

République Algérienne Démocratique et Populaire

Université Abou Bekr Belkaïd – Tlemcen

Faculté des Sciences

Département d'informatique

Mémoire de fin d'études pour l'obtention du diplôme de

Master en Informatique

Option : MODÈLE D'INTELLIGENCE ET DÉCISION (M.I.D)

Thème

Détection précoce de la maladie
d'Alzheimer par Machine Learning

Réalisé par :

MR IBRAHIM BENMANSOUR

Présenté le 25 Juin 2024 devant le jury composé de MM.

Président Mr. Sidi Mohammed CHOUITI, Dr (Université de Tlemcen)

Examinatrice Mme. Radja MAAROUF, Dr (Université de Tlemcen)

Encadrant Mr. Salim ZIANI-CHERIF, Dr (Université de Tlemcen)

Année Universitaire : 2023 - 2024

Remerciements

La réalisation de ce mémoire a été une aventure enrichissante et stimulante, rendue possible grâce au soutien et à l'encouragement de nombreuses personnes et institutions, auxquelles je tiens à exprimer ma profonde gratitude.

Avant tout, je souhaite remercier mon encadrant, Monsieur Salim ZIANI-CHERIF, pour ses conseils avisés, sa disponibilité et son soutien constant tout au long de ce travail. Son encadrement précieux et ses remarques pertinentes ont été déterminants dans l'aboutissement de cette recherche.

Je remercie également les membres du jury, Monsieur Sidi Mohammed CHOUITI et Madame Radja MAAROUF, pour avoir accepté de lire notre mémoire et d'évaluer notre travail.

Mes remerciements les plus sincères vont à mes parents et à ma tante, pour leur soutien indéfectible, leur patience et leur encouragement tout au long de cette aventure. Leur présence à mes côtés a été une source inestimable de motivation et de réconfort.

Je tiens également à exprimer ma gratitude à ma famille élargie, pour leur amour et leur soutien continus.

Un grand merci à mes amis, notamment Aymen Salhi et Aïcha rihab ouahrani, pour leur amitié et leur soutien. Merci également à OC Mindsight pour leur soutien tout au long de cette période.

À tous, je vous exprime ma reconnaissance la plus sincère.

Table des matières

Remerciements	ii
Table des matières	iv
Table des figures	vi
Liste des tableaux	vii
Introduction générale	1
1 Le cerveau humain et la maladie d'Alzheimer	3
1.1 Cerveau humain : concepts de base	3
1.1.1 Anatomie du cerveau	3
1.1.2 Fonctionnement neuronal et réseaux synaptiques	4
1.1.3 Implications de la neurobiologie dans les maladies neurodégénératives	4
1.2 Introduction à la maladie d'Alzheimer	5
1.2.1 Définition et symptômes de la maladie d'Alzheimer	5
1.2.2 Impact socio-économique	6
1.2.3 Conclusion	7
1.3 Pathophysiologie de la maladie d'Alzheimer	7
1.3.1 Changements pathologiques dans le cerveau	7
1.3.2 Progression de la maladie	8
1.3.3 Impacts sur la qualité de vie	9
1.3.4 Mécanismes moléculaires et recherches en cours	9
1.4 Diagnostic de la maladie d'Alzheimer	10
1.4.1 Techniques diagnostiques actuelles	10
1.4.2 Importance et défis du diagnostic précoce	12
1.5 Utilisation des images IRM dans le diagnostic de la maladie d'Alzheimer	13
1.5.1 Rôle des images IRM	13
1.5.2 Avantages de l'IRM par rapport à d'autres méthodes d'Imagerie	13
1.5.3 Défis et limitations	14
1.5.4 Futur de l'IRM dans la Recherche sur Alzheimer	14
1.6 Conclusion	15
2 Modèles et architectures des convolutional neural network	16
2.1 Concepts fondamentaux du machine learning	16
2.1.1 Définition et importance du machine learning	16
2.1.2 Catégories de machine learning	16

2.1.3	Processus de machine learning	17
2.2	Présentation aux réseaux de neurones artificiels (ANN)	18
2.2.1	Structure des ANN	19
2.2.2	Fonctionnement de base des ANN	20
2.2.3	Types de réseaux de neurones	22
2.3	Fondements des réseaux de neurones convolutifs (CNN)	22
2.3.1	Définition des CNN	23
2.3.2	Convolution simple	23
2.3.3	Structure des CNN	24
2.4	Présentation des modèles CNN choisi pour le projet	25
2.4.1	VGGNet	25
2.4.2	ResNet	26
2.4.3	DenseNet	27
2.4.4	Inception (GoogLeNet)	27
2.4.5	Tableau de comparaison des architectures CNN	28
2.4.6	Explication du choix des modèles pour le projet	28
2.5	Adaptation des CNN pour l'analyse des images IRM	29
2.5.1	Prétraitement des images IRM	29
2.5.2	Utilisation des modèles pré-entraînés pour l'analyse des images IRM	29
2.5.3	Stratégies d'entraînement	30
2.6	Methodes d'évaluation des modèles CNN	30
2.6.1	Techniques de validation	31
2.7	Conclusion	32
3	Implémentation et résultats	33
3.1	Présentation du dataset	33
3.1.1	Description du dataset OASIS	33
3.1.2	Justification du choix du dataset	33
3.1.3	Conclusion	35
3.2	Préparation des données et équilibrage des classes	35
3.2.1	Introduction au problème des classes non équilibrées	35
3.2.2	Description et caractéristiques du dataset OASIS	35
3.2.3	Identification des classes dans le dataset	37
3.2.4	Méthodes d'équilibrage des classes	37
3.2.5	Impact de l'équilibrage sur les performances du modèle	38
3.3	Modèles utilisés et configuration	40
3.3.1	Prétraitement des Images	40
3.3.2	Configuration des modèles	40
3.4	Discussion des résultats et choix du modèle	54
3.4.1	Discussion des résultats	54
3.4.2	Choix du meilleur modèle	55
3.5	Conclusion	56
	Conclusions générales et perspectives	57
	Bibliographie	59

Table des figures

1.1 Anatomie du cerveau humain	4
1.2 Prévalence de la maladie d'Alzheimer par tranche d'âge (34)	5
1.3 Plaques amyloïdes (orange) déposées entre les cellules cérébrales responsables de la communication (bleu) et de la réponse immunitaire (rouge). (35)	8
1.4 IRM cérébrale	11
1.5 TEP cérébrale	11
2.1 Représentation d'un neurone artificiel	18
2.2 Représentation d'un neurone artificiel (24)	19
2.3 Représentation d'un réseau de neurones artificiels	20
2.4 illustration de l'opération de convolution avec un filtre 3x3 appliqué sur une image 5x5.	23
2.5 Détection des contours verticaux à l'aide d'un noyau de convolution.	24
2.6 exemple de couche max pooling.	25
2.7 exemple de Couche entièrement connectées (37).	25
2.8 Architecture de VGG16 (21).	26
2.9 Architecture de ResNet (20).	26
2.10 Architecture de DenseNet (16)	27
2.11 Architecture de Inception (17)	28
3.1 Répartition des images par classe	35
3.2 Non demented IRM	36
3.3 Very mild dementia IRM	36
3.4 Mild dementia IRM	37
3.5 Moderate dementia IRM	37
3.6 Journal d'entraînement InceptionV3	43
3.7 Courbe de perte InceptionV3	43
3.8 Courbe de précision InceptionV3	44
3.9 Matrice de confusion InceptionV3	44
3.10 Évaluation des métriques : InceptionV3	45
3.11 Journal d'entraînement VGG16	46
3.12 Courbe de perte VGG16	46
3.13 Courbe de précision VGG16	47
3.14 Matrice de confusion VGG16	47
3.15 Évaluation des métriques VGG16	48
3.16 Journal d'entraînement ResNet101	49
3.17 Courbe de perte ResNet101	49
3.18 Courbe de précision ResNet101	50

3.19 Matrice de confusion ResNet101	50
3.20 Évaluation des métriques ResNet101	51
3.21 Journal d'entraînement DenseNet121	52
3.22 Courbe de perte DenseNet121	52
3.23 Courbe de précision DenseNet121	53
3.24 Matrice de confusion DenseNet121	53
3.25 Évaluation des métriques DenseNet121	54

Liste des tableaux

- 1.1 Tableau des facteurs de risque pour la maladie d'Alzheimer 6
- 1.2 Caractéristiques des plaques amyloïdes et des enchevêtrements neurofibrillaires 8

- 2.1 Comparaison des différents types d'apprentissage automatique 17
- 2.2 Comparaison des différentes fonctions d'activation utilisées dans les ANN . 21
- 2.3 Comparaison des caractéristiques des architectures de réseaux neuronaux . 28

- 3.1 Caractéristiques du dataset OASIS 34
- 3.2 Tableau des performances des modèles 54

Introduction générale

La maladie d'Alzheimer, une pathologie neurodégénérative progressive, représente l'une des principales causes de handicap et de dépendance parmi les personnes âgées. Affectant des millions d'individus à travers le monde, cette maladie entraîne une détérioration graduelle de la mémoire et des fonctions cognitives. En l'absence de traitement, la détection précoce est essentielle pour ralentir la progression de la maladie grâce à des interventions opportunes et personnalisées. La maladie d'Alzheimer est la forme la plus courante de démence, touchant environ 60 à 70 % des personnes atteintes de démence. Elle se caractérise par une accumulation anormale de protéines dans et autour des cellules cérébrales, notamment les plaques amyloïdes et les enchevêtrements neurofibrillaires, qui entraînent la mort des neurones et la perte de tissu cérébral. (33)

L'émergence des technologies de l'information et de la communication, surtout dans le domaine Machine Learning (ML), offre des possibilités inédites pour révolutionner améliorer les méthodes de diagnostic. Le Machine Learning, un sous-domaine de l'intelligence artificielle, permet aux systèmes de "lire" et d'apprendre à partir de données sans être explicitement programmés pour des tâches spécifiques. Dans le contexte médical, et particulièrement pour la maladie d'Alzheimer, ces technologies permettent de traiter de grandes quantités de données et d'extraire des modèles complexes qui seraient pratiquement invisible par les méthodes conventionnelles. L'application du ML à l'analyse des images IRM cérébrales se présente comme une approche prometteuse pour identifier des indicateurs précoces de la maladie d'Alzheimer. Les IRM, ou imageries par résonance magnétique, fournissent des images détaillées de la structure du cerveau, permettant de détecter les changements subtils associés à la maladie, souvent avant l'apparition des symptômes cliniques.

Les techniques avancées de ML, telles que les réseaux de neurones convolutifs (CNN), sont particulièrement efficaces pour l'analyse des images médicales. Les CNN, inspirés de la structure du cortex visuel humain, sont capables d'apprendre des caractéristiques discriminantes des images à travers des couches de neurones artificiels. Ces modèles peuvent détecter des anomalies subtiles dans les images IRM, telles que l'atrophie de l'hippocampe ou la présence de plaques amyloïdes, qui sont des marqueurs précoces de la maladie d'Alzheimer. En entraînant ces modèles sur de grandes bases de données d'images IRM, il est possible de développer des systèmes capables de diagnostiquer la maladie avec une précision et une sensibilité élevées. (36)

L'objectif principal de ce projet est de concevoir et de valider un modèle de Machine Learning capable d'analyser des images IRM cérébrales pour détecter précocement des signes de la maladie d'Alzheimer. cet outil, modeliser par machine learning va permettre

d'anticiper la détection de la maladie. Diagnostiquer la maladie à un stade précoce, permet d'initier des traitements plus rapidement, ce qui peut ralentir la progression de la maladie et améliorer la qualité de vie des patients. De plus, un diagnostic précoce permet aux patients et à leurs familles de planifier à l'avance et de prendre des décisions éclairées concernant les soins et la gestion de la maladie.

La réalisation de ce projet repose sur plusieurs étapes clés : la collecte et le prétraitement des données IRM, le développement et l'entraînement du modèle de ML, la validation et l'évaluation du modèle, et l'analyse des résultats obtenus. La collecte des données implique l'accès à des bases de données d'images IRM de haute qualité, comme le dataset OASIS (Open Access Series of Imaging Studies), qui fournit une ressource précieuse pour l'entraînement des modèles. Le prétraitement des données repose sur des techniques de normalisation et de segmentation des images pour garantir une cohérence et une précision dans l'analyse. Le développement du modèle implique l'utilisation de techniques avancées de ML, telles que les CNN, pour extraire des caractéristiques discriminantes des images IRM. L'entraînement du modèle nécessite des algorithmes d'optimisation et des méthodes de validation croisée pour éviter le surapprentissage et garantir une généralisation robuste des résultats. Enfin, l'évaluation et la validation du modèle comprend des métriques de performance telles que la précision, la sensibilité, et la spécificité.

Ce mémoire est structuré en trois chapitres principaux, chacun explorant des aspects fondamentaux du projet. Le premier chapitre pose les fondements théoriques nécessaires à la compréhension de la complexité du cerveau humain et de la pathologie de la maladie d'Alzheimer. Il explore en détail l'anatomie et le fonctionnement du cerveau, les mécanismes pathologiques de la maladie, les méthodes de diagnostic actuelles, et l'impact socio-économique de la maladie sur les individus et la société. Le deuxième chapitre décrit les concepts fondamentaux du machine learning puis présente les aspects techniques des Réseaux de Neurones Convolutifs (CNN), essentiels pour notre approche de Machine Learning. Il détaille l'architecture des CNN, discute des modèles spécifiques adaptés à l'analyse d'images IRM.

Enfin, le troisième chapitre présente la mise en œuvre pratique de notre modèle de Machine Learning, depuis la préparation et le prétraitement des données IRM jusqu'à l'entraînement du modèle. Il évalue ensuite les performances du modèle, analyse les résultats obtenus et discute de leur pertinence clinique et de leurs implications incidences sur le diagnostic de la maladie d'Alzheimer.

et le dernier chapitre est consacré à la conclusion et perspective, ce projet vise à explorer le potentiel du Machine Learning pour améliorer le diagnostic précoce de la maladie d'Alzheimer à travers l'analyse des images IRM cérébrales. En développant des modèles de ML précis et robustes, nous espérons non seulement améliorer la détection précoce de la maladie, mais aussi contribuer à la recherche et au développement de nouvelles approches thérapeutiques pour lutter contre cette pathologie dévastatrice. Les résultats de ce projet pourraient transformer la manière dont la maladie d'Alzheimer est diagnostiquée et traitée, offrant de nouvelles perspectives pour la gestion et le traitement des patients.

Chapitre 1

Le cerveau humain et la maladie d'Alzheimer

1.1 Cerveau humain : concepts de base

Le cerveau humain, extrêmement complexe et dynamique, est l'organe central du système nerveux central et joue un rôle crucial dans presque toutes les fonctions du corps. C'est le siège de l'intelligence, interprète des sens, initiateur du mouvement corporel, et régulateur du comportement.

1.1.1 Anatomie du cerveau :

Cortex cérébral :

Le cortex est la couche externe ridée du cerveau, vital pour des fonctions cognitives complexes. Il est divisé en quatre lobes principaux, chacun ayant des rôles spécifiques (32) figure 1.1 :

- **Lobe frontal** : Associé à la planification complexe, à l'expression de la personnalité, aux décisions, et aux mouvements volontaires.
- **Lobe pariétal** : Joue un rôle dans l'intégration sensorielle, y compris le toucher, la température, et la perception de la douleur.
- **Lobe occipital** : Essentiel pour la vision, ce lobe traite les informations visuelles en provenance des yeux.
- **Lobe temporal** : Important pour la compréhension auditive, l'organisation de la mémoire, et également l'aire de Wernicke, qui affecte la capacité de comprendre le langage écrit et parlé.

Cervelet :

Situé sous le cerveau, le cervelet coordonne la motricité volontaire, l'équilibre, et la régulation des mouvements musculaires ainsi que la posture.

Tronc cérébral :

Comprend le mésencéphale, le pont, et le bulbe rachidien. Il est crucial pour la transmission de l'information entre le cerveau et la moelle épinière et gère des fonctions vitales comme la respiration, la régulation du rythme cardiaque, et la digestion.

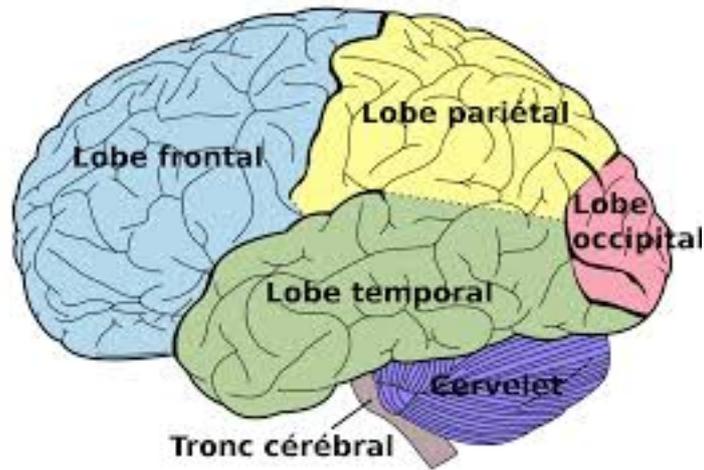


FIGURE 1.1 – Anatomie du cerveau humain

1.1.2 Fonctionnement neuronal et réseaux synaptiques :

Les neurones communiquent via des synapses où les signaux électriques sont convertis en signaux chimiques. Ainsi les neurotransmetteurs, libérés par les neurones, traversent l'espace synaptique pour atteindre les neurones récepteurs, permettant ainsi la transmission de l'information à travers le cerveau(32).

- **Plasticité synaptique :** Les synapses peuvent se renforcer ou s'affaiblir en réponse à une activité accrue ou réduite. Cette plasticité est la base de l'apprentissage, de la mémoire, et de l'adaptation comportementale.
- **Réseaux de neurones :** Les neurones fonctionnent ensemble en réseaux. Des circuits spécifiques peuvent être activés en réponse à des stimuli particuliers, soutenant des fonctions comme la réflexion, la planification ou même des réactions réflexes simples.

1.1.3 Implications de la neurobiologie dans les maladies neurodégénératives :

Les perturbations dans la communication neuronale, les changements dans la structure cérébrale, ou les défaillances dans les processus biochimiques du cerveau peuvent conduire à des conditions neurodégénératives comme la maladie d'Alzheimer. Comprendre ces changements et perturbations paraît alors essentiel pour la bonne prise en main des causes et mécanismes sous-jacents à ces pathologies(2).

1.2 Introduction à la maladie d'Alzheimer

1.2.1 Définition et symptômes de la maladie d'Alzheimer :

Définition générale :

La maladie d'Alzheimer est un trouble neurodégénératif chronique qui se manifeste par une perte progressive de la mémoire et des fonctions cognitives. Elle est caractérisée par deux types principaux de lésions cérébrales : l'apristion des plaques amyloïdes et les enchevêtrements neurofibrillaires(13).

Symptômes initiaux et évolution

Les premiers symptômes incluent souvent des difficultés à retenir des informations récemment apprises, telles que des conversations ou des événements. À mesure que la maladie progresse, les patients peuvent éprouver des désorientations dans le temps et l'espace, des changements d'humeur et de comportement, et une augmentation des symptômes de confusion(25).

Épidémiologie et impact global :

L'épidémiologie de la maladie d'Alzheimer révèle des tendances significatives quant à sa prévalence et aux facteurs de risque associés.

