASIS)	IRM structurales	CNN 3D	Élevée
[11]Alp, S., et al.,2024	IRM 3D ADNI and OASIS	Images IRM pondérées en T1	Vision Transformer (ViT)	99,048 % / 99,014 %
[12]Odimayo, S al.,2024	ADNI	Image IRM des deux plans de l'axe sagittal, médio-sagittal et parasagittal	SNeurodCNN (convolution ciblée)	97,8 % / 98,1 %
[13]Ataelfadiel, A.A.-K et al.,	ADNI	les séquences IRM structurales pondérées en T1	CNN + XGBoost	98,7 %
[14]Zheng, B., et et al.,2023	ADNI	IRM structurelle	EfficientNet 3D + ViT	Très élevée
[15]Patel et al.,	Kaggle	DTI-MD (Diffusion Tensor Imaging modality)	SqueezeNet, ResNet-50, etc.	99 %

Chapitre 2

[16]Ghazal et al.,2022	Kaggle	l'imagerie par tenseur de diffusion (DTI-MD) et les images cérébrales IRM	Apprentissage par transfert (multi-classes)	91,70 %
[17]Roy et al.,2019	OASIS	IRM structurelle	CNN (sans données cliniques)	80

2.4 Discussion

L'analyse des différentes approches étudiées dans la littérature met en lumière l'évolution rapide et significative des techniques d'intelligence artificielle appliquées à la classification de la maladie d'Alzheimer à partir d'images IRM structurelles.

Ces études peuvent être classées selon les critères suivants :

Les modalités d'imagerie utilisée influence fortement la qualité des informations extraites ,chaque modalité apportant une perspective différente sur les structures et fonctions cérébrale

2.5 Rôle des bases de données

Les bases de données ADNI et OASIS sont les plus utilisées. ADNI offre des données longitudinales, ce qui permet d'étudier la progression de la maladie, tandis que OASIS permet d'explorer des stades variés de la démence. L'utilisation de grandes bases bien annotées est essentielle pour entraîner des modèles robustes.

L'imagerie structurelle pondérée en T1 est particulièrement efficace pour détecter l'atrophie cérébrale ,notamment dans l'hippocampe ,un marqueur clé de la maladie d'Alzheimer .

2.6 L'importance du prétraitement

Plusieurs études, comme celle basée sur la méthode VBM-DARTEL [6], soulignent l'importance cruciale du prétraitement des données IRM. Des techniques telles que la normalisation spatiale, la correction du champ de biais, ou la segmentation des régions d'intérêt (ROI) permettent de standardiser les images structurelles pour en améliorer la

comparabilité et la qualité d'analyse. Ces étapes sont fondamentales pour garantir la fiabilité des modèles d'apprentissage automatique.

2.7 Diversité des méthodes de classification

Les méthodes utilisées varient considérablement, allant des méthodes qui utilisent des extracteurs de caractéristiques manuelles avec des classificateurs comme SVM, aux approches hybrides qui combinent des caractéristiques extraites par les CNN et des classificateurs traditionnels comme SVM, les forêts aléatoires ou des méthodes qui utilisent directement les CNN. Les réseaux convolutifs restent les plus répandus en raison de leur capacité à apprendre automatiquement des caractéristiques discriminantes à partir des images brutes.

2.8 Classification

Si la majorité des travaux se concentrent sur une classification binaire (AD vs CN), certains visent une classification multi-classes (AD, MCI, CN, MD, etc.), ce qui reflète mieux la réalité clinique. Bien que plus complexe, cette approche est essentielle pour un dépistage plus fin et adapté au parcours clinique du patient. Elle reste cependant un défi, car elle nécessite des bases de données bien étiquetées et équilibrées.

2.9 Performance et limites

Les modèles atteignent souvent des performances impressionnantes (jusqu'à 99 % de précision), mais ces résultats doivent être considérés avec précaution. La généralisation à de nouveaux jeux de données cliniques, la sensibilité à l'hétérogénéité des scanners, ou encore l'explicabilité des modèles sont des enjeux majeurs. Certains modèles, bien que très performants, restent difficilement interprétables par les cliniciens (ex. les ViT ou les CNN profonds).

2.10 Apports du Deep Learning

Les modèles basés sur le Deep Learning dominent nettement le domaine. Les CNN 2D et 3D permettent une analyse plus riche des structures cérébrales, avec des performances souvent supérieures à 95 % de précision. Les architectures 3D-CNN permettent notamment de préserver l'intégralité de l'information volumétrique, offrant une compréhension plus fine des altérations anatomiques liées à la MA.

2.11 Conclusion

L'intégration de l'intelligence artificielle, et plus particulièrement des approches d'apprentissage profond, dans le traitement des images médicales a révolutionné le domaine

du diagnostic assisté. À travers ce chapitre, nous avons mis en évidence les fondements théoriques du **Machine Learning** et du **Deep Learning**, en insistant sur les **réseaux neuronaux convolutifs (CNN)**, qui occupent une place centrale dans l'analyse automatique des IRM cérébrales.

Les CNN se sont révélés particulièrement efficaces pour la classification des images IRM structurales, grâce à leur capacité à apprendre des représentations hiérarchiques complexes directement à partir des données brutes. De même, d'autres architectures émergentes, comme les **Vision Transformers (ViT)**, ou encore les combinaisons hybrides avec des modèles classiques comme **XGBoost**, ont montré des résultats prometteurs, en particulier dans le cadre de la détection précoce de la maladie d'Alzheimer. Ces approches permettent non seulement d'augmenter la précision diagnostique, mais aussi de réduire l'intervention humaine dans les étapes fastidieuses de l'analyse.

Cependant, malgré l'efficacité démontrée de ces outils, leur mise en œuvre soulève encore plusieurs défis. Parmi ceux-ci, on peut citer la nécessité d'un **prétraitement rigoureux des images IRM**, la standardisation des formats, la gestion des biais liés aux données hétérogènes, ainsi que la validation des performances des modèles dans des contextes cliniques réels.

Ainsi, pour tirer pleinement parti du potentiel offert par l'intelligence artificielle, il est essentiel de définir une **méthodologie rigoureuse**, allant de la **collecte des données** jusqu'à la **construction et l'évaluation du modèle de classification**. Le chapitre suivant sera donc consacré à la **description détaillée de la démarche méthodologique** adoptée dans le cadre de ce travail, en présentant notamment les étapes de prétraitement des images IRM, l'architecture du modèle CNN développé, ainsi que les critères d'évaluation utilisés pour valider ses performances dans le contexte de la maladie d'Alzheimer.

Chapitre 3

Approche proposée

3.1 Introduction :

Dans ce chapitre, nous présentons l'ensemble des étapes méthodologiques suivies dans le cadre de cette étude, visant à concevoir un système automatisé d'aide au diagnostic de la maladie d'Alzheimer à partir d'images IRM structurales. L'approche proposée repose sur un pipeline rigoureux et structuré qui va de la collecte des données jusqu'à la classification finale des patients selon trois groupes diagnostiques : Alzheimer (AD), Trouble Cognitif Léger (MCI) et sujets témoins cognitivement normaux (CN).

Ce chapitre détaille les différentes étapes utilisées, en soulignant les choix des techniques effectués, les outils utilisés dans ce travail, ainsi que leur justification dans le contexte spécifique du diagnostic de la maladie d'Alzheimer.

2.3 Approche proposée

Le choix de l'IRM structurale pondérée en T1 comme modalité d'imagerie repose sur sa capacité éprouvée à capturer les altérations anatomiques fines associées aux pathologies neurodégénératives, notamment l'atrophie de l'hippocampe et du cortex temporal médian, caractéristiques précoces de la maladie d'Alzheimer. Les données utilisées proviennent de la base ADNI (Alzheimer's Disease Neuroimaging Initiative), un référentiel largement reconnu dans le domaine de la recherche en neurosciences, et sont accompagnées d'annotations cliniques précises permettant une classification supervisée.

L'étape de prétraitement constitue une phase critique du pipeline, visant à corriger les artefacts liés à l'acquisition des images, à homogénéiser les données et à les aligner dans un espace standardisé commun (MNI). Ce processus repose sur l'utilisation conjointe de la plateforme SPM et de son algorithme avancé DARTEL, permettant une normalisation non linéaire de haute précision. Des opérations complémentaires telles que la segmentation des tissus, la correction du biais d'intensité et le lissage spatial sont également appliquées.

Afin de rendre les volumes IRM 3D compatibles avec les architectures classiques de réseaux de neurones convolutifs (CNN), une transformation en images 2D est réalisée. Ce processus inclut l'extraction et la sélection de 50 coupes informatives centrées sur les régions les plus pertinentes pour la pathologie. Cette réduction contrôlée vise à préserver la richesse de l'information diagnostique tout en réduisant la complexité computationnelle.

Enfin, un modèle CNN est mis en œuvre pour l'apprentissage et la classification. Ce modèle est entraîné à partir des images prétraitées, et ses performances sont évaluées à l'aide de

métriques standard telles que la précision, le rappel, le F1-score et l'AUC. Une attention particulière est portée à l'optimisation et à la régularisation du réseau afin de prévenir le sur-apprentissage et d'améliorer sa capacité de généralisation.




Figure 3.1 :Schéma général du pipeline méthodologique proposé pour la classification de la maladie d'Alzheimer à partir d'IRM structurelle

3.3 Collecte et description des données

3.3.1 Data sets

ADNI : Les données utilisées dans la préparation de ce travail ont été téléchargées à partir de la base de données de l'**Alzheimer's Disease Neuroimaging Initiative (ADNI)**.

L'ADNI a été lancée en 2004 par le **National Institute on Aging (NIA)**, le **National Institute of Biomedical Imaging and Bioengineering (NIBIB)**, la **Food and Drug Administration (FDA)**, des entreprises pharmaceutiques privées ainsi que des organisations à but non lucratif. Ce projet public-privé, d'un budget de 60 millions de dollars sur 5 ans, est une **étude longitudinale multicentrique** conçue pour développer des **biomarqueurs cliniques, d'imagerie, génétiques et biochimiques**, destinés à la **détection précoce et au suivi de la maladie d'Alzheimer (AD)**.

L'ADNI est le fruit des efforts de nombreux co-investigateurs issus d'un large éventail d'institutions académiques et d'entreprises privées. Les participants ont été recrutés dans **plus de 50 centres à travers les États-Unis et le Canada**.

Depuis son lancement il y a plus d'une décennie, le projet a connu **trois grandes phases : ADNI-1, ADNI-GO (Grand Opportunités), ADNI-2 et ADNI-3**.

L'objectif initial d'ADNI était de recruter **800 participants**. Par la suite, ADNI-GO et ADNI-2 ont permis d'élargir le recrutement. À ce jour, **plus de 1500 adultes âgés de 55 à 90 ans** ont participé à la recherche, regroupant des individus cognitivement normaux, des personnes atteintes de troubles cognitifs légers (MCI) précoces ou avancés, et des patients atteints d'une forme légère de la maladie d'Alzheimer.

La durée du suivi de chaque groupe est définie selon les protocoles des phases ADNI-1, ADNI-GO et ADNI-2. Les sujets initialement recrutés dans ADNI-1 et ADNI-GO ont eu la possibilité de continuer leur suivi dans ADNI-2.

ADNI-3 a débuté en **2016** et implique des chercheurs de **59 centres de recherche** aux États-Unis et au Canada. Entre **1070 et 2000 participants** y seront inclus : environ **700 à 800 participants issus des phases précédentes (ADNI-2)** et **370 à 1200 nouveaux sujets**.

Des caractéristiques cliniques, cognitives, d'imagerie, biomarqueurs et génétiques sont évaluées à travers **trois cohortes** : individus cognitivement normaux, personnes atteintes de MCI et patients atteints de démence légère due à la maladie d'Alzheimer.

Pour des informations actualisées, consulter : www.adni-info.org

3.3.2 Description démographique des sujets :

Le jeu de données utilisé dans cette étude provient des bases de l'**Alzheimer's Disease Neuroimaging Initiative (ADNI)**. Il se compose d'un total de **150 sujets** (hommes et femmes) âgés de **55 à 90 ans**, répartis équitablement entre trois groupes : **50 patients atteints de la maladie d'Alzheimer (AD)**, **50 sujets témoins cognitivement normaux (CN)**, et **50 patients présentant un trouble cognitif léger (MCI)**. Les données ont été acquises à l'aide des scanners du système médical **GE Healthcare**.

Le groupe **MCI** regroupe à parts égales des patients en phase précoce (**EMCI**) et avancée (**LMCI**) du trouble cognitif léger, conformément aux pratiques d'agrégation adoptées dans de nombreux travaux antérieurs. Les catégories de diagnostic utilisées sont les suivantes :

AD (Alzheimer's Disease) : patients diagnostiqués avec la maladie d'Alzheimer.

