

الجمهورية الجزائرية الديمقراطية
الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة أبي بكر بلقايد - تلمسان -

Université Aboubakr Belkaid – Tlemcen –

Faculté de TECHNOLOGIE



MEMOIRE

Présenté pour l'obtention du **diplôme de MASTER**

En : Génie Biomédical

Spécialité : Imagerie Médicale

Par : BOUSSOUSSOU Yasser Et BERDI Yasser

Sujet

Détection Précoce Des Maladies Neurodégénératives

Soutenu publiquement, le /06/2022, devant le jury composé de :

Mr. Haj sliman Zine eddine	Prof	Université de Tlemcen	Président
Mr. LAZOUNI Mohammed el Amine	MCA	Université de Tlemcen	Examineur
Mr. BOUKLI HACENE Ismail	MCA	Université de Tlemcen	Encadreur
Mlle. SAIM Meriem	Doctorante	Université de Tlemcen	Co-Encadreur

Année universitaire : 2021 /2022

Résumé :

Les maladies neurodégénératives sont des maladies très courantes dans le monde, en particulier la maladie d'Alzheimer qui est la plus fréquente.

Cette maladie qui affecte le cerveau est représentée par une démence neurologique au niveau de la matière grise et de l'hippocampe. Et pour cela nous avons appliqué notre travail sur les images IRM basons sur l'étude de forme et la morphologie des matière gris où nous pouvons identifier la maladie

Donc pour cet objectif nous avons appliqué premièrement une isolation de cerveau sur les images IRM utilisant la morphologie mathématique suivant d'un filtrage au but de réduction de bruits, pour réaliser un pré-traitement de base de données visons l'obtention des résultats valable de classification

Notre algorithme est appliqué sur une base de donnes de société ADNI contient des images IRM de vérité terrain classe sur les trois stades de la maladie, afin d'afficher les résultats de notre algorithme pour l'évaluer.

Mot clés : Alzheimer, IRM, matière grise.AD, CN, MCI.

Abstract:

Neurodegenerative diseases are very common in the world, especially Alzheimer's disease which is the most frequent.

This disease that affects the brain is represented by a neurological dementia at the level of the gray matter and the hippocampus. And for this we have applied our work on MRI images based on the study of shape and morphology of gray matter where we can identify the disease

So we realized an algorithm in this objective, serves to apply a brain extraction on MRI images applying mathematical morphology and noise reduction filtering in order to prepare our database in order to get better result of classification

The algorithm realized by us was applied a database of ADNI company which serves a set of ground truth MRI images separated into three stages of the disease, in order to display the results of our algorithm to evaluate it.

Keyword:

Alzheimer's disease, MRI, gray matter.AD, CN, MCI

ملخص

تعد أمراض التنكس العصبي من الأمراض الشائعة جدًا في العالم ، وخاصة مرض الزهايمر الأكثر شيوعًا

هذا المرض الذي يصيب الدماغ يتمثل في الخرف العصبي المتمثل في تقلص المادة الرمادية والحصين. ولهذا طبقنا عملنا على صور التصوير بالرنين المغناطيسي بناءً على دراسة شكل وتشكل المادة الرمادية حيث يمكننا تحديد المرض

لذلك أدركنا خوارزمية لهذا الغرض، تتمثل في تطبيق استخراج للدماغ على صور التصوير بالرنين المغناطيسي باستخدام علم التشكل الرياضي وتصفية لتقليل التشويش من أجل إعداد قاعدة البيانات للحصول على أفضل النتائج الممكنة في مجال التصنيف.

تم تطبيق الخوارزمية الخاصة بنا على قاعدة بيانات تخص شركة ادني التي تحتوي على مجموعة صور لتصوير بالرنين المغناطيسي تمثل حالات حقيقية للمرضى من اجل عرض نتائج خوارزمتنا وتقييمها

الكلمات المفتاحية

مرض الزهايمر التصوير بالرنين المغناطيسي

Remerciement

Nous remercions tout d'abord **Allah** le tout-puissant de nous avoir donnés le courage, la patience et surtout la Volonté de mener à bien réaliser ce travail.

Nous remercions avec appréciation notre encadreur et prof **Mr. Ismail Boukli Hacene, maitre de conférence à l'université de Tlemcen** , pour sa personnalité honnête qui nous fait apprendre beaucoup dans 5 années passé et sa confiance vers nous a propos de ce projet, ses encouragements et conseils, qui nous a donné l'esprit pour rester toujours motivés.

Un grand remerciement pour notre Co-encadreur **MERIEM SAIM, doctorante à l'université de Tlemcen** qui nous a toujours courage et oriente pour réaliser notre travail. Ce fut un réel plaisir de l'avoir comme co-encadreur. ce travail a été accompli grâce à ses encouragements et ses conseils. L'atteinte de ces objectifs n'aurait pas été possible sans leur aide très appréciable.

Grand remerciement pour **Pr. Hadj Slimane Zinedine**, professeur à l'université de Tlemcen , qui nous a fait l'honneur de présider mon jury. Veuillez trouver ici, monsieur, le témoignage de notre vive gratitude, haute considération et profond respect.

Nous tenons à remercions **Monsieur Lazouni mohammed el amine** pour aimablement accepté d'examiner ce modeste travail. C'est un grand honneur pour nous de vous compter parmi les membres du jury. Que ce travail soit le témoin de nos sincères remerciements et de notre profonde gratitude.

Nous avons dédié ce travail A :

Nos chers parents qui nous ont trop aidées, familles et amies

Merci à toutes et à tous

Table de Matière

RESUME	2
ABSTRACT.....	2
الملخص.....	3
Remerciements	4
Table de Matière.....	5
LISTE DES FIGURES.....	9
LISTE DES TABLEAUX.....	12
LISTES DES ABREVIATION.....	13
INTRODUCTION GENERALE.....	15

Chapitre 1 : L'aspect médical de la maladie d'Alzheimer

I.	Introduction.....	19
II.	Comprendre le cerveau.....	19
III.	Système nerveux centrale SNC et ses éléments principaux.....	20
3.	1. l'encéphale.....	20
3.	2. Cerveau.....	21
3.	2. 1. Cervelet.....	21
3.	3. Tronc cérébral.....	22
3.	3. 1. Liquide céphalorachidien.....	22
3.	3. 2. La moelle épinière.....	22
4.	Cerveau au niveau cellulaire.....	22
4.	1. L'architecture des neurones.....	22
4.	2. Les différents types de neurones.....	23
4.	3. Les cellules de soutien.....	24
5.	Les maladies neurodégénératives.....	24
5.	1. Mécanismes de mort des neurones MND.....	25
6.	La maladie d'Alzheimer.....	28
6.	1. les lobes du cerveau	29
6.	2. Biomarqueurs.....	31
7.	Anapathologie e physiopathologie d'Alzheimer.....	32

7.	1. Anatomopathologie.....	33
8.	Diagnostic de la maladie d'Alzheimer.....	34
8.	1. Les examens à effectuer pour poser un diagnostic.....	35
8.	1. i. Les tests cliniques.....	35
8.	1. ii. Les tests paracliniques.....	35
9.	L'imagerie par Résonance magnétique IRM.....	36
10.	La mesurer de l'atrophie hippocampique en routine clinique.....	37
10.	1. Les différentes séquences de L'IRM.....	38
10.	1. i. La séquence T1.....	38
10.	1. ii. La séquence T2.....	38
10.	1. iii. La séquence Flair.....	39
11.	Imagerie cérébrale.....	40
12.	Le cerveau et l'intelligence artificiel.....	40
13.	Conclusion.....	41

Chapitre 2 : Outils & méthodes

1.	Introduction.....	43
2.	Etat de l'art.....	43
3.	Méthodes et outils.....	45
3.	1. Prétraitement.....	45
3.	1. 1. Filtrage par ondelettes.....	45
3.	1. 1. 1. Définition des ondelettes.....	45
3.	1. 1. 2. Ondelettes orthogonales.....	45
3.	1. 1. 3. Condition d'admissibilité.....	45
3.	1. 1. 4. Transformée en ondelette continue directionnelle.....	46
3.	1. 1. 4. i. Décomposition en ondelettes.....	46
3.	1. 1. 4. ii. Reconstruction en ondelettes.....	46
3.	1. 1. 5. Symlets.....	47
3.	1. 2. Extraction de région d'intérêt.....	48
3.	1. 2. 1. Définition de la morphologie mathématique.....	48
3.	1. 2. 2. Dilatation.....	48
3.	1. 2. 3. Erosion.....	49
3.	1. 2. 4. Ouverture morphologique.....	50

3. 1. 2. 5. Fermeture morphologique.....	51
3. 1. 3. Segmentation par K-means clustering.	52
3. 1. 3. 1. Définition de la segmentation.....	52
3. 1. 3. 2. Définition de l’algorithme K-means.....	52
3. 1. 1. 3. Etapes essential d’application de K-means.....	52
3. 1. 3. 4. Résultat de segmentation par le K-means.....	53
3. 2. Classification.....	54
3. 2. 1. Apprentissage automatique (Machine Learning).....	54
3. 2. 1. 1. Extraction des caractéristiques.....	54
3. 2. 1. 1. i. Définition de l’histogramme des gradients oriente (HOG).....	54
3. 2. 1. 1. ii. Définition de model binaire local (LBP).....	55
3. 2. 1. 1. iii. Définition de matrice co-occurrence de niveau de gris (GLCM).....	56
3. 2. 1. 2. Classification.....	56
3. 2. 1. 2. i. Multi-support vector machine (Multi-SVM).....	56
3. 2. 1. 2. ii. K-Nearest Neighbors (KNN).....	57
3. 2. 2. Apprentissage approfondie (Deep Learning).....	58
3. 2. 2. 1. Réseaux de neurone convolutif (CNN).....	58
3. 2. 2. 1. i. Définition de CNN.....	58
3. 2. 2. 1. ii. Etapes de fonctionnement de CNN.....	59
3. 2. 3. Métrique d’évaluation de classification.....	60
4. Conclusion.....	61