— Statistiques sur la prévalence :

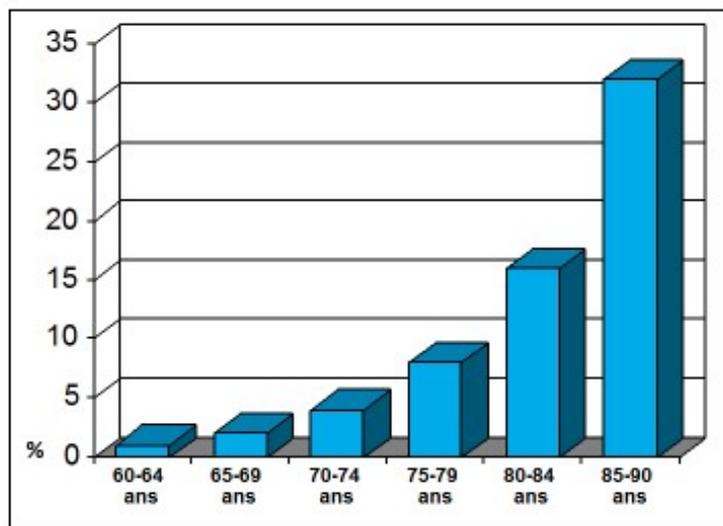


FIGURE 1.2 – Prévalence de la maladie d'Alzheimer par tranche d'âge (34)

La figure 1.2 (34) illustre la prévalence croissante de la maladie d'Alzheimer avec l'âge, mettant en évidence une tendance inquiétante qui souligne la corrélation entre le vieillissement et le risque accru de développer cette pathologie neurodégénérative. Comme l'indique la figure, la prévalence de la maladie est relativement basse chez les individus âgés de 60 à 74 ans, mais elle commence à augmenter de manière significative à partir de 75 ans. Ce phénomène s'accélère dans les groupes d'âge plus avancés, culminant avec plus de 30% chez les individus âgés de 85 à 90 ans.

— Facteurs de risque :

Les facteurs de risque de la maladie d'Alzheimer peuvent être regroupés en plusieurs catégories, chacune ayant une influence relative différente sur le développement de la maladie, comme illustré Table [1.1](#).

Catégorie	Facteur de risque	Influence relative
Génétiques	Gène APOE- ϵ 4	Forte
	Mutations APP, PSEN1, PSEN2	Très forte
Environnementaux	Exposition aux métaux lourds	Modérée
	Traumatismes crâniens	Modérée à forte
Style de vie	Activité physique	Modérée
	Alimentation	Modérée
	Tabagisme	Forte
	Éducation et engagement cognitif	Modérée

TABLE 1.1 – Tableau des facteurs de risque pour la maladie d'Alzheimer

1.2.2 Impact socio-économique

Conséquences sur les patients et les familles :

La maladie d'Alzheimer, en tant que trouble dégénératif progressif, affecte non seulement les patients mais aussi profondément les vies de leurs familles et de leurs proches. Les responsabilités des soins quotidiens, souvent assumées par les membres de la famille, peuvent entraîner une charge émotionnelle et financière considérable.

- **Charge émotionnelle :** Les familles sont souvent confrontées à des défis émotionnels à mesure que la condition du patient se détériore. Cela peut inclure la douleur de voir un être cher perdre sa mémoire et ses capacités cognitives, ainsi que le stress lié à la gestion des symptômes comportementaux comme l'agitation ou l'agressivité.
- **Charge financière :** Les coûts des soins à domicile ou professionnels, des médicaments, des dispositifs d'assistance et des modifications nécessaires à la maison peuvent s'accumuler, mettant les familles face à de lourdes dépenses. De plus, les aidants familiaux peuvent être forcés de réduire leurs heures de travail ou de quitter leur emploi, entraînant une perte de revenus et d'autres difficultés financières.

Charge pour les systèmes de santé :

La gestion de la maladie d'Alzheimer impose également une lourde charge aux systèmes de santé du monde entier, en raison de l'augmentation des besoins en soins de longue durée et des coûts associés.

- **Coûts directs :** Ces coûts incluent les dépenses pour les consultations médicales, les traitements pharmacologiques, les hospitalisations, et les soins spécialisés en établissement. Ces coûts sont exacerbés par la durée prolongée sur laquelle ces soins doivent être administrés en raison de la nature progressive de la maladie.
- **Coûts indirects :** Ils comprennent la perte de productivité des patients et des aidants, ainsi que les coûts associés aux programmes de soutien gouvernementaux et non gouvernementaux. L'impact économique global peut également inclure l'augmentation de l'utilisation des ressources communautaires et de l'assistance sociale.

1.2.3 Conclusion

Cette section a soulevé la problématique de l'impact profond et multidimensionnel de la maladie d'Alzheimer, non seulement sur les patients eux-mêmes mais aussi sur leurs familles et les systèmes de santé. Les conséquences émotionnelles et financières pour les familles soulignent l'énorme fardeau quotidien de la maladie, marqué par des défis tant dans la gestion des symptômes que dans le soutien apporté aux êtres chers affectés. De plus, la charge imposée aux systèmes de santé illustre l'importance cruciale de stratégies de soins efficaces et accessibles pour faire face à cette maladie, notamment en raison de ses coûts directs et indirects élevés.

Face à ces défis, il est impératif de développer des politiques de santé publique plus robustes et des programmes de soutien améliorés pour atténuer l'impact de la maladie d'Alzheimer. Cela comprend l'investissement dans la recherche pour de meilleurs traitements et approches préventives, l'amélioration de l'accès aux ressources de soins de santé, et le soutien accru aux aidants familiaux.

Parallèlement à ces stratégies générales, il est crucial de continuer à évaluer et à améliorer notre approche face à cette maladie dévastatrice pour mieux soutenir les millions de personnes touchées dans le monde. La prochaine section discutera des changements pathologiques associés à la maladie d'Alzheimer, tout en mettant en lumière les innovations technologiques, notamment les applications de l'intelligence artificielle, qui peuvent contribuer significativement à la détection précoce et à la gestion de cette pathologie.

1.3 Pathophysiologie de la maladie d'Alzheimer

1.3.1 Changements pathologiques dans le cerveau

Les maladies neurodégénératives, telles que la maladie d'Alzheimer, sont caractérisées par des altérations pathologiques spécifiques dans le cerveau. Ces changements incluent la formation de plaques amyloïdes et d'enchevêtrements neurofibrillaires, qui perturbent les fonctions neuronales et contribuent au déclin cognitif Table 1.2.

Plaques amyloïdes :

- **Définition et composition :** Les plaques amyloïdes sont des agrégats denses de peptides bêta-amyloïdes qui s'accumulent dans les espaces intercellulaires du cerveau figure 1.3. Ces peptides proviennent de la dégradation anormale de la protéine précurseur de l'amyloïde, un processus influencé par divers facteurs génétiques et environnementaux. (1)
- **Impact sur les neurones :** Les plaques perturbent la communication neuronale en interférant avec les synapses, contribuant à la perte neuronale et à l'inflammation cérébrale. Cela entraîne une détérioration des fonctions cognitives, manifestée par des symptômes de perte de mémoire et de désorientation. (2)

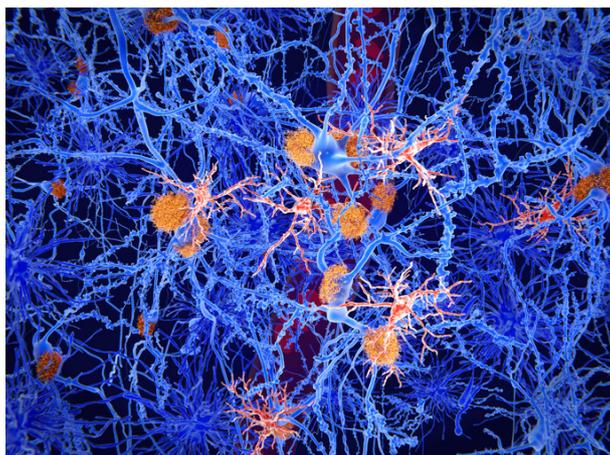


FIGURE 1.3 – Plaques amyloïdes (orange) déposées entre les cellules cérébrales responsables de la communication (bleu) et de la réponse immunitaire (rouge). (35)

Enchevêtrements neurofibrillaires :

- **Définition et composition :** Constitués de protéines τ hyperphosphorylées, ces enchevêtrements se forment à l'intérieur des cellules nerveuses. Normalement impliquée dans la stabilisation des microtubules, la protéine tau devient dysfonctionnelle et s'accumule, formant des structures enchevêtrées qui entravent le transport intracellulaire. (3)
- **Conséquences pour le cerveau :** La présence d'enchevêtrements neurofibrillaires est fortement corrélée avec le degré de démence. Ils contribuent à la dégradation des neurones et à la perte de connexions neuronales, exacerbant les symptômes de déclin cognitif et comportemental. (4)

	Plaques amyloïdes	Enchevêtrements neurofibrillaires
Définition	Agrégats de peptides bêta-amyloïdes	Protéines tau hyperphosphorylées
Localisation	Espaces intercellulaires	Intérieur des cellules nerveuses
Conséquences	Perturbation de la communication neuronale	Dégradation des neurones

TABLE 1.2 – Caractéristiques des plaques amyloïdes et des enchevêtrements neurofibrillaires

1.3.2 Progression de la maladie

La progression de la maladie d'Alzheimer se manifeste par une détérioration graduelle des capacités cognitives et comportementales des patients. Cette progression, souvent marquée par plusieurs stades distincts, impacte profondément la qualité de vie des individus touchés et de leurs soignants.

Dégradation cognitive et comportementale :

- **Étapes de la progression :** La maladie d'Alzheimer évolue généralement en plusieurs stades, commençant par des troubles cognitifs légers avant de progresser vers des stades modérés et sévères, où les patients perdent la capacité de mener des activités quotidiennes indépendamment. (5)
- **Symptômes comportementaux :** En plus des déficits cognitifs, les patients peuvent expérimenter des changements comportementaux tels que l'apathie, l'agitation, et parfois l'agressivité, qui sont souvent les plus difficiles à gérer pour les soignants. (6)

1.3.3 Impacts sur la qualité de vie

L'impact de la maladie d'Alzheimer sur la qualité de vie des patients est considérable, affectant non seulement les individus diagnostiqués mais également leurs proches et les soignants qui les entourent.

Défis quotidiens :

- **Description des difficultés :** Les patients atteints de la maladie d'Alzheimer font face à de multiples défis dans leurs activités quotidiennes à mesure que la maladie progresse. Ces difficultés comprennent la gestion des tâches ménagères, l'hygiène personnelle, et la communication. Le déclin cognitif rend ces activités de plus en plus ardues, entraînant souvent une dépendance accrue à l'aide extérieure. (7)
- **Conséquences pour les patients et leur entourage :** Ces défis affectent profondément le sentiment d'autonomie des patients et peuvent conduire à des sentiments de frustration et de tristesse. L'impact émotionnel sur les familles et les soignants est également significatif, car ils doivent ajuster continuellement leurs attentes et leur soutien en fonction de la progression de la maladie. (8)

Implications pour les soins :

- **Besoins en soins de longue durée :** Au fur et à mesure que la maladie avance, la nécessité de soins spécialisés et de longue durée devient impérative. Cela peut inclure des soins à domicile ou l'admission dans des établissements spécialisés offrant des soins adaptés aux personnes atteintes de démence. (9)
- **Soutien des aidants et professionnels de santé :** Discuter des meilleures pratiques pour les soignants, y compris la formation à la gestion des symptômes comportementaux et cognitifs de la maladie, ainsi que le soutien émotionnel pour les aidants. L'importance de créer un environnement sécurisant et stimulant pour les patients est cruciale pour maintenir la qualité de vie autant que possible. (10)

1.3.4 Mécanismes moléculaires et recherches en cours

Recherche biomédicale :

- **Découvertes récentes :** Les recherches continuent de révéler les rôles complexes des protéines bêta-amyloïdes et tau dans la pathogenèse de la maladie, offrant des

perspectives pour de nouvelles cibles thérapeutiques. Des études récentes explorent des interventions visant à réduire l'accumulation de ces protéines ou à améliorer les réponses cellulaires au stress et à la dégénérescence .(11)

- **Thérapies expérimentales** : Les essais cliniques récents incluent des traitements immunothérapeutiques et des médicaments qui ciblent spécifiquement les voies moléculaires impliquées dans la formation des plaques amyloïdes et des enchevêtrements tau, avec l'espoir de ralentir ou d'arrêter la progression de la maladie .(12)

1.4 Diagnostic de la maladie d'Alzheimer

1.4.1 Techniques diagnostiques actuelles

Examen clinique

- **Évaluation des symptômes** :

L'évaluation initiale des symptômes de la maladie d'Alzheimer commence généralement par un examen clinique détaillé. Le médecin interroge le patient et ses proches sur les symptômes observés, tels que des troubles de la mémoire, des difficultés de planification ou de résolution de problèmes, des changements de comportement, et d'autres altérations cognitives. Cette évaluation aide à établir un historique des symptômes et à déterminer leur impact sur les activités quotidiennes(26).

- **Tests Cognitifs et Neuropsychologiques** :

Les tests cognitifs sont essentiels pour mesurer de manière objective les fonctions mentales. Parmi les plus courants :

- **Mini-Mental State Examination (MMSE)** : Ce test évalue diverses fonctions cognitives, incluant l'orientation temporelle et spatiale, la mémoire à court terme, le calcul, le langage, et la compréhension. Un score inférieur à la normale peut indiquer une déficience cognitive (26).
- **Montreal Cognitive Assessment (MoCA)** : Similaire au MMSE mais plus sensible pour détecter les stades précoces de la démence, le MoCA teste la mémoire à court terme, les compétences visuo-spatiales, l'exécution des fonctions exécutives, l'attention, la concentration, et le langage(26).
- **Échelle d'évaluation de la démence d'Alzheimer (ADAS-Cog)** :

Spécifiquement conçue pour évaluer la sévérité des symptômes cognitifs de la maladie d'Alzheimer, cette échelle mesure les perturbations de la mémoire, du langage, et des praxies(26).

Imagerie médicale

- **IRM et TEP** :

- ★ **Imagerie par Résonance Magnétique (IRM)** : L'IRM est utilisée pour visualiser la structure du cerveau et détecter les changements anatomiques tels que l'atrophie du cortex ou d'autres régions spécifiques comme l'hippocampe, souvent affectées dans la maladie d'Alzheimer figure 1.4

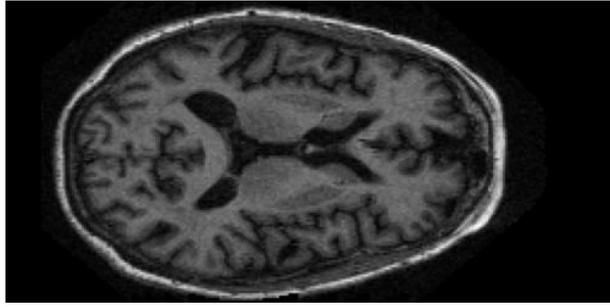


FIGURE 1.4 – IRM cérébrale

- ★ **Tomographie par Émission de Positrons (TEP)** : La TEP peut être utilisée avec des traceurs spécifiques pour détecter les plaques amyloïdes ou mesurer la consommation de glucose dans différentes parties du cerveau, offrant des indices sur les zones où l'activité neuronale est réduite figure [1.5](#)

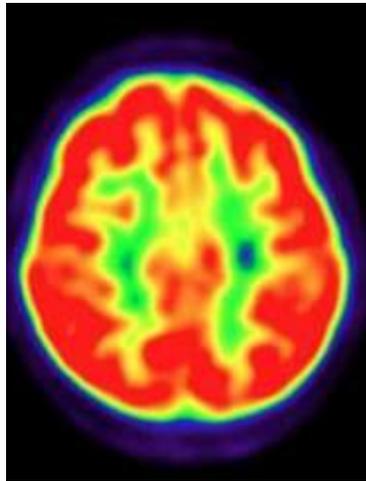


FIGURE 1.5 – TEP cérébrale

- **Imagerie du dépôt amyloïde :**

L'imagerie TEP avec des traceurs comme le Pittsburgh Compound B (PiB) permet de visualiser directement l'accumulation de plaques amyloïdes dans le cerveau, fournissant une preuve concrète de la pathologie de la maladie d'Alzheimer.

Analyses des biomarqueurs

- **Liquide céphalo-rachidien (LCR) :**

Les analyses du LCR peuvent révéler des niveaux anormalement bas de peptides amyloïdes- β 42 et élevés de tau phosphorylée, indiquant la présence de processus pathologiques typiques de la maladie d'Alzheimer. (23)

- **Biomarqueurs sanguins :**

Les développements récents dans les biomarqueurs sanguins pour la protéine tau et les formes de bêta-amyloïde offrent des méthodes moins invasives pour le diagnostic précoce de la maladie, bien que ces tests soient encore en cours de validation pour leur précision et leur efficacité dans la pratique clinique (23).

1.4.2 Importance et défis du diagnostic précoce

Avantages du diagnostic précoce :

- **Planification et intervention précoces :** Un diagnostic précoce permet aux patients et à leurs familles de planifier à l'avance les soins, les traitements et la gestion de la maladie, tout en offrant une fenêtre pour intervenir avant une détérioration cognitive sévère.
- **Avantages économiques :** La détection précoce peut réduire les coûts à long terme en retardant l'apparition de symptômes graves et en minimisant la nécessité de soins intensifs et prolongés. Elle permet également de mieux gérer les ressources de santé et d'optimiser les dépenses en traitement et en soutien.
- **Soutien aux patients et aux familles :** Connaître le diagnostic tôt aide à mobiliser des ressources de soutien psychologique et social pour les patients et leurs aidants.

Défis dans le diagnostic précoce :

- **Limites des techniques actuelles :** Malgré les avancées, les méthodes actuelles de diagnostic peuvent parfois être imparfaites, avec des risques de faux positifs ou faux négatifs, particulièrement dans les stades précoces de la maladie.
- **Questions éthiques et psychologiques :** Le diagnostic précoce soulève des questions sur la gestion des informations potentiellement bouleversantes et l'impact de telles nouvelles sur les patients et leurs familles.

1.5 Utilisation des images IRM dans le diagnostic de la maladie d'Alzheimer

1.5.1 Rôle des images IRM

Principes de base de l'IRM :

- **Fonctionnement de l'IRM** : L'imagerie par résonance magnétique (IRM) utilise des champs magnétiques puissants et des ondes radio pour produire des images détaillées des structures internes du cerveau. Les protons présents dans les tissus réagissent aux champs magnétiques, et ces réactions sont captées et transformées en images par un ordinateur.
- **Types d'IRM** :
 - **IRM structurelle** : Utilisée pour observer la structure physique du cerveau et détecter des anomalies telles que l'atrophie.
 - **IRM fonctionnelle (IRMf)** : Mesure l'activité cérébrale en détectant les changements associés au flux sanguin, souvent utilisée pour comprendre la fonction cérébrale en temps réel.
 - **IRM de diffusion** : Évalue la diffusion de l'eau dans les tissus cérébraux, utile pour détecter les microstructures et la connectivité des fibres nerveuses.

Utilisation dans la détection des changements pathologiques :

- **Détection de l'atrophie cérébrale** : L'IRM structurelle est particulièrement utile pour identifier l'atrophie dans des régions spécifiques du cerveau, telles que l'hippocampe et le cortex entorhinal, qui sont souvent affectées par la maladie d'Alzheimer. La réduction de volume dans ces zones peut indiquer une dégénérescence neuronale précoce.
- **Cartographie de l'activité cérébrale** : L'IRM fonctionnelle permet de visualiser les changements dans l'activité cérébrale, en particulier dans les régions impliquées dans la mémoire et la cognition, fournissant des indices sur la manière dont la maladie affecte le fonctionnement du cerveau.

1.5.2 Avantages de l'IRM par rapport à d'autres méthodes d'Imagerie

Comparaison avec d'autres techniques :

- **Avantages sur le CT Scan** : Contrairement aux scanners CT, l'IRM ne nécessite pas l'utilisation de radiations ionisantes, ce qui la rend plus sûre pour des examens répétés. De plus, l'IRM offre une meilleure résolution pour les tissus mous, permettant une visualisation plus détaillée des structures cérébrales.
- **Complémentarité avec la TEP** : L'IRM peut être utilisée en complément de la tomographie par émission de positons (TEP) pour fournir une image plus complète de la maladie d'Alzheimer. Par exemple, la TEP peut détecter les plaques amyloïdes, tandis que l'IRM révèle les changements structurels.