EMCI (Early Mild Cognitive Impairment) : patients au début de la phase prodromique.

LMCI (Late Mild Cognitive Impairment) : patients en fin de phase prodromique (équivalent au label MCI dans ADNI-1).

CN (Cognitively Normal) : sujets témoins sans déficit cognitif.

Les **informations démographiques et cliniques** des participants sont résumées dans le tableau incluant notamment les scores du **Mini-Mental State Examination (MMSE)**, un test standardisé d'évaluation des fonctions cognitives. Des scores MMSE faibles sont généralement associés à une altération plus prononcée des capacités cognitives.

Les images utilisées incluent :

- Des **IRM structurelles pondérées en T1 (sMRI)**, acquises en 3D avec une résolution de **256 × 256 × 196 voxels** et une taille de voxel de **1,0 × 1,0 × 1,2 mm³**.

Pour plus de détails concernant les protocoles d'acquisition, le lecteur est invité à se référer aux documents techniques de l'**ADNI**.

Table 3.1 :Données statistiques liées aux sujets

Classes	CN	MCI	AD
Nombre	50	50	50
Sexe (F/M)	27/23	20/30	28/22
Age	72.5±6.1	74.40 ± 7.47	75.60 ± 8.63
MMSE	28.93±1.18	27.4 ± 1.99	23.0 ± 2.42

Les données exploitées dans cette étude sont issues d’images IRM pondérées en **T1**, déjà reconnues pour leur capacité à représenter avec précision l’anatomie cérébrale. Ce type de séquence est particulièrement pertinent dans le contexte de la maladie d’Alzheimer, car il permet de visualiser les structures affectées par l’atrophie, telles que l’hippocampe et le cortex temporal médian. Ces images constituent ainsi une base fiable pour les étapes ultérieures du prétraitement et de la classification.

3.4 Prétraitement des données IRM

Les images obtenues par résonance magnétique (IRM) peuvent être affectées par divers artefacts, provenant soit de sources physiologiques (tels que les mouvements de la tête, la respiration ou l’anxiété du patient), soit de limitations techniques liées à l’appareil de scanner lui-même (comme les distorsions géométriques ou les pertes de signal). Afin d’atténuer ces effets indésirables, le prétraitement des images est important.

Toutes les images ont été débruitées, corrigées pour l’inhomogénéité du champ magnétique et pour les variations d’intensité, puis soumises à une extraction du crâne (skull-stripping). Par la suite, elles ont été segmentées en trois types de tissus : la substance grise (GM), la substance blanche (WM) et le liquide céphalo-rachidien (CSF). Les segments tissulaires ont ensuite été normalisés spatialement en utilisant le gabarit CAT12, généré à partir de 555 sujets sains issus de la base de données IXI (<http://www.brain-development.org>), à l’aide de l’algorithme de

recalage déformable DARTEL. Ces étapes constituent les principales phases du prétraitement des données.

Pour effectuer ces étapes, plusieurs outils spécialisés dans l'analyse statistique et le traitement des images IRM sont couramment utilisés. Parmi les plus reconnus figure **Statistical Parametric Mapping (SPM)** [38], une plateforme largement adoptée pour le prétraitement et l'analyse des données neuroimagerie. Dans le cadre de cette étude, nous utilisons **SPM** conjointement avec son algorithme complémentaire **DARTEL (Diffeomorphic Anatomical Registration using Exponentiated Lie algebra)** [39], qui permet une normalisation spatiale plus précise grâce à un recalage non linéaire de haute résolution. Ces outils offrent des modules performants pour assurer un traitement rigoureux et reproductible des images cérébrales.

SPM (Statistical Parametric Mapping) est une méthodologie statistique utilisée principalement pour le traitement et l'analyse d'images cérébrales obtenues par neuroimagerie fonctionnelle ou structurelle, comme l'IRM ou la TEP. Elle repose sur la modélisation mathématique des signaux présents dans les images voxel par voxel, en appliquant des tests statistiques paramétriques pour détecter des différences significatives entre différentes conditions expérimentales ou groupes de patients.

Dans le contexte du traitement d'images IRM structurelles, **SPM** est utilisé pour réaliser des étapes de **prétraitement** essentielles, notamment [40]:

- **La segmentation** des tissus cérébraux (subdivisant chaque voxel en matière grise, blanche, LCR, etc.) à l'aide de modèles statistiques basés sur des mélanges de gaussiennes.
- **La normalisation spatiale**, permettant de transformer chaque cerveau en un espace de référence commun (souvent l'espace MNI), facilitant ainsi la comparaison entre sujets.
- **Le lissage spatial**, réalisé par convolution gaussienne, qui permet de mieux répondre aux hypothèses des tests statistiques paramétriques, de réduire le bruit, et d'augmenter la sensibilité de détection.
- **La modulation**, qui consiste à conserver l'information volumique après transformation spatiale, en compensant les effets de dilatation ou de contraction à l'aide du déterminant jacobien.

SPM automatise et standardise ainsi la préparation et l'analyse d'ensembles complexes d'images, en facilitant les comparaisons inter-sujets et inter-groupes tout en réduisant les biais expérimentaux.

DARTEL (Diffeomorphic Anatomical Registration Through Exponentiated Lie Algebra) est une méthode d'enregistrement diffeomorphe développée dans SPM, assurant une correspondance fluide, réversible et précise entre les structures cérébrales de différents sujets. Contrairement aux approches classiques de normalisation, DARTEL utilise un modèle de déformation plus complexe [41], intégrant jusqu'à 6 millions de paramètres, ce qui permet de capturer des variations anatomiques plus fines.

Le processus repose sur la segmentation préalable des IRM en cartes de tissus (**matière grise et blanche**), qui sont ensuite alignées itérativement vers un modèle moyen commun. Les déformations sont modélisées comme des champs de flux, optimisés selon un critère combinant similarité d'image et régularisation. Les images ainsi transformées sont modulées par le déterminant jacobien afin de conserver les volumes tissulaires et permettre des comparaisons interindividuelles fiables.






Figure 3.2 : Images des trois plans (coronale, sagittale et axiale) ; (a) T1w originales (b) après utilisation de VBM à l'espace natif (visualisé à l'aide de la fonction Check-Reg du logiciel SPM).



(a)

(b)



(c)

Figure 3.3 :les images résultantes des trois plans prétraitées, segmentées et recalées dans l'espace MNI ; (a) Tw1, (b) la matière grise, (c) la matière blanche (visualisé à l'aide de la fonction Check-Reg du logiciel SPM).

3.5 Conversion des Images 3D en 2D et Sélection de Coupes Informatives

Les images IRM structurales utilisées dans cette étude sont initialement acquises sous forme de volumes tridimensionnels (3D) au format **NIfTI (.nii)**, largement adopté dans le domaine de l'imagerie cérébrale. Cependant, les réseaux neuronaux convolutifs (CNN) standards, notamment dans leur implémentation 2D, requièrent des images bidimensionnelles

(2D) comme entrées. Afin de rendre ces volumes exploitables par des architectures CNN classiques, une phase de **conversion des images 3D en coupes 2D** est indispensable.

Cette conversion est réalisée à l'aide de scripts développés sous **MATLAB**, qui permettent de parcourir les volumes IRM voxel par voxel, et d'extraire les **coupes axiales, sagittales ou coronales**, selon la direction choisie. Dans notre cas, les **coupes axiales** sont privilégiées en raison de leur pertinence clinique pour l'évaluation de la dégénérescence, l'une des premières manifestations anatomiques de la maladie d'Alzheimer.

Étant donné que chaque volume IRM comporte plusieurs centaines de coupes, **une étape de sélection est appliquée afin d'extraire uniquement les 50 coupes les plus informatives**. Ce choix vise à concentrer l'analyse sur la région centrale du cerveau, généralement la plus riche en informations pathologiques, tout en éliminant les extrémités du volume (contenant peu ou pas de matière cérébrale utile). Cette sélection peut être opérée de manière automatique par détection de contenu (analyse d'intensité moyenne, de surface segmentée) ou manuelle selon des critères anatomiques précis.

En résumé, cette étape de transformation constitue un pont essentiel entre l'acquisition des données médicales brutes et leur exploitation par les algorithmes d'apprentissage profond, assurant à la fois efficacité, pertinence diagnostique et compatibilité technique avec l'approche de classification envisagée.

3.6 Classification par Réseaux Neuronaux Convolutifs (CNN)

Les Réseaux Neuronaux Convolutifs (CNN) représentent une avancée majeure dans le domaine de l'apprentissage profond, particulièrement adaptés à l'analyse d'images. Leur capacité à extraire automatiquement des caractéristiques discriminantes en fait un outil de choix pour la classification d'images médicales, notamment dans le cadre du diagnostic assisté par ordinateur. Dans cette section, nous présentons les principes de base des CNN ainsi que leur application spécifique à notre étude.

3.6.1 Introduction aux CNN

Il existe une grande variété de réseaux de neurones spécialisés, parmi lesquels les réseaux de neurones convolutifs (**CNN**) figurent parmi les plus répandus [\[42\]](#). Ces derniers ont démontré une efficacité remarquable dans divers domaines de la vision par ordinateur, notamment la reconnaissance d'objets, leur détection ainsi que la segmentation d'images. Les CNN partagent des similitudes structurelles avec les réseaux de neurones classiques, dans la

mesure où ils sont constitués de plusieurs couches de neurones interconnectées, dotées de poids et de biais ajustables à travers un processus d'apprentissage supervisé.

Pour comprendre le fonctionnement d'un réseau de neurones convolutifs (CNN), il est pertinent d'établir une analogie avec le traitement de l'information visuelle dans le système biologique humain. De manière comparable à la transmission des signaux visuels de la rétine vers le cerveau via le nerf optique, les CNN traitent les images en recherchant des caractéristiques spécifiques telles que les couleurs, les contours ou les motifs. Inspirés de l'architecture du cortex visuel, ces réseaux reposent sur une organisation hiérarchique composée de plusieurs couches successives. Chaque couche extrait des niveaux croissants d'abstraction à partir des données d'entrée, permettant ainsi une représentation progressive et enrichie de l'information visuelle.

La puissance des réseaux de neurones convolutifs (CNN) réside dans leur capacité à exploiter la profondeur du réseau à travers l'opération de convolution, permettant la construction d'abstractions hiérarchiques et riches à partir de caractéristiques de bas niveau extraites dans les premières couches. En convoluant successivement des cartes de caractéristiques, le réseau est en mesure de détecter des formes complexes, telles que des objets ou des entités spécifiques (par exemple, un chien ou un chat), en les composant à partir d'éléments plus simples comme des bords, des textures ou des motifs géométriques.

Cette capacité repose sur l'apprentissage automatique des filtres de convolution, ajustés au cours de l'entraînement par rétropropagation du gradient. Contrairement aux méthodes traditionnelles basées sur des descripteurs définis manuellement, les CNN apprennent de manière autonome des représentations discriminantes à différents niveaux d'abstraction bas, intermédiaire et élevé directement à partir des images. Un autre avantage notable est qu'ils ne nécessitent pas de connaissances préalables spécifiques au domaine, rendant possible l'apprentissage de tâches complexes uniquement à partir des données disponibles.

Comparativement aux réseaux de neurones classiques, les réseaux de neurones convolutifs (CNN) se distinguent par leur efficacité dans le traitement des données d'image. En effet, au lieu d'apprendre un poids par pixel pour chaque neurone, comme c'est le cas dans un réseau de neurones entièrement connecté, ce qui entraînerait, par exemple, un million de paramètres par neurone pour une image de taille mégapixel, un CNN apprend uniquement un nombre restreint de paramètres par filtre. Par exemple, un filtre de taille 3×3 nécessite l'apprentissage de seulement neuf poids, auxquels s'ajoute un biais. Cette architecture locale

et partagée permet aux CNN de traiter les images de manière beaucoup plus efficace, en réduisant considérablement la complexité du modèle tout en conservant la capacité à extraire des caractéristiques pertinentes.

Les composantes fondamentales d'un réseau de neurones convolutif (CNN) comprennent généralement une couche d'entrée, suivie de couches de convolution, d'activation, de sous-échantillonnage (**pooling**), et se terminent par une ou plusieurs couches entièrement connectées. L'ensemble de ces éléments structurels constitue l'ossature typique d'une architecture CNN. À titre illustratif, cette configuration est parfaitement incarnée par l'architecture **LeNet** classique, introduite dans [43], qui demeure une référence historique dans le domaine de la reconnaissance d'images.




Figure 3.4 :Un réseau neuronal simple et un réseau neuronal convolutif.

a. Couche de convolution :

L'objectif principal de cette étape est d'extraire automatiquement des caractéristiques pertinentes à partir de l'image, en générant une représentation fondée sur les traits distinctifs présents dans l'ensemble de données analysé [44]. Le mécanisme de fonctionnement repose sur une structure simple mais efficace : chaque couche de convolution est constituée d'un ensemble de filtres (ou noyaux) convolutifs, dont le nombre est spécifié par l'utilisateur (par exemple 1 à 128). La profondeur de chaque filtre est déterminée par le nombre de canaux de l'entrée (par exemple, une image en niveaux de gris ou en couleur).