Chapitre 3 : Résultat & discussion

1.Introduction.....	63
2. Matériels.....	63
3. 1. Hardware.....	63
2. 2. Software.....	64
2. 2. i. Langage de programmation.....	64
2. 2. ii. Base de Données ADNI.....	64
3. Méthodes développées.....	64
3. 1. Pré-traitement.....	66
3. 1. 1. Extraction de cerveau.....	67

3. 1. 2. Résultat de l'extraction de cerveau.....	67
3. 1. 2. Filtrage.....	69
3. 1. 2. 1. Définition des Métriques d'évaluation des filtres	69
3.1. 2. 2. Evaluation des filtres	70
3. 1. 2. 3. Interprétation des résultats de filtrage	73
3. 1. 2. 4. Evaluation des multiples ondelettes de Filtrage	73
3. 1. 3. Segmentation des tissus cérébrale par k-means.....	75
3. 1. 3. i. Résultat de segmentation k-means.....	75
3. 1. 3. ii. Interprétation.....	76
3. 2. Machine Learning : résultats et discussion.....	76
3. 2. 1. Extraction des caractéristiques.....	76
3. 2. 1. i. Caractérisation par le HOG.....	79
3. 2. 1. ii. Caractérisation par LBP.....	79
3. 2. 1. iii. Caractérisation par matrice co-occurrence de niveau de gris.....	81
3. 2. 2. Classification.....	82
3. 2. 2. i. Expérimentation 1 classification par le HOG.....	82
3. 2. 2. ii. Expérimentation 2 classification par le LBP.....	84
3. 2. 2. iii. Expérimentation 3 classification par le GLCM.....	85
3. 2. 2. iv. Comparaison.....	86
3. 3. Deep Learning : résultat et discussion.....	87
3. 3. 1. Expérimentation 1 CNN1 (deux couches de convolution).....	87
3. 3. 2. Expérimentation 2 : trois couches de convolution(CNN2).....	89
3. 3. 3. Expérimentation 3 (Augmentation de base de données) CNN3.....	91
3. 3. 3. 4. Comparaison.....	94
4. Comparaison entre le Deep Learning et le Machine Learning.....	94
5. Interface graphique de Alzhnet.....	95
6. Conclusion.....	97
7. Conclusion general.....	99
8. Les references.....	104

Liste des figures :

Chapitre 1 : L'aspect médical de la maladie d'Alzheimer

Figure I.1 : le système nerveux.....	21
Figure I.2 : les principaux composant du cerveau.....	22
Figure I.3 : la substance grise et blanche.....	23
Figure I.4 : cellule nerveuse.....	24
Figure I.5 : un cerveau sein et un cerveau atteint de l'Alzheimer.....	26
Figure I.6 : Mécanismes de mort de cellule neuronal.....	27
Figure I.7 : Mécanismes de formation des agrégats de protéines dans les MND.....	28
Figure I.8 : Protéines agrégées dans les maladies neurodégénératives.....	28
Figure I.9 : les lobes cérébraux	30
Figure I.10 : l'hippocampe.....	31
Figure I.11 : les coupes IRM du cerveau.....	32
Figure I.12 : les coupes IRM du cerveau.....	38
Figure 1.13 : coupe axiale pondération T1 de liquide du système ventriculaire	40
Figure 1.14 : coupe axiale pondération T2 de liquide du système ventriculaire	40
Figure I.15 : séquence FLAIR montrant une lésion périventriculaire.....	41

Chapitre 2 : Outils et méthodes

Figure II.1: Fonction de mise à l'échelle des symlets.....	52
Figure II.2: L'angle de phase des symlets.....	53
Figure II.3: Exemple de dilatations sur des images binaires.....	54
Figure II.4: Exemple d'érosions sur des images binaire	54
Figure II.5: Ouverture morphologique sur une image de cornée.....	55
Figure II.6: Ouverture morphologique sur une image de cornée.....	56
Figure II.7: segmentation par algorithme de K-means a 3 clusters.....	58
Figure II.8: Une illustration des caractéristiques HOG 2D pour une coupe axiale.....	59
Figure II.9: Schéma représente le principe de LBP	60
Figure II.10: quelque paramètre de textures obtenue par le GLCM.....	61
Figure II.11: séparation de merge optimale par SVM.....	62
Figure II.12: Classification multi-class par SVM.....	62
Figure II.13: une prédiction de l'algorithme K-NN.....	63
Figure II.14: Principe de convolution matricielle de CNN.....	63
Figure II.15: Architecture d'algorithme de CNN	64
Figure II.16 : Principe de calcule de précision.....	65

Chapitre 3 : Résultat et discussion

Figure III.1: Le logo de langage de programmation Matlab.....	69
Figure III.2: une image de chaque stade de la maladie mentionne dans la base de donnée.....	70
Figure III.3: plan des taches réalisé dans ce chapitre.....	71

Figure III.4: Plans de la partie de pré-traitement de l'image.....	71
Figure III.5: Application des multiples filtres sur une image.....	72
Figure III.6: Algorithme d'extraction de cerveau.....	78
Figure III.7: Binarisation d'image.....	79
Figure III.8: les étapes d'extractions de cerveau.....	79
Figure III.9: Extraction de cerveau.....	80
Figure III.10: Segmentation par K-means	80
Figure III.11: Modalités d'extraction de caractéristique.....	81
Figure III.12: les caractéristiques extraites par le HOG sur une image de cas MCI.....	82
Figure III.13: Extraction de caractéristiques par une cellule de taille 3*3.....	82
Figure III.14: Extraction de caractéristiques par une cellule de taille 5*5.....	83
Figure III.15: Extraction de caractéristiques par une cellule de taille 1*1.....	83
Figure III.16: : Nombre de caractéristiques obtenue par chaque cellule der HOG.....	83
Figure III.17: les information extrait par LBP avec une cellules de taille 10*10.....	84
Figure III.18: les information extrait par LBP avec une cellules de taille 5*5	85
Figure III.19: les information extrait par LBP avec une cellules de taille 3*3	85
Figure III.20: Nombre de caractéristiques obtenue par chaque cellule der LBP.....	86
Figure III.21: Extraction de caractéristiques d'une image segmentée par l'algorithme de k-means par une cellule de taille 1*1.....	88
Figure III.22: les information extrait par LBP avec une cellules de taille 10*10	90
Figure III.23: la structure générale de CNN avec 2 couches utilisé.....	93
Figure III.24: Développement de précision de CNN 1.....	94
Figure III.25: Structure de CNN en 3 couches de convolution utilisé.....	95

Figure III.26: Développement de précision et la perte.....	96
Figure III.27: Structure générale de Alzhnet.....	97
Figure III.28: Développement de précision et la perte.....	97
Figure III.29: Résultat de teste d Alzhnet.....	98
Figure III.30: Résultat de teste d Alzhnet sur des image non traite.....	99
Figure III.31: Comparaison entre le DL et ML.....	101

Liste des tableaux :

Tableau III.1 : : Résultat de plusieurs métriques d'évaluation de chaque filtre sur des images de base de données.
Tableau III.2 : Résultat de PSNR de chaque ondelette sur la même image
Tableau III.3 : Résultat d'entropie de chaque ondelette sur la même image
Tableau III.4 : Résultat de paramètre d'évaluation sur le SYM16
Tableau III.5 : les valeurs des éléments de texture appliquée par le GLCM sur une image IRM
Tableau III.6 : la précision de classification obtenue par chaque taille de cellule
Tableau III.7 : la précision de classification obtenue par chaque taille de cellule
Tableau III.8 : la précision de classification obtenue par chaque taille de cellule
Tableau III.9 : la précision de classification obtenue par chaque taille de cellule
Tableau III.10 : les résultats de précision selon les éléments de texture utilisé
Tableau III.11: les résultats de précision de CNN1 sur les 3 stade de la maladie
Tableau III.12 : les résultats de précision de CNN2 sur les 3 stade de la maladie
Tableau III.13: les résultats de précision de CNN2 sur les 3 stade de la maladie

Liste des abréviations

AD : Alzheimer disease

APP : Aphasie primaire progressive

APNF : Aphasie primaire progressive

CN: Cas normal

CNN: Convontional neural network

DLFT : Dégénérescences lobaires fronto-temporales

DL: Deep learning

ENT: entropie de l'image

FTD : Dégénérescences fronto-temporales

FUS :Fused-in-sarcoma

GLCM : Gray level co-occurrence matrix

HOG : Histogramme des gradients oriente

IA : L'intelligence Artificielle

IATI : indice de qualité des données

KNN: K-nearest neighbors

LCR : Liquide céphalorachidien

LBP : Model binaire local

MND : maladies neurodégénératives

MA : Maladie d'Alzheimer

ML: Machine learning

MSE: erreur quadratique

MCI: Multi cognitive impairment.

PrP : La protéine du prion

PFNA : l'aphasie primaire progressive non fluente

PLPA : l'aphasie progressive logopénique

PSNR: peak signal noise ratio

SLA : La sclérose latérale amyotrophique

SNC : Système nerveux centrale

SD : démence sémantique

SYM : ondelettes des symlets

SVM: Support vector machine

SSIM: Image structural similarity

TOC : Le Trouble obsessionnel-compulsif

TDP: TAR DNA-binding protein 43

non fluente

TEP : Tomographie par Emission de Positons

TEP-FDG : Tomographie à Émission de Positons au Fluoro-désoxy-glucose

VIH : Virus de l'Immunodéficience Humaine

*‘Introduction
général’*

Introduction générale

La maladie d'Alzheimer (MA) est la pathologie la plus fréquente conduisant à la démence chez les personnes âgées et touche environ 47,5 millions de personnes dans le monde. L'un des objectifs actuels de la communauté scientifique est d'établir un diagnostic précoce, avant la déclaration des premiers symptômes cliniques de la maladie, afin d'anticiper la prise en charge et par conséquent d'améliorer la qualité de vie des malades.