Implications cliniques :

- **Précision du diagnostique :** L'IRM améliore la précision du diagnostique de la maladie d'Alzheimer en permettant de visualiser directement les changements anatomiques associés à la maladie. Des études ont montré que l'atrophie de l'hippocampe mesurée par l'IRM peut prédire avec une bonne précision le passage de l'état de déficience cognitive légère (MCI) à la maladie d'Alzheimer (source : Alzheimer's Research & Therapy).
- **Suivi de la progression de la maladie :** L'IRM est également utilisée pour suivre la progression de la maladie, en mesurant les changements de volume cérébral et l'augmentation de l'atrophie au fil du temps, ce qui est essentiel pour évaluer l'efficacité des traitements.

1.5.3 Défis et limitations

Contraintes techniques :

L'IRM est une technique coûteuse et peut ne pas être facilement accessible dans toutes les régions. De plus, elle nécessite que les patients restent immobiles pendant l'examen, ce qui peut être difficile pour certains patients atteints de démence.

Interprétation des résultats :

L'interprétation des images IRM peut être complexe et nécessite une expertise spécifique pour distinguer les changements normaux liés à l'âge des signes de pathologie de la maladie d'Alzheimer.

1.5.4 Futur de l'IRM dans la Recherche sur Alzheimer

Développements technologiques :

Les avancées technologiques en IRM, telles que l'IRM à haute résolution et les techniques de traitement d'image avancées, promettent d'améliorer encore la précision et la capacité diagnostique.

Recherche en cour :

De nombreuses études utilisent l'IRM pour explorer les mécanismes pathologiques de la maladie d'Alzheimer et tester de nouvelles thérapies. Par exemple, le projet ADNI (Alzheimer's Disease Neuroimaging Initiative) utilise des données IRM pour évaluer les risques de progression de la MCI à la maladie d'Alzheimer (source : UCSF Radiology).

1.6 Conclusion

Ce premier chapitre a établi les bases théoriques nécessaires pour comprendre la complexité du cerveau humain et la pathologie de la maladie d'Alzheimer, en soulignant l'importance cruciale de la détection précoce et des interventions efficaces.

Nous avons exploré l'anatomie et les fonctions du cerveau humain, détaillant les rôles du cortex cérébral, du cervelet et du tronc cérébral, ainsi que les mécanismes de communication neuronale et de plasticité synaptique. Ces éléments sont essentiels pour appréhender comment des perturbations peuvent mener à des maladies neurodégénératives.

La maladie d'Alzheimer a été introduite comme un trouble neurodégénératif progressif marqué par l'accumulation de plaques amyloïdes et d'enchevêtrements neurofibrillaires. Nous avons discuté de ses symptômes initiaux, de sa progression vers des stades plus avancés, et de son impact socio-économique, tant sur les patients et leurs familles que sur les systèmes de santé.

Nous avons examiné la pathophysiologie de la maladie, en soulignant les effets destructeurs des plaques amyloïdes et des enchevêtrements neurofibrillaires sur les neurones. Comprendre ces mécanismes pathologiques est crucial pour le développement de thérapies ciblées.

En ce qui concerne le diagnostic, nous avons passé en revue les techniques actuelles, incluant les examens cliniques, les tests cognitifs et neuropsychologiques, l'imagerie médicale (IRM et TEP), et les analyses de biomarqueurs. Nous avons mis en avant les avantages du diagnostic précoce et les défis subsistants.

Enfin, nous avons discuté de l'utilisation des images IRM dans le diagnostic de la maladie, en soulignant leurs avantages par rapport à d'autres méthodes d'imagerie et les promesses des développements technologiques futurs pour améliorer la précision diagnostique.

En résumé, ce chapitre a mis en lumière l'importance de la recherche continue et des innovations technologiques pour améliorer la détection précoce et la gestion de la maladie d'Alzheimer. Les chapitres suivants aborderont des aspects plus techniques et des solutions innovantes pour cette cause vitale, ouvrant la voie à des traitements plus efficaces et à un meilleur soutien pour les millions de personnes touchées par cette maladie à travers le monde.

Chapitre 2

Modèles et architectures des convolutional neural network

2.1 Concepts fondamentaux du machine learning

2.1.1 Définition et importance du machine learning

Définition

Le Machine Learning (ML), ou apprentissage automatique, est une branche de l'intelligence artificielle (IA) qui permet aux ordinateurs d'apprendre à partir des données et de prendre des décisions sans être explicitement programmés. En utilisant des algorithmes, le ML construit des modèles mathématiques basés sur des données d'entraînement pour faire des prédictions ou prendre des décisions de manière autonome(27).

L'importance du machine learning apparaît dans ses nombreuses applications, où il change les méthodes traditionnelles et propose des solutions nouvelles.

- **Finance** : Détection des fraudes, gestion des risques.
- **Marketing** : Segmentation des clients, recommandations personnalisées.
- **Transport** : Conduite autonome, optimisation des routes.

2.1.2 Catégories de machine learning

Le ML se divise en plusieurs catégories selon la nature des données et les objectifs de l'apprentissage. Ces catégories comprennent l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement, chacune ayant ses propres méthodes et applications Table 2.1.

Apprentissage supervisé

- **Définition** : Utilise des données étiquetées pour entraîner des modèles. Chaque exemple d'entraînement est associé à une étiquette ou un résultat connu(27).
- **Exemples** :

1. **Régression linéaire** : Prédiction de valeurs continues (ex : prix de l'immobilier).
2. **Classification** : Catégorisation d'éléments (ex : reconnaissance d'images, spam/non-spam).

Apprentissage non supervisé

- **Définition** : Utilise des données non étiquetées pour découvrir des structures ou des motifs cachés(29).
- **Exemples** :
 1. **Clustering (K-means)** : Groupement de données similaires.
 2. **Réduction de dimensions (PCA)** : Simplification des données en préservant les informations essentielles.

Apprentissage par renforcement

- **Définition** : Apprentissage basé sur des essais et des erreurs, où un modèle apprend à maximiser une récompense cumulative en interagissant avec un environnement(30).
- **Exemples** :
 1. **Jeux Vidéo** : Enseigner à un agent à jouer à des jeux.
 2. **Robotique** : Optimisation des mouvements de robots.

Type d'Apprentissage	Avantages	Inconvénients
Apprentissage Supervisé	Précis, Interprétable	Nécessite de grandes quantités de données étiquetées
Apprentissage Non Supervisé	Découverte de motifs cachés	Résultats moins interprétables
Apprentissage par Renforcement	Efficace pour les tâches séquentielles complexes	Complexité algorithmique et besoin de simulations

TABLE 2.1: Comparaison des différents types d'apprentissage automatique

2.1.3 Processus de machine learning

Le processus de machine learning est une série structurée d'étapes permettant de développer, entraîner et déployer des modèles prédictifs efficaces (31).

Cycle de vie du machine learning

Le cycle de vie d'un projet de ML comprend plusieurs étapes clés : figure 2.1

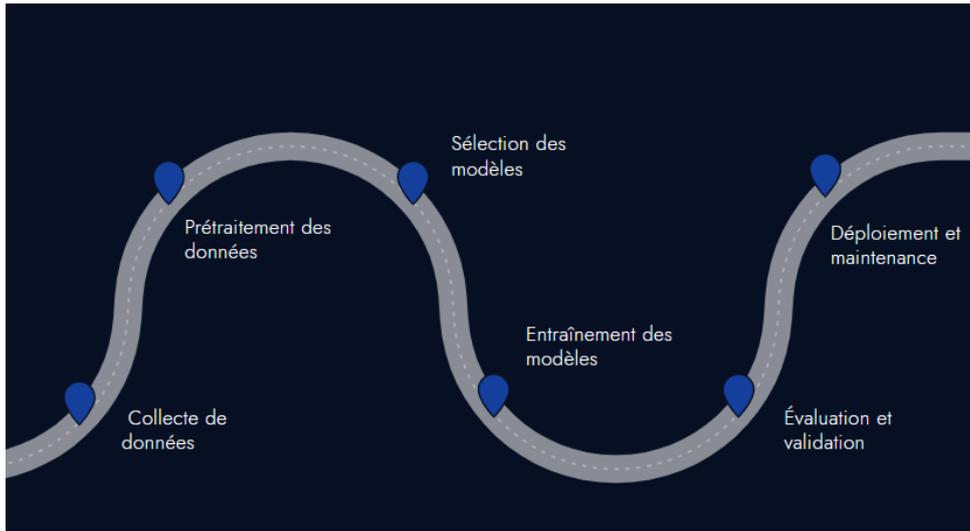


FIGURE 2.1 – Représentation d'un neurone artificiel

- Collecte de données : Recueillir des données pertinentes et de qualité à partir de diverses sources.
- Prétraitement des données : Nettoyer et transformer les données pour les rendre appropriées à l'analyse.
- Sélection des modèles : Choisir le modèle de machine learning le plus adapté à la tâche.
- Entraînement des modèles : Utiliser les données prétraitées pour former le modèle choisi.
- Évaluation et validation : Tester le modèle sur des données de validation pour évaluer sa performance.
- Déploiement et maintenance : Mettre en production le modèle et surveiller ses performances pour effectuer des mises à jour si nécessaire.

Techniques de prétraitement

La qualité et la quantité des données sont cruciales pour améliorer la précision des modèles. Les techniques de prétraitement des données comprennent :

- **Normalisation** : Consiste à ajuster les valeurs des données pour qu'elles se situent dans une même plage.
- **Encodage des variables catégorielles** : Transformation des données catégorielles en format numérique.

2.2 Présentation aux réseaux de neurones artificiels (ANN)

L'apprentissage automatique offre une base solide pour permettre aux machines d'apprendre à partir de données. En évoluant vers les réseaux de neurones artificiels (ANN), nous atteignons une nouvelle dimension d'apprentissage. Inspirés par le cerveau humain, les ANN sont capables de reconnaître des motifs complexes et d'établir des relations

sophistiquées dans les données. Cette transition du machine learning vers les ANN ouvre des perspectives avancées pour des applications nécessitant des analyses et des prédictions plus approfondies et précises.

Définition des ANN :

Les réseaux de neurones artificiels (ANN) sont des modèles informatiques inspirés des structures et du fonctionnement du cerveau humain. Ils sont conçus pour reconnaître des motifs et des relations complexes dans les données à travers un processus d'apprentissage.

2.2.1 Structure des ANN :

Neurones :

Le neurone artificiel figure [2.2](#), composant basique des ANN, est représenté par une combinaison d'entrées, combinées via une fonction dite d'activation, pour produire une sortie. Il est modélisé mathématiquement par les équations 2.1 et 2.2 :

$$z = \sum_{i=1}^n w_i x_i + b \quad (2.1)$$

$$y = f(z) \quad (2.2)$$

Où w_i sont les poids, x_i sont les entrées, b est le biais, et f est la fonction d'activation.

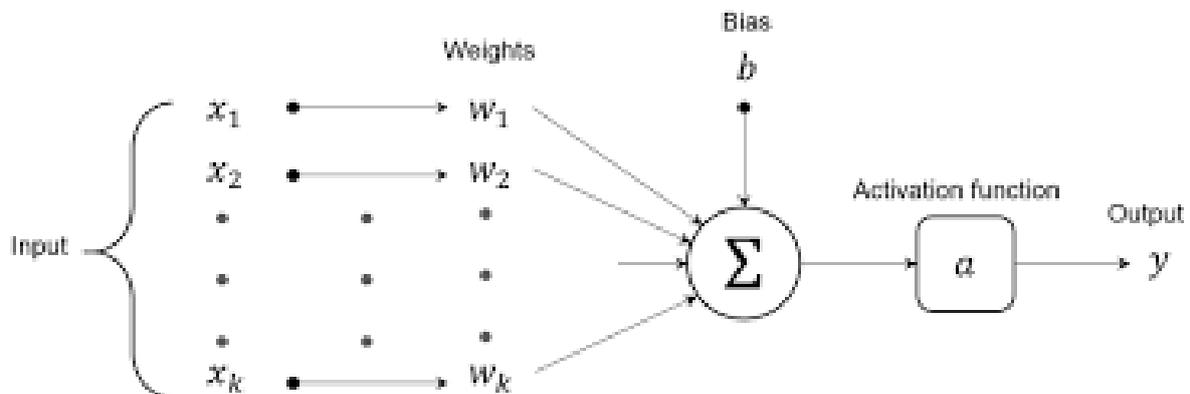


FIGURE 2.2 – Représentation d'un neurone artificiel [\(24\)](#)

Les réseaux de neurones artificiels sont composés de couches, chacune étant constituée de nombreux neurones. Ces couches permettent de structurer le réseau de manière à ce qu'il puisse apprendre et extraire des caractéristiques complexes à partir des données.

Les ANN figure [2.3](#) sont organisés en couches :

1. **Couche d'entrée** : Reçoit les données initiales.
2. **Couches cachées** : Effectuent des transformations et extraient des caractéristiques.
3. **Couche de sortie** : Produit les résultats finaux.

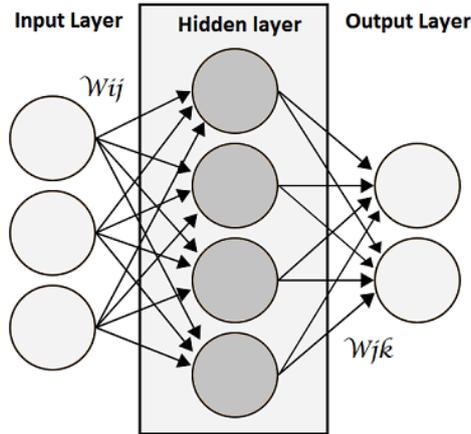


FIGURE 2.3 – Représentation d'un réseau de neurones artificiels

2.2.2 Fonctionnement de base des ANN

Les réseaux de neurones artificiels (ANN) sont des modèles d'apprentissage inspirés par le cerveau humain, permettant de résoudre des problèmes complexes grâce à une architecture de neurones interconnectés. Leur fonctionnement de base repose sur trois étapes essentielles : la propagation avant, où les données sont transmises à travers les couches du réseau pour produire une sortie ; et la rétropropagation, un processus qui ajuste les poids des neurones en fonction de l'erreur de sortie pour améliorer la précision du modèle.

Propagation avant :

La propagation avant implique le passage des données d'entrée à travers les couches de neurones jusqu'à la sortie. Le processus comprend

$$z = \sum_{i=1}^n w_i x_i + b \quad (2.3)$$

$$y = f(z) \quad (2.4)$$

La propagation avant implique le passage des données d'entrée à travers les couches de neurones jusqu'à la sortie. Le processus comprend deux étapes principales :

Dans l'équation (2.3), z représente la sortie pondérée du neurone, w_i sont les poids associés aux entrées x_i , et b est le biais ajouté pour ajuster l'output. Cette somme pondérée est calculée pour chaque neurone de la couche.

Ensuite dans l'équation (2.4), z est transformé par une fonction d'activation $f(z)$ pour produire la sortie y du neurone. Les fonctions d'activation courantes incluent la sigmoïde, la tangente hyperbolique (\tanh), et la ReLU (Rectified Linear Unit). Ces fonctions introduisent la non-linéarité nécessaire pour permettre au réseau d'apprendre des relations complexes entre les données.

Le choix de la fonction d'activation est crucial pour le comportement et les performances d'un réseau de neurones artificiels. Table 2.2 compare les formules, avantages, et inconvénients des fonctions d'activation les plus couramment utilisées dans les ANN.

Fonction d'activation	Formule	Avantages	Inconvénients
ReLU	$f(x) = \max(0, x)$	Simple, efficace	Neurones morts
Sigmoid	$f(x) = \frac{1}{1+e^{-x}}$	Sortie comprise entre 0 et 1	Gradient évanescent
Tanh	$f(x) = \tanh(x)$	Sortie centrée autour de zéro	Gradient évanescent
Linear	$f(x) = x$	Utilisé pour régression	Pas de non-linéarité

TABLE 2.2 – Comparaison des différentes fonctions d'activation utilisées dans les ANN

Après avoir calculé la sortie y pour chaque neurone d'une couche, ces valeurs sont transmises aux neurones de la couche suivante, où le même processus se répète. Ce mécanisme de transfert de données continue jusqu'à ce que la couche de sortie soit atteinte, fournissant ainsi la prédiction finale du réseau.

Algorithme de rétropropagation :

La rétropropagation est l'étape où le modèle apprend à partir des erreurs commises lors des prédictions. Ce processus s'appuie sur les fonctions de coût pour évaluer la performance du modèle et utilise le gradient de l'erreur pour ajuster les poids des neurones afin de minimiser cette erreur.

Fonctions de coût : Les fonctions de coût, également appelées fonctions de perte, mesurent la différence entre les prédictions du modèle et les valeurs réelles. Deux fonctions de coût couramment utilisées sont :

- **MSE (Mean Squared Error/Erreur quadratique moyenne) :**

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.5)$$

Cette fonction mesure la moyenne des carrés des écarts entre les valeurs prédites \hat{y}_i et les valeurs réelles y_i . L'objectif est de minimiser cette valeur pour améliorer la précision du modèle.

- **Cross-Entropy :**

$$\text{Cross-Entropy} = - \sum_{i=1}^n y_i \log(\hat{y}_i) \quad (2.6)$$

Cette fonction est souvent utilisée pour les problèmes de classification. Elle mesure la divergence entre les distributions de probabilité des prédictions et des valeurs réelles, pénalisant davantage les prédictions incorrectes.

Calcul du gradient de l'erreur : Pour ajuster les poids des neurones, la rétropropagation calcule le gradient de l'erreur par rapport à chaque poids. Ce gradient indique dans quelle direction et de quelle amplitude les poids doivent être ajustés pour réduire l'erreur.

Ajustement des poids : Les poids sont ajustés en utilisant une méthode de descente de gradient, selon la formule suivante :

$$w_{\text{new}} = w_{\text{old}} - \eta \frac{\partial E}{\partial w} \quad (2.7)$$

où η est le taux d'apprentissage, un paramètre qui détermine la taille des ajustements des poids. En répétant ce processus d'ajustement, le modèle apprend progressivement à minimiser l'erreur, améliorant ainsi ses performances de prédiction.

2.2.3 Types de réseaux de neurones

Les réseaux de neurones se divisent en différentes catégories selon leur architecture et leur utilisation.

Réseaux de neurones à propagation avant (Feedforward) :

Ces réseaux sont composés de couches où chaque neurone est connecté à tous les neurones de la couche suivante. Ils sont utilisés pour des tâches telles que la classification d'images et la reconnaissance vocale. Ils ne possèdent pas de boucles et les données circulent dans une seule direction, de l'entrée vers la sortie.

Réseaux de neurones convolutifs (CNN) :

Les CNN sont spécialement conçus pour l'analyse des données structurées en matrices, comme les images. Leur architecture tire parti de la structure spatiale des données pour extraire des caractéristiques pertinentes. Ils sont particulièrement efficaces pour des tâches telles que la reconnaissance d'objets, la classification et la segmentation d'images, ainsi que l'analyse d'images médicales.

Réseaux de neurones génératifs adversaires (GAN) :

Les GAN consistent en deux réseaux de neurones qui s'affrontent dans un cadre de jeu à somme nulle. Un générateur crée des données artificielles, tandis qu'un discriminateur évalue leur authenticité. Ils sont utilisés pour la génération d'images, de vidéos et d'autres types de données synthétiques.

2.3 Fondements des réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) sont une amélioration des réseaux de neurones artificiels (ANN), conçus pour traiter les images. Alors que les ANN sont polyvalents, les CNN sont spécialement adaptés pour analyser les données visuelles. Grâce à leurs couches convolutives, ils extraient automatiquement les caractéristiques importantes des images, les rendant idéaux pour la vision par ordinateur et d'autres applications visuelles. En bref, les CNN améliorent les ANN en étant plus efficaces pour les données visuelles.