Lors de cette opération, chaque filtre est appliqué à l'image en se déplaçant (ou glissant) spatialement sur celle-ci, de manière à produire une carte d'activation en sortie, également

appelée carte de caractéristiques. Cette opération consiste en une série de multiplications entre les valeurs des pixels de l'image et celles du filtre correspondant. Sur le plan mathématique, la convolution est une opération commutative, généralement notée selon la formule présentée en (équation 3.1).

$$conv(x, y) = (I * K)(x, y) \sum_i \sum_k I(i, k) K(x - i, y - k) \dots\dots\dots (3.1)$$

Où :

x, y représentent, les coordonnées en pixels d'une image.

conv : est la sortie de l'opération de convolution.

I : Image d'entrée.

K : est le filtre.

i × k : représente la taille du filtre.

Le volume de sortie résultant d'une opération de convolution est déterminé par plusieurs paramètres essentiels, à savoir : le nombre de filtres (K), la taille des filtres (F), le pas de convolution (stride, noté S) et le remplissage par zéros (padding, noté P). Le champ récepteur, déjà évoqué, correspond aux dimensions spatiales couvertes par chaque filtre lors de la convolution. Le nombre de filtres utilisés détermine quant à lui la profondeur du volume de sortie obtenu après l'application des filtres.

La taille du noyau influence la manière dont le filtre est appliqué sur l'image, tandis que le pas (S) définit le nombre de pixels sautés lors du déplacement du filtre sur les dimensions spatiales de l'image. Afin de contrôler plus finement la dimensionnalité du volume de sortie, il est parfois utile d'ajouter des zéros autour des bords de l'image d'entrée, une technique appelée zéro-padding. Cette opération permet de dissocier la taille des filtres de celle du volume de sortie, offrant ainsi une plus grande flexibilité dans la conception de l'architecture du réseau convolutif, comme illustré dans la figure III.2

Chapitre 3

0	0	0	0	0	0
0	35	19	25	6	0
0	13	22	16	53	0
0	4	3	7	10	0
0	9	8	1	3	0
0	0	0	0	0	0

Figure 3.5 :une matrice 4x4 à zéro-padding

b. Couche d'activation

Dans la couche d'activation, les réponses de sortie des couches de convolution, sont cartographiées, via une fonction d'activation non linéaire. Un choix populaire, parmi les fonctions d'activation, est la fonction ReLU.

Selon la figure III.3, si l'entrée est négative, elle sera convertie en 0, et le neurone ne sera pas activé. Cela signifie, qu'à la fois, seuls quelques neurones sont activés, ce qui rend le réseau, clairsemé et très efficace.

Matrice d'entrée					Activation RELU			
55	-2	51	24	→	55	0	51	24
86	25	75	-63		86	25	75	0
25	-12	02	35		25	0	02	35
95	15	-25	44		95	15	0	44

Figure 3.6 :Mécanisme de la fonction RELU.

c. Couche de pooling :

La couche de pooling contribue à réduire la dimensionnalité des cartes de caractéristiques générées par les couches de convolution, ce qui allège le modèle en diminuant le nombre de paramètres à traiter. Elle agit en regroupant les informations de régions voisines, conservant ainsi les éléments les plus pertinents tout en atténuant les variations mineures.

Ce processus permet d'obtenir une représentation plus compacte et plus résistante aux petites déformations ou déplacements dans l'image. Les méthodes les plus utilisées sont le max pooling et le average pooling, tandis que d'autres variantes comme le sum pooling restent moins courantes.




Figure 3.7 :Exemple illustratif des différentes stratégies de pooling (max, moyen et somme) avec une fenêtre de taille 2×2 et un pas de déplacement identique.

d. **Couche entièrement connectée** : La couche entièrement connectée correspond à celle des réseaux de neurones classiques, dans laquelle chaque neurone est connecté à l'ensemble des neurones de la couche précédente. Son apprentissage repose sur le même mécanisme d'optimisation, tel que précédemment décrit, et son fonctionnement est illustré dans la figure III.4.




Figure 3.8 :Couche entièrement connectée sur une matrice

.La couche Softmax

Est une couche de sortie utilisée dans les modèles de classification multi-classes. Elle transforme les scores bruts du réseau en probabilités comprises entre 0 et 1, dont la somme est égale à 1. Chaque valeur représente la probabilité d'appartenance de l'entrée à une classe donnée. La classe prédite est celle avec la probabilité la plus élevée.

3.6.2 Optimisation

L'optimisation constitue une étape fondamentale dans le processus d'apprentissage des algorithmes d'apprentissage profond. Elle vise à ajuster les paramètres du modèle de manière à minimiser ou maximiser une fonction objective, selon la nature de la tâche à accomplir. Dans le cadre de tâches de minimisation, cette fonction est généralement désignée sous les termes de fonction de coût, de perte ou d'erreur[\[45\]](#).

3.6.3 Régularisation

La régularisation constitue une étape cruciale dans l'entraînement des modèles d'apprentissage automatique, visant à optimiser la fonction de résolution tout en évitant le phénomène de sur-apprentissage (overfitting). Ce dernier se produit lorsque le modèle s'adapte excessivement aux données d'apprentissage, compromettant ainsi sa capacité de généralisation sur de nouvelles données. Plusieurs techniques ont été développées pour y remédier efficacement.

3.6.4 La modification de l'architecture du réseau

Est également une stratégie courante. Elle repose sur l'ajustement structurel du modèle, en ajoutant ou supprimant des couches, ou en adaptant les paramètres de configuration, jusqu'à l'obtention d'une architecture optimale répondant aux besoins spécifiques de la tâche.

La couche Dropout

Représente une technique de régularisation particulièrement efficace introduite récemment. Son principe consiste à désactiver aléatoirement un pourcentage donné de neurones à chaque itération d'apprentissage. Par exemple, un taux de dropout de 50 % implique que la moitié des neurones d'une couche donnée ne participent pas temporairement à la mise à jour des poids lors de la rétropropagation. Cette approche favorise une meilleure indépendance des neurones, en réduisant les co-adaptations entre eux, ce qui améliore la robustesse et la capacité de généralisation du modèle[46].




Figure 3.9 :Exemple de couche dropout (la probabilité de 50 % apparaît à droite)

Architecture proposée

Chapitre 3

L'architecture du réseau de neurones convolutionnels (CNN) utilisée dans cette étude a été conçue pour classifier les images IRM 2D converties à partir de volumes 3D. Le réseau est constitué de plusieurs couches successives permettant l'extraction hiérarchique de caractéristiques discriminantes voir figure et tableau 2

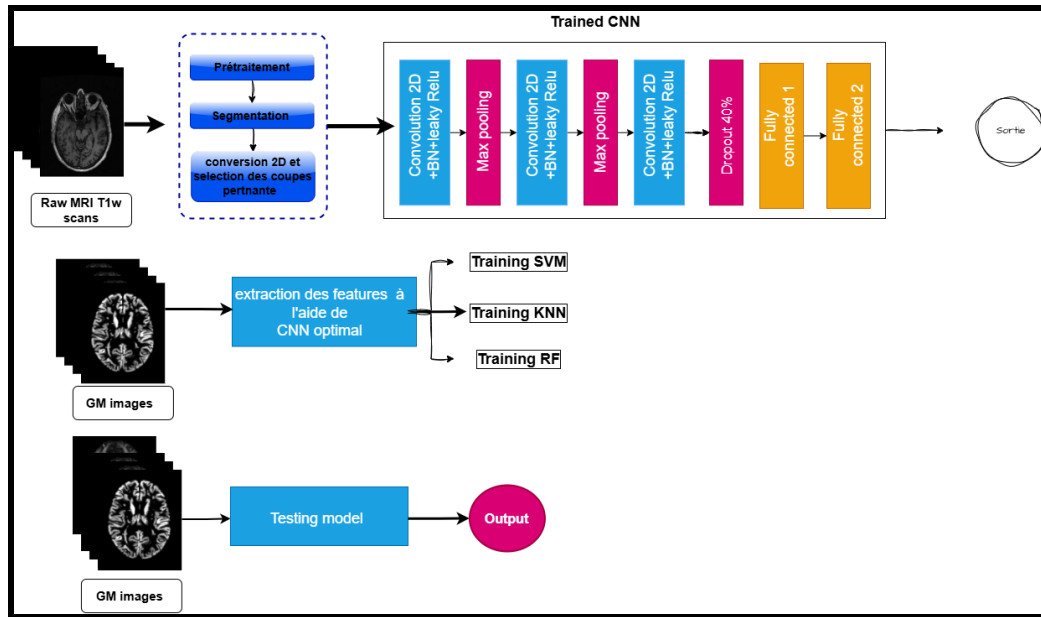


Figure 3.10 :architecture de modèle proposée

Table 2.2 ::Propriétés des couches pour l'architecture 2DCNN proposée

Étape	Description
Entrée	Image IRM 2D de taille 137 × 113 × 1
Convolution 1	32 filtres 3×3 + LeakyReLU ($\alpha = 0.01$) + MaxPooling (2×2)
Convolution 2	64 filtres 5×5 + LeakyReLU + MaxPooling (2×2)
Convolution 3	128 filtres 5×5 + LeakyReLU + MaxPooling (2×2)
Global Average Pooling	Réduction spatiale des cartes de caractéristiques
Dropout	Taux de régularisation : 40% pour éviter

Chapitre 3

	le surapprentissage
Fully Connected	Couche dense : 64 neurones
Sortie (FC)	Couche dense finale avec 3 neurones correspondant aux classes : AD, CN, MCI
Classification	Fonction Softmax pour la sortie multiclassées

- **Taille des filtres** : Des noyaux de petite taille (3×3 et 5×5) ont été choisis pour permettre une extraction locale efficace des caractéristiques, tout en conservant une complexité raisonnable.
- **Nombre de filtres** : Le nombre de canaux augmente progressivement ($32 \rightarrow 64 \rightarrow 128$) pour permettre une extraction de plus en plus abstraite des motifs caractéristiques des images cérébrales.
- **Fonction d'activation LeakyReLU ($\alpha = 0.01$)** : Cette fonction permet d'atténuer le problème de "neurones morts", souvent rencontré avec la ReLU classique.
- **MaxPooling** : Le pooling avec stride 2 permet de réduire la taille spatiale des cartes d'activation, diminuant ainsi le nombre de paramètres et les coûts de calcul tout en conservant les informations essentielles.
- **Global Average Pooling** : Moins sujet à l'overfitting que les couches entièrement connectées classiques, elle permet une meilleure généralisation.
- **Dropout (0.4)** : Utilisé comme méthode de régularisation, il permet de limiter le surapprentissage en désactivant aléatoirement des neurones lors de l'apprentissage.

3.7Présentation des Classifieurs Utilisés

Les classifieurs choisis pour cette étude sont les suivants :

3.7.1 Support Vector Machine (SVM) : un algorithme d'apprentissage supervisé qui vise à trouver l'hyperplan optimal séparant les différentes classes en maximisant la marge entre elles, ce qui permet une bonne généralisation sur des données non vues.

3.7.2 K-Nearest Neighbors (KNN) : une méthode non paramétrique qui classe un échantillon en fonction des classes majoritaires de ses k plus proches voisins dans l'espace des caractéristiques, reposant sur une mesure de distance appropriée.

3.7.3 Random Forest (RF) : un modèle d'ensemble constitué d'un grand nombre d'arbres de décision, où chaque arbre est construit sur un sous-ensemble aléatoire des données et des variables, permettant de réduire le surapprentissage et d'améliorer la précision globale.

3.8 Conclusion

Dans ce chapitre, nous avons présenté de manière détaillée l'approche méthodologique développée pour concevoir un système d'aide au diagnostic précoce de la maladie d'Alzheimer à partir d'images IRM structurales. Chaque étape du pipeline a été décrite avec rigueur, depuis la sélection et la préparation des données issues de la base ADNI jusqu'à la mise en œuvre du modèle de classification basé sur les réseaux neuronaux convolutifs (CNN).

L'étape de **prétraitement** a permis d'améliorer la qualité des images et d'assurer leur comparabilité interindividuelle grâce à des outils performants tels que SPM et DARTEL. La **conversion des images 3D en 2D** et la sélection de coupes informatives ont permis d'optimiser l'entrée du modèle tout en réduisant la charge computationnelle, un aspect fondamental pour la reproductibilité et l'efficacité du processus.