La MA est une maladie neurodégénérative qui atteint un grand nombre de personnes nécessitant une prise en charge spécifique et donc une adaptation du système sanitaire et médico-social. Le diagnostic précoce permet d'anticiper les conséquences de la perte progressive des fonctions cognitives et ainsi de maintenir sa qualité de vie plus longtemps. Il permet aussi de faire le diagnostic d'autres maladies apparentées. Les centres de diagnostic spécialisés permettent de fiabiliser le diagnostic. Cette maladie a aussi un impact socio-économique, l'augmentation des coûts de l'examen complémentaire de la maladie d'Alzheimer est un problème difficile, comment peut-on définir ces coûts, et comment les mesurer, notamment lorsque les systèmes de prise en charge ou de remboursement varient, ou lorsque les données sont totalement inexistantes dans certains pays ? Le coût total de la maladie d'Alzheimer ou d'une maladie apparentée en Europe est estimé à 160,3 milliards d'euros en 2008 (1,3 % du produit intérieur brut 2008), dont 71,7 milliards en coûts directs (45 %) et 88,6 milliards (55 %) en coûts indirects. Les coûts annuels par personne atteinte de la maladie d'Alzheimer sont estimés à 22 194 € [54], dont 9 925 € en coûts directs et 12 270 € en coûts indirects. Pour la zone européenne, le poids de la maladie est estimé à 2,12 millions d'années de vie ajustées à l'incapacité (441 années de vie ajustées à l'incapacité pour 100 000 personnes). Ce poids est supérieur à celui du diabète. Donc pour diagnostiquer cette maladie avant le déclenchement ça nous a coûté cher, l'imagerie cérébrale est une partie importante dans l'exploration de la démence cérébrale, qui est la principale cause de la maladie d'Alzheimer. Elle cherche des signes positifs de démence neurodégénératives, comme une atrophie de localisation évocatrice, ou des lésions vasculaires. L'imagerie cérébrale est donc systématique pour toute démence d'installation récente. L'imagerie IRM contribue au diagnostic positif des démences neurodégénératives, et en particulier à celui de la maladie d'Alzheimer. L'analyse morphologique des structures encéphaliques permet de mettre en évidence des modifications visibles sous forme d'une atrophie focale ou d'anomalies de signal spécifiques de certaines démences dégénératives. L'IRM participe également aux

efforts d'identification des patients ayant un risque élevé de développer une maladie d'Alzheimer

Dans notre travail, nous avons appliqué les outils de l'intelligence artificielle pour la détection précoce de la maladie d'Alzheimer et pour cela, nous avons étudié les deux approches bien connues de l'intelligence artificielle que sont : l'apprentissage automatique et l'apprentissage profond. L'apprentissage automatique qui utilise des données extraites manuellement pour s'entraîner certain classifieur et trouver des résultats précis et se concentre sur le développement d'un programme informatique qui accède aux données, l'apprentissage profond qui passe par le déploiement d'un réseau de neurones artificiel.

L'apprentissage automatique se base sur le type de caractéristiques et le classifieur utiliser pour cela nous avons étudié l'impact des méthodes les plus utilisées dans la vision par ordinateur et la détection des objet tel que le HOG (Histogramme de Gradient Orienté) et le LBP (le Modèle Binaire Local), par la suite nous avons aussi extraire 12 paramètres de texture tel que Energie, entropie, contraste, homogénéité, corrélation, ombre, prominence , dissimilarité, moment différent inverse, somme entropie , somme variance , Deuxième moment angulaire. A la fin, dans la partie du classification, nous avons appliqué les deux très connues classifieur qui sont le SVM (support Vector Machine) et le KNN (K Nearest Neighbor) pour prend les meilleurs résultats.

L'apprentissage profond est un sous-ensemble du Machine Learning, ou apprentissage automatique, basé sur des réseaux neuronaux artificiels. Le processus d'apprentissage est qualifié de profond parce que la structure des réseaux neuronaux artificiels se compose de plusieurs couches d'entrée, de sortie et masquées. Chaque couche contient des unités qui transforment les données d'entrée en informations que la couche suivante peut utiliser une tâche prédictive spécifique. Grâce à cette structure, une machine est capable d'apprendre au travers de son propre traitement de données. Dans cette partie de notre travaille nous avons étudié l'impact de la complexité d'un model CNN et aussi la taille de la base de donne. Pour cella nous avons réalisée trois expérimentations. Dans les deux premières expérimentations nous avons proposée deux architectures de CNN : CNN1 et CNN2 respectivement. Par la suite, dans la troisième expérimentation nous avons augmenté la base de données appliquons le CNN2. Et nous avons étudié ces deux approches pour conclure la meilleure méthode qui donne des résultats valables.

Le but de notre travail est d'obtenir les meilleurs résultats de classification passons sur la comparaison entre les résultats des méthodes de classification KNN, SVM et CNN nous et avons tester plusieurs filtres tels que le filtrage par ondelette et le moyenne, le median, Wiener... afin de trouver meilleur type de filtrage.

Le mémoire est structuré en trois chapitres :

Le chapitre01 :

Concerne à l'aspect médicale du maladie Alzheimer et les éléments principale de système nerveux central

Le chapitre 02 : ~~qui~~ concerne les méthodes et les outils utilise dans l'algorithme que nous avons réalisé pour classifiez la maladie d'Alzheimer.

Le chapitre 03 :

Concerne les résultats de notre approche, avec les interprétations des ces résultats

Chapitre 01

'L'aspect médicale'

1. Introduction :

La maladie d'Alzheimer est une maladie neurodégénérescence qui représentée par une démence cérébrale, et grâce a la progression des technologie médicale les scientifiques ont réaliser un avancement dans la détection précoce de cette maladie, et l'exploration des maladies qui affectons le cerveau, donc le domaine du neurosciences connue une révolution scientifique.

L'objectif de ce chapitre est d'identifier la maladie qui nous s'intéresse la maladie d'Alzheimer, pour comprend profondément le mécanisme de la maladie d'Alzheimer. En premier place nous avons concentre sur la partie anatomique et la fonctionnalité du cerveau, et aussi pour mieux compréhension des stades de la maladie. En deuxième partie nous présentons les différent modalités de l'imagerie par résonance magnétique IRM qui fournit des images sur les coupes du cerveau présente les trois régions principales du cerveau et spécialement la matière grise qui sert a l'endroit de développent du maladie qu'on a besoin, enfin nous avons terminé par une conclusion.

2. Comprendre le cerveau [1]

Philosophiquement, le cerveau est l'organe qui sent, pense et opère. C'est donc l'organe qui donne un sens à l'existence.

Sociologiquement, le cerveau est le chef d'orchestre de l'ensemble du corps, il le gère ainsi que lui-même. Il est responsable de nos attitudes, et donc de nos interactions avec les autres individus qui forment la société.

Scientifiquement, le cerveau est une tâche immense car il recèle encore des mystères dans son fonctionnement naturel et pathologique et dans ses capacités d'adaptation. Il est aujourd'hui vital de percer les mécanismes de la genèse de nos capacités intellectuelles, de nos émotions, et des comportements moteurs qui en sont la conséquence.[1].

Enfin, la tâche médicale actuelle est d'appréhender le cerveau malade dans le contexte des maladies neurologiques (Alzheimer, Parkinson, SLA (La sclérose latérale amyotrophique), sclérose en plaques, épilepsie, etc.) ou psychiatriques (dépression, schizophrénie, autisme, TOC, etc.) en vue de développer les traitements de demain.

3. Système nerveux centrale SNC et ses éléments principaux

Le système nerveux central (SNC) comprend l'encéphale et la moelle épinière.

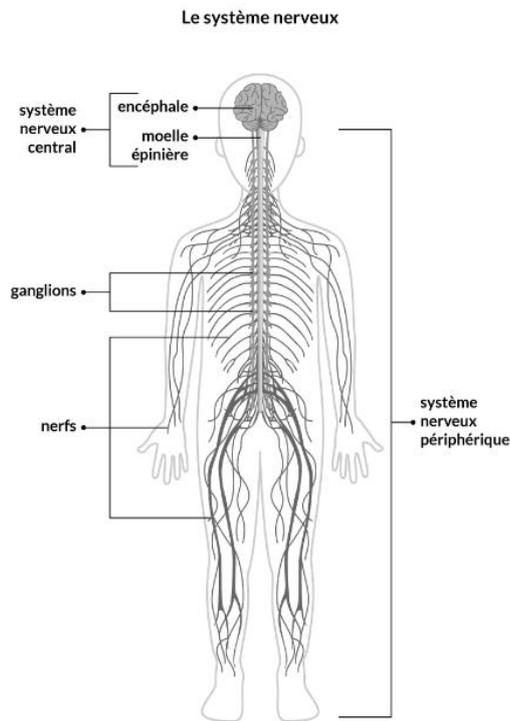


Figure I.1 : Le système nerveux [2].

3. 1. L'Encéphale

L'encéphale contrôle la majorité des fonctions du corps, notamment la perception, le mouvement, les sensations, la pensée, la parole et la mémoire. Et il est composé de 3 sections principales : le cerveau, le cervelet et le tronc cérébral.