2.3.1 Définition des CNN

Les réseaux de neurones convolutifs (CNN) sont des réseaux de neurones artificiels spécialement conçus pour analyser les données structurées en matrices, comme les images. Leur architecture permet d'exploiter la structure spatiale des données pour extraire des caractéristiques pertinentes, ce qui les rend particulièrement efficaces pour des tâches telles que la reconnaissance d'objets, la classification et la segmentation d'images. Les CNN sont largement utilisés dans l'imagerie médicale pour détecter des anomalies dans des images comme les IRM et les radiographies, facilitant le diagnostic précoce de maladies telles que le cancer, les maladies cardiovasculaires et neurodégénératives.

2.3.2 Convolution simple

La convolution est une opération mathématique qui consiste à appliquer un filtre sur une image pour extraire des caractéristiques spécifiques. Le filtre est glissé sur l'image, et pour chaque position, une somme pondérée des valeurs de pixels et des valeurs du filtre est calculée, produisant ainsi une nouvelle image filtrée figure 2.4

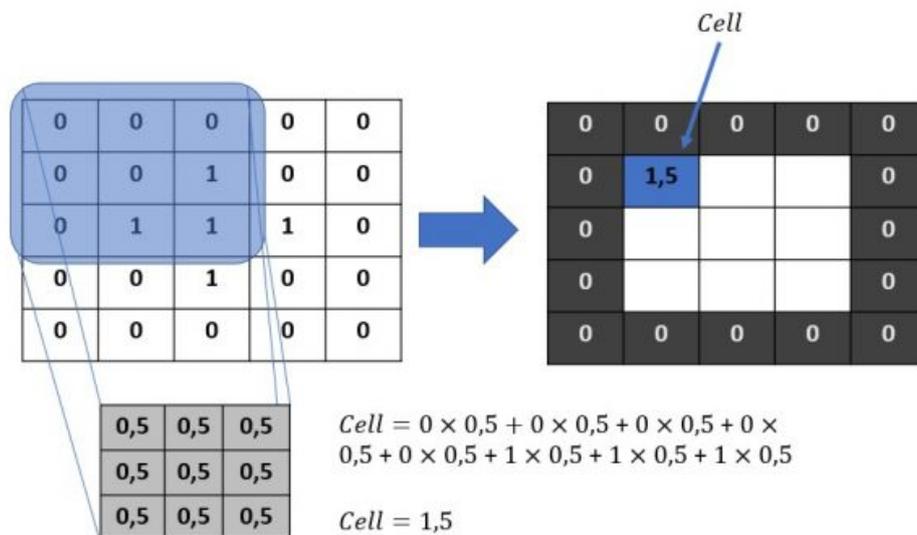


FIGURE 2.4 – illustration de l'opération de convolution avec un filtre 3x3 appliqué sur une image 5x5.

Filtres

Les filtres sont des matrices de petites dimensions (par exemple, 3x3, 5x5) qui sont appliquées à l'image d'entrée. Ils peuvent détecter différentes caractéristiques comme les bords, les textures, et les motifs complexes. Chaque filtre détecte une caractéristique spécifique, et l'ensemble des filtres forme une couche convolutive figure 2.5.

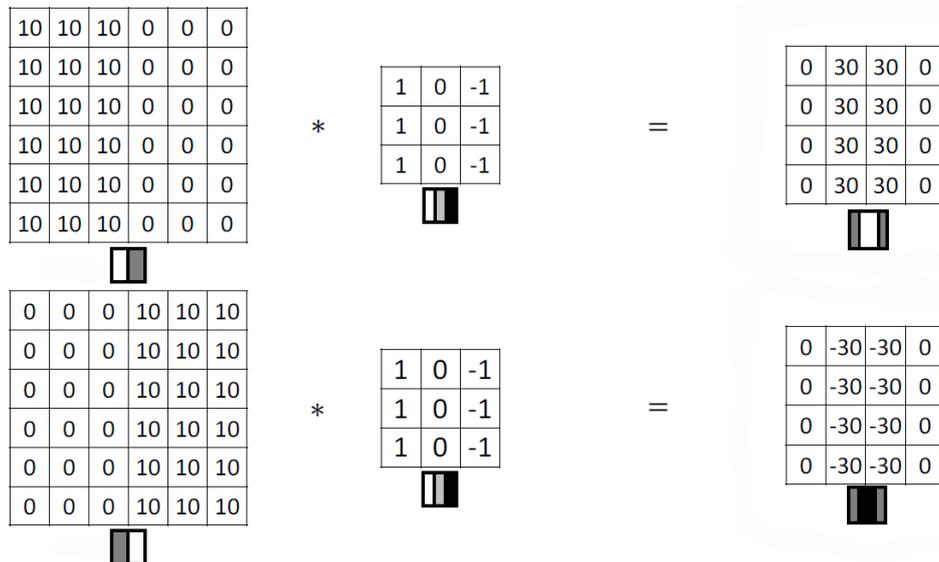


FIGURE 2.5 – Détection des contours verticaux à l'aide d'un noyau de convolution.

2.3.3 Structure des CNN

Les réseaux de neurones convolutifs (CNN) sont spécialement conçus pour traiter les données structurées en grille, comme les images. Leur structure se compose de plusieurs types de couches, chacune ayant un rôle spécifique et complémentaire dans l'extraction et la transformation des caractéristiques des données d'entrée.

Couches convolutives

Les couches convolutives sont des éléments clés des réseaux de neurones convolutifs (CNN). Elles effectuent l'opération de convolution (représenté dans la figure 2.4) plusieurs fois en appliquant différents filtres à l'image d'entrée. Chaque application de filtre produit des cartes de caractéristiques (feature maps) qui capturent divers aspects des données. À mesure que l'on avance dans le réseau, ces couches convolutives extraient des caractéristiques de plus en plus abstraites, permettant au modèle de comprendre des structures complexes dans les images.

Couches de pooling

Les couches de pooling figure 2.6 réduisent la dimensionnalité des cartes de caractéristiques tout en conservant les informations essentielles. Les types courants de pooling incluent le max pooling, qui prend la valeur maximale d'une région, et l'average pooling, qui prend la moyenne des valeurs d'une région.

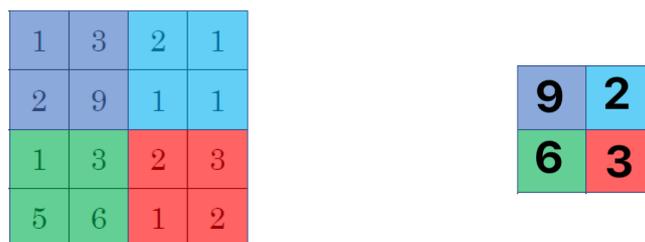


FIGURE 2.6 – exemple de couche max pooling.

Couches entièrement connectées

Les couches entièrement connectées figure 2.7, situées vers la fin du CNN, sont similaires aux couches des réseaux de neurones traditionnels. Elles prennent les cartes de caractéristiques des couches précédentes et les transforment en un vecteur de caractéristiques, utilisé pour la classification finale.

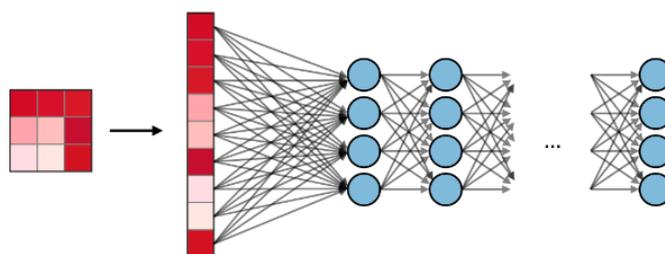


FIGURE 2.7 – exemple de Couche entièrement connectées(37).

2.4 Présentation des modèles CNN choisi pour le projet

2.4.1 VGGNet

VGGNet, représenté en figure 2.8, et développé par Karen Simonyan et Andrew Zisserman, se distingue par son architecture simple mais efficace, utilisant uniquement des convolutions 3x3 empilées en profondeur. L'architecture se compose de 16 à 19 couches pondérées, selon les variantes VGG16 ou VGG19. La structure de base inclut plusieurs blocs de couches convolutives, suivis de couches de pooling, se terminant par des couches entièrement connectées pour la classification finale (14) :

- **Convolution 3x3** : Utilisation exclusive de filtres 3x3 avec un pas (stride) de 1 et un padding de 1 pour conserver les dimensions de l'image d'entrée.
- **Pooling** : Utilisation d'un max pooling 2x2 pour réduire la dimensionnalité après chaque bloc convolutif.
- **Couches entièrement connectées** : Deux ou trois couches entièrement connectées avec ReLU suivies d'une couche softmax pour la classification finale.

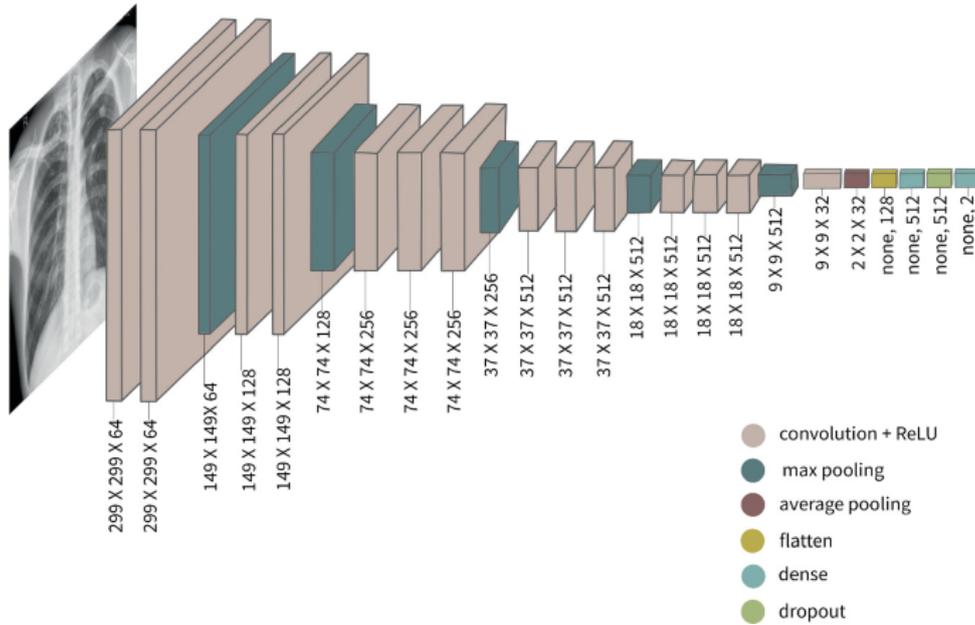


FIGURE 2.8 – Architecture de VGG16(21).

2.4.2 ResNet

ResNet (Residual Network), illustré en figure 2.9, a été développé par Kaiming He et ses collègues, a introduit les connexions résiduelles pour faciliter l’entraînement de très profonds réseaux. Ces connexions permettent de transmettre directement l’information d’une couche à l’autre, contournant une ou plusieurs couches intermédiaires.(15)

- **Bloc résiduel** : Chaque bloc résiduel inclut des couches convolutives suivies d’une addition de l’entrée initiale au résultat convolué, ce qui permet des gradients plus stables lors de l’entraînement.
- **profondeur** : Les variantes de ResNet incluent ResNet-18, ResNet-34, ResNet-50, ResNet-101 et ResNet-152, indiquant le nombre de couches pondérées.
- **Skip connections** : Les connexions de saut (skip connections) aident à lutter contre la dégradation des gradients dans les réseaux profonds.

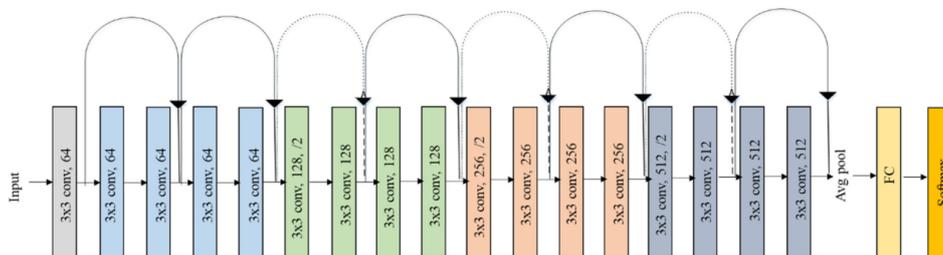


FIGURE 2.9 – Architecture de ResNet (20).

2.4.3 DenseNet

DenseNet (Densely Connected Convolutional Networks) représenté en figure 2.10, développé par Gao Huang et ses collègues, est une architecture où chaque couche reçoit les caractéristiques de toutes les couches précédentes, favorisant la réutilisation maximale des caractéristiques et une réduction du nombre de paramètres. (16)

- **Bloc dense** : Dans chaque bloc dense, chaque couche convolutive est connectée à toutes les couches précédentes via des connexions directes, permettant une meilleure propagation des gradients et une réutilisation efficace des caractéristiques.
- **Réduction de la dimensionnalité** : Utilisation de couches de transition (convolutions 1x1 suivies de pooling) entre les blocs denses pour réduire la dimensionnalité.
- **Paramètres réduits** : Moins de paramètres comparé aux architectures traditionnelles grâce à la réutilisation des caractéristiques.

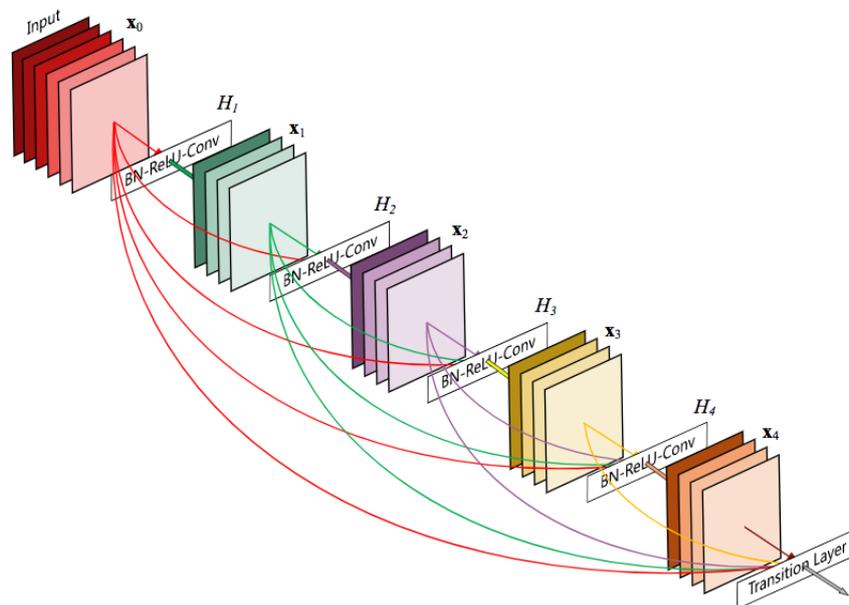


FIGURE 2.10 – Architecture de DenseNet (16)

2.4.4 Inception (GoogLeNet)

GoogLeNet illustré en figure 2.11, a été développé par Christian Szegedy et ses collègues, a introduit le concept de modules Inception qui combinent des convolutions de différentes tailles et des opérations de pooling dans une seule couche, capturant ainsi des caractéristiques à différentes échelles. (17)

- **Module Inception** : Chaque module inclut des convolutions 1x1, 3x3, 5x5 et des pooling 3x3, tous appliqués en parallèle, suivis d'une concaténation des résultats.
- **Efficacité computationnelle** : Réduction du nombre de paramètres par l'utilisation de convolutions 1x1 pour réduire la dimensionnalité avant des convolutions plus larges.
- **Profondeur** : GoogLeNet se compose de 22 couches profondes mais est plus efficient grâce aux modules Inception.

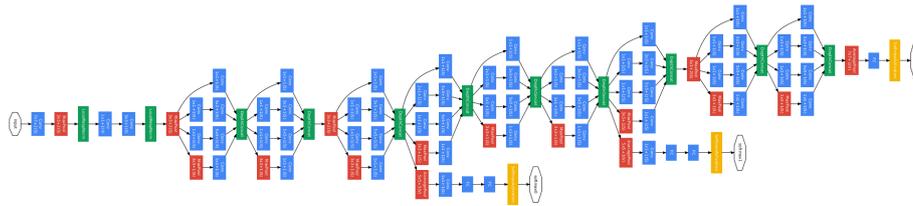


FIGURE 2.11 – Architecture de Inception (17)

2.4.5 Tableau de comparaison des architectures CNN

Pour mieux comprendre les différences et les similitudes entre les diverses architectures de réseaux de neurones convolutifs (CNN), nous présentons ci-dessous la table 2.3 comparatif qui résume les principales caractéristiques et performances de chaque modèle.

Caractéristique	VGGNet	ResNet	DenseNet	Inception (GoogLeNet)
Simplicité Architecturale	Utilise convolutions 3x3 et FC	Connexions résiduelles	Connexions denses	Modules Inception combinant plusieurs convolutions
Profondeur	16-19 couches	18-152 couches	Variable, haute profondeur	22 couches (GoogLeNet)
Efficacité Paramétrique	Faible	Moyenne	Élevée	Élevée
Performance Benchmark	Haute précision mais exigeante	Très haute précision, rapide convergence	Haute précision, moins de paramètres	Haute précision, optimisée pour la computation
Complexité de l'Implémentation	Simple	Moyenne	Élevée	Très élevée
Besoin en Données	Élevé	Très élevé	Élevé	Moyenne à élevé
Mémoire et Puissance	Exigences élevées	Moyennes à élevées	Élevées (mémoire)	Optimisée

TABLE 2.3 – Comparaison des caractéristiques des architectures de réseaux neuronaux

2.4.6 Explication du choix des modèles pour le projet

Pour ce projet, l'objectif est d'analyser des images IRM pour la détection précoce de la maladie d'Alzheimer. Les modèles VGGNet, ResNet, DenseNet et Inception ont été choisis pour leurs capacités à extraire des caractéristiques pertinentes des images et à fournir des prédictions précises.

- **VGGNet** est sélectionné pour sa simplicité architecturale, permettant une implémentation et une compréhension faciles, ce qui est bénéfique pour une première approche.

- **ResNet** est inclus pour sa capacité à gérer des réseaux très profonds sans problème de vanishing gradient, crucial pour capturer des caractéristiques complexes dans les images IRM.
- **DenseNet** est choisi pour son efficacité paramétrique et sa capacité à réutiliser les caractéristiques, ce qui peut réduire les exigences en termes de données et améliorer la performance.
- **Inception** est préféré pour son efficacité computationnelle et sa capacité à capturer des caractéristiques à différentes échelles, ce qui est utile pour les images médicales aux structures variées.

2.5 Adaptation des CNN pour l'analyse des images IRM

2.5.1 Prétraitement des images IRM

Pour que les CNN puissent analyser efficacement les images IRM, un prétraitement rigoureux est nécessaire.

Le prétraitement des données est crucial pour améliorer la qualité des images et la performance des modèles CNN. Il permet de réduire le bruit et les artefacts, homogénéiser les images et faciliter l'extraction des caractéristiques pertinentes. Le prétraitement adéquat garantit une base solide pour les étapes suivantes de l'analyse.

La normalisation est une étape clé pour ajuster les valeurs d'intensité des pixels des images afin qu'elles se situent dans une plage spécifique, généralement entre 0 et 1 ou -1 et 1. Cela permet d'accélérer l'entraînement des modèles et d'améliorer leur convergence, et parmi les méthodes de normalisation courantes, on peut citer :

- **Normalisation min-max** : Redimensionne les valeurs des pixels entre 0 et 1.
- **Z-score** : Centre les valeurs autour de 0 avec un écart-type de 1.

2.5.2 Utilisation des modèles pré-entraînés pour l'analyse des images IRM

Les modèles pré-entraînés, souvent formés sur de grandes bases de données d'images générales, peuvent être réutilisés et ajustés pour des tâches spécifiques telles que l'analyse des images IRM.

Ces modèles pré-entraînés accélèrent considérablement le processus d'entraînement en utilisant des connaissances acquises sur des tâches similaires.

- **Réduction du temps d'entraînement** : Les modèles pré-entraînés peuvent être ajustés pour répondre aux besoins spécifiques des images IRM, comme l'adaptation des couches finales pour la classification des anomalies cérébrales.
- **Transfert de connaissances** : Le transfert de connaissances permet d'appliquer les caractéristiques apprises à partir d'autres ensembles de données à de nouvelles tâches spécifiques, améliorant ainsi la performance.