L'intégration d'un **modèle CNN personnalisé**, structuré en couches convolutionnelles, de normalisation, de pooling et entièrement connectées, a offert une solution d'apprentissage supervisé performante pour la classification des images selon trois groupes cliniques : AD, MCI et CN. Des techniques d'optimisation et de régularisation ont également été appliquées afin de garantir la stabilité et la robustesse du modèle.

Cette approche pose ainsi les bases expérimentales solides sur lesquelles reposent les analyses du chapitre suivant. Le **chapitre 4** sera consacré à la présentation et à l'interprétation des **résultats obtenus**, à travers plusieurs expérimentations comparatives. Il permettra d'évaluer les performances du système proposé, d'en dégager les points forts et les limites, et d'envisager des pistes d'amélioration pour des travaux futurs.

Chapitre 4

Résultats et Discussion

4.1 Introduction

Ce chapitre présente et analyse les résultats des différentes expérimentations menées pour évaluer l'efficacité du système proposé de diagnostic précoce de la maladie d'Alzheimer à partir d'images IRM structurelles. Trois approches sont étudiées : une classification par CNN appliquée aux différentes régions cérébrales, une combinaison CNN + classifieurs classiques, puis une fusion des caractéristiques extraites. Les performances sont comparées à l'aide de courbes d'apprentissage, matrices de confusion et indicateurs tels que l'accuracy, la sensibilité, la spécificité et le F1-score.

4.2 Environnement de travail

Les expériences menées dans le cadre de cette étude ont été réalisées en local sur un ordinateur, PC portable (nom de l'hôte : *DESKTOP-6TOM2M8*), un **processeur** Intel(R) Core (TM) i5-6300U CPU @ 2.40GHz, 2.50 GHz (architecture double cœur avec hyper-threading), **avec une RAM** de 8 Go. Sur le plan logiciel, le développement et l'entraînement des modèles ont été effectués à l'aide de **MATLAB R2021b**

4.3 Évaluation de la performance du modèle

L'évaluation des performances constitue une étape cruciale dans le développement de tout système de classification, notamment dans le domaine médical où les erreurs peuvent avoir des conséquences importantes. Dans cette étude, l'objectif est de déterminer dans quelle mesure les modèles proposés sont capables de distinguer entre différents stades de la maladie d'Alzheimer, à partir d'images IRM structurelles.

Pour cela, une série de métriques quantitatives standard est utilisée, permettant de mesurer à la fois l'exactitude globale du modèle, mais aussi sa capacité à détecter correctement chaque classe (patients atteints de la maladie, sujets MCI, et individus sains). Ces indicateurs sont essentiels pour juger non seulement de la performance brute du modèle, mais également de sa robustesse face à la variabilité inter-sujets et à la distribution potentiellement déséquilibrée des données.

4.3.1 Rappel sur les métriques d'évaluation

La section suivante présente les différentes métriques utilisées dans le cadre de cette étude ainsi que leurs formules mathématiques.

4.3.2 Matrice de confusion

La matrice de confusion est un outil central pour évaluer la performance d'un modèle de classification. Elle compare les prédictions du modèle aux classes réelles, permettant ainsi d'identifier précisément les cas bien ou mal classés.

Dans un problème multi-classes (comme ici avec les classes *AD*, *MCI* et *CN*), la matrice est carrée ($n \times n$), où chaque cellule (i, j) indique le nombre d'instances de la classe réelle i prédites comme appartenant à la classe j .

Elle permet d'extraire des éléments clés :

- **TP (True Positive)** : bonne classification d'une classe spécifique
- **TN (True Negative)** : bonnes classifications des autres classes
- **FP (False Positive)** : mauvaise attribution d'une instance à une classe
- **FN (False Negative)** : omission d'une classe réelle

Accuracy (Exactitude) :

Il s'agit du pourcentage total de prédictions correctes. Elle mesure la capacité globale du modèle à bien classer les exemples, toutes classes confondues.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \dots\dots\dots(4.1)$$

Sensitivity (Rappel ou Taux de vrais positifs) :

Également appelée recall, cette métrique indique la proportion de cas positifs correctement identifiés. Elle est essentielle pour évaluer la capacité du modèle à détecter les cas de maladie d'Alzheimer ou MCI.

$$\text{Sensitivity} = \frac{TP}{TP + FN} \dots\dots\dots(4.2)$$

Precision (Précision) :

Elle représente la proportion des prédictions positives qui sont réellement positives.

$$\text{Precision} = \frac{TP}{TP+FP} \dots\dots\dots(4.3)$$

F1-Score :

C'est une moyenne harmonique entre la précision et le rappel. Elle est particulièrement utile lorsque les classes sont déséquilibrées.

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \dots\dots\dots(4.4)$$

4.4 Expérience 1 : Classification avec CNN

Dans cette première expérience, l'objectif était d'évaluer les performances du modèle CNN proposé sur trois types d'images IRM 2D extraites de différentes régions cérébrales : la **matière grise**, la **matière blanche**, et le **cerveau entier**. Chaque modèle est entraîné indépendamment sur les données correspondantes, selon la même architecture CNN, afin de comparer l'impact de la région cérébrale utilisée sur la qualité de la classification.

4.4.1 Résultats

Les figures ci-dessous illustrent les courbes d'apprentissage du modèle CNN pour chaque type de région cérébrale, montrant l'évolution de la précision (accuracy) et de la fonction de perte (loss) au fil des époques, aussi bien pour les ensembles d'entraînement que de validation.




Figure 6 Courbes d'apprentissage (Accuracy et loss) pour l'entraînement du modèle CNN sur les images IRM du cerveau entier




Figure 4.1 : Courbes d'apprentissage (Accuracy et loss) pour l'entraînement du modèle CNN sur les images IRM du matière grise




Figure 4.2 : Courbes d'apprentissage (Accuracy et loss) pour l'entraînement du modèle CNN sur les images IRM du cerveau entier

Tableau 4.1 :Précision de classification du modèle CNN selon la région cérébrale utilisée.

Région cérébrale	Accuracy (%)
Matière grise	80,87%
Matière blanche	78,13%
Cerveau entier	75,60%

4.4.2 Discussion des résultats de la première expérimentation

L'analyse des performances du modèle CNN sur les différentes régions anatomiques met en évidence des écarts significatifs selon la modalité utilisée. L'entraînement sur les images issues de la **matière grise** a permis d'atteindre la **meilleure précision** avec un taux de **80,87 %**, ce qui témoigne de la richesse des informations discriminantes contenues dans cette structure, souvent impliquée dans les premiers signes de neurodégénérescence, notamment dans le contexte de la maladie d'Alzheimer.

À l'inverse, l'utilisation du **cerveau entier** a conduit à une performance légèrement inférieure (**75,60 %**). Cette baisse peut s'expliquer par la complexité accrue des données, incluant à la fois des régions informatives et non informatives pour la tâche de classification, ce qui peut perturber l'apprentissage du modèle.

Enfin, l'analyse de la **matière blanche** a abouti à une précision intermédiaire (**78,13 %**), suggérant que cette structure contient également des caractéristiques pertinentes, bien que moins directement marquées que celles de la matière grise.

Ces résultats montrent que la **spécificité anatomique** des images utilisées joue un rôle déterminant dans la performance du modèle, et qu'un **choix raisonné des modalités** d'entrée peut significativement impacter l'efficacité de la classification. Cette observation ouvre la voie à des approches multimodales ou à la sélection de régions d'intérêt (ROI) plus ciblées dans les travaux futurs.

À la lumière des résultats obtenus lors de la première expérimentation, il apparaît que l'utilisation d'un modèle CNN seul permet d'obtenir des performances intéressantes, mais

perfectibles, selon la modalité anatomique choisie. Afin d'explorer davantage les potentialités de classification, une **seconde expérimentation** a été mise en œuvre, intégrant un **schéma hybride** combinant l'extraction automatique des caractéristiques via le CNN à des **classifieurs traditionnels** tels que SVM, k-NN ou encore Random Forest

4.5 Expérience 2 : Extraction de caractéristiques via CNN + Classifieurs classiques

4.5.1 Méthodologie

Dans le cadre de cette seconde expérimentation, une approche hybride est adoptée, combinant les capacités d'extraction de caractéristiques du réseau neuronal convolutionnel (CNN) à des classifieurs d'apprentissage automatique traditionnels. L'objectif est d'évaluer si les représentations internes apprises par le CNN peuvent être exploitées de manière plus efficace par des classifieurs classiques pour améliorer les performances de classification.

L'architecture CNN précédemment entraînée est utilisée comme extracteur de caractéristiques. Plus précisément, les descripteurs ont été extraits à partir de la **première couche entièrement connectée (fc1)**, juste avant la couche de sortie. Cette couche fournit une représentation vectorielle de dimension 64, capturant les caractéristiques abstraites les plus discriminantes apprises par le réseau à partir des images IRM.

Ces vecteurs sont ensuite utilisés comme **entrée pour la classification** via plusieurs modèles d'apprentissage supervisé traditionnels : **Support Vector Machine (SVM)**, **k-Nearest Neighbors (k-NN)** et **Random Forest (RF)**.

L'ensemble du processus de classification est réalisé à l'aide de l'**application "Classification Learner" intégrée à MATLAB**, qui permet de tester rapidement plusieurs algorithmes, d'ajuster les paramètres, et de visualiser les performances sous forme de matrices de confusion, courbes ROC et scores d'évaluation (accuracy, précision, rappel...).

Cette stratégie permet de comparer l'efficacité de différents classifieurs à partir d'un espace de caractéristiques identique, en vue de déterminer le modèle le plus performant selon la modalité d'imagerie utilisée.

4.5.2 Résultats obtenus

À la suite de l'extraction des caractéristiques à partir de la première couche entièrement connectée (fc1) du réseau CNN, plusieurs classifieurs traditionnels ont été appliqués, notamment le **Support Vector Machine (SVM)**, le **k-Nearest Neighbors (k-NN)** et le

Random Forest. L'objectif de cette seconde expérimentation est d'évaluer l'efficacité de la combinaison entre l'extraction automatique de caractéristiques par CNN et la classification supervisée via des algorithmes d'apprentissage machine classiques.

Les résultats sont présentés dans un tableau comparatif synthétique pour chaque classifieur et pour chacune des trois modalités anatomiques testées : **matière grise, matière blanche, et cerveau entier**. Ces performances sont ensuite complétées par les matrices de confusion correspondantes et les courbes ROC, afin de visualiser plus finement la capacité de discrimination de chaque modèle.

4.5.2.1 Résultats pour la matière grise

Cette première configuration repose sur l'extraction des caractéristiques issues de **la matière grise**. Le tableaux suivants présentent les performances des trois classifieurs.

Table 3.2:Les performance pour matière grise

Classifieur	Classe	Accuracy (%)	Precision (%)	Sensitivity (Recall) (%)	Specificity (%)	F1-score (%)
CNN+KNN	AD	99,89 %	99,64%	99,60%	99,75%	96,64%
	CN	86,93 %	78,29%	81,04%	89,96%	80,38%
	MCI	86,53 %	80,27%	79,12%	89,53%	79,75%
	Moyenne	91,12 %	86,55%	86,59 %	93,25%	86,59%
CNN+SVM	AD	90,99%	99,48%	99,60%	99,68%	99,54%
	CN	88.87 %	74,55%	81,23%	91,90%	77,75%
	MCI	88.04 %	79,55%	77,54%	87,60%	78,28%
	Moyenne	92,27%	84,53%	86.12	93.06	85.28
CNN+RF	AD	99.63 %	99,20%	99,32%	98,96%	99,26%
	CN	88.16 %	74,47%	79,87%	91,79%	77,08%
	MCI	87.46 %	77,80%	72,84%	89,36%	75,24%
	Moyenne	91.75 %	83,82%	84,01%	93,37%	83,86%




Figure 4.3 :Matrice de confusion de classification (MG) CNN+ : (a)KNN ; (b) SVM et (c) RF

4.5.2.2 Résultats pour la matière blanche

Table 4.3:Les performances de la matière blanche

Classifieur	Classe	Accuracy%	Précision (%)	Sensibilité (Rappel) (%)	Spécificité (%)	F1-score (%)
CNN+ RF	AD	99.63 %	99,20%	99,32%	98,96%	99,26%
	CN	88.16 %	74,47%	79,87%	91,79%	77,08%
	MCI	87.46 %	77,80%	72,84%	89,36%	75,24%
	Moyenne	91.75 %	83,82%	84,01%	93,37%	83,86%
CNN+ KNN	AD	99,79%	99,76%	99.80%	99,86%	99,78%
	CN	80,06%	70,09%	70,56%	84,92%	70,32%
	MCI	79,94%	70,06%	69,72%	85,08%	69,89%
	Moyenne	86,60%	79,97%	80,03%	89,95%	79,99%
CNN+SVM	AD	99.66 %	99.72%	99.64%	99.86%	99.68%
	CN	87.44 %	74.85%	76.44%	87.16%	75.64%
	MCI	86.48 %	75.62%	74.08%	88.06%	75.64%