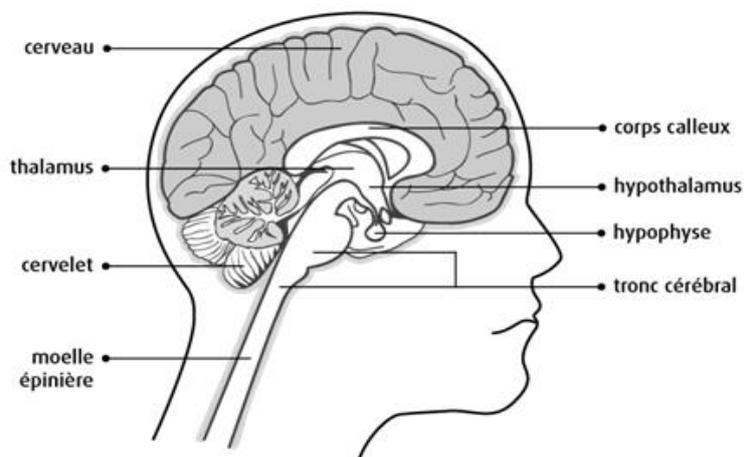


Figure I.2 : Les principaux composant du cerveau [3]

3. 2. Cerveau

Le cerveau est la plus grande section de l'encéphale (ce qui explique l'utilisation populaire du mot "cerveau" plutôt que "encéphale" dans le langage courant). Il est divisé en 2 parties appelées hémisphère cérébral gauche et hémisphère cérébral droit. Ces 2 hémisphères sont reliés entre eux par un pont de fibres nerveuses appelé le corps calleux. La moitié droite du cerveau (hémisphère droit) contrôle le côté gauche du corps et la moitié gauche du cerveau (hémisphère gauche) contrôle le côté droit du corps.

3. 2. 1. Cervelet

Le cervelet est situé sous le cerveau, dans la partie arrière de l'encéphale. Il est divisé en 2 parties, ou hémisphères, et responsable sur les mouvements, la posture, l'équilibre, les actions complexes. Il contient aussi de la substance grise et de la substance blanche.

➤ **La matière grise :**

Correspondant au corps des cellules nerveuses, recouvrent les hémisphères et le cervelet (cortex) et se trouvent également disséminés sous forme de noyaux dans la substance blanche.

➤ **La matière blanche :**

Correspondant aux fibres nerveuses (axones et dendrites) recouvertes d'une gaine de myéline, est située au-dessous du cortex cérébral et autour des noyaux gris.[A]

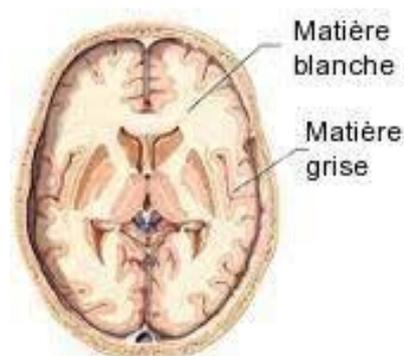


Figure I.3 : Un plan transversal représentant la substance grise et blanche [5]

3. 3. Tronc cérébral [6]

Le tronc cérébral est un faisceau de tissu nerveux situé à la base de l'encéphale. Il relie le cerveau et le cervelet à la moelle épinière, et il fait circuler des messages entre les autres parties de l'encéphale et le reste du corps et il contrôle la respiration, température du corps, pression artérielle, fréquence cardiaque, faim et soif, digestion des aliments [5].

3. 3. 1. Liquide céphalorachidien :

Le liquide céphalorachidien (LCR) est un liquide clair et aqueux qui entoure et protège le cerveau et la moelle épinière et leur sert de coussinet. Le LCR transporte aussi les éléments nutritifs du sang au cerveau et il en élimine les déchets. Le LCR circule dans des cavités appelées ventricules et à la surface du cerveau et de la moelle épinière [6].

3. 3. 2. La Moelle épinière [6]:

Se rattache à l'encéphale au niveau du tronc cérébral et est protégée par les vertèbres, qui forment la colonne vertébrale. Les nerfs émergent de la moelle épinière pour innerver les deux côtés du corps. La moelle épinière fait circuler les signaux nerveux, leur permettant d'aller et venir entre l'encéphale et les nerfs du reste du corps.

4. Cerveau au niveau cellulaire

Le neurone est une cellule, au même titre qu'une cellule du foie ou du cœur, mais sa tâche principale n'est pas la même, car il est principalement chargé de transmettre des informations sûres de longues distances.

Les neurones créent un réseau complexe de connexions, qui permet de rediriger les informations, en série ou en parallèle, dans différentes zones corticales. Les messages sont transférés sous deux formes : électriquement à l'intérieur du neurone et, plus couramment, chimiquement d'un neurone à l'autre.[7].

4. 1. L'architecture du neurone

Les informations d'entrée provenant des neurones en amont sont transmises par les dendrites. Elle quitte le neurone via l'axone pour être transférée aux neurones de sortie.

Un neurone maintient un contact avec de nombreuses autres cellules nerveuses ces contacts sont appelés des « synapses ». (Il y a 10.000 connexions pour une seule cellule nerveuse). Ces substances, appelées " neurotransmetteurs ", si elles sont libérées en plus grande quantité, elles vont entraîner des troubles divers.

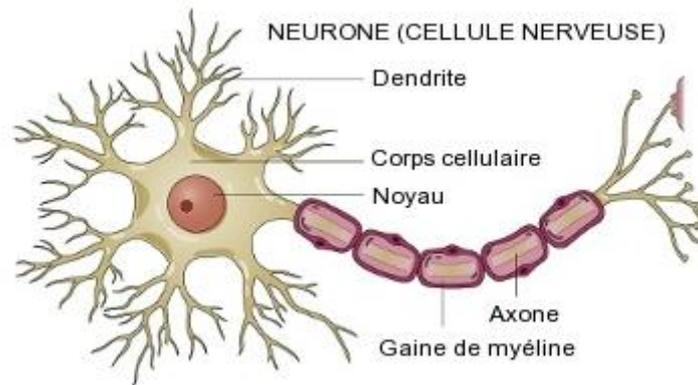


Figure I.4 : Cellule nerveuse [8]

4. 2. Les différents types de neurones

Pour une plus détails sur les neurones on peut distinguer les neurones selon ces types, et pour cela il existe les types suivants :

- **Distinction selon le nombre de neurites :**

- 1 neurite : neurone unipolaire
- 2 neurites : neurone bipolaire
- N neurites : neurone multipolaire.

- **Distinction anatomique (3 exemples) :**

- Les cellules pyramidales se trouvent dans la matière grise, ou cortex cérébral.
- Les neurones en étoiles se trouvent également dans le cortex cérébral.
- Les cellules de Purkinje sont des cellules aux ramifications très nombreuses et diffuses que l'on retrouve exclusivement dans le cervelet.

- **Distinction selon la fonction :**

- Les neurones sensoriels sont directement reliés aux organes des sens et sont responsables de faire transiter l'information sensorielle (on dit aussi «information ascendante ») vers le cerveau.

- Les motoneurones ou neurones moteurs se chargent de faire transiter les ordres provenant du cerveau (on dit également « information descendante ») en direction des muscles.
- Les interneurones sont représentés par tous les neurones qui ne sont ni sensoriels ni moteurs mais qui font la jonction entre ces deux types de neurones.

4. 3. Les cellules de soutien

L'architecture neuronale est renforcée par un ensemble de cellules qualifiées de connues par cellules gliales ou cellules de soutien, nous listons les principaux composants ci-dessous :

- **Les astrocytes** sont responsables du contrôle de la concentration de plusieurs substances dans le fluide cellulaire. en outre, ils jouent également un rôle important en aidant les neurones dans le processus d'information.
- **Les cellules de Schwann et les oligodendrocytes** sont des cellules uniques qui forment une couche isolante, constituée de myéline, qui entoure les fibres nerveuses. Cette couche de protection biologique optimise la vitesse à laquelle les données sont transférées le long de l'axone.
- **La microglie** est une sorte de cellule de nettoyage qui débarrasse l'espace extracellulaire de tous les déchets cellulaires qui l'entourent.[9].

5. Les Maladies Neurodégénératives

Les MND sont définies comme une neurodégénérescence. Le mot "neurodégénérescence" est composé du préfixe "neuro", qui désigne les cellules nerveuses, ou neurones, et du radical "dégénérescence", qui désigne le processus biologique de perte progressive des structures, qui indique des dysfonctionnements.

Autrement, une maladie neurodégénérative est une situation pathologique affectant les neurones, entraînant leur mort. Chacune de ces fonctions comme le langage, l'apprentissage, la prise de décision, la motricité, les sens... sont régis par un ensemble spécifique de neurones. Lorsque, dans une MND, un groupe de neurones est sélectivement détruit, cela provoque des symptômes très divers comme la perte de mémoire, une paralysie musculaire, des troubles mentaux, etc .[10].