En outre, ces modèles pré-entraînés peuvent être ajustés pour répondre aux besoins spécifiques des images IRM grâce à des techniques de personnalisation. Cela inclut l'ajus-

tement des couches supérieures du modèle tout en gardant les couches inférieures gelées pour conserver les caractéristiques générales apprises.

2.5.3 Stratégies d'entraînement

Paramètres d'entraînement

Appelés aussi hyper-paramètres, ils sont essentiels pour optimiser les performances du modèle. La sélection des hyperparamètres clés, tels que le taux d'apprentissage, la taille du batch et le nombre d'époques, a un impact significatif sur les performances de model.

Méthodes de régularisation

La régularisation aide à prévenir le surapprentissage, c'est-à-dire lorsque le modèle s'ajuste trop bien aux données d'entraînement, au détriment de sa performance sur de nouvelles données. Elle améliore la généralisation du modèle en le rendant plus robuste. Parmi les techniques les plus connues, on peut citer

- **Dropout** : Application pratique du dropout pour améliorer la généralisation du modèle.
- **Régularisation L2** : Utilisation de la régularisation L2 pour pénaliser les poids des neurones.

2.6 Methodes d'évaluation des modèles CNN

Pour valider un modèle de réseaux de neurones convolutifs (CNN), il ne suffit pas simplement de vérifier sa convergence. En effet, les résultats obtenus peuvent ne pas être représentatifs de la qualité réelle du modèle. Il est donc essentiel d'utiliser des méthodes objectives et reconnues pour évaluer et valider le modèle. Cela inclut l'utilisation de métriques d'évaluation pour mesurer quantitativement les performances du modèle et des techniques de validation pour garantir que le modèle se généralise bien à de nouvelles données. Ces approches fournissent une base solide pour juger la qualité et la fiabilité des CNN. Les métriques d'évaluation sont essentielles pour analyser la performance des modèles CNN. Elles fournissent des indications claires sur l'efficacité du modèle pour la classification ou la détection. Avant de détailler ces métriques, il est important de comprendre quelques termes de base.

Lorsqu'on évalue les prédictions d'un modèle, on se réfère souvent à des instances positives et négatives. Une instance positive est une donnée qui appartient à la classe d'intérêt, par exemple, une image IRM montrant une tumeur. À l'inverse, une instance négative n'appartient pas à la classe d'intérêt, comme une image IRM sans tumeur.

Pour comprendre les métriques d'évaluation, il est essentiel de connaître les notions de vrai positif, faux positif, vrai négatif et faux négatif :

Vrai Positifs (VP) : Les instances positives correctement identifiées. Par exemple, une tumeur détectée comme une tumeur.

Faux Positifs (FP) : Les instances négatives incorrectement identifiées comme positives. Par exemple, une image saine détectée comme une tumeur.

Vrai Négatifs (VN) : Les instances négatives correctement identifiées. Par exemple, une image saine détectée comme saine.

Faux Négatifs (FN) : Les instances positives incorrectement identifiées comme négatives. Par exemple, une tumeur détectée comme étant saine.

Après avoir compris ces termes de base, on peut passer aux métriques d'évaluation.

- **Précision** La précision évalue le pourcentage de prédictions correctes sur l'ensemble des prédictions effectuées :

$$\text{Précision} = \frac{VP}{VP + FP} \quad (2.8)$$

Elle est particulièrement utile pour des ensembles de données équilibrés.

- **Sensibilité (Recall)** La sensibilité mesure la capacité du modèle à identifier correctement les cas positifs :

$$\text{Sensibilité} = \frac{VP}{VP + FN} \quad (2.9)$$

Cette métrique est cruciale dans les domaines médicaux où il est essentiel de détecter tous les cas positifs.

- **Spécificité** La spécificité mesure la capacité du modèle à identifier correctement les cas négatifs :

$$\text{Spécificité} = \frac{VN}{VN + FP} \quad (2.10)$$

Elle est importante pour minimiser les faux positifs, ce qui est essentiel dans de nombreuses applications cliniques.

- **F1-score** Le F1-score est la moyenne harmonique de la précision et de la sensibilité, fournissant une mesure équilibrée de ces deux métriques :

$$F1 = 2 \cdot \frac{\text{Précision} \cdot \text{Sensibilité}}{\text{Précision} + \text{Sensibilité}} \quad (2.11)$$

Il est particulièrement utile dans les cas de déséquilibre des classes, c'est-à-dire lorsque certaines classes sont beaucoup plus fréquentes que d'autres.

2.6.1 Techniques de validation

Pour évaluer la robustesse des modèles CNN et garantir leur capacité de généralisation, plusieurs techniques de validation sont employées.

Validation croisée

La validation croisée k-fold divise les données en k sous-ensembles (folds). Le modèle est entraîné sur k-1 folds et testé sur le fold restant, ce processus étant répété k fois. Les résultats sont ensuite moyennés pour obtenir une évaluation plus fiable.

Sets de test indépendants

Utiliser un set de test indépendant, qui n'a pas été utilisé pendant l'entraînement ou la validation, est essentiel pour évaluer la performance réelle du modèle. Cela permet d'obtenir une mesure objective de la généralisation du modèle.

2.7 Conclusion

Ce chapitre décrit les fondements des réseaux de neurones convolutifs (CNN), en soulignant leur importance et leur utilité pour l'analyse des images, notamment dans le domaine médical. Nous avons débuté par une introduction détaillée aux concepts fondamentaux du machine learning, en expliquant ses différentes catégories et ses processus essentiels, établissant ainsi une base solide pour comprendre l'importance des réseaux de neurones artificiels (ANN) et des CNN.

Les sections sur les ANN ont mis en lumière leur structure et fonctionnement de base, incluant la propagation avant, les fonctions d'activation et l'apprentissage par rétropropagation. Ensuite, la discussion s'est focalisée sur les CNN, en expliquant les principes de la convolution et en détaillant la structure des CNN, avec une emphase sur les couches convolutives, de pooling et entièrement connectées.

La présentation des modèles CNN, tels que VGGNet, ResNet, DenseNet, Inception et EfficientNet, a permis de comprendre leurs architectures spécifiques et leurs contributions significatives à l'évolution de l'analyse des images. Chaque modèle a été discuté en termes de conception.

La section sur l'adaptation des CNN pour l'analyse des images IRM a abordé les défis spécifiques et les stratégies d'entraînement, montrant l'importance des prétraitements des données, l'utilisation des modèles pré-entraînés et les méthodes de régularisation. Ces adaptations sont cruciales pour améliorer l'efficacité et la précision des modèles CNN dans le diagnostic médical.

Enfin, les méthodes d'évaluation des modèles CNN ont été présentées, couvrant des métriques essentielles telles que la précision, la sensibilité, la spécificité et le F1-score, ainsi que les techniques de validation comme la validation croisée et l'utilisation de sets de test indépendants. Ces méthodes garantissent la robustesse et la fiabilité des modèles CNN, en assurant leur performance dans des conditions variées.

Ce chapitre aura ainsi fourni une compréhension approfondie des modèles et architectures des CNN, illustrant leur potentiel dans le domaine de l'imagerie médicale et au-delà. Les techniques et concepts discutés forment une base essentielle pour les applications avancées et les innovations futures dans l'analyse des images médicales et autres domaines de la vision par ordinateur.

Chapitre 3

Implémentation et résultats

3.1 Présentation du dataset

3.1.1 Description du dataset OASIS

Pour assurer au mieux les performances des modèles de Machine Learning appliqués à la détection de la maladie d'Alzheimer, il est essentiel de partir d'une base de données solide et fiable. Le dataset OASIS (Open Access Series of Imaging Studies) répond parfaitement à ces exigences.

Origine et création

Le dataset OASIS a été créé pour fournir des données IRM accessibles au public, facilitant ainsi la recherche sur les maladies neurodégénératives. Il a été mis en place par le Washington University Alzheimer's Disease Research Center en collaboration avec le Howard Hughes Medical Institute([19](#)).

Composition

Le dataset comprend des IRM structurelles de cerveaux de sujets âgés de 18 à 96 ans, incluant des sujets sains ainsi que des sujets atteints de diverses phases de démence([19](#)).

— **Type de données :**

- Images IRM de haute résolution, fournissant des détails précis sur la structure cérébrale.
- Les images incluent des coupes transversales, sagittales et coronales du cerveau.

— **Données complémentaires :** Informations démographiques et cliniques : âge, sexe, diagnostics, scores cognitifs, stades de la maladie.

3.1.2 Justification du choix du dataset

L'adoption du dataset OASIS dans cette projet repose sur plusieurs propriétés intéressantes qui en font un choix optimal :

1-Accessibilité publique

- Le dataset est disponible en open-source, permettant une large accessibilité et favorisant la reproduction des résultats par d'autres chercheurs.
- Facilite la collaboration et l'innovation dans le domaine de la recherche sur les maladies neurodégénératives.

2-Qualité et variété des données

- Les images IRM de haute qualité permettent des analyses détaillées et précises.
- La couverture des différents stades de la maladie d'Alzheimer permet de développer et tester des modèles de diagnostic sur une variété de cas.

Tableau des caractéristiques du dataset

Pour mieux comprendre les raisons du choix du dataset OASIS, la table 3.1 ci-dessous résume ses principales caractéristiques et leur importance dans le contexte de cette recherche.

Caractéristique	Description	Importance
Origine	Washington University et Howard Hughes Medical Institute	Historique
Type de Données	IRM structurelles	Analyse des structures cérébrales
Données Complémentaires	Informations démographiques et cliniques	Contexte épidémiologique
Accessibilité	Open-Source	Reproductibilité
Utilisation	Large adoption dans la recherche	Crédibilité scientifique

TABLE 3.1 – Caractéristiques du dataset OASIS

3.1.3 Conclusion

En conclusion, nous retiendrons que le dataset OASIS est un choix judicieux pour cette étude en raison de sa qualité, de sa variété, et de sa large adoption dans la communauté scientifique. Son accessibilité publique et sa richesse en informations démographiques et cliniques en font un outil indispensable pour le développement et la validation de modèles de diagnostic basés sur le Machine Learning.

3.2 Préparation des données et équilibrage des classes

3.2.1 Introduction au problème des classes non équilibrées

L'un des défis majeurs en machine learning est de gérer des datasets où les classes sont déséquilibrées. Ce déséquilibre peut conduire à des modèles biaisés qui ont de la difficulté à être performant sur les classes minoritaires, ce qui est particulièrement problématique dans des applications critiques comme la détection de maladies.

3.2.2 Description et caractéristiques du dataset OASIS

Avant de plonger dans la présentation des classes et de leur équilibrage, il est essentiel de comprendre la structure et la composition du dataset OASIS.

Classes de données

Les patients sont classifiés en quatre catégories selon la progression de la maladie, basées sur le Clinical Dementia Rating (CDR) [\(22\)](#) figure [3.1](#) :

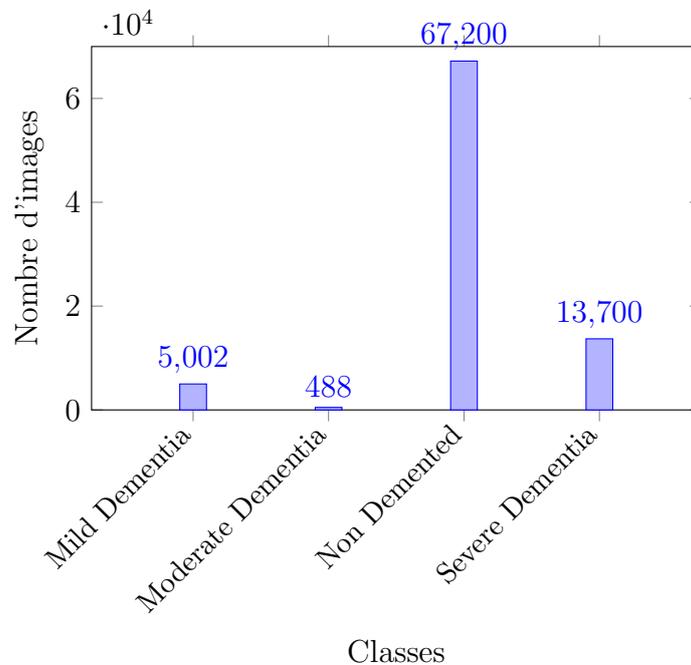


FIGURE 3.1 – Répartition des images par classe

La figure 3.1 montre la répartition des images par classe pour un ensemble de données de détection de la démence. Les classes incluent "Mild Dementia", "Moderate Dementia", "Non Demented" et "Severe Dementia". La majorité des images appartiennent à la classe "Non Demented" avec 67,200 images, suivie de "Severe Dementia" avec 13,700 images. Les classes "Mild Dementia" et "Moderate Dementia" comptent respectivement 5002 et 488 images. Cette distribution déséquilibrée peut affecter les performances des modèles de machine learning, rendant nécessaire l'application de techniques pour équilibrer les classes ou pour ajuster les modèles afin de mieux traiter les classes minoritaires.

1. **Non demented (CDR 0)** : Cette classe représente les individus qui ne présentent pas de symptômes de démence. Ils ont une fonction cognitive normale et ne montrent aucun signe de déclin lié à la maladie d'Alzheimer ou à d'autres formes de démence Figure 3.2.



FIGURE 3.2 – Non demented IRM

2. **Very mild dementia (CDR 0.5)** : Connu également sous le nom de démence très légère ou stade prodromique de la maladie d'Alzheimer. Les personnes dans cette catégorie commencent à éprouver de légers changements dans leur capacité à penser et à se rappeler des informations, mais ces changements ne sont pas suffisamment graves pour affecter significativement leur vie quotidienne. Par exemple, ils peuvent oublier des mots ou l'emplacement des objets quotidiens figure 3.3.

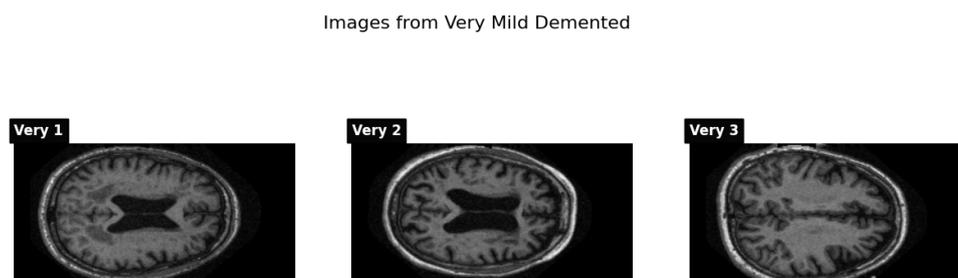


FIGURE 3.3 – Very mild dementia IRM

3. **Mild dementia (CDR 1)** : Les personnes atteintes de démence légère ont des difficultés notables qui commencent à affecter leur vie quotidienne. Par exemple, ils peuvent avoir des problèmes avec les tâches qui nécessitent la planification ou l'organisation, comme payer des factures ou suivre des recettes. Leur capacité à se souvenir d'événements récents peut être altérée, et ils peuvent se perdre, même dans des endroits familiers figure 3.4.

Images from Mild Demented

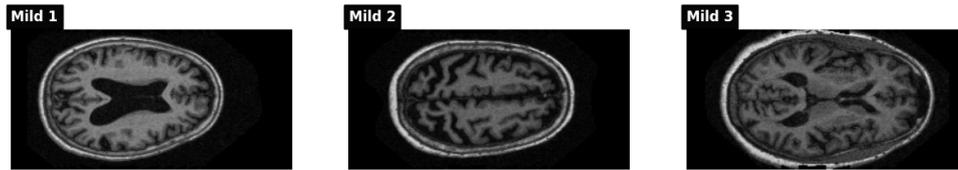


FIGURE 3.4 – Mild dementia IRM

4. **Moderate dementia (CDR 2)** : À ce stade, les individus ont besoin d'une assistance plus significative pour accomplir les activités quotidiennes. Ils peuvent avoir des difficultés à s'habiller, à se baigner, et à manger sans aide. Leur capacité à communiquer commence à décliner, ils peuvent oublier l'histoire récente et même des détails de leur vie personnelle. La confusion et la désorientation deviennent plus fréquentes, et des modifications de la personnalité et du comportement peuvent être observées figure [3.5](#).

Images from Moderate Demented

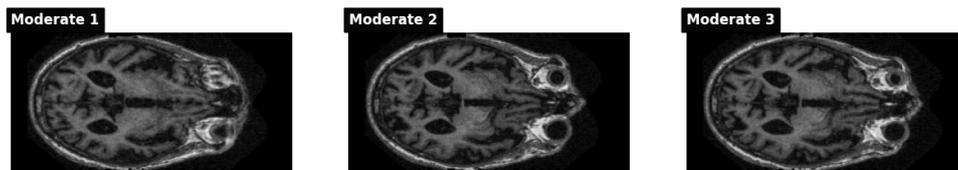


FIGURE 3.5 – Moderate dementia IRM

3.2.3 Identification des classes dans le dataset

La composition des classes dans le dataset OASIS montre un déséquilibre significatif. Les images des patients non déments (CDR 0) prédominent largement par rapport aux autres classes, ce qui peut biaiser le modèle si des mesures d'équilibrage ne sont pas appliquées.

3.2.4 Méthodes d'équilibrage des classes

Pour remédier au problème des classes non équilibrées, plusieurs techniques peuvent être utilisées :

- **Sur-échantillonnage des classes minoritaires** : Augmenter le nombre d'exemples des classes minoritaires en dupliquant des exemples ou en générant de nouvelles données synthétiques.
- **Sous-échantillonnage des classes majoritaires** : Réduire le nombre d'exemples des classes majoritaires pour atteindre un équilibre avec les classes minoritaires.

- **Synthèse de nouvelles données (SMOTE)** : Utiliser des techniques comme SMOTE (Synthetic Minority Over-sampling Technique) pour créer des exemples synthétiques des classes minoritaires.

Pour le dataset OASIS, nous avons choisi d'utiliser une combinaison de sur-échantillonnage et de Sous-échantillonnage.

Sur-échantillonnage et Sous-échantillonnage

Les classes "Very mild dementia" et "Mild dementia" ont été augmentées en dupliquant aléatoirement des exemples existants jusqu'à atteindre 5,000 images par classe. Simultanément, les classes "Non demented" et "Moderate dementia" ont été sous-échantillonnées pour également atteindre 5,000 images par classe, assurant ainsi un équilibre parfait entre toutes les classes Listing [3.1](#)

```
1 import random
2
3 target_samples = 5000
4
5 # Oversample small classes
6 moderate_demented_samp = random.choices(moderate_demented_train, k=
    target_samples)
7 mild_demented_samp = random.choices(mild_demented_train, k=
    target_samples)
8
9 # Undersample large classes
10 very_mild_demented_samp = random.sample(very_mild_demented_train, k=
    target_samples)
11 non_demented_samp = random.sample(non_demented_train, k=target_samples)
12
13 # Check results
14 print(len(non_demented_samp))
15 print(len(very_mild_demented_samp))
16 print(len(mild_demented_samp))
17 print(len(moderate_demented_samp))
```

Listing 3.1 – code python de Sur-échantillonnage et Sous-échantillonnage classes

3.2.5 Impact de l'équilibrage sur les performances du modèle

Pour évaluer l'impact de l'équilibrage des classes, nous avons comparé les performances du modèle avant et après l'application des techniques d'équilibrage.