	Moyenne	91.19 %	83.40%	83.39%	91.69%	83.39%
--	----------------	----------------	---------------	---------------	---------------	---------------

AD	2495		5
CN		1764	736
MCI	6	751	1743
	AD	CN	MCI

Predicted Class

(a)

AD	2491	1	8
CN		1911	589
MCI	7	641	1652
	AD	CN	MCI

Predicted Class

(b)

AD	2490		10
CN		1822	678
MCI	6	741	1753
	AD	CN	MCI

Predicted Class

(c)


Figure 4.4: Matrice de confusion de classification (MB) CNN+ : (a) KNN ; (b) SVM et (c) RF

4.6.2.3 Résultats pour le cerveau entier


Table 4.4 : Les performances du cerveau entier

Classifieur	Classe	Accuracy%	Précision (%)	Sensibilité (Rappel) (%)	Spécificité (%)	F1-score (%)
CNN+ RF	AD	97.23%	96.98%	96.12%	98.75%	96.55 %
	CN	85.04%	73.23%	78.52%	88.03%	75.78 %
	MCI	83.45%	73.36%	68.68%	89.60%	70.94 %
	Moyenne	88.57%	81.19%	81.11%	92.13%	81.09 %
CNN+ KNN	AD	97.64 %	97.24%	97.20%	98,32%	97.22 %


	CN	88.05 %	76.32%	77.72%	87.94%	77.01 %
	MCI	86.84 %	75,32%	73.96%	87.88%	74.63 %
	Moyenne	90.84 %	82.96%	82.96%	91.38%	82.95 %
CNN+SVM	AD	96.76 %	96.23%	94.91%	98.45%	95.56 %
	CN	89.41 %	77.42%	79.40%	87.64%	78.40 %
	MCI	87.17 %	76.60%	76.32%	86.88%	76,46 %
	Moyenne	91.11 %	83.42%	83.54%	90.99%	83.47 %



(a)



(b)



(c)

Figure 4.5 :Matrice de confusion de classification (MB) CNN+ : (a)KNN ; (b) SVM et (C) RF




Figure 4.6 : Évaluation comparative des classifieurs sur les différentes régions du cerveau"

L'histogramme présenté ci-dessous offre une visualisation comparative claire des performances obtenues par les trois classifieurs classiques (KNN, SVM, Random Forest) selon les différentes modalités anatomiques considérées. Il met en évidence l'influence significative de la région cérébrale utilisée pour l'apprentissage sur l'accuracy du modèle.

4.5.3 Discussion des résultats de la deuxième expérimentation

Les performances sont analysées pour les trois types de régions cérébrales : matière grise, matière blanche et cerveau entier. Les résultats indiquent que l'approche hybride permet d'atteindre des performances globalement supérieures à celles obtenues dans la première expérimentation avec le CNN seul.

Pour la matière grise, les trois classifieurs ont montré des performances robustes, en particulier le SVM, avec une précision supérieure à 89 % et des F1-scores élevés pour toutes les classes. Cette amélioration s'explique probablement par la capacité du CNN à extraire des caractéristiques discriminantes, combinée à la puissance des classifieurs classiques à gérer des espaces de caractéristiques bien séparés.

Dans le cas de la matière blanche, les résultats sont également encourageants, notamment avec Random Forest, qui a présenté un bon équilibre entre sensibilité et spécificité pour les trois classes. Cela confirme que la matière blanche contient des informations pertinentes pour la classification, bien que souvent sous-estimée.

Concernant le cerveau entier, bien que les performances restent satisfaisantes, elles sont légèrement inférieures à celles observées avec les modalités focalisées. Cela suggère que la combinaison de zones cérébrales non ciblées pourrait introduire des redondances ou du bruit affectant l'efficacité des descripteurs extraits.

L'analyse globale montre que l'approche CNN + classifieurs classiques améliore la capacité de généralisation, notamment dans le contexte d'un nombre limité de données d'entraînement. Le tableau comparatif final et l'histogramme généré permettent de visualiser clairement les performances différentielles entre les classifieurs et les régions, confirmant l'intérêt de l'approche multimodale et multi-classifieur pour le diagnostic assisté de la maladie d'Alzheimer.

4.6 Troisième expérimentation : Fusion des caractéristiques extraites par CNN

4.6.1 Méthodologie

Dans cette troisième expérimentation, nous avons exploré l'impact de la **fusion des caractéristiques** issues des différentes régions cérébrales (matière grise, matière blanche et cerveau entier) sur les performances de classification. L'objectif principal est de tirer parti de la **complémentarité des informations anatomiques** disponibles dans chaque modalité afin d'améliorer la capacité de discrimination du système.

La stratégie adoptée repose sur l'extraction préalable des **vecteurs de caractéristiques** à partir de la première couche entièrement connectée (f_{c1}) du modèle CNN entraîné individuellement sur chaque type de région. Ces vecteurs ont ensuite été **concaténés** deux à deux, puis dans un second temps les trois à la fois, pour constituer une représentation plus riche des données IRM.

Nous avons ainsi évalué les combinaisons suivantes :

- Fusion 1 : Matière grise + Matière blanche
- Fusion 2 : Matière grise + Cerveau entier
- Fusion 3 : Matière blanche + Cerveau entier
- Fusion 4 : Matière grise + Matière blanche + Cerveau entier

Pour chaque fusion, les vecteurs résultants ont été utilisés comme entrées pour trois classifieurs classiques (SVM, KNN, Random Forest), dans le but de comparer leurs

performances respectives. Les résultats obtenus sont présentés ci-après à travers les matrices de confusion, les métriques d'évaluation standard.

4.7 Résultats expérimentaux

Fusion 1 : Matière grise + Matière blanche

Dans cette première configuration de fusion, les vecteurs de caractéristiques extraits des régions de la matière grise et de la matière blanche ont été combinés.

Table4.5:Les performances du Fusion 1

	Classe	Accuracy (%)	Précision (%)	Sensibilité (Recall) (%)	Spécificité (%)	F1-score (%)
CNN+RF	AD	99.79%	99,60%	99.80%	99,85%	99.70%
	CN	92,50%	77.09%	82,39%	94.78%	79.65%
	MCI	91,88%	80,26%	74,63%	95,18%	77.33%
	Moyenne	94,72%	85.65%	85.61%	96,60%	85,56%
CNN+KNN	AD	99.92%	99.76%	100.00%	99.88%	99.88%
	CN	88,89%	83.67%	99,71%	99,85%	90,39%
	MCI	88.89%	83.37%	83.74%	91.68%	88.01%
	Moyenne	92.57%	88 ?93%	99,48%	94.47%	92.76%
CNN+SVM	AD	99,88%	99.76%	99.84%	99.88%	99,80%
	CN	91.01%	83.25%	99.72%	92.88%	90.86%
	MCI	91,12%	85,09%	82,74%	94.09%	83,90%
	Moyenne	94.00%	89.37%	94.10%	95,62%	91,52%




Figure 4.7 :Matrice de confusion de classification (Fusion 1) CNN+ : (a)KNN ; (b) SVM et (C) RF

Fusion 2 : Matière grise + Cerveau entier

Cette deuxième fusion combine les caractéristiques extraites de la matière grise et du cerveau entier afin de bénéficier à la fois d'informations régionales et globales. Les résultats obtenus à l'aide des classifieurs KNN, SVM et Random Forest sont présentés ci-dessous.

Table4.6:Les performances du Fusion 2

Classifieur	Classe	Accuracy%	Précision (%)	Sensibilité (Rappel) (%)	Spécificité (%)	F1-score (%)
CNN+ RF	AD	95,73%	97.18%	94,21%	95,87%	95.67%
	CN	9,52%	82.12%	85,57%	90,23%	83.82%
	MCI	89,25%	83,57%	91,30%	86,57%	87.27%
	Moyenne	92,17%	87.62%	90,36%	90.89%	88,92%
CNN+ KNN	AD	98,55%	99.27%	99,20%	98.75%	99,24%
	CN	96.72%	99,83%	92,44%	96.43%	92,13%
	MCI	94.85%	91,60%	92.37%	94,71%	91,98%
	Moyenne	99,71%	94,23%	94.67%	96,63%	94.45%
CNN+SVM	AD	97,08%	98,00%	96.08%	97,91%	97,03%
	CN	93,87%	86,84%	87,39%	93.70%	87.11%
	MCI	92,86%	85,61%	93.51%	91.01%	89.39%

	Moyenne	94.60%	90,1	92.33%	94,21%	91,18%
--	----------------	---------------	-------------	---------------	---------------	---------------

AD	2482	4	14
CN	5	2306	189
MCI	17	188	2295
	AD	CN	MCI

Predicted Class

(a)

AD	2450	15	35
CN	5	2217	278
MCI	18	290	2192
	AD	CN	MCI

Predicted Class

(b)

AD	2434	12	54
CN	5	2163	329
MCI	44	438	2018
	AD	CN	MCI

Predicted Class

(c)

Figure 4.8 :Matrice de confusion de de classification (Fusion 2) CNN+ : (a)KNN ; (b) SVM et (C) RF

• Fusion 3 : Matière blanche + Cerveau entier

Dans cette expérimentation, nous avons combiné les caractéristiques extraites des images de la matière blanche et celles du cerveau entier, dans le but d'exploiter à la fois les informations locales et globales.

Table 4.7:Les performances du Fusion 3

Classifieur	Classe	Accuracy%	Précision (%)	Sensibilité (Rappel) (%)	Spécificité (%)	F1-score (%)
CNN+ RF	AD	94.08%	97.44%	94.08%	98,35%	95.74%
	CN	90.79%	77.62%	90.79%	91,17%	83,66%
	MCI	88.20%	79,34%	88.20%	91,25%	83.53%
	Moyenne	91.02%	84,80%	91.02%	93.59%	87,64%
CNN+ KNN	AD	98,92%	99.04%	98.92%	99.52%	98.98%
	CN	89.20%	88,28%	89.20%	94.08%	88.74%
	MCI	87,48%	88.29%	87.48%	94.20%	87,88%

	Moyenne	91.87%	91.87%	91,87%	95,93%	91,87%
CNN+SVM	AD	97.10%	98.07%	97.10%	98,80%	97,58%
	CN	91,37%	86.56%	91.37%	94.47%	88,90%
	MCI	90.31%	87,98%	90.31%	94.62%	89.13%
	Moyenne	92.93%	90,87%	92.93%	95,30%	91.87%

True Class	AD	2473	4	23
	CN	3	2230	267
	MCI	21	292	2187
	Predicted Class	AD	CN	MCI

True Class	AD	2454	18	48
	CN	8	2212	280
	MCI	27	308	2168
	Predicted Class	AD	CN	MCI

True Class	AD	2418	11	71
	CN	10	2113	377
	MCI	58	562	1885
	Predicted Class	AD	CN	MCI

Figure 4.9 :Matrice de confusion de classification (Fusion 2) CNN+ : (a)KNN ; (b) SVM et (C) RF

(a)

(b)

(c)


Fusion 4 : Matière grise + Matière blanche + Cerveau entier

Dans le cadre de cette dernière expérimentation, les caractéristiques extraites des trois régions cérébrales (matière grise, matière blanche et cerveau entier) ont été fusionnées afin d'exploiter l'ensemble des informations anatomiques disponibles.


Table4.8:Les performances du Fusion 4

Classifieur	Classe	Accuracy%	Précision (%)	Sensibilité (Rappel) (%)	Spécificité (%)	F1-score (%)
CNN+ RF	AD	97,60%	93.79%	96,34%	98.71%	95.55%


	CN	94.81%	88,05%	93,82%	96.46%	92,66%
	MCI	95,84%	91.44%	94.48%	97,09%	93.53%
	Moyenne	96.08%	91.09%	94,88%	97,42%	93.91%
CNN+ KNN	AD	99,59%	99,28%	99.48%	99,64%	99,38%
	CN	96.45%	94,40%	95,00%	97,18%	94.70%
	MCI	96.23%	94.72%	93,92%	97,38	94,32%
	Moyenne	97,42%	96,13%	96.13%	98,07%	96.13%
CNN+SVM	AD	98.94%	97.07%	98.13%	99.52%	97,75%
	CN	96.45%	92.39%	94,92%	97.69%	94,75%
	MCI	97,79%	95.17%	96.49%	98.24%	96.52%
	Moyenne	97.73%	94.88%	97,51%	98,48%	96.34%



(a)



(b)



(c)

Figure 4.10 Matrice de confusion de classification (Fusion 2) CNN+ : (a) KNN ; (b) SVM et (c) RF




Figure 4.11 : Évaluation comparative des classifieurs sur les différentes fusions des régions cérébrale"

Cette figure illustre la variation des précisions de classification obtenues par les trois classifieurs (KNN, SVM, RF) pour chaque combinaison de régions cérébrales fusionnées : matière grise + matière blanche (MG+MB), matière grise + cerveau entier (MG+CE), matière blanche + cerveau entier (MB+CE), et fusion complète (MG+MB+CE).