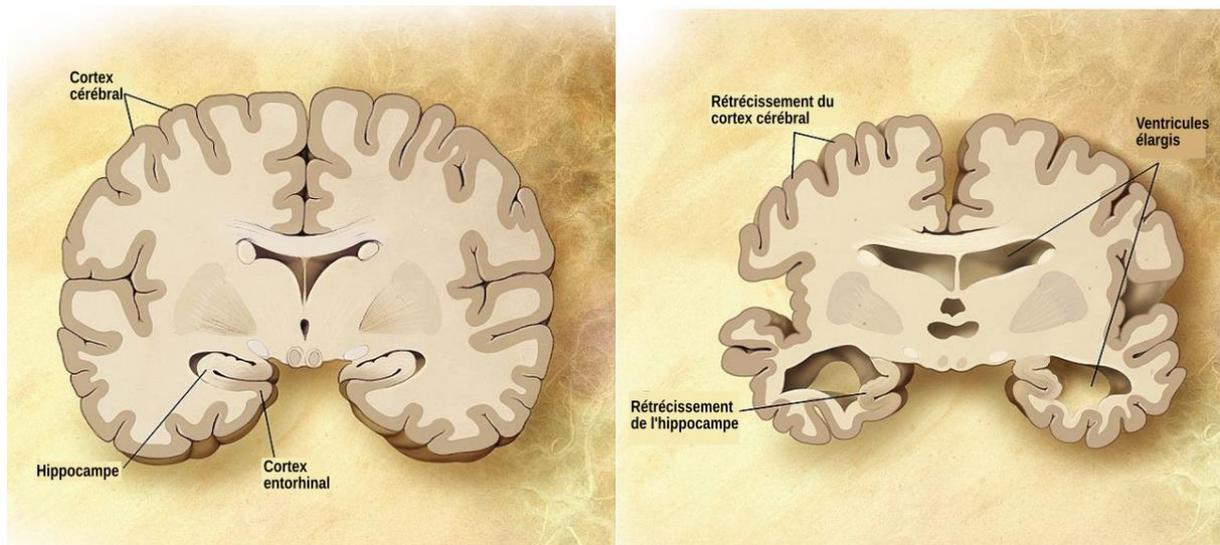


Figure I.5 : Comparaison d'un cerveau sain et d'un cerveau d'un patient atteint de la maladie d'Alzheimer [11]

La figure I.5 représente la démence cérébrale dans la maladie d'Alzheimer (cerveau droit). Les lésions neuronales entraînent un rétrécissement du cortex cérébral et de l'hippocampe et un élargissement des ventricules latéraux, ce qui provoque les différents symptômes [11].

5. 1. Mécanismes de mort des neurones MND

Les causes de l'apparition des MND ne sont pas bien connues, mais le mécanisme de la mort cellulaire a fait l'objet de nombreuses recherches chez l'homme et dans des échantillons animaux de ces pathologies.

Cependant, bon nombre des mécanismes proposés sont encore largement débattus au sein de la communauté scientifique. Cela est principalement dû à l'incroyable diversité des types de neurones affectés, qui peuvent différer en matière de morphologie, de localisation, de rôle ou de composition neurochimique.[12].

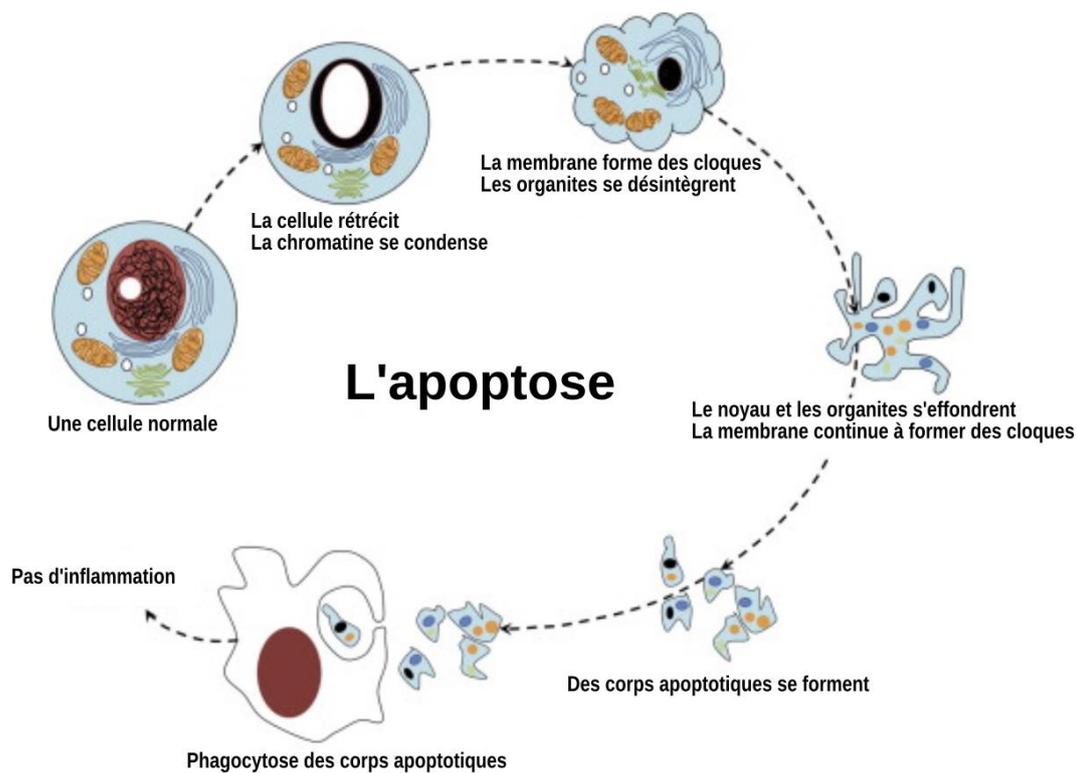


Figure I.6 : Mécanismes de mort de cellule neuronale [13]

Bien que ces troubles soient manifestement hétérogènes, il existe des mécanismes physiopathologiques communs. Le mécanisme le plus commun à presque toutes les MND est l'agrégation toxique des protéines.

Le génome humain code pour près de 30 000 protéines, qui ont chacune une forme unique ou plusieurs fonctions biologiques. Après leur synthèse, ces protéines prennent une forme native unique en 3D qui leur permet d'exécuter leurs fonctions biologiques.

Dans certaines circonstances, certaines protéines présentent une forme anormale en raison d'un mauvais repliement. Et dans des circonstances physiologiques, ces protéines mal repliées sont soit corrigées par des chaperons, soit dégradées et éliminées par le système ubiquitine-protéasome ou par le système phagosome-lysosome (autophagie).

Plusieurs changements tels que l'âge, les mutations génétiques, les modifications du pH ou de l'environnement intracellulaire, le stress oxydatif ou les métaux lourds, peuvent entraîner une augmentation de la concentration de protéines mal repliées. [14]

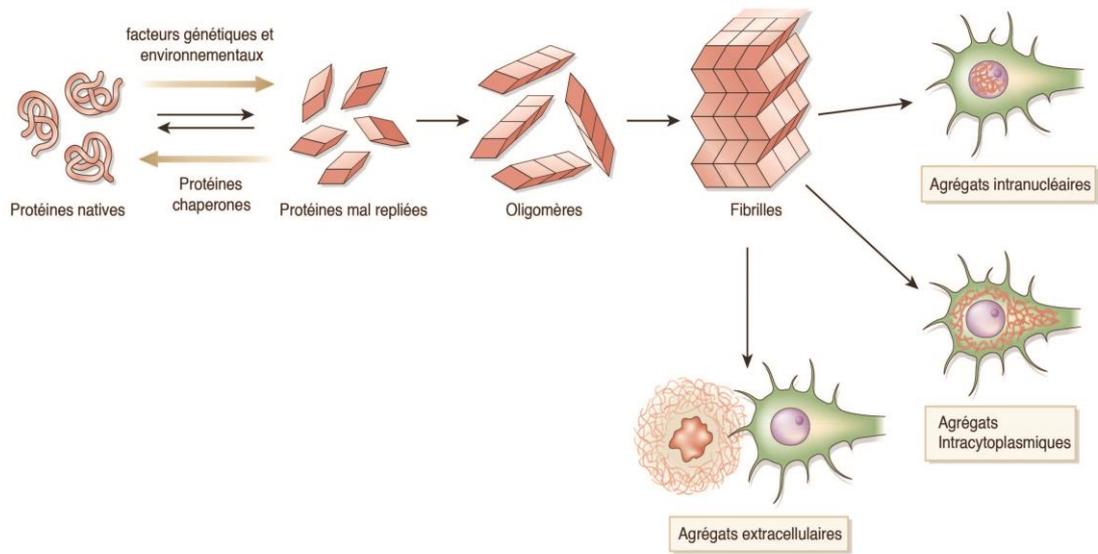


Figure I.7 : Mécanismes de formation des agrégats de protéines dans les MND [13]

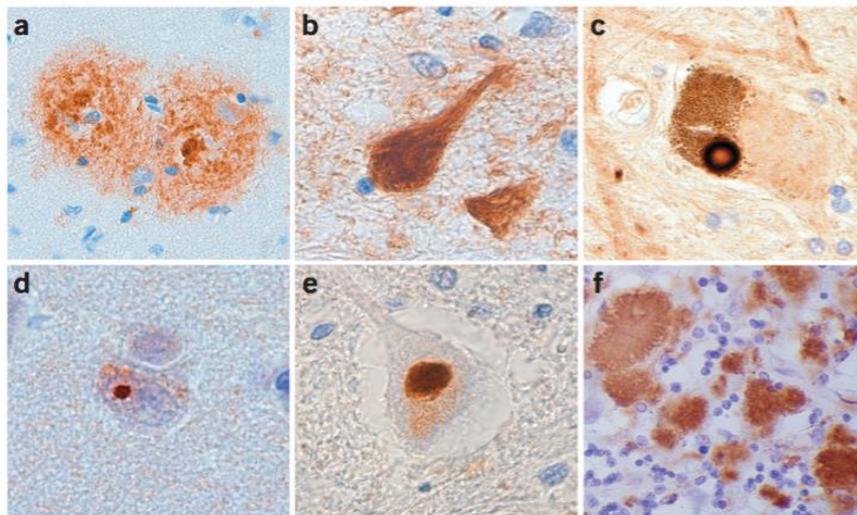


Figure I.8: Protéines agrégées dans les maladies neurodégénératives [13]

La **Figure I.8** représentée les agrégats des protéines sur les pathologies neurodégénératives, sachant que (a) présenté une plaque sénile dans le cortex d'un patient Alzheimer, et (b) nous montrons les agrégats de protéines Tau dans l'hippocampe d'un patient atteint de dégénérescence fronto-temporale, puis l'image (c) représente le corps de Lewy dans la substance noire d'un patient parkinsonien. Ensuite l'image (d) montre l'inclusion intranucléaire de polyglutamine dans le cortex d'un patient atteint de la chorée de Huntington, et l'image (e) représente l'inclusion d'ubiquitine dans la moelle épinière d'un

patient atteint de la sclérose latérale amyotrophique. Enfin, la dernière image (f) montre la protéine Prp dans le cervelet d'un patient atteint de la maladie de Creutzfeld-Jakob.