Illustration de l'impact des classes non équilibrées

Pour illustrer l'impact des classes non équilibrées, nous avons entraîné un modèle de base avant l'application des techniques d'équilibrage. Le modèle dans Listing [3.2](#) a été utilisé :

```

1 model = tf.keras.models.Sequential([
2     layers.Conv2D(32, (3,3), activation='relu', input_shape=(128, 128,
3         3)),
4     layers.MaxPooling2D(2, 2),
5     layers.Conv2D(64, (3,3), activation='relu'),
6     layers.MaxPooling2D(2,2),
7     layers.Conv2D(128, (3,3), activation='relu'),
8     layers.MaxPooling2D(2,2),
9     layers.Conv2D(128, (3,3), activation='relu'),
10    layers.MaxPooling2D(2,2),
11    layers.Flatten(),
12    layers.Dense(512, activation='relu'),
13    layers.Dense(4, activation='softmax')
])

```

Listing 3.2 – code python pour un model cnn basic

Les résultats suivants montrent les performances du modèle avant et après l'équilibrage :

— **Sans équilibrage :**

- Class 0 : Precision = 0.7777, Recall = 1.0000, F1 Score = 0.8749
- Class 1 : Precision = 0.0000, Recall = 0.0000, F1 Score = 0.0000
- Class 2 : Precision = 0.0000, Recall = 0.0000, F1 Score = 0.0000
- Class 3 : Precision = 0.0000, Recall = 0.0000, F1 Score = 0.0000
- Micro-average Precision : 0.7777
- Micro-average Recall : 0.7777
- Micro-average F1 Score : 0.7777

— **Avec équilibrage :**

- Class 0 : Precision = 0.9764, Recall = 0.9047, F1 Score = 0.9392
- Class 1 : Precision = 0.9215, Recall = 0.9719, F1 Score = 0.9460
- Class 2 : Precision = 0.9738, Recall = 0.9859, F1 Score = 0.9798
- Class 3 : Precision = 0.9608, Recall = 1.0000, F1 Score = 0.9800
- Micro-average Precision : 0.9564
- Micro-average Recall : 0.9564
- Micro-average F1 Score : 0.9564

Analyse des résultats :

L'analyse des résultats montre une amélioration significative des performances après l'application des techniques d'équilibrage. Avant l'équilibrage, le modèle montrait un fort biais en faveur de la classe majoritaire, avec une précision et un rappel très élevés pour la classe 0, mais des scores nuls pour les autres classes. Après l'équilibrage, les performances du modèle se sont améliorées de manière substantielle pour toutes les classes, comme en témoigne l'augmentation des scores de précision, de rappel et de F1-Score. Cette amélioration confirme l'importance de l'équilibrage des classes pour le développement de modèles robustes et généralisables.

3.3 Modèles utilisés et configuration

3.3.1 Prétraitement des Images

Le prétraitement des images est une étape important pour préparer les données avant de les introduire dans les modèles de machine learning. Voici le code Listing 3.3 utilisé pour le prétraitement des images IRM dans notre étude :

```
1 img = Image.open(path)
2 img = img.resize((128,128))
3 img = np.array(img)
4 if(img.shape == (128,128,3)):
5     data_test.append(np.array(img))
6     result_test.append(encoder.transform([[0]]).toarray())
```

Listing 3.3 – code python pretraitement des images

Explication du Code de Prétraitement

- **Ouverture de l'image : 'img = Image.open(path)'** : Cette ligne ouvre une image à partir du chemin spécifié (path). La bibliothèque PIL (Python Imaging Library) est utilisée pour manipuler les images.
- **Redimensionnement de l'image : 'img = img.resize((128,128))'** : L'image est redimensionnée à 128x128 pixels. Le redimensionnement est essentiel pour normaliser toutes les images à une taille uniforme, facilitant ainsi le traitement par les modèles de CNN qui exigent des dimensions d'entrée fixes.
- **Conversion en tableau numpy : 'img = np.array(img)'** : L'image redimensionnée est convertie en un tableau numpy. Les tableaux numpy sont des structures de données efficaces pour effectuer des opérations mathématiques, ce qui est la base pour le prétraitement des images.
- **Vérification de la forme de l'image : "if(img.shape == (128,128,3))"** Cette condition vérifie si l'image a la forme correcte, à savoir 128x128 pixels avec 3 canaux de couleur (RVB). Cela garantit que seules les images valides sont utilisées dans l'ensemble de données.
- **Ajout de l'image à la liste des données de test : data_test.append(np.array(img))** L'image vérifiée et convertie est ajoutée à la liste 'data_test', qui stocke toutes les images prêtes pour l'entraînement ou le test des modèles.
- **Encodage de l'étiquette et ajout à la liste des résultats :**
'result_test.append(encoder.transform([[0]]).toarray())' L'étiquette de classe de l'image est encodée à l'aide d'un encodeur ('OneHotEncoder' de sklearn) et ajoutée à la liste 'result_test'. Cela permet de transformer les étiquettes en un format compatible pour l'entraînement des modèles.

3.3.2 Configuration des modèles

Pour configurer nos modèles de réseaux de neurones convolutifs (CNN) basés sur des modèles pré-entraînés, nous utilisons une fonction générique qui nous permet de personnaliser les paramètres clés comme le nombre d'unités cachées, le taux de dropout, et le taux d'apprentissage. Cette fonction prend également en entrée un modèle de base

pré-entraîné, ce qui permet de tirer parti des connaissances acquises à partir de grands ensembles de données d'images génériques.

Voici la définition de la fonction de création de modèle Listing 3.4 :

```
1 def create_model(hidden_units=256, dropout_rate=0.5, learning_rate
2   =0.001, pretrained_base_model):
3     model = Sequential([
4         pretrained_base_model,
5         BatchNormalization(),
6         GlobalAveragePooling2D(),
7         Dense(hidden_units, activation='relu'),
8         Dropout(dropout_rate),
9         Dense(4, activation='softmax')
10    ])
11
12    # Train the pretrained base
13    model.layers[0].trainable = True
14
15    optimizer = Adam(learning_rate=learning_rate)
16
17    model.compile(optimizer=optimizer, loss='
18        sparse_categorical_crossentropy', metrics=['accuracy'])
19    return model
```

Listing 3.4 – code python fonction `create_model`

Explication de la fonction de création de modèle

- **Initialisation du modèle séquentiel** : `'model = Sequential([...])'` : Utilise l'API Sequential de Keras pour empiler les couches du modèle de manière linéaire.
- **Modèle pré-entraîné** : `'pretrained_base_model'` : Cette couche représente le modèle de base préentraîné (par exemple, VGG16, ResNet121, DenseNet, Inception) qui sera utilisé pour l'extraction des caractéristiques. Ce modèle est déjà formé sur un large ensemble de données comme ImageNet.
- **Normalisation par lots** : `'BatchNormalization()'` : Ajoute une couche de normalisation par lots pour stabiliser et accélérer l'entraînement en normalisant les sorties des couches précédentes.
- **Global Average Pooling** : `'GlobalAveragePooling2D()'` : Convertit les cartes de caractéristiques en un vecteur en prenant la moyenne des valeurs sur chaque carte de caractéristiques. Cela réduit la dimensionnalité et les paramètres tout en conservant des informations importantes.
- **Couche Dense avec ReLU** : `'Dense(hidden_units, activation='relu')'` : Ajoute une couche dense avec `hidden_units` (par défaut 256) unités et une fonction d'activation ReLU. Cette couche apprend des combinaisons non linéaires des caractéristiques extraites.
- **Dropout** : `'Dropout(dropout_rate)'` : Ajoute une couche de dropout pour prévenir le surapprentissage en désactivant aléatoirement un pourcentage des neurones pendant l'entraînement. Le taux de dropout par défaut est de 0.5.
- **Couche de sortie avec Softmax** : `'Dense(4, activation='softmax')'` : La couche de sortie contient 4 neurones, un pour chaque classe, avec une activation softmax pour produire des probabilités de classe.

- **Définir la couche de base comme entraînable** : `'model.layers[0].trainable = True'` : Cette ligne assure que les poids du modèle de base préentraîné peuvent être ajustés durant l'entraînement, permettant au modèle de s'adapter aux nouvelles données.
- **Compilation du modèle** :
 - `'optimizer = Adam(learning_rate=learning_rate)'` : Utilise l'optimiseur Adam avec un taux d'apprentissage spécifié.
 - `model.compile(optimizer=optimizer, loss='sparse_categorical_crossentropy', metrics=['accuracy'])'` : Compile le modèle avec la fonction de perte `sparse_categorical_crossentropy` et la métrique de précision.

Configuration des modèles spécifiques

Modèle InceptionV3

Pour configurer le modèle InceptionV3, nous utilisons la fonction `create_model` avec InceptionV3 comme modèle de base pré-entraîné Listing 3.5.

```

1 from tensorflow.keras.applications import InceptionV3
2
3 pretrained_base_model = InceptionV3(weights='imagenet', include_top=
  False, input_shape=(128, 128, 3))
4 model = create_model(hidden_units=512, dropout_rate=0.5,
  pretrained_base_model=pretrained_base_model)
5 history = model.fit(x_train, y_train_int, epochs=100, batch_size=32,
  validation_data=(x_val, y_val_int))
6
7 # Evaluate model on validation set
8 accuracy = model.evaluate(x_val, y_val_int)[1]
```

Listing 3.5 – code python creation du modele InceptionV3

Résultats d'Entraînement et Évaluation Les résultats d'entraînement et d'évaluation pour le modèle InceptionV3 sont présentés ci-dessous :

— Journal d'entraînement : figure 3.6

```
Epoch 93/100
500/500 — 36s 72ms/step - accuracy: 1.0000 - loss: 5.8272e-05 - val_accuracy: 0.9945 - val_loss:
0.0307
Epoch 94/100
500/500 — 36s 73ms/step - accuracy: 0.9994 - loss: 0.0021 - val_accuracy: 0.9925 - val_loss: 0.031
0
Epoch 95/100
500/500 — 36s 73ms/step - accuracy: 0.9992 - loss: 0.0037 - val_accuracy: 0.9900 - val_loss: 0.032
5
Epoch 96/100
500/500 — 36s 73ms/step - accuracy: 0.9985 - loss: 0.0057 - val_accuracy: 0.9575 - val_loss: 0.147
8
Epoch 97/100
500/500 — 36s 73ms/step - accuracy: 0.9974 - loss: 0.0095 - val_accuracy: 0.9883 - val_loss: 0.047
4
Epoch 98/100
500/500 — 36s 73ms/step - accuracy: 0.9986 - loss: 0.0048 - val_accuracy: 0.9885 - val_loss: 0.047
6
Epoch 99/100
500/500 — 36s 73ms/step - accuracy: 0.9958 - loss: 0.0321 - val_accuracy: 0.9540 - val_loss: 0.220
4
Epoch 100/100
500/500 — 36s 73ms/step - accuracy: 0.9978 - loss: 0.0086 - val_accuracy: 0.9927 - val_loss: 0.024
9
125/125 — 2s 19ms/step - accuracy: 0.9903 - loss: 0.0424
```

FIGURE 3.6 – Journal d'entraînement InceptionV3

— Courbe de perte : figure 3.7

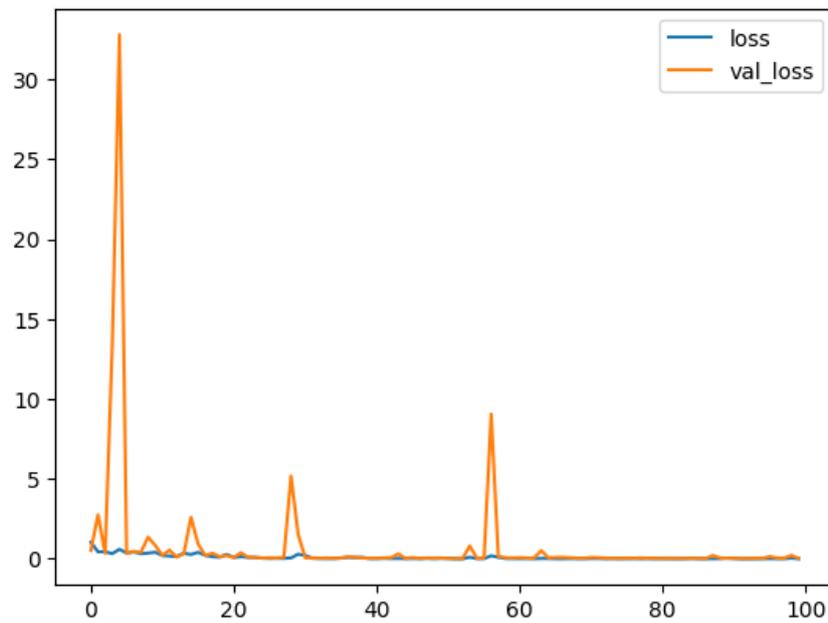


FIGURE 3.7 – Courbe de perte InceptionV3

— Courbe de précision : figure 3.8

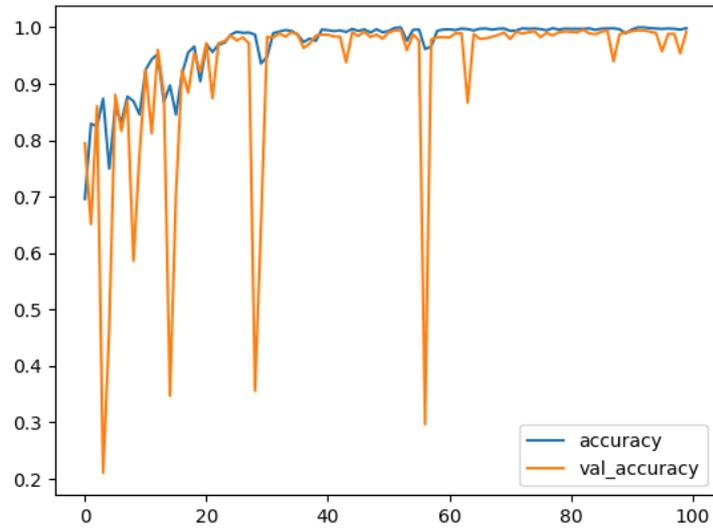


FIGURE 3.8 – Courbe de précision InceptionV3

— Matrice de confusion : figure 3.9

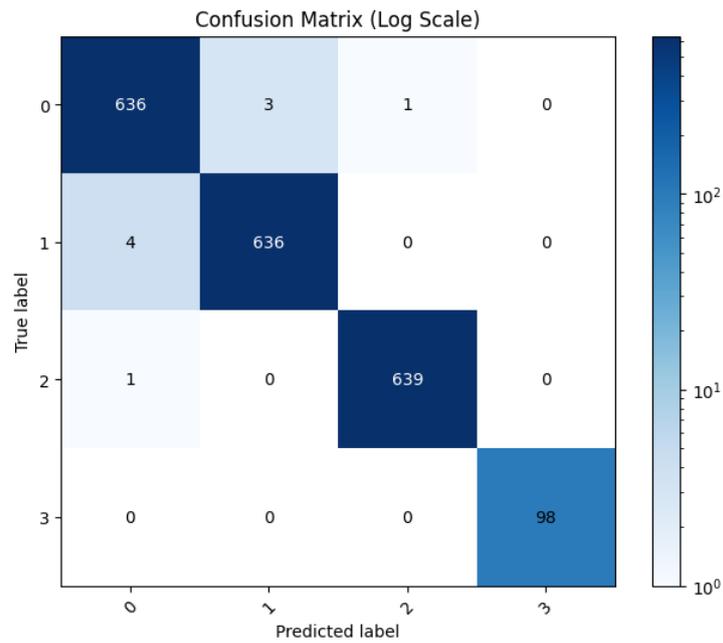


FIGURE 3.9 – Matrice de confusion InceptionV3

— **Évaluation des métriques** : figure [3.10](#)

```
Class 0: Precision = 0.9922, Recall = 0.9938, F1 Score = 0.9930
Class 1: Precision = 0.9953, Recall = 0.9938, F1 Score = 0.9945
Class 2: Precision = 0.9984, Recall = 0.9984, F1 Score = 0.9984
Class 3: Precision = 1.0000, Recall = 1.0000, F1 Score = 1.0000
Micro-average Precision: 0.9955
Micro-average Recall: 0.9955
Micro-average F1 Score: 0.9955
```

FIGURE 3.10 – Évaluation des métriques : InceptionV3

Modèle VGG16 Pour configurer le modèle VGG16, nous utilisons la fonction `create_model` avec VGG16 comme modèle de base préentraîné. Listing [3.6](#)

```
1 from tensorflow.keras.applications import VGG16
2
3 pretrained_base_model = VGG16(weights='imagenet', include_top=False,
4   input_shape=(128, 128, 3))
5 model = create_model(hidden_units=512, dropout_rate=0.5,
6   pretrained_base_model=pretrained_base_model)
7 history = model.fit(x_train, y_train_int, epochs=100, batch_size=32,
8   validation_data=(x_val, y_val_int))
9
10 # Evaluate model on validation set
11 accuracy = model.evaluate(x_val, y_val_int)[1]
```

Listing 3.6 – code python creation du modele VGG16

Résultats d'Entraînement et Évaluation Les résultats d'entraînement et d'évaluation pour le modèle VGG16 sont présentés ci-dessous :

— Journal d'entraînement : figure 3.11

```
Epoch 92/100
500/500 — 37s 75ms/step - accuracy: 0.9988 - loss: 0.0054 - val_accuracy: 0.9920 - val_loss: 0.033
2
Epoch 93/100
500/500 — 37s 74ms/step - accuracy: 0.9994 - loss: 0.0016 - val_accuracy: 0.9830 - val_loss: 0.131
1
Epoch 94/100
500/500 — 37s 74ms/step - accuracy: 0.9980 - loss: 0.0065 - val_accuracy: 0.9448 - val_loss: 39347
672.0000
Epoch 95/100
500/500 — 37s 74ms/step - accuracy: 0.9955 - loss: 0.0176 - val_accuracy: 0.9945 - val_loss: 0.024
4
Epoch 96/100
500/500 — 37s 74ms/step - accuracy: 0.9994 - loss: 0.0017 - val_accuracy: 0.9707 - val_loss: 0.761
5
Epoch 97/100
500/500 — 37s 75ms/step - accuracy: 0.9967 - loss: 0.0129 - val_accuracy: 0.8863 - val_loss: 0.487
2
Epoch 98/100
500/500 — 37s 75ms/step - accuracy: 0.9988 - loss: 0.0037 - val_accuracy: 0.9760 - val_loss: 0.133
0
Epoch 99/100
500/500 — 37s 74ms/step - accuracy: 0.9995 - loss: 0.0015 - val_accuracy: 0.8863 - val_loss: 0.417
6
Epoch 100/100
500/500 — 37s 74ms/step - accuracy: 0.9950 - loss: 0.0168 - val_accuracy: 0.9920 - val_loss: 0.026
0
125/125 — 3s 21ms/step - accuracy: 0.9926 - loss: 0.0344
```