On observe que la fusion des trois régions (MG+MB+CE) donne les meilleurs résultats, en particulier avec le classifieur SVM, atteignant une précision de 96,6 %.

4.8 Discussion des résultats

Les résultats montrent que la **fusion binaire** entre régions cérébrales améliore les performances par rapport à l'utilisation individuelle. La combinaison **matière grise + cerveau entier** a offert de bonnes performances, suggérant une complémentarité entre ces régions.

La **fusion trirégionale** (matière grise, matière blanche, cerveau entier) a fourni les **meilleurs résultats**, en particulier avec **SVM**, qui a dépassé **95 % de précision**. Cette amélioration démontre l'efficacité de l'approche multimodale pour renforcer le pouvoir discriminant du système.

Parmi les classifieurs, **SVM s'est montré le plus performant et stable**, suivi de KNN, tandis que Random Forest a montré une légère baisse, surtout pour les cas MCI.

En conclusion, la fusion des caractéristiques issues de plusieurs régions constitue une stratégie pertinente pour améliorer la détection précoce de la maladie d'Alzheimer.

4.9 Discussion globale des trois expériences

Dans la **première expérience**, basée uniquement sur des CNN, la **matière grise** a donné les **meilleurs résultats** avec **80,87 % de précision**, contre **78,13 %** pour la matière blanche et **75,60 %** pour le cerveau entier. Cela confirme le rôle prédominant de la matière grise dans les premiers signes de la maladie.

La **deuxième expérience**, combinant extraction par CNN et classification par KNN, SVM, et RF, a montré une **amélioration notable**, surtout avec **SVM** appliqué à la matière grise et au cerveau entier, atteignant **jusqu'à 93,94 % de précision**.

La **troisième expérience**, fondée sur la fusion des caractéristiques extraites de différentes régions, a permis d'atteindre les **meilleures performances globales**. La fusion trirégionale (MG+MB+CE) associée au classifieur **SVM** a permis d'atteindre **96,6 % de précision**,

soulignant l'intérêt d'une approche multimodale exploitant la complémentarité des régions cérébrales.

En conclusion, cette série d'expériences met en évidence l'importance de la qualité des données d'entrée, du choix du classifieur, et surtout de l'enrichissement des représentations par la fusion de régions cérébrales. **Une approche combinée CNN + SVM appliquée à des données fusionnées se révèle être une solution performante pour le diagnostic assisté de la maladie d'Alzheimer.**

4.10 Conclusion

Ce chapitre a présenté et analysé les résultats expérimentaux obtenus dans le cadre du développement d'un système d'aide au diagnostic précoce de la maladie d'Alzheimer à partir d'images IRM structurelles. Trois approches complémentaires sont explorées pour évaluer la robustesse du modèle et la pertinence des données utilisées.

La méthode la plus performante identifiée dans cette étude est celle combinant l'extraction automatique de caractéristiques par un réseau de neurones convolutif (CNN), suivie d'une classification par un modèle traditionnel, en particulier le SVM, appliquée aux **caractéristiques fusionnées des trois régions cérébrales** (matière grise, matière blanche et cerveau entier). Cette approche a atteint une **précision maximale de 96,33 %**, démontrant une nette supériorité par rapport aux autres configurations.

Ce résultat met en évidence la pertinence de la **fusion multimodale** dans le renforcement du pouvoir discriminant du système, en exploitant efficacement la richesse anatomique des IRM structurelles. Il constitue un apport majeur à notre mémoire, en soulignant l'intérêt d'une intégration stratégique des données cérébrales pour améliorer le **diagnostic assisté de la maladie d'Alzheimer**.

Conclusion générale

Ce mémoire a porté sur le développement d'un système d'aide au diagnostic précoce de la maladie d'Alzheimer, en s'appuyant sur l'analyse d'images IRM structurales à l'aide de techniques d'intelligence artificielle, et plus précisément de réseaux de neurones convolutifs (CNN). Nous avons proposé une approche complète, allant de la collecte et du prétraitement des données à l'entraînement de modèles de classification, en explorant différentes stratégies expérimentales.

Trois principales expériences ont été menées : une classification directe par CNN sur des régions cérébrales distinctes, une approche hybride combinant CNN et classifieurs classiques (KNN, SVM, RF), et enfin une stratégie de fusion des caractéristiques issues de plusieurs régions anatomiques. Les résultats ont montré que :

- La **matière grise** est la région la plus discriminante lorsqu'elle est utilisée seule.
- L'association **CNN + SVM** améliore significativement les performances de classification, notamment pour les cas de MCI.
- La **fusion des trois régions (MG, MB, CE)** combinée à SVM offre les **meilleurs résultats**, atteignant une précision globale **supérieure à 95 %**, démontrant ainsi la pertinence d'une approche multimodale.

L'ensemble des analyses confirme que l'intégration des techniques d'apprentissage profond dans le traitement des données IRM constitue une voie prometteuse pour la détection automatisée de la maladie d'Alzheimer. En capitalisant sur la complémentarité des informations issues de différentes régions cérébrales, notre méthode contribue à renforcer la fiabilité du diagnostic et à ouvrir la voie vers des outils d'aide à la décision plus performants et cliniquement utiles

Annexe A : Anatomie Cérébrale

Introduction :

Dans cette annexe, nous proposons une présentation structurée de l'anatomie cérébrale afin de mieux interpréter les informations contenues dans les images obtenues par résonance magnétique. Une description des structures principales du cerveau est tout d'abord fournie, en mettant en évidence leur organisation fonctionnelle ainsi que leur rôle dans le traitement cognitif.

Nous abordons également la variabilité morphologique interindividuelle, inhérente au développement cérébral, en nous appuyant notamment sur le processus de morphogenèse. Ce dernier permet de formuler des hypothèses sur la nature des déformations à estimer lors de l'alignement spatial des images.

Dans un second temps, les principales modalités d'observation du cerveau sont brièvement présentées, avec un accent particulier sur l'imagerie par résonance magnétique (IRM). Nous décrivons les fondements physiques de la résonance magnétique nucléaire, les étapes de formation des images, les contrastes disponibles, ainsi que les caractéristiques spécifiques de ces images, telles que les artefacts et le bruit, éléments déterminants dans l'analyse des données en neuroimagerie.

1. Le cerveau

1.1 Description du cerveau

Le cerveau humain, bien qu'il ne représente qu'environ 2 % de la masse corporelle totale (soit approximativement 1,4 kg), est l'organe principal de régulation et de contrôle du corps. Il assure à la fois les fonctions physiologiques fondamentales telles que la respiration, la régulation du rythme veille-sommeil ou encore la motricité, et les fonctions cognitives supérieures telles que la pensée, la mémoire, le langage, les émotions et le comportement social.

Sur le plan cellulaire[\[47\]](#), le tissu cérébral est constitué de deux types majeurs de cellules : les neurones et les cellules gliales. Les neurones sont les cellules fonctionnelles du système nerveux, spécialisées dans la réception, le traitement et la transmission de l'information. Chaque neurone comprend un soma (corps cellulaire), des dendrites qui reçoivent les signaux,

et un axone qui les transmet. Un seul neurone peut établir plusieurs milliers de connexions synaptiques, formant ainsi un réseau neuronal dense et extrêmement complexe. Les cellules gliales, quant à elles, assurent diverses fonctions de soutien, de nutrition, de protection et de régulation de l'environnement extracellulaire, contribuant ainsi indirectement au bon fonctionnement neuronal.

Sur le plan macroscopique, le cerveau se divise en substance grise, principalement composée de corps cellulaires neuronaux, et substance blanche, formée essentiellement des prolongements axonaux myélinisés permettant la communication entre différentes régions cérébrales. Ces deux types de tissus sont interconnectés et indispensables à l'intégration fonctionnelle du cerveau.

L'encéphale comprend trois grandes structures : le cerveau proprement dit, le cervelet et le tronc cérébral.

Le tronc cérébral, situé à la base de l'encéphale, relie le cerveau à la moelle épinière. Il est responsable des fonctions vitales automatiques comme la respiration et la régulation cardiaque, et joue un rôle dans l'état d'éveil et la transmission des influx nerveux.

Le cervelet coordonne les mouvements, l'équilibre et la posture.

Le cerveau, la partie la plus volumineuse, est formé de deux hémisphères cérébraux (gauche et droit), chacun divisé en quatre lobes fonctionnels :

Le lobe frontal, impliqué dans le raisonnement, la planification, les émotions et le contrôle moteur ;

Le lobe pariétal, intervenant dans le traitement de l'espace, la perception corporelle et les calculs ;

Le lobe occipital, dédié à l'analyse des informations visuelles ;

Le lobe temporal, responsable de l'audition, du langage et de la mémoire.

La surface du cerveau, ou cortex cérébral, est fortement plissée, formant des scissures (sillons) et des circonvolutions (gyri), qui permettent une augmentation significative de la surface corticale sans accroître le volume crânien. Ce cortex constitue la couche externe de substance grise et participe à l'intégration sensorielle, motrice et cognitive. Environ 70 % de sa surface est enfouie dans les plis, rendant seulement une partie visible depuis l'extérieur.

Ainsi, l'architecture cérébrale, à la fois anatomiquement sophistiquée et fonctionnellement hiérarchisée, constitue le fondement de l'ensemble des capacités humaines.




Figure A.1 : Anatomie cérébrale (illustrations modifiées d'après <http://www.abieducation.com>)

Parmi les structures internes majeures de l'encéphale, on distingue plusieurs régions essentielles au bon fonctionnement du cerveau. Le corps calleux, un épais faisceau de fibres nerveuses myélinisées assurant la communication entre les deux hémisphères cérébraux, en est un exemple notable. Il permet la coordination bilatérale des activités cérébrales. Les noyaux gris centraux, comprenant le noyau caudé, le putamen et le pallidum, sont impliqués dans la régulation des mouvements volontaires et dans certaines fonctions cognitives.

Le thalamus, quant à lui [47], agit comme un centre de relais sensoriel en triant et redirigeant les influx nerveux vers les aires corticales appropriées. Il entretient également des connexions étroites avec plusieurs autres structures, notamment le tronc cérébral, l'hypothalamus et les noyaux gris centraux. L'hypothalamus joue un rôle crucial dans l'homéostasie de l'organisme, en contrôlant les fonctions endocriniennes via l'hypophyse

ainsi que les comportements fondamentaux tels que la faim, la soif, le sommeil, la reproduction et les émotions.

Le système ventriculaire est formé de cavités remplies de liquide céphalorachidien (LCR), qui est produit par les plexus choroïdes. Ce liquide assure une fonction de protection mécanique du cerveau, contribue à l'élimination des déchets métaboliques et participe à la régulation de l'environnement chimique neuronal. Le système limbique, constitué d'un ensemble de structures interconnectées telles que l'hippocampe, l'amygdale et certaines régions de l'hypothalamus, est quant à lui impliqué dans la gestion des émotions, la mémoire à long terme et les comportements de survie.

Enfin, l'encéphale est protégé par un triple système de défense : le crâne, qui constitue une barrière osseuse rigide ; les méninges, membranes enveloppant le cerveau et assurant une protection physique et immunologique ; et le liquide céphalorachidien, qui amortit les chocs et assure le transport de diverses substances chimiques nécessaires au métabolisme cérébral.

1.2 Variabilité morphologique interindividuelle

Dans la section précédente, nous avons décrit l'anatomie cérébrale et les fonctions associées à ses différentes structures. Bien que ces structures soient présentes chez tous les individus en bonne santé, elles présentent d'importantes variations interindividuelles en termes de taille et de forme. Cette diversité constitue ce que l'on appelle la variabilité morphologique interindividuelle. Toutefois, nos connaissances actuelles sur la nature et l'étendue de cette variabilité demeurent limitées.

Cela s'explique en grande partie par le fait que l'anatomie cérébrale a longtemps été étudiée exclusivement à partir de dissections post-mortem, méthode qui présente plusieurs contraintes : limitation de l'observation à un seul plan de coupe, déformations dues au dessèchement du tissu cérébral et à son extraction de la boîte crânienne, ainsi que difficulté à réunir un échantillon suffisamment représentatif de cerveaux sains.

L'émergence de l'imagerie in vivo a permis de surmonter bon nombre de ces limitations, ouvrant ainsi de nouvelles perspectives pour l'étude anatomique du cerveau [48]. Cette avancée a notamment rendu possible la construction d'atlas cérébraux numériques, à la fois anatomiques et fonctionnels. Divers travaux ont depuis été réalisés pour analyser la variabilité de certaines structures cérébrales dans des populations saines, en s'intéressant à la fois à leur forme et à leur volume [Blatter 95, Allen 02].