6. La maladie Alzheimer [22]

Le cerveau est composé de plusieurs parties qui ont des rôles précis, tout en restant très complémentaires les unes des autres.

6. 1. les lobes du cerveau

Les hémisphères cérébraux sont les plus larges parties du cerveau. Il existe deux : un hémisphère droit et un hémisphère gauche. On les connaît généralement le cerveau droit et cerveau gauche. Ces hémisphères contrôlent l'ensemble des fonctions mentales comme les mouvements volontaires, pensée, apprentissages, mémoire, etc. et chaque hémisphère est lui-même partagé en quatre zones appelées lobes et qui sont le lobe frontal, le lobe pariétal, le lobe temporal et le lobe occipital.

Les principales fonctions de chaque lobe sont les suivantes[1] :

- **Les lobes frontaux** : parole et langage, raisonnement, mémoire, prise de décision, personnalité, jugement, mouvements. Le lobe frontal droit gère les mouvements du côté gauche du corps, et inversement, le lobe frontal gauche gère les mouvements du côté droit.
- **Les lobes pariétaux** : lecture, repérage dans l'espace, sensibilité. Là aussi, le lobe pariétal droit gère la sensibilité du côté gauche du corps et réciproquement
- **Les lobes occipitaux** : vision
- **Les lobes temporaux** : langage, mémoire, émotions.

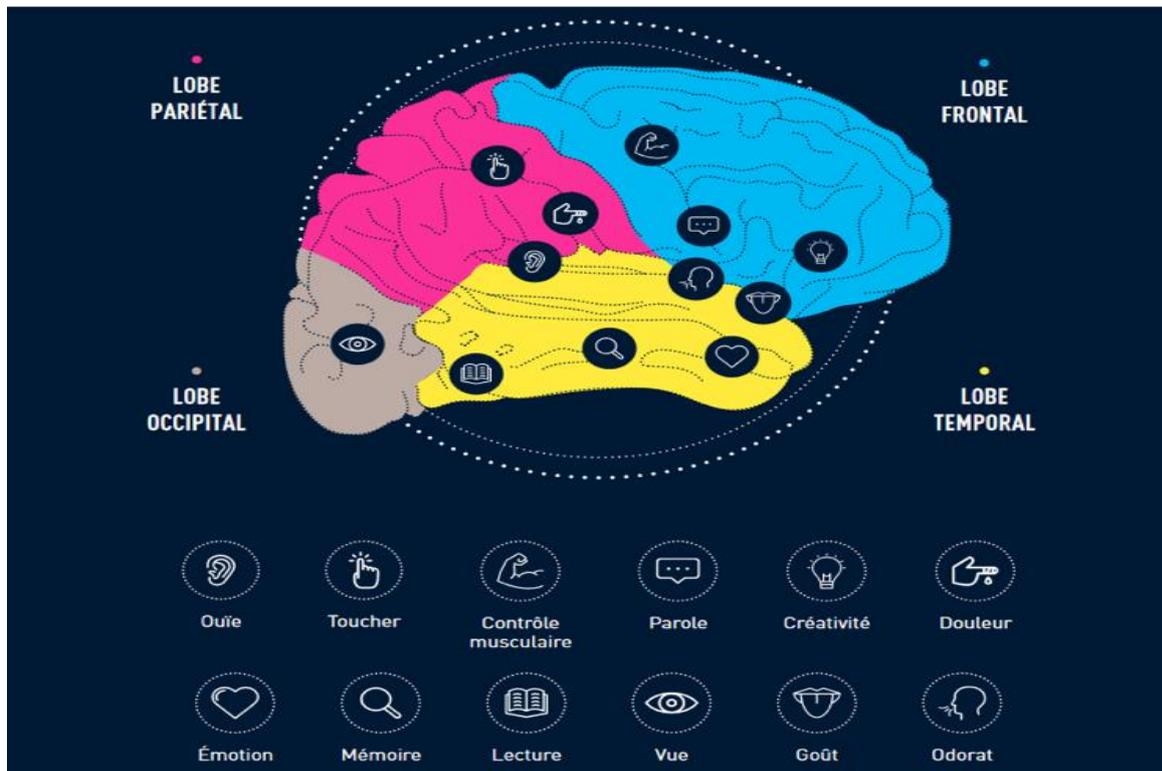


Figure 1.9: Les lobes cérébraux [16]

La maladie d'Alzheimer est une Dégénérescences lobaires fronto-temporales (DLFT), il existe plusieurs syndromes cliniques regroupés dans la DLFT :

- ✓ la variante comportementale (FTD),
- ✓ l'aphasie primaire progressive non fluente (PFNA),
- ✓ la démence sémantique (SD) et
- ✓ l'aphasie progressive logopénique (PLPA).

Il y a aussi Trois principaux types de lésions pathologiques sous-tendent les DLFT :

DLFT-tau, DLFT-TDP et DLFT-FUS.

Les inclusions de la protéine tau (Tubulin-associated Unit), ou tauopathies, sont observées dans près de 30 % des cas de DLFT (DLFT-TAU). Les inclusions de la protéine de liaison à l'ADN TAR 43 (TDP-43) [DLFT-TDP] sont les plus fréquentes, se produisant dans 60 % des cas. Elles sont classées en 4 sous-types, A à D, en fonction de leur densité et de leur localisation dans les couches corticales, les inclusions de la protéine FUS (Fused in Sarcoma) et des protéines de la famille FET (FUS, EWS, TAF15) sont minoritaires et retrouvées dans 10% des cas (DLFT-FUS).

TDP-43 (TAR DNA binding protein 43) et FUS (Fused in liposarcoma) sont deux protéines liées à la pathologie qui partagent des similitudes de structure et de fonction, impliquant un mécanisme mutuel de toxicité. TDP-43 et FUS sont toutes deux recrutées dans le GS (Les Granule de Stress) dans des conditions de stress. Le mécanisme de toxicité de FUS diffère de celui de TDP-43 et ne semble pas impliquer une perte de fonction dans la réponse au stress.[17].

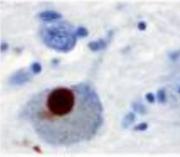
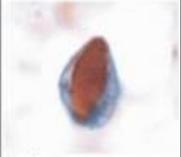
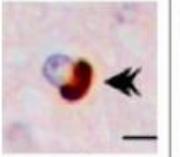
Type de démence	Démence d'Alzheimer	Démence à corps de Lewy et démence associée à la maladie de Parkinson	Démence frontotemporale		
Histopathologie	 Plaques séniles, amas neurofibrillaires	 Corps de Lewy	 Inclusions intranucléaires	 Amas cytoplasmiques d'ubiquitine positifs	 Amas cytoplasmiques et nucléaires
Dépôt de protéine	Bêta-amyloïde TAU	Alpha-synucléine	TAU	TDP43	FUS

Figure I.10: Caractéristiques moléculaires et histopathologiques des démences [18]

En raison de l'hétérogénéité pathologique, seules les études corrélationnelles portant sur les diagnostics peuvent être informatives, tandis que les études cliniques sont nécessairement discordantes.

Une étude autopsique [19] a démontré que les patients ayant un certain diagnostic de DLFT, tau négatif ou tau positif, par rapport aux patients atteints de la maladie d'Alzheimer, présentaient des concentrations de T-tau et un rapport T-tau/A β 1-42 nettement inférieurs et des dosages d'A β 1-42 nettement plus élevés, mais les niveaux de concentration dans cette étude, le rapport T-tau/A β -42 était plus discriminant que le dosage de T-tau par lui-même pour différencier les patients DLFT des patients atteints de la maladie d'Alzheimer, avec une sensibilité de 79 % et une spécificité de 97 %.