FIGURE 3.11 – Journal d'entraînement VGG16

— Courbe de perte : figure 3.12

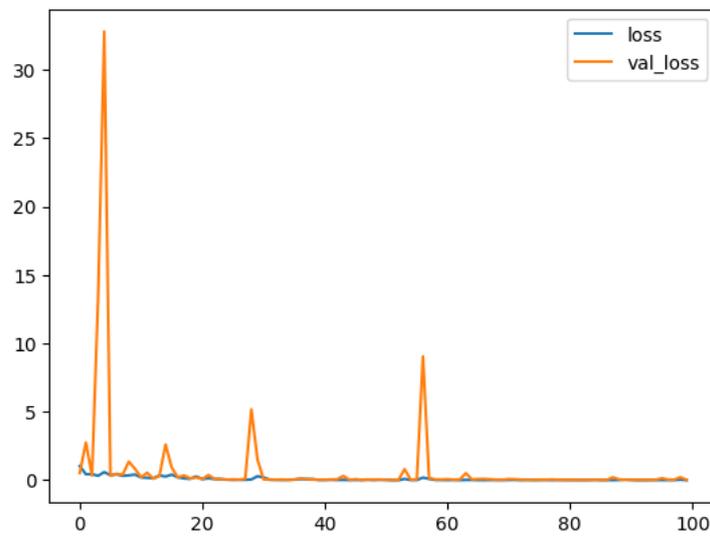


FIGURE 3.12 – Courbe de perte VGG16

— Courbe de précision : figure 3.13

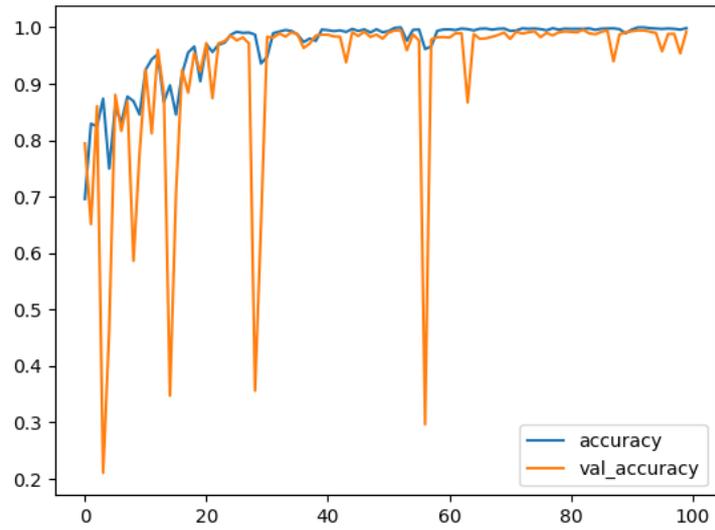


FIGURE 3.13 – Courbe de précision VGG16

— Matrice de confusion : figure 3.14

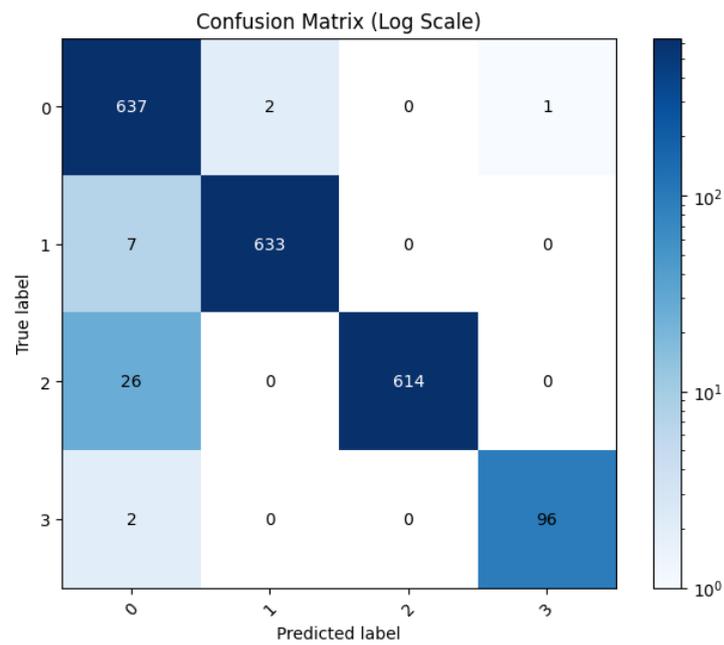


FIGURE 3.14 – Matrice de confusion VGG16

— **Évaluation des métriques** : figure [3.15](#)

```
Class 0: Precision = 0.9479, Recall = 0.9953, F1 Score = 0.9710
Class 1: Precision = 0.9969, Recall = 0.9891, F1 Score = 0.9929
Class 2: Precision = 1.0000, Recall = 0.9594, F1 Score = 0.9793
Class 3: Precision = 0.9897, Recall = 0.9796, F1 Score = 0.9846
Micro-average Precision: 0.9812
Micro-average Recall: 0.9812
Micro-average F1 Score: 0.9812
```

FIGURE 3.15 – Évaluation des métriques VGG16

Modèle ResNet101 Pour configurer le modèle ResNet101, nous utilisons la fonction `create_model` avec ResNet101 comme modèle de base préentraîné Listing [3.7](#).

```
1 from tensorflow.keras.applications import ResNet101
2
3 pretrained_base_model = ResNet101(weights='imagenet', include_top=False,
4   input_shape=(128, 128, 3))
5 model = create_model(hidden_units=512, dropout_rate=0.5,
6   pretrained_base_model=pretrained_base_model)
7 history = model.fit(x_train, y_train_int, epochs=100, batch_size=32,
8   validation_data=(x_val, y_val_int))
9
10 # Evaluate model on validation set
11 accuracy = model.evaluate(x_val, y_val_int)[1]
```

Listing 3.7 – code python creation du modele ResNet101

Résultats d'Entraînement et Évaluation Les résultats d'entraînement et d'évaluation pour le modèle ResNet101 sont présentés ci-dessous :

— Journal d'entraînement : figure 3.16

```
Epoch 92/100
500/500 — 62s 124ms/step - accuracy: 0.9990 - loss: 0.0057 - val_accuracy: 0.9915 - val_loss: 0.0309
Epoch 93/100
500/500 — 62s 124ms/step - accuracy: 0.9983 - loss: 0.0064 - val_accuracy: 0.9902 - val_loss: 0.0586
Epoch 94/100
500/500 — 62s 124ms/step - accuracy: 0.9976 - loss: 0.0093 - val_accuracy: 0.9952 - val_loss: 0.0252
Epoch 95/100
500/500 — 62s 124ms/step - accuracy: 0.9973 - loss: 0.0105 - val_accuracy: 0.9923 - val_loss: 0.0357
Epoch 96/100
500/500 — 82s 124ms/step - accuracy: 0.9995 - loss: 0.0026 - val_accuracy: 0.9940 - val_loss: 0.0313
Epoch 97/100
500/500 — 62s 123ms/step - accuracy: 1.0000 - loss: 6.8889e-05 - val_accuracy: 0.9970 - val_loss: 0.0198
Epoch 98/100
500/500 — 62s 124ms/step - accuracy: 0.9992 - loss: 0.0029 - val_accuracy: 0.9638 - val_loss: 0.2288
Epoch 99/100
500/500 — 62s 123ms/step - accuracy: 0.9984 - loss: 0.0075 - val_accuracy: 0.9970 - val_loss: 0.0187
Epoch 100/100
500/500 — 62s 124ms/step - accuracy: 0.9994 - loss: 0.0017 - val_accuracy: 0.9385 - val_loss: 0.3069
125/125 — 4s 33ms/step - accuracy: 0.9437 - loss: 0.2829
```

FIGURE 3.16 – Journal d'entraînement ResNet101

— Courbe de perte : figure 3.17

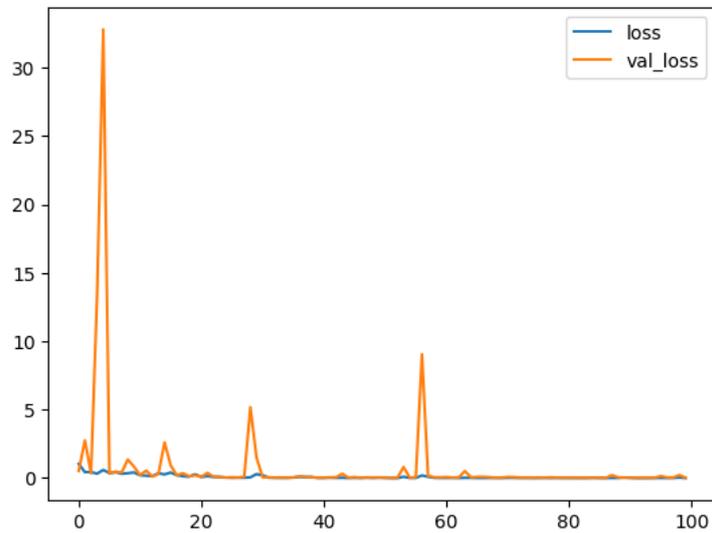


FIGURE 3.17 – Courbe de perte ResNet101

— Courbe de précision : figure 3.18

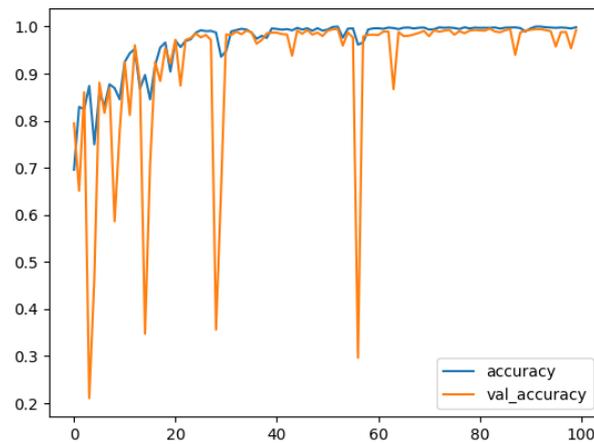


FIGURE 3.18 – Courbe de précision ResNet101

— Matrice de confusion : figure 3.19

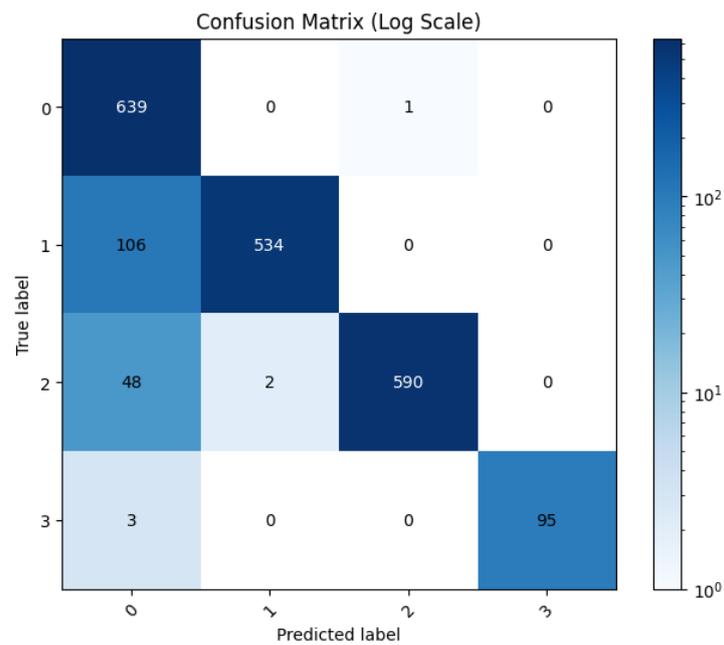


FIGURE 3.19 – Matrice de confusion ResNet101

— **Évaluation des métriques** : figure [3.20](#)

```
Class 0: Precision = 0.8028, Recall = 0.9984, F1 Score = 0.8900
Class 1: Precision = 0.9963, Recall = 0.8344, F1 Score = 0.9082
Class 2: Precision = 0.9983, Recall = 0.9219, F1 Score = 0.9586
Class 3: Precision = 1.0000, Recall = 0.9694, F1 Score = 0.9845
Micro-average Precision: 0.9207
Micro-average Recall: 0.9207
Micro-average F1 Score: 0.9207
```

FIGURE 3.20 – Évaluation des métriques ResNet101

Modèle DenseNet121 Pour configurer le modèle DenseNet121, nous utilisons la fonction `create_model` avec DenseNet121 comme modèle de base préentraîné Listing [3.8](#).

```
1 from tensorflow.keras.applications import DenseNet121
2
3 pretrained_base_model = DenseNet121(weights='imagenet', include_top=
4     False, input_shape=(128, 128, 3))
5 model = create_model(hidden_units=512, dropout_rate=0.5,
6     pretrained_base_model=pretrained_base_model)
7 history = model.fit(x_train, y_train_int, epochs=100, batch_size=32,
8     validation_data=(x_val, y_val_int))
9
10 # Evaluate model on validation set
11 accuracy = model.evaluate(x_val, y_val_int)[1]
```

Listing 3.8 – code python creation du modele DenseNet121

Résultats d'Entraînement et Évaluation Les résultats d'entraînement et d'évaluation pour le modèle DenseNet121 sont présentés ci-dessous :

— **Journal d'entraînement** : figure [3.21](#)

```
Epoch 92/100
500/500 ————— 40s 79ms/step - accuracy: 0.9987 - loss: 0.0034 - val_accuracy: 0.9940 - val_loss: 0.038
9
Epoch 93/100
500/500 ————— 39s 79ms/step - accuracy: 0.9980 - loss: 0.0062 - val_accuracy: 0.9875 - val_loss: 0.080
2
Epoch 94/100
500/500 ————— 40s 79ms/step - accuracy: 0.9983 - loss: 0.0051 - val_accuracy: 0.9962 - val_loss: 0.018
5
Epoch 95/100
500/500 ————— 39s 79ms/step - accuracy: 0.9973 - loss: 0.0088 - val_accuracy: 0.9895 - val_loss: 0.063
8
Epoch 96/100
500/500 ————— 39s 79ms/step - accuracy: 0.9989 - loss: 0.0029 - val_accuracy: 0.9918 - val_loss: 0.058
6
Epoch 97/100
500/500 ————— 40s 79ms/step - accuracy: 0.9990 - loss: 0.0035 - val_accuracy: 0.9918 - val_loss: 0.036
0
Epoch 98/100
500/500 ————— 39s 79ms/step - accuracy: 0.9986 - loss: 0.0034 - val_accuracy: 0.9475 - val_loss: 0.328
7
Epoch 99/100
500/500 ————— 39s 79ms/step - accuracy: 0.9974 - loss: 0.0115 - val_accuracy: 0.9908 - val_loss: 0.058
4
Epoch 100/100
500/500 ————— 40s 79ms/step - accuracy: 0.9969 - loss: 0.0088 - val_accuracy: 0.9933 - val_loss: 0.034
5
125/125 ————— 3s 21ms/step - accuracy: 0.9897 - loss: 0.0818
```

FIGURE 3.21 – Journal d'entraînement DenseNet121

— **Courbe de perte** : figure [3.22](#)

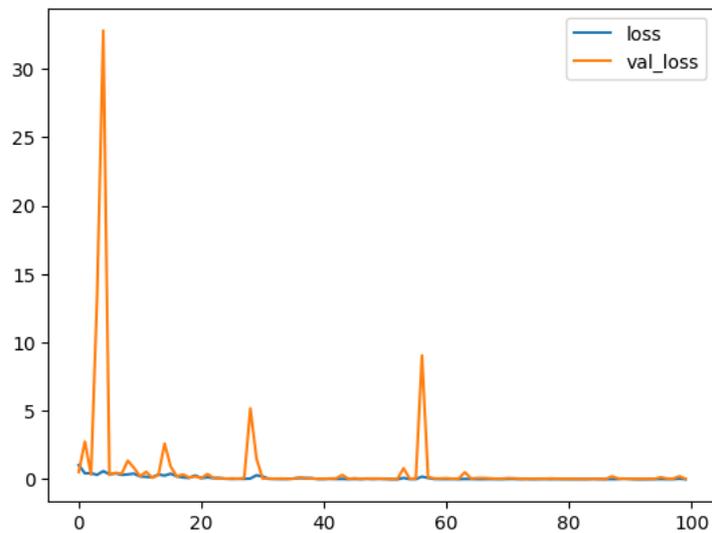


FIGURE 3.22 – Courbe de perte DenseNet121

— Courbe de précision : figure 3.23

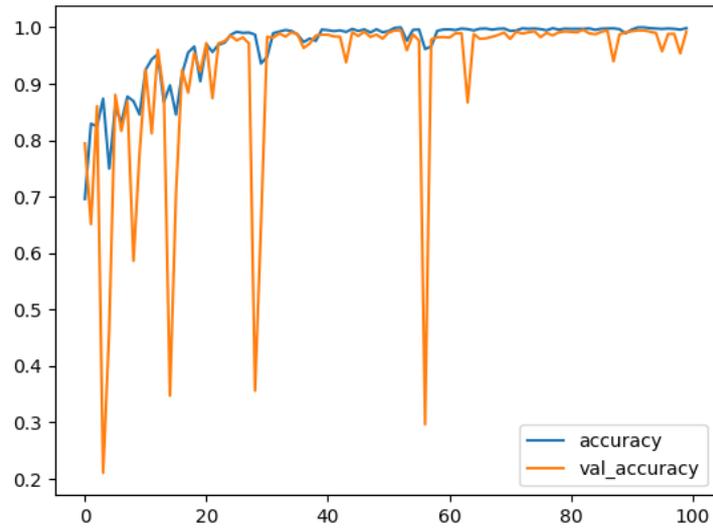


FIGURE 3.23 – Courbe de précision DenseNet121

— Matrice de confusion : figure 3.24

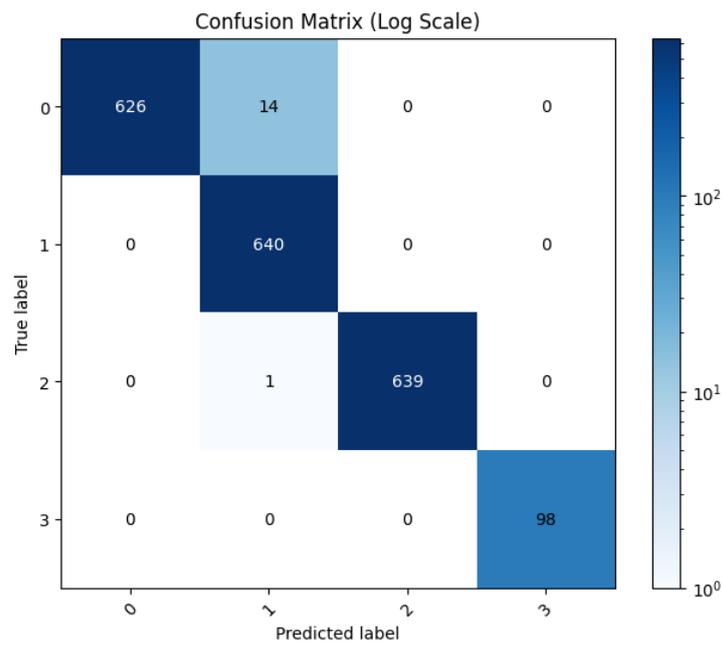


FIGURE 3.24 – Matrice de confusion DenseNet121

— Évaluation des métriques : figure 3.25

```
Class 0: Precision = 1.0000, Recall = 0.9781, F1 Score = 0.9889
Class 1: Precision = 0.9771, Recall = 1.0000, F1 Score = 0.9884
Class 2: Precision = 1.0000, Recall = 0.9984, F1 Score = 0.9992
Class 3: Precision = 1.0000, Recall = 1.0000, F1 Score = 1.0000
Micro-average Precision: 0.9926
Micro-average Recall: 0.9926
Micro-average F1 Score: 0.9926
```

FIGURE 3.25 – Évaluation des métriques DenseNet121

3.4 Discussion des résultats et choix du model

3.4.1 Discussion des résultats

Cette section se concentre sur l’analyse approfondie des résultats obtenus par les différents modèles CNN appliqués aux images IRM du dataset OASIS. Nous discuterons des performances des modèles, des matrices de confusion, des problèmes d’overfitting et d’underfitting, de l’impact de l’équilibrage des classes et comparerons les modèles pré-entraînés.

Résumé des performances des modèles

Les résultats des performances des différents modèles sont déjà présentés dans la section précédente. Les performances des modèles InceptionV3, DenseNet121, ResNet101, et VGG16 sont comparées en termes de précision, rappel, F1-score, et micro-average Table 3.2.

Modèle	Précision Micro- average	Rappel Micro- average	F1 Score Micro- average
InceptionV3	0.9955	0.9955	0.9955
DenseNet121	0.9926	0.9926	0.9926
ResNet101	0.9207	0.9207	0.9207
VGG16	0.9812	0.9812	0.9812

TABLE 3.2 – Tableau des performances des modèles

Analyse des matrices de confusion

Les matrices de confusion révèlent la performance des modèles en termes de classification correcte et incorrecte des classes.

- InceptionV3 montre une excellente performance avec très peu d’erreurs de classification, surtout dans les classes 0 et 3.
- DenseNet121 présente également de très bonnes performances, avec un léger nombre d’erreurs dans la classification des classes 0 et 1.
- ResNet101 montre des erreurs de classification plus fréquentes, particulièrement entre les classes 0 et 1.

- VGG16 présente de bonnes performances globales, mais avec des erreurs notables entre les classes 0 et 2.

Impact des modèles pré-entraînés

Les modèles préentraînés offrent l'avantage de démarrer avec des poids optimisés sur de grandes bases de données, améliorant ainsi les performances et accélérant le processus d'entraînement.