Ces recherches ont mis en évidence des différences de volume cérébral global en fonction du sexe et de l'âge, ainsi que des variations spécifiques touchant certaines régions telles que les ventricules, le corps calleux ou encore les lobes cérébraux. Par ailleurs, il a été démontré que les deux hémisphères cérébraux ne sont pas parfaitement symétriques. D'autres études se sont intéressées à la variabilité corticale. Si les plis majeurs comme la fissure longitudinale, la fissure transverse, le sillon central, le sillon latéral ou encore les gyri pré- et post-centraux apparaissent relativement constants d'un individu à l'autre, les plis secondaires, eux, présentent une grande hétérogénéité : ils peuvent varier considérablement en forme, en emplacement, et être parfois absents chez certains individus.

Pour une analyse approfondie de la variabilité corticale et des approches de modélisation du cortex, le lecteur est invité à consulter les travaux de [Mangin 95]

1.3 Légitimité du recalage non rigide des images cérébrales

Le recalage non rigide des images cérébrales constitue un outil essentiel pour l'étude de la variabilité morphologique interindividuelle. Cette technique consiste à estimer une transformation qui associe à chaque point d'une image le point correspondant dans une autre image, reflétant ainsi la même réalité anatomique [49]. Cette transformation permet de caractériser précisément la variabilité morphologique entre les deux images.

Une hypothèse couramment admise dans ce contexte est l'existence d'une fonction bijective permettant d'établir une correspondance univoque entre les points des deux images. Cette propriété, également désignée sous le terme de conservation de la topologie, a été au cœur de la contribution présentée au chapitre 4. Elle garantit notamment la préservation de l'intégrité des structures déformées, c'est-à-dire l'absence de déchirures ou d'apparition de trous au cours du processus de déformation. De plus, elle assure que les relations d'adjacence entre structures connexes sont maintenues.

Afin de discuter brièvement de la légitimité de cette hypothèse, nous nous appuyerons sur les différentes étapes du développement embryonnaire de l'encéphale. Notre description débute à la quatrième semaine, dès la formation du tube neural (figure 1.2-a). L'objectif est de démontrer que l'ensemble du développement encéphalique, depuis le tube neural jusqu'à la maturation adulte, peut être considéré comme une série de déformations topologiquement conservées, c'est-à-dire sans déchirure ni formation de trous, tout en respectant les relations d'adjacence entre les différentes structures.



(a) Tube neural	(b) Vésicules cérébrales primaires	(c) Vésicules cérébrales secondaires	(d) Structures de l'encéphale adulte	(e) Cavités de l'encéphale adulte
Extrémité antérieure (rostrale)  Extrémité postérieure (caudale)	 Prosencéphale (cerveau antérieur) Mésencéphale (cerveau moyen) Rhombencéphale (cerveau postérieur)	 Télencéphale	Cerveau : hémisphères cérébraux (cortex, substance blanche, noyaux gris centraux)	Ventricules latéraux, partie supérieure du troisième ventricule
		Diencéphale	Diencéphale (thalamus, hypothalamus, épithalamus)	Majeure partie du troisième ventricule
		Mésencéphale	Tronc cérébral : mésencéphale	Aqueduc du mésencéphale
		Métencéphale	Tronc cérébral : pont	Quatrième ventricule
		Myélocéphale	Cervelet	
			Tronc cérébral : bulbe rachidien	Canal de l'épendyme
			Moelle épinière	

Figure A.2 :Développement embryonnaire de l'encéphale humain (illustration modifiée d'après [Marieb 93])

Dès la formation du tube neural, celui-ci se différencie rapidement pour donner naissance aux diverses structures du système nerveux central. La partie antérieure, ou rostrale, est à l'origine de l'encéphale, tandis que la partie postérieure, ou caudale, forme la moelle épinière. Des constriction successives délimitent trois vésicules cérébrales primaires : le prosencéphale (cerveau antérieur), le mésencéphale (cerveau moyen) et le rhombencéphale (cerveau postérieur) (figure 1.2-b).

À la cinquième semaine, ces vésicules primaires se subdivisent en cinq vésicules cérébrales secondaires (figure 1.2-c) : le prosencéphale se divise en télencéphale et diencéphale, tandis que le mésencéphale reste inchangé. Le rhombencéphale se divise quant à lui en métencéphale et myélocéphale. L'évolution de ces cinq régions conduit à la formation des principales structures de l'encéphale adulte (figure 1.2-d). Ainsi, le télencéphale donne naissance aux deux hémisphères cérébraux, qui émergent sous la forme de renflements antérieurs. Le diencéphale engendre l'hypothalamus, le thalamus et l'épithalamus. Le métencéphale est à l'origine du pont et du cervelet, tandis que le myélocéphale forme le bulbe rachidien.

Par ailleurs, la cavité centrale du tube neural s'élargit à quatre endroits spécifiques, formant ainsi les ventricules cérébraux (figure 1.2-e). Enfin, la position relative des différentes parties de l'encéphale évolue au cours de son développement, la croissance étant contrainte par les parois de la boîte crânienne.




Figure A.3 : illustre les conséquences du manque d'espace au sein de la boîte crânienne sur le développement de l'encéphale (illustration modifiée d'après [Marieb, 1993]).

À la cinquième semaine du développement, la formation des deux grandes courbures repousse le télencéphale et le diencéphale vers le tronc cérébral. Le développement des hémisphères cérébraux se poursuit à 13 semaines, à 26 semaines, puis à la naissance. À l'origine, la surface du cerveau est lisse ; les circonvolutions apparaissent progressivement au cours du développement. Les hémisphères cérébraux se développent en direction postéro-latérale, jusqu'à recouvrir complètement le diencéphale ainsi que la partie supérieure du tronc cérébral.

Au cours du développement de l'encéphale, la croissance de la structure est contrainte par les limites imposées par la boîte crânienne, ce qui entraîne l'apparition de deux courbures majeures : **la courbure mésencéphalique** et **la courbure cervicale (figure 1.3-a)**. Le manque d'espace intracrânien empêche la progression antérieure des hémisphères cérébraux et les contraint à se développer vers l'arrière et les côtés, suivant une configuration en fer à cheval (figure 1.3-b), jusqu'à envelopper presque entièrement le diencéphale et le

mésencéphale (figure 1.3-c). Au fur et à mesure de leur croissance, la surface des hémisphères se replie sur elle-même, donnant naissance aux scissures et aux circonvolutions caractéristiques du cortex cérébral (figure 1.3-d).

Le processus de formation de l'encéphale, tel que décrit, est identique pour tous les individus en l'absence de pathologies spécifiques. Par conséquent, toutes les structures cérébrales sont présentes de manière constante dans une population d'individus sains, et leurs relations d'adjacence sont conservées en raison de leur origine commune. Seules leur taille et leur forme diffèrent d'un individu à l'autre. Cette observation justifie l'hypothèse selon laquelle il est légitime d'estimer une transformation respectant la propriété de conservation de la topologie.

Cette hypothèse s'applique également à l'appariement des régions corticales, bien que la structure du cortex puisse paraître topologiquement complexe à première vue. En effet, le nombre de sillons, leur position et leur continuité peuvent varier considérablement entre les individus. Toutefois, dans la mesure où le cortex résulte du plissement progressif de la surface des hémisphères cérébraux, il peut être considéré comme topologiquement équivalent à une sphère. Cela renforce ainsi la validité de l'hypothèse de conservation de la topologie pour les opérations de recalage non rigide.

1.4 Les modalités d'observation du cerveau

Au cours du XX^e siècle, de nombreuses techniques d'observation du cerveau ont émergé, répondant aux limitations inhérentes à la dissection post mortem, qui constituait jusque-là l'unique méthode d'étude anatomique cérébrale. Ces nouvelles approches se répartissent généralement en deux grandes catégories : les techniques fournissant une information anatomique et celles délivrant une information fonctionnelle.

S'agissant de l'imagerie anatomique, deux méthodes sont principalement utilisées : la tomodensitométrie (ou scanner X) et l'imagerie par résonance magnétique (IRM). Le scanner X repose sur les différences d'absorption des rayons X à travers les tissus biologiques et peut être complété par l'administration d'un agent de contraste. Cette technique offre une résolution spatiale satisfaisante, de l'ordre du millimètre, mais présente un contraste limité entre les différents tissus cérébraux. À l'inverse, l'IRM exploite les propriétés magnétiques des noyaux atomiques, notamment ceux de l'hydrogène [\[50\]](#), soumis à un champ magnétique intense. Elle permet non seulement d'éviter l'exposition aux rayonnements ionisants, mais

offre également une résolution millimétrique accompagnée de contrastes marqués, selon les séquences utilisées, entre les diverses structures cérébrales.

L'IRM ne se limite pas à l'imagerie anatomique conventionnelle. Elle permet également d'explorer la vascularisation cérébrale grâce à l'angiographie par résonance magnétique (ARM), avec ou sans produit de contraste, en exploitant le mouvement du sang pour en améliorer la distinction par rapport aux tissus environnants. Par ailleurs, l'imagerie de diffusion, autre variante de l'IRM, permet de caractériser l'architecture microscopique des tissus neuronaux en analysant les déplacements des molécules d'eau. La spectroscopie par résonance magnétique constitue un autre prolongement, permettant l'analyse des propriétés biochimiques des tissus.

Concernant l'imagerie fonctionnelle, deux grandes approches peuvent être distinguées : celles visant à mesurer l'activité métabolique cérébrale, généralement à l'aide de traceurs, et celles destinées à mettre en évidence l'activité neuronale. Parmi les premières, la tomographie par émission de positons (TEP) et la tomographie par émission monophotonique (TEMP) sont les plus représentatives. Ces deux techniques utilisent des traceurs radioactifs couplés à des molécules impliquées dans le métabolisme cérébral, mais leur résolution spatiale reste relativement faible (entre 3 et 6 mm).

En ce qui concerne la mesure de l'activité neuronale, les méthodes les plus couramment utilisées sont l'électroencéphalographie (EEG), la magnétoencéphalographie (MEG) et l'imagerie par résonance magnétique fonctionnelle (IRMf). L'EEG et la MEG reposent respectivement sur la détection de signaux électriques et magnétiques par l'intermédiaire d'électrodes. L'IRMf, quant à elle, permet d'estimer l'activité cérébrale en mesurant les variations locales du taux d'oxygénation sanguine, corrélées à l'activité neuronale.

1.5 Conclusion

L'exploration des différentes dimensions de l'anatomie cérébrale, de son développement embryologique à sa variabilité interindividuelle, ainsi que la diversité des modalités d'imagerie disponibles, permet de mieux comprendre les fondements scientifiques sur lesquels reposent les méthodes d'analyse et de mise en correspondance des structures cérébrales. En particulier, l'évolution continue des techniques d'imagerie, notamment l'IRM, a ouvert la voie à des approches non invasives, précises et reproductibles pour l'étude du cerveau humain in vivo. Ces avancées justifient l'usage de modèles conservant la topologie pour le recalage d'images, en cohérence avec l'organisation stable et continue des structures

cérébrales au sein d'une population saine. Cette annexe pose ainsi les bases conceptuelles nécessaires à la compréhension des choix méthodologiques développés dans les chapitres suivants.

Annexe B :

Autres Architectures populaire de CNN :

1.Le Net : un réseau neuronal convolutif simple

LeNet représente l'un des premiers modèles emblématiques de réseaux neuronaux convolutifs (CNN), développé par Yann LeCun et ses collaborateurs, initialement conçu pour la reconnaissance automatique des chiffres manuscrits. Ce modèle constitue une référence historique dans le domaine de la vision par ordinateur.

L'élément fondamental de l'architecture CNN repose sur la couche convolutive, qui constitue le bloc de base de l'apprentissage. Cette couche applique une opération de convolution, consistant à calculer une somme pondérée des valeurs d'entrée à l'aide de filtres, suivie d'une fonction d'activation non linéaire. Le résultat de cette opération est une carte de caractéristiques (feature map) en deux dimensions, mettant en évidence des motifs locaux pertinents. Ces cartes sont ensuite généralement réduites en résolution par des opérations de sous-échantillonnage, comme le pooling, afin de conserver les informations essentielles tout en diminuant la complexité computationnelle du modèle[\[51\]](#).

LeNet illustre ainsi de manière efficace les principes fondamentaux des réseaux convolutifs, en combinant des couches de convolution, de pooling et des couches entièrement connectées, formant une architecture adaptée aux premières applications de classification d'images.




Figure B.1 :Un exemple de l'architecture LeNet.