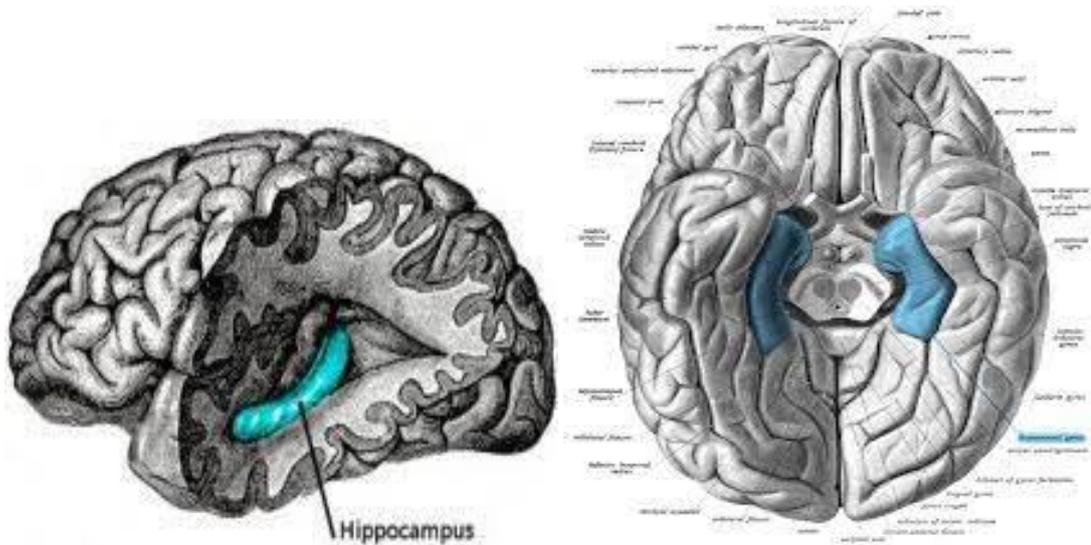


Figure 1.11: Hippocampe [20]

6. 1. Biomarqueurs

Nous suivons ici la proposition des groupes de travail.[21] du NIA-AA d'utiliser ce terme pour inclure les indications diagnostiques obtenues à partir de toutes les méthodes paracliniques, qu'elles soient biologiques au sens restreint du terme (c'est-à-dire l'analyse des fluides biologique) ou d'imagerie cérébrale.

Dans cette étude américaine.[21], les biomarqueurs sont classés en fonction de la physiopathologie supposée de la MA, de sorte que la mesure du peptide A bêta 1-42 et la recherche de la capture du ligand amyloïde dans les TEP sont classées collectivement comme marqueurs du processus pathogène d'accumulation amyloïde (supposé se produire avant la perte neuronale), la recherche d'une augmentation de la protéine tau dans le LCR est classée avec la détection par imagerie d'un hypométabolisme ou d'une atrophie du cortex cérébral, car ils reflèteraient tous la destruction synaptique et la perte neuronale (supposée suivre l'amylogénèse). bien que cette classification soit moins évidente, Dubois et al [3] suggéraient déjà clairement l'utilisation de ces biomarqueurs, même s'ils se limitaient à la maladie d'Alzheimer proprement dite "hippocampique".

Les marqueurs actuels, généralement utilisés en recherche clinique ou dans les centres universitaires, consistent principalement en la détermination dans le LCR du niveau du peptide amyloïde A bêta 1-42, qui est déterminé comme étant inférieur à la norme (l'A bêta 1-40 ou même de nombreux autres produits du clivage enzymatique de la protéine APP sont

rarement déterminés), et du niveau des protéines tau et phospho-tau, qui est déterminé comme étant supérieur à la norme. Comme mentionné précédemment, ces tests doivent encore être standardisés.

La méthode Innocent combine le test de l'isoforme 181 phospho-tau et l'indice IATI (rapport entre l'A bêta 1-42 mesurée et l'A bêta 1-42 estimée à partir de la valeur de tau) pour obtenir une mesure de la lyse neuronale et une mesure de l'amélogénèse pathologique.

Dans une importante étude prospective, la sensibilité et la spécificité de ces mesures étaient de l'ordre de 80 % et 70 %, respectivement, pour la prédiction de la conversion du MCI en MA.

En plus d'une standardisation généralisée de ces tests, il est probable que d'autres biomarqueurs explorant d'autres voies métaboliques, notamment ceux mesurés dans le plasma, seront développées. Les marqueurs génétiques sont résumés en clinique dans la recherche de mutations des gènes APP, préséniline 1 et 2, en fonction du contexte de suspicion de maladie d'Alzheimer familiale. Et le génotypage Apo E à la recherche d'un génotype epsilon 4 hétérozygotes où homozygote peut apporter des arguments en faveur de l'AD-ICD.[21].

7. Ana pathologie et Physiopathologie d'Alzheimer

Au stade avéré de la démence de la MA, il existe un consensus solide pour identifier les arguments positifs en faveur du diagnostic, même pour des degrés légers de démence (score CDR = 1, est une des échelles les plus utiles pour quantifier la sévérité des déficits cognitifs dans les démences).

La démence, au sens contemporain du terme, consiste, au terme d'un processus d'aggravation progressive, en une perte d'autonomie cognitive et d'adaptation du comportement suffisamment sévères pour affecter tous les aspects de la vie quotidienne du patient, vie professionnelle, familiale, sociale.

Les critères sont :[21] :

1. Les déficits cognitifs multiples :

- Altération de la mémoire
- Au moins l'une des perturbations cognitives suivantes : aphasie, apraxie, agnosie, perturbation des fonctions exécutives

2. Les déficits cognitifs décrits en A1 et A2 sont à l'origine :

D'une altération significative du fonctionnement social ou professionnel avec un déclin significatif par rapport au niveau de fonctionnement antérieur.

3. La progression est reconnue par une initiation progressive et un déclin continu de la cognition.

4. Les déficiences cognitives des critères A1 et A2 ne sont pas causées par les éléments suivants :

i. D'autres affections du système nerveux central susceptibles d'entraîner des troubles progressifs de la mémoire et d'autres capacités cognitives (par exemple, maladie cérébro-vasculaire, maladie de Parkinson, maladie de Huntington, démences fronto-temporales, hématome sous-dural, hydrocéphalie à pression normale, tumeur cérébrale, etc.)

ii. À des maladies systémiques susceptibles de provoquer une démence (par exemple, hypothyroïdie, carence en vitamine B12 ou en folates, carence en vitamine B3, hypercalcémie, neurosyphilis, infection par le VIH).

iii. À des problèmes liés à des substances (par exemple, l'alcool, les substances psychodysléptiques).

5. Les déficiences ne surviennent pas exclusivement au cours de l'évolution d'un trouble mental.

6. Le trouble n'est pas explicité davantage par un trouble de l'axe 1 (c'est-à-dire principalement : trouble dépressif majeur, psychoses délirantes telles que la schizophrénie). Ces caractéristiques diagnostiques largement utilisées sont néanmoins problématiques, notamment l'affirmation selon laquelle un trouble de la mémoire est une composante obligatoire du diagnostic de la MA, qui ne tient pas compte de l'hétérogénéité des manifestations cliniques de la maladie.

7. 1. Anatomopathologie

La MA occupe une place très importante pour la détermination de leur diagnostic, l'examen neuropathologique pose également des problèmes importants, qui apparaissent dès

que l'on souhaite aller au-delà d'une évaluation qualitative de la présence des lésions caractéristiques de la maladie (plaques séniles, dégénérescence neuro-fibrillaire et autres caractéristiques associées) et quantifier les lésions, ainsi que les immunomarquages spécifiques, et cartographier ces différents indicateurs et leur " progression " à travers un ensemble de cas classés en fonction de la sévérité de la maladie.

Le document de consensus neuropathologique le plus récent a été publié il y a longtemps (1997) et un travail de consensus récemment publié (janvier 2012) par les groupes de travail du NIA AA offre un parallèle à l'approche clinique et de bio-imagerie présentée dans les documents publiés en 2011. Il est utile de noter que, comme pour l'imagerie TEP amyloïde, la neuropathologie réalisée sur de grandes séries de cas a constamment révélé le paradoxe de l'identification (en particulier pour les plaques séniles et la charge amyloïde) de patients présentant ces anomalies et pas encore de signes cliniques de la maladie. Cette incohérence a été résolue par l'hypothèse - non encore confirmée - que ces cas correspondaient à des patients en devenir, a conduit les NIA-AA Workgroups à élaborer un système taxonomique différent qui distingue entre :

- les données relatives à l'« AD-C » c'est-à-dire à la maladie d'Alzheimer
- en un état clinique impliquant des troubles cognitifs objectivement identifiables
- celles relatives à l'« AD-P », c'est-à-dire la maladie d'Alzheimer étudiée en termes de processus physiopathologiques : amyloïdogenèse, lésions neuronales, neuro-inflammation, stress oxydatif, etc.

8. Diagnostic de la maladie d'Alzheimer [22]

Le diagnostic précoce est une avancée significative dont les patients sont les premiers bénéficiaires. Il permettra en effet d'appliquer dans les meilleurs délais les traitements médicamenteux en cours ainsi que tous les conseils préventifs de prévention.

Faire un diagnostic précoce, en revanche, vous permettra de mieux stimuler vos capacités cognitives et mémorielles. Elle permet également à la personne malade d'anticiper et de prendre des décisions pour l'avenir tout en conservant toutes ses capacités de discernement et de décision.

Néanmoins, un patient sur deux ignore qu'il est atteint de la maladie et ne le saura qu'à un stade plus avancé.

En conséquence, environ un million de personnes n'ont pas accès à des soins adaptés. Pour les malades, cela a des conséquences considérables.

Néanmoins, si elle est diagnostiquée suffisamment tôt, la progression de la maladie peut être ralentie avec le bon traitement. Si vous ou un membre de votre famille présentez de nombreux symptômes, il est fortement recommandé de consulter un médecin. Mais qui est-ce qui tourne ? Plusieurs professionnels de la santé sont à votre disposition pour vous guider dans cette « voie vers le diagnostic ».

8. 1. Les examens à effectuer pour poser un diagnostic

Avant les années 2000, le diagnostic clinique de la maladie d'Alzheimer était un diagnostic d'exclusion : il était posé après élimination des autres maladies neurologiques ou d'autres affections. Depuis 2007, il existe des tests neuropsychologiques capables de détecter de façon précoce les premiers troubles de la mémoire de la maladie d'Alzheimer.

i. Les Tests Cliniques

Les tests cliniques regroupent les tests de mémoire et les tests neuropsychologiques. Ils sont respectivement effectués par le neurologue et le neuropsychologue. Ces tests permettent de détecter de façon précoce les premiers troubles de la mémoire de la maladie d'Alzheimer. Ils permettent d'évaluer les différentes fonctions cognitives comme la mémoire, le langage, la motricité ou encore l'attention. Menés lors des consultations mémoire, ils sont indispensables pour repérer et diagnostiquer la maladie. Les résultats de ces tests sont confrontés aux données médicales issues des examens biologiques (tests paracliniques).

ii. Les Tests Paracliniques

Depuis 2013, les tests biologiques sont inclus dans le parcours diagnostique de la maladie d'Alzheimer, ils doivent être cumulativement compatibles pour conclure au diagnostic de la maladie d'Alzheimer et cela même à un stade précoce.