- InceptionV3 et DenseNet121 montrent des performances supérieures grâce à leurs architectures préentraînées.
- Les modèles préentraînés ont des scores de précision et de rappel plus élevés, indiquant qu'ils sont mieux adaptés pour des tâches complexes comme la classification des images IRM.

3.4.2 Choix du meilleur modèle

Critères de sélection du meilleur modèle

Les critères pour sélectionner le meilleur modèle incluent une précision globale élevée, la stabilité des performances, la complexité et le temps de calcul raisonnables, ainsi que la capacité à bien généraliser sur les données de validation. Une précision globale élevée est essentielle car elle indique que le modèle est capable de faire des prédictions correctes de manière cohérente. La stabilité des performances est également cruciale, car un modèle qui fonctionne de manière fiable sur différents ensembles de données est plus fiable pour des applications pratiques. La complexité et le temps de calcul raisonnables sont importants pour s'assurer que le modèle peut être utilisé efficacement sans nécessiter des ressources computationnelles excessives, ce qui est particulièrement pertinent pour les déploiements en production. Enfin, la capacité à généraliser bien sur les données de validation est un indicateur clé de la robustesse du modèle, signifiant qu'il peut maintenir ses performances lorsqu'il est confronté à des données qu'il n'a pas vues auparavant, ce qui est essentiel pour éviter le surapprentissage et assurer une performance optimale dans des scénarios réels.

Présentation du meilleur modèle

Nous avons retenu InceptionV3 comme meilleur modèle sur la base de ses performances. Il a montré des performances exceptionnelles avec une précision globale élevée et une capacité à bien généraliser sur les données de validation.

Résumé des résultats et des performances clés qui justifient cette sélection :

- Précision Micro-average : 0.9955
- Rappel Micro-average : 0.9955
- F1 Score Micro-average : 0.9955

Ces résultats, combinés à une stabilité dans les courbes de perte et de précision, justifient la sélection d'InceptionV3 comme le meilleur modèle pour la classification des images IRM du dataset OASIS.

3.5 Conclusion

Ce chapitre a détaillé l'ensemble du processus d'implémentation et d'évaluation des modèles de machine learning appliqués à la détection de la maladie d'Alzheimer à partir des images IRM du dataset OASIS.

Nous avons commencé par une présentation complète du dataset OASIS, en expliquant son origine, sa composition, et les raisons justifiant son choix. Ce dataset, reconnu pour sa qualité et sa diversité, a permis de développer et de tester des modèles de diagnostic sur une variété de cas.

Ensuite, nous avons abordé le problème des classes non équilibrées, en détaillant les méthodes utilisées pour équilibrer les classes et en démontrant l'impact significatif de ces techniques sur les performances des modèles. L'équilibrage des classes, via des techniques telles que le sur-échantillonnage, le sous-échantillonnage, et l'utilisation de SMOTE, s'est avéré crucial pour obtenir des résultats robustes et généralisables.

La section qui suit a détaillé le prétraitement des images et la configuration des différents modèles CNN, y compris InceptionV3, VGG16, ResNet101, et DenseNet121. Chaque modèle a été configuré avec des paramètres spécifiques et des résultats d'entraînement et d'évaluation ont été présentés pour chaque configuration. Les modèles préentraînés ont montré des performances supérieures grâce à leurs architectures optimisées sur de grandes bases de données d'images.

Enfin, une analyse comparative des résultats des différents modèles a été effectuée. InceptionV3 a été identifié comme le meilleur modèle basé sur des critères de précision, de stabilité, et de généralisation. Il a atteint une précision, un rappel, et un F1-score micro-averagés de 0.9955, démontrant des performances exceptionnelles pour la classification des images IRM.

Cette étude souligne l'importance des techniques d'équilibrage des classes et de l'utilisation de modèles préentraînés pour le développement de systèmes de diagnostic robustes et fiables. Les résultats obtenus avec InceptionV3 ouvrent des perspectives prometteuses pour l'amélioration des outils de détection précoce de la maladie d'Alzheimer, contribuant ainsi à une meilleure prise en charge des patients.

En conclusion, ce chapitre a fourni une base solide pour comprendre et mettre en œuvre des modèles de machine learning dans le domaine de la détection des maladies neurodégénératives, tout en mettant en évidence les défis et les solutions liés aux données déséquilibrées et aux performances des modèles.

Conclusions générales et perspectives

Dans ce mémoire, nous avons exploré l'application des modèles de machine learning pour la détection précoce de la maladie d'Alzheimer à partir d'images IRM. L'utilisation du dataset OASIS, reconnu pour sa qualité et sa diversité, a permis de développer et de tester des modèles robustes sur une variété de cas, offrant une base solide pour cette étude. Le dataset OASIS a été soigneusement choisi en raison de sa réputation et de la richesse de ses annotations, permettant une analyse approfondie des caractéristiques cliniques et structurelles des sujets étudiés.

Nous avons abordé le problème des classes non équilibrées, un défi classique dans l'apprentissage automatique, en utilisant des techniques d'équilibrage telles que le sur-échantillonnage, le sous-échantillonnage et la création de nouvelles données synthétiques avec SMOTE. Ces techniques se sont révélées très performantes pour obtenir des résultats robustes et généralisables, améliorant significativement les performances des modèles. L'importance de l'équilibrage des classes réside dans sa capacité à prévenir le biais du modèle vers la classe majoritaire, assurant ainsi une évaluation plus juste et plus précise des performances du modèle.

Le prétraitement des images et la configuration des différents modèles de réseaux de neurones convolutifs (CNN), y compris InceptionV3, VGG16, ResNet101 et DenseNet121, ont été détaillés. Les modèles pré-entraînés ont démontré des performances élevées grâce à leurs architectures optimisées sur de grandes bases de données d'images. Parmi ces modèles, InceptionV3 s'est distingué comme le plus performant, atteignant une précision, un rappel et un F1-score micro-averagé de 0.9955. Cette performance exceptionnelle justifie sa sélection comme le meilleur modèle pour la classification des images IRM du dataset OASIS. L'utilisation de modèles préentraînés permet de tirer parti des connaissances acquises lors de l'entraînement sur des bases de données étendues, ce qui est particulièrement bénéfique dans le cadre de la détection précoce de maladies complexes comme l'Alzheimer.

L'analyse comparative des résultats des différents modèles a aussi mis en lumière l'importance des techniques d'équilibrage des classes et de l'utilisation de modèles pré-entraînés pour le développement de systèmes de diagnostic robustes et fiables. Les résultats obtenus ouvrent des perspectives prometteuses pour l'amélioration des outils de détection précoce de la maladie d'Alzheimer, contribuant ainsi à une meilleure prise en charge des patients. L'amélioration continue des modèles de machine learning et l'optimisation des processus de prétraitement des données sont des étapes cruciales pour le développement de solutions diagnostiques efficaces.

Pour les perspectives futures, l'ajout de techniques de segmentation pourrait encore

améliorer la précision et la sensibilité des modèles. La segmentation permet de décomposer les images IRM en régions spécifiques, facilitant l'identification des structures cérébrales pertinentes et des anomalies associées à la maladie d'Alzheimer. En combinant la segmentation avec les techniques de détection actuelles, il serait possible de mieux isoler les zones d'intérêt et d'améliorer la capacité des modèles à détecter des signes précoces de la maladie. Par exemple, la segmentation pourrait permettre de focaliser l'analyse sur des régions clés comme l'hippocampe, où les premiers signes de la maladie d'Alzheimer apparaissent en premier.

L'intégration de techniques avancées de segmentation dans le flux de travail des modèles de détection pourrait également permettre une analyse plus détaillée des changements structurels dans le cerveau au fil du temps. En utilisant des algorithmes de segmentation sophistiqués, les modèles pourraient non seulement identifier la présence de la maladie, mais aussi suivre sa progression, offrant ainsi des informations précieuses pour le suivi et la gestion des patients.

Cette approche pourrait également faciliter la détection d'autres anomalies cérébrales, permettant une évaluation globale de la santé du cerveau et une détection précoce de différentes pathologies neurologiques.

Pour finir, ce mémoire a fourni une base solide pour l'utilisation des techniques de machine learning dans le diagnostic précoce de la maladie d'Alzheimer. Les résultats obtenus avec InceptionV3 montrent un potentiel immense pour améliorer la détection précoce de cette maladie dévastatrice. Les techniques de segmentation représentent une voie prometteuse pour renforcer encore ces outils diagnostiques, permettant une prise en charge plus proactive et efficace des patients. Les progrès dans ce domaine pourraient transformer la manière dont la maladie d'Alzheimer est diagnostiquée et gérée, offrant de nouvelles perspectives pour la recherche et le développement de traitements innovants. La combinaison de la détection par machine learning et de la segmentation ouvre des horizons prometteurs pour une compréhension plus approfondie des maladies neurologiques et une amélioration significative des interventions cliniques.

Bibliographie

- [1] Selkoe, D. J. (2001). Alzheimer's disease : Genes, proteins, and therapy. *Physiological Reviews*, 81(2), 741-766.
- [2] Hardy, J., & Selkoe, D. J. (2002). The amyloid hypothesis of Alzheimer's disease : Progress and problems on the road to therapeutics. *Science*, 297(5580), 353-356.
- [3] Lee, V. M., Goedert, M., & Trojanowski, J. Q. (2001). Neurodegenerative tauopathies. *Annual Review of Neuroscience*, 24(1), 1121-1159.
- [4] Ballatore, C., Lee, V. M., & Trojanowski, J. Q. (2007). Tau-mediated neurodegeneration in Alzheimer's disease and related disorders. *Nature Reviews Neuroscience*, 8(9), 663-672.
- [5] Jack Jr, C. R., Knopman, D. S., Jagust, W. J., et al. (2010). Hypothetical model of dynamic biomarkers of the Alzheimer's pathological cascade. *The Lancet Neurology*, 9(1), 119-128.
- [6] Lyketsos, C. G., Carrillo, M. C., Ryan, J. M., et al. (2011). Neuropsychiatric symptoms in Alzheimer's disease. *Alzheimer's & Dementia*, 7(5), 532-539.
- [7] Black, W., & Almeida, O. P. (2004). A systematic review of the association between the Behavioral and Psychological Symptoms of Dementia and burden of care. *International Psychogeriatrics*, 16(3), 295-315.
- [8] Schulz, R., & Martire, L. M. (2004). Family caregiving of persons with dementia : Prevalence, health effects, and support strategies. *American Journal of Geriatric Psychiatry*, 12(3), 240-249.
- [9] Gaugler, J. E., Kane, R. L., Kane, R. A., et al. (2005). Family care for older adults with disabilities. *Aging & Mental Health*, 9(1), 18-23.
- [10] Brodaty, H., & Donkin, M. (2009). Family caregivers of people with dementia. *Dialogues in Clinical Neuroscience*, 11(2), 217-228.
- [11] Masters, C. L., Bateman, R., Blennow, K., et al. (2015). Alzheimer's disease. *Nature Reviews Disease Primers*, 1, 15056.
- [12] Cummings, J. L., Morstorf, T., & Zhong, K. (2014). Alzheimer's disease drug-development pipeline : Few candidates, frequent failures. *Alzheimer's Research & Therapy*, 6(4), 37.

- [13] Dubois, B., Feldman, H. H., Jacova, C., et al. (2007). Research criteria for the diagnosis of Alzheimer’s disease : revising the NINCDS–ADRDA criteria. *Lancet Neurology*, 6(8), 734-746. doi : [10.1016/S1474-4422\(07\)70178-3](https://doi.org/10.1016/S1474-4422(07)70178-3).
- [14] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv :1409.1556*.
- [15] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [16] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- [17] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- [18] Tan, M., & Le, Q. V. (2019). EfficientNet : Rethinking model scaling for convolutional neural networks. In *International Conference on Machine Learning* (pp. 6105-6114).
- [19] Marcus, D. S., et al. (2007). "Open Access Series of Imaging Studies (OASIS) : Cross-sectional MRI Data in Young, Middle Aged, Nondemented, and Demented Older Adults." *Journal of Cognitive Neuroscience*.
- [20] Li, H., Habes, M., Fan, Y., et al. (2019). A Deep Learning Approach for Automated Diagnosis and Multi-Class Classification of Alzheimer’s Disease Stages Using Resting-State fMRI and Residual Neural Networks. *ResearchGate*. doi : [10.1109/TMI.2019.2935945](https://doi.org/10.1109/TMI.2019.2935945).
- [21] Patel, S. B., Patel, P. H., Jain, V. D., Verma, J. P. (2022). Improvised VGG16 CNN Architecture for Predicting Tuberculosis Using the Frontal Chest X-Ray Images. In : Somani, A. K., Mundra, A., Doss, R., Bhattacharya, S. (eds) *Smart Systems : Innovations in Computing. Smart Innovation, Systems and Technologies*, vol 235. Springer, Singapore. https://doi.org/10.1007/978-981-16-2877-1_7.
- [22] Morris, J. C. (1993). The Clinical Dementia Rating (CDR) : Current version and scoring rules. *Neurology*, 43(11), 2412-2414. doi : [10.1212/WNL.43.11.2412](https://doi.org/10.1212/WNL.43.11.2412).
- [23] Blennow, K., & Zetterberg, H. (2018). "Biomarkers for Alzheimer’s disease : current status and prospects for the future." *Journal of Internal Medicine*, 284(6), 643-663.
- [24] Faber, V., Gates, M., Karel, E., Paulino, G. H., & Su, X. (2020). NPLIC : A Machine Learning Approach to Piecewise Linear Interface Construction. *Computational Methods in Applied Mathematics*, 20(3), 549-567. doi : [10.1515/cmam-2020-0030](https://doi.org/10.1515/cmam-2020-0030).
- [25] Alzheimer’s Association. (2021). "2021 Alzheimer’s Disease Facts and Figures." *Alzheimer’s & Dementia : The Journal of the Alzheimer’s Association*, 17(3), 327-406.
- [26] McKhann, G. M., et al. (2011). "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 : The Journal of the Alzheimer’s Association*, 7(3), 263-269.

- [27] Murphy, K. P. (2012). *Machine Learning : A Probabilistic Perspective*. MIT Press. ISBN : 978-0262018029. Chapitre 1 : Introduction.
- [28] James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning : with Applications in R*. Springer. ISBN : 978-1461471370. Chapitre 3 : Linear Regression, Chapitre 4 : Classification.
- [29] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning : Data Mining, Inference, and Prediction*. Springer. ISBN : 978-0387848570. Chapitre 14 : Unsupervised Learning.
- [30] Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning : An Introduction*. MIT Press. ISBN : 978-0262039246. Chapitre 1 : Introduction.
- [31] Han, J., Kamber, M., & Pei, J. (2011). *Data Mining : Concepts and Techniques*. Morgan Kaufmann. ISBN : 978-0123814791. Chapitre 2 : Data Preprocessing.
- [32] Bear, M. F., Connors, B. W., & Paradiso, M. A. (2020). *Neuroscience : Exploring the Brain* (4th ed.). Wolters Kluwer. Chapitres 2, 3, 4, 5 et 24.
- [33] World Health Organization. (2023). Dementia. [Online] Available : <https://www.who.int/news-room/fact-sheets/detail/dementia> (visité : 10 May 2023).
- [34] Daily Science. (2014). Alzheimer : Un diagnostic précoce est-il justifié? [Online] Available : <https://dailyscience.be/18/08/2014/alzheimer-un-diagnostic-precoce-est-il-justifie/> (visité : 12 May 2023).
- [35] BrightFocus Foundation. (2023). What are Alzheimer's Plaques and Tangles? [Online] Available : <https://www.brightfocus.org/news/amyloid-plaques-and-neurofibrillary-tangles> (visité : 4 June 2024).
- [36] Ithapu, V. K., Singh, V., & Johnson, S. C. (2017). Randomized Deep Learning Methods for Clinical Trial Enrichment and Design in Alzheimer's Disease. In S. K. Zhou, H. Greenspan, & D. Shen (Eds.), *Deep Learning for Medical Image Analysis* (pp. 337-354). Academic Press. doi : [10.1016/B978-0-12-810408-8.00015-6](https://doi.org/10.1016/B978-0-12-810408-8.00015-6).
- [37] Shervine Amidi. (2024). Pense-bête réseaux de neurones convolutionnels. [Online] Available : <https://stanford.edu/~shervine/1/fr/teaching/cs-230/pense-bete-reseaux-neurones-convolutionnels> (visité : 7 June 2024).

Résumé : Ce mémoire explore l'utilisation des réseaux de neurones convolutifs (CNN) pour la détection précoce de la maladie d'Alzheimer à partir d'images IRM, en utilisant le dataset OASIS. Il détaille la maladie d'Alzheimer, ses mécanismes pathologiques, et les méthodes diagnostiques actuelles, soulignant l'importance du diagnostic précoce. Les modèles CNN InceptionV3, VGG16, ResNet101 et DenseNet121 sont comparés, avec InceptionV3 se distinguant par sa précision élevée. L'étude propose également des techniques de préparation des données et d'équilibrage des classes pour améliorer la robustesse des modèles.

Les images IRM jouent un rôle crucial dans le diagnostic, avec des avantages par rapport à d'autres méthodes d'imagerie et des perspectives d'amélioration grâce aux avancées technologiques. Le mémoire propose l'ajout de techniques de segmentation pour améliorer la précision des modèles. L'utilisation des techniques de machine learning et des images IRM offre un potentiel significatif pour améliorer le diagnostic précoce de la maladie d'Alzheimer, transformant ainsi les approches diagnostiques et thérapeutiques, et ouvrant la voie à de nouvelles recherches et innovations.

Mots clés : réseaux de neurones convolutifs, Alzheimer, IRM, diagnostic.

Abstract : This dissertation explores the use of convolutional neural networks (CNN) for the early detection of Alzheimer's disease from MRI images, using the OASIS dataset. It details Alzheimer's disease, its pathological mechanisms, and current diagnostic methods, highlighting the importance of early diagnosis. The CNN models InceptionV3, VGG16, ResNet101, and DenseNet121 are compared, with InceptionV3 standing out for its high accuracy. The study also proposes data preparation and class balancing techniques to improve the robustness of the models.

MRI images play a crucial role in diagnosis, offering advantages over other imaging methods and opportunities for improvement through technological advancements. The thesis suggests incorporating segmentation techniques to enhance model accuracy. The use of machine learning techniques and MRI images offers significant potential to improve early diagnosis of Alzheimer's disease, thereby transforming diagnostic and therapeutic approaches, and paving the way for new research and innovations.

Mots clés : convolutional neural networks, Alzheimer, IRM, diagnosis.

ملخص :

تستكشف هذه الأطروحة استخدام الشبكات العصبية التلافيفية (CNN) للكشف المبكر عن مرض الزهايمر من صور الرنين المغناطيسي، باستخدام مجموعة بيانات OASIS. وهي تفصل مرض الزهايمر وآلياته المرضية والأساليب التشخيصية الحالية، مع التأكيد على أهمية التشخيص المبكر. تم مقارنة نماذج CNN وهي InceptionV3 و VGG16 و ResNet101 و DenseNet121، حيث تميز InceptionV3 بدقته العالية. تقترح الدراسة أيضًا تقنيات لتحضير البيانات وموازنة الفئات لتحسين قوة النماذج.

تلعب صور الرنين المغناطيسي دورًا حاسمًا في التشخيص، حيث تقدم مزايا على الأساليب التصويرية الأخرى وفرصًا للتحسين بفضل التقدم التكنولوجي. تقترح الأطروحة إضافة تقنيات تقسيم لتحسين دقة النماذج. إن استخدام تقنيات التعلم الآلي وصور الرنين المغناطيسي يوفر إمكانات كبيرة لتحسين التشخيص المبكر لمرض الزهايمر، مما يؤدي إلى تحول في الأساليب التشخيصية والعلاجية ويفتح الطريق لأبحاث وابتكارات جديدة.

الكلمات المفتاحية :

الشبكات العصبية التلافيفية، الزهايمر، صور الرنين المغناطيسي، التشخيص.