2.AlexNet :

AlexNet représente une architecture de réseau de neurones convolutifs (CNN) profondément hiérarchisée, introduite en 2012 à l'occasion du concours ImageNet Large Scale Visual Recognition Challenge (ILSVRC), où elle s'est distinguée par ses performances remarquables, surpassant largement les méthodes traditionnelles d'apprentissage automatique [52]. Cette architecture comprend huit couches d'apprentissage, dont cinq sont des couches convolutionnelles destinées à l'extraction automatique de caractéristiques, et trois sont des couches entièrement connectées, intervenant en phase de classification. Le réseau contient environ 60 millions de paramètres ajustables. La dernière couche entièrement connectée est associée à une couche de sortie Softmax, générant un vecteur de probabilités pour 1000 classes, correspondant aux différentes catégories d'objets présentes dans la base de données ImageNet. Cette architecture a marqué un tournant décisif dans le domaine de la vision par ordinateur, en posant les bases des approches modernes en apprentissage profond.




Figure B.2 :Architecture AlexNet.

3.VGG :

Le réseau VGG, introduit en 2014 par le Visual Geometry Group (VGG) de l'Université d'Oxford, constitue une avancée notable dans l'architecture des réseaux neuronaux convolutifs profonds [53]. L'approche défendue par ses auteurs repose sur l'idée que l'augmentation de la profondeur du réseau peut significativement améliorer les performances de classification. Trois variantes principales de ce modèle ont été proposées : VGG-11, VGG-16 et VGG-19, les chiffres faisant référence au nombre total de couches que contient chaque architecture. Ces modèles se distinguent par l'utilisation répétée de petites fenêtres de convolution (3×3) et de couches de pooling, permettant une meilleure extraction hiérarchique des caractéristiques. Grâce à cette conception, les architectures VGG ont démontré une grande efficacité dans diverses tâches de reconnaissance d'images [54].

4.Google Net

GoogLeNet est un réseau neuronal convolutif profond introduit en 2014, fondé sur l'architecture [55]. Il se distingue par sa profondeur, avec un total de 22 couches, ainsi que par sa capacité à réduire la complexité computationnelle grâce à une stratégie efficace de réduction dimensionnelle intégrée dans ses modules Inception. Contrairement aux architectures antérieures telles qu'AlexNet et VGGNet, GoogLeNet parvient à atteindre des performances élevées tout en maintenant un nombre de paramètres nettement inférieur. À titre de comparaison, il nécessite environ 12 fois moins de paramètres qu'AlexNet, ce qui permet d'alléger le coût en mémoire et d'accélérer les temps d'entraînement, sans compromettre la précision du modèle. Cette architecture a marqué une étape importante dans l'évolution des CNN profonds, en démontrant l'intérêt de combiner profondeur et efficacité.

5.ResNet

Le réseau ResNet, fondé sur le principe de l'apprentissage résiduel, a été introduit en 2015 et décliné en plusieurs variantes selon la profondeur du modèle, notamment ResNet18, ResNet34, ResNet101 et ResNet152 [55]. Parmi ces versions, ResNet50 est l'un des modèles les plus largement utilisés. Il se compose de 50 couches de convolution et comporte environ 25,5 millions de paramètres. L'architecture résiduelle repose sur l'intégration de connexions appelées *skip connections*, qui permettent de contourner certaines couches du réseau. Cette approche atténue les problèmes liés à la dégradation de la performance dans les réseaux profonds, tout en facilitant l'apprentissage de représentations plus complexes. ResNet a ainsi contribué à un progrès notable dans le développement de réseaux de neurones profonds, en permettant d'entraîner des modèles plus profonds et plus performants.

Références

1. *Thayumanasamy, I. and K. Ramamurthy, Performance analysis of machine learning and deep learning models for classification of Alzheimer's disease from brain MRI. Traitement du Signal, 2022. 39(6): p. 1961.*
2. *Mosconi, L., et al., Early detection of Alzheimer's disease using neuroimaging. Experimental gerontology, 2007. 42(1-2): p. 129-138.*
3. *MERIEU, B., MASTER EN SCIENCE BIOLOGIQUE Spécialité: pharmacotoxicologie.*
4. *Fouquet, M., et al., Imagerie cérébrale et physiopathologie de la maladie d'Alzheimer. Psychol Neuropsychiatr Vieil, 2007. 5(4): p. 269-79.*
5. *Palix, C., Vers une meilleure compréhension des biomarqueurs en tant que facteurs de risque dans le vieillissement normal et la maladie d'Alzheimer: liens avec la cognition et la neuroimagerie multimodale, 2023, Normandie Université.*
6. *McKhann, G.M., et al., The diagnosis of dementia due to Alzheimer's disease: recommendations from the National Institute on Aging-Alzheimer's Association workgroups on diagnostic guidelines for Alzheimer's disease. Alzheimer's & dementia, 2011. 7(3): p. 263-269.*
7. *Aderghal, K., Classification of multimodal MRI images using Deep Learning: Application to the diagnosis of Alzheimer's disease, 2021, Université de Bordeaux; Université Ibn Zohr (Agadir).*
8. *Petersen, R.C., Mild cognitive impairment as a diagnostic entity. Journal of internal medicine, 2004. 256(3): p. 183-194.*
9. *Dubois, B., et al., Revising the definition of Alzheimer's disease: a new lexicon. The Lancet Neurology, 2010. 9(11): p. 1118-1127.*
10. *Bier, J.C., Les biomarqueurs de la maladie d'Alzheimer: concepts et cas clinique. Rev Med Brux, 2013. 34: p. 306-10.*
11. *Bordet, R., et al., Biomarqueurs aux phases précoces de développement dans la maladie d'Alzheimer. Therapies, 2010. 65(4): p. 277-283.*
12. *Rossant, C., Coloration des fibres axonales en IRM de diffusion. 2008.*
13. *Bloch, F., Nuclear induction. Physical review, 1946. 70(7-8): p. 460.*
14. *Yesli, S., Filtrage par diffusion anisotropique appliquée aux images IRM, 2013, Université Mouloud Mammeri.*
15. *Scherrer, B., Segmentation des tissus et structures sur les IRM cérébrales: agents markoviens locaux coopératifs et formulation bayésienne, 2008, Institut National Polytechnique de Grenoble-INPG.*
16. *Warnking, J., Délinéation des aires visuelles rétinotopiques chez l'homme par IRM fonctionnelle, 2002, Université Joseph Fourier–Grenoble I.*
17. *Langlois, S., Analyse et correction des distorsions en imagerie par résonance magnétique, 1998, Caen.*
18. *Noblet, V., Recalage non rigide d'images cérébrales 3D avec contrainte de conservation de la topologie, 2006, Ph. D Thesis.*
19. *Dawant, B.M., et al., Automatic 3-D segmentation of internal structures of the head in MR images using a combination of similarity and free-form transformations. I. Methodology and validation on normal subjects. IEEE transactions on medical imaging, 2002. 18(10): p. 909-916.*
20. *STRUCTURALE, I. and E. HALLUCINATIONS, Imagerie cérébrale et.*
21. *Anichini, G. and B. Geffroy, L'intelligence artificielle à l'épreuve des savoirs tacites. Analyse des pratiques d'utilisation d'un outil d'aide à la détection en radiologie. Sciences sociales et santé, 2021. 39(2): p. 43-69.*
22. *Collins, H., Sociologie méta-appliquée et intelligence artificielle. Zilsel, 2019. 5(1): p. 161-173.*

Références

23. Islam, J. and Y. Zhang. A novel deep learning based multi-class classification method for Alzheimer's disease detection using brain MRI data. in *Brain Informatics: International Conference, BI 2017, Beijing, China, November 16-18, 2017, Proceedings*. 2017. Springer.
24. Fei-Fei, L., A. Karpathy, and J. Johnson, Cs231n: Convolutional neural networks for visual recognition, 2018, Stanford, <http://cs231n.stanford.edu/>. [Accessed August 23, 2018].
25. Chen, S., et al. Alzheimer's disease classification using structural MRI based on convolutional neural networks. in *Proceedings of the 2020 2nd International Conference on Big-Data Service and Intelligent Computation*. 2020.
26. Gulhare, K.K., S. Shukla, and L. Sharma, Deep neural network classification method to Alzheimer's disease detection. *Int J Adv Res Comput Sci Softw Eng*, 2017. **7**(6): p. 1-4.
27. Zhang, Y., S. Liu, and X. Yu, Longitudinal structural MRI analysis and classification in Alzheimer's disease and mild cognitive impairment. *International Journal of Imaging Systems and Technology*, 2020. **30**(2): p. 421-433.
28. YİĞİT, A. and Z. Işık, Applying deep learning models to structural MRI for stage prediction of Alzheimer's disease. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2020. **28**(1): p. 196-210.
29. Yagis, E., et al. 3d Convolutional neural networks for diagnosis of alzheimer's disease via structural mri. in *2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS)*. 2020. IEEE.
30. Alp, S., et al., Joint transformer architecture in brain 3D MRI classification: its application in Alzheimer's disease classification. *Scientific Reports*, 2024. **14**(1): p. 8996.
31. Odimayo, S., C.C. Olisah, and K. Mohammed, Structure focused neurodegeneration convolutional neural network for modelling and classification of Alzheimer's disease. *Scientific Reports*, 2024. **14**(1): p. 15270.
32. Ataelfadiel, A.A.-K., M. AbuDawas, and B.K. Pattanayak, Structural MRI classification in Alzheimer's disease using CNN-XGBoost: An early diagnosis.
33. Zheng, B., et al., A modified 3D EfficientNet for the classification of Alzheimer's disease using structural magnetic resonance images. *IET Image Processing*, 2023. **17**(1): p. 77-87.
34. Patel, P.J. and M.H. Patel, Alzheimer Disease Detection using Deep Learning. *JOURNAL OF TECHNICAL EDUCATION*: p. 9.
35. Ghazal, T.M. and G. Issa, Alzheimer disease detection empowered with transfer learning. *Computers, Materials & Continua*, 2022. **70**(3): p. 5005-5019.
36. Roy, S.S., R. Sikaria, and A. Susan, A deep learning based CNN approach on MRI for Alzheimer's disease detection. *Intelligent Decision Technologies*, 2019. **13**(4): p. 495-505.
37. Shukla, A., R. Tiwari, and S. Tiwari, Review on alzheimer disease detection methods: Automatic pipelines and machine learning techniques. *Sci*, 2023. **5**(1): p. 13.
38. Goodfellow, I., Y. Bengio, and A. Courville, Regularization for deep learning. *Deep learning*, 2016: p. 216-261.
39. Ashburner, J., A fast diffeomorphic image registration algorithm. *neuroimage*, 2007. **38**(1): p. 95-113.
40. Good, C.D., et al., A voxel-based morphometric study of ageing in 465 normal adult human brains. *neuroimage*, 2001. **14**(1): p. 21-36.
41. Ashburner, J., Computational anatomy with the SPM software. *Magnetic resonance imaging*, 2009. **27**(8): p. 1163-1174.
42. LeCun, Y., I. Kanter, and S. Solla, Second order properties of error surfaces: Learning time and generalization, in *Advances in neural information processing systems* 1990.
43. LeCun, Y., LeNet-5, convolutional neural networks. URL: <http://yann.lecun.com/exdb/lenet>, 2015. **20**(5): p. 14.
44. Dumoulin, V. and F. Visin, A guide to convolution arithmetic for deep learning. *arXiv preprint arXiv:1603.07285*, 2016.
45. Kingma, D.P. and J. Ba, Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.

Références

46. Srivastava, N., et al., Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 2014. **15**(1): p. 1929-1958.
47. Ashtari-Majlan, M., A. Seifi, and M.M. Dehshibi, A multi-stream convolutional neural network for classification of progressive MCI in Alzheimer's disease using structural MRI images. *IEEE Journal of Biomedical and Health Informatics*, 2022. **26**(8): p. 3918-3926.
48. Ashburner, J., J.L. Andersson, and K.J. Friston, Image registration using a symmetric prior—in three dimensions. *Human brain mapping*, 2000. **9**(4): p. 212-225.
49. Bakircioğlu, M., et al., Curve matching on brain surfaces using frenet distances. *Human brain mapping*, 1998. **6**(5-6): p. 329-333.
50. Allen, J.S., H. Damasio, and T.J. Grabowski, Normal neuroanatomical variation in the human brain: an MRI-volumetric study. *American Journal of Physical Anthropology: The Official Publication of the American Association of Physical Anthropologists*, 2002. **118**(4): p. 341-358.
51. LeCun, Y., The MNIST database of handwritten digits. <http://yann.lecun.com/exdb/mnist/>, 1998.
52. Krizhevsky, A., I. Sutskever, and G.E. Hinton, Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 2012. **25**.
53. Aderghal, K., et al. Classification of Alzheimer disease on imaging modalities with deep CNNs using cross-modal transfer learning. in *2018 IEEE 31st international symposium on computer-based medical systems (CBMS)*. 2018. IEEE.
54. Vedaldi, A. and A. Zisserman, Vgg convolutional neural networks practical. *Department of Engineering Science, University of Oxford*, 2016. **66**.
55. He, K., et al. Deep residual learning for image recognition. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.