Les médecins utilisent l'imagerie cérébrale avec les images fournies par l'IRM et ils se focalisent sur :

- La région de l'hippocampe
- L'atrophie du lobe temporal médian
- L'amygdale

NOTE : l'amygdale c'est la région essentielle pour ressentir et percevoir certaines émotions.

9. L'imagerie par Résonance magnétique IRM

La maladie d'Alzheimer est un problème de santé publique majeur en raison du nombre croissant de cas dans les pays occidentaux dont la population est vieillissante. Il est donc crucial de pouvoir détecter la maladie le plus tôt possible. De nombreuses études ont prouvé que l'imagerie par résonance magnétique (IRM) permet d'identifier les dommages cérébraux, notamment dans les structures temporales médianes les plus touchées par la maladie, comme l'hippocampe et le cortex entorhinal.

Ces marqueurs sont liés à la progression de la maladie. Chez les patients souffrant de troubles de la mémoire, ils permettent de prédire la progression de la maladie d'Alzheimer. S'il n'existe toujours pas de traitement curatif de la maladie d'Alzheimer, de nombreux essais sont menés pour évaluer de nouvelles stratégies thérapeutiques. Ces traitements seront d'autant plus utiles qu'ils seront administrés tôt et dans des populations bien sélectionnées, ce qui implique la mise en place d'outils de diagnostic précoce et de suivi appropriés.

L'IRM structurelle montre que l'atrophie liée à la maladie d'Alzheimer est une préoccupation majeure pour le patient. Cette atrophie est considérée comme un marqueur de la maladie d'Alzheimer et de sa progression. Elle est liée à la neurodégénérescence. Sa localisation est corrélée à celle de la pathologie tau et aux déficits neuropsychologiques.

L'atrophie débute dans les régions temporales médianes, en particulier le cortex entorhinal, puis s'étend selon un schéma caractéristique aux régions temporales antérieures et latérales, limbiques et associatives temporo-pariétales et frontales.

L'atrophie est corrélée à des déficits cognitifs. L'implication de la région temporale médiane (voie perforante, cortex entorhinal, hippocampe et cortex cingulaire postérieur) est corrélée à des déficits de mémoire précoces. L'atrophie temporale, frontale et pariétale est associée à l'apparition de troubles du comportement plus importants et constitue un signe de démence.[23].

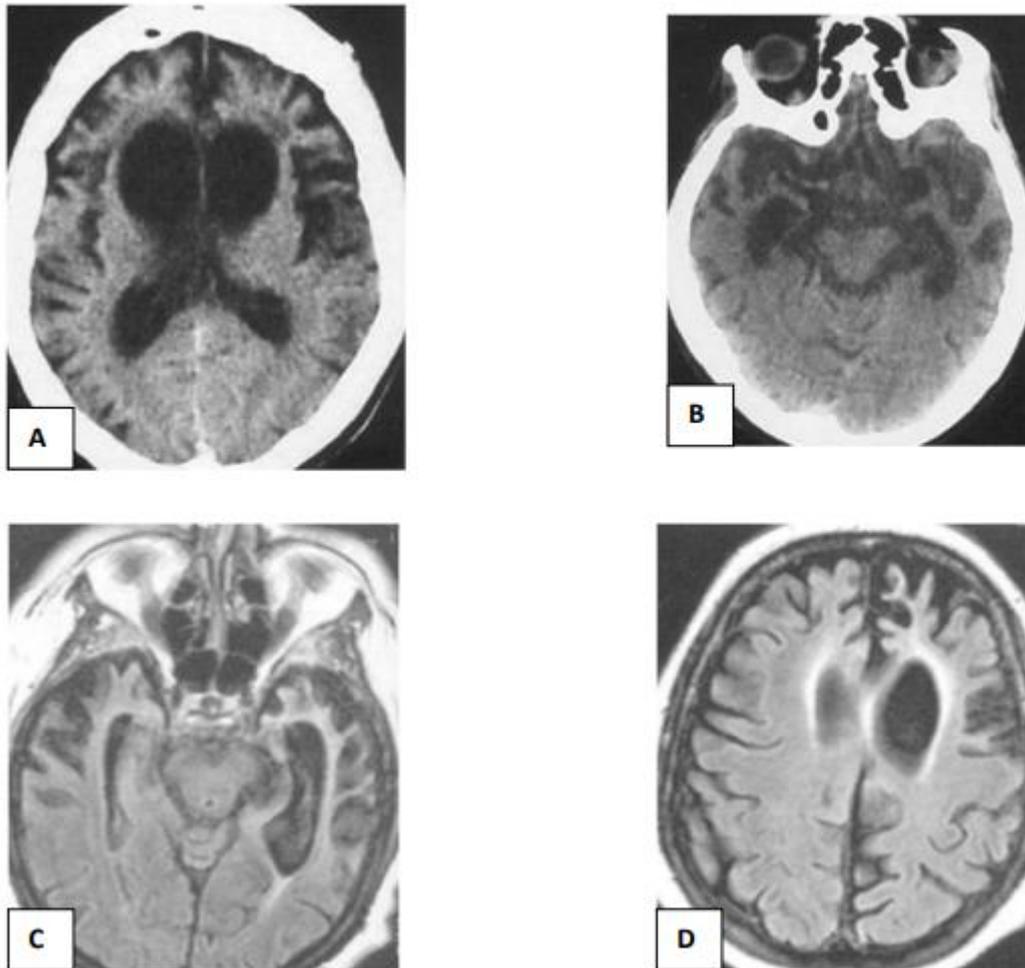


Figure I.12: Les coupes IRM du cerveau [24]

la Figure I.12 représente en A et B le TDM d'une atrophie fronto-temporale. en C et D image IRM en pondération T1. Notez l'atrophie corticale siégeant au niveau des lobes frontaux droit et gauche et fosse temporales internes droite et gauche.

Nous remarquons que les images TDM ne donne pas la clarté suffisante que celle qui fournies par l'IRM, et c'est pour ca nous choisissons de travailler sur les images IRM à cause de la quantité d'information exister dans ces images.

10. La mesurer de l'atrophie hippocampique en routine clinique

L'atrophie temporale médiane est retrouvée de manière significative et très précoce dans la maladie d'Alzheimer. Cette atrophie a une valeur diagnostique et pronostique chez les patients présentant des troubles de la mémoire. La sévérité de l'atteinte temporale médiane peut être évaluée visuellement. Des échelles telles que l'échelle de Scheltens peuvent être utilisées. Cette échelle est basée sur trois éléments évalués sur une coupe

coronale : la taille de l'hippocampe, l'expansion de la corne temporale ventriculaire et l'expansion de la fissure choroïdienne.

10. 1. Les différentes séquences de l'IRM

i. La séquence T1

La séquence volumique tridimensionnelle pondérée en T1 nous permettra de chercher et de préciser l'atrophie cérébrale. en raison, de la nette prévalence épidémiologique de la maladie d'Alzheimer, les coupes dans le plan coronal perpendiculaire au grand axe des hippocampes sont indispensables. L'acquisition volumétrique présente de multiples avantages qui la font préférer aux séquences coronales 2D. Elle permet de corriger une éventuelle asymétrie de position, ce qui permet d'évaluer et de quantifier son importance dans l'atrophie de l'hippocampe. Les coupes sagittales permettront l'étude du gradient antéro-postérieur de l'atrophie dans le cadre d'une démence fronto-temporale ou d'une atrophie corticale postérieure. Elles permettent la volumétrie de l'hippocampe (manuelle ou à l'aide de logiciels spécialisés). Enfin, le volume T1 semble supérieur pour la détection des lésions lacunaires, en particulier dans les ganglions de la base. L'enregistrement sur un support informatique permettra d'évaluer l'évolution de l'atrophie sur des coupes identiques et d'améliorer la qualité de la comparaison, principalement visuelle, des changements.[25].

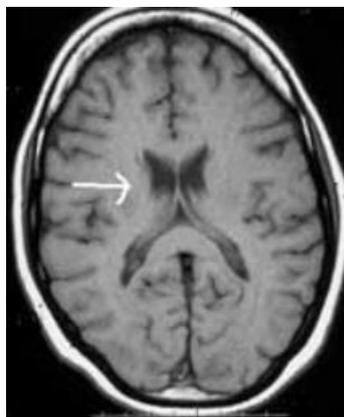


Figure 1.13: coupe axiale pondération T1 de liquide du système ventriculaire (flèche) est hypo intense. [26]

ii. La séquence T2

La séquence d'écho de gradient T2 axial (T2*) est effectuée pour chercher des micro-saignements cérébraux. Ils sont des indicateurs de la sévérité de la microangiopathie et sont plus souvent présents chez les sujets hypertendus. Les microbleeds cérébraux pourraient être

un indicateur négatif de la pathologie vasculaire, mais leur valeur diagnostique et prédictive reste controversée. Le lien entre la présence de micro-saignements et le déclin cognitif a été démontré chez des sujets avec et sans pathologie neurologique. La présence de micro-saignements n'exclut pas le diagnostic de la maladie d'Alzheimer, mais peut également suggérer une angiopathie amyloïde.

La séquence coronale pondérée en T2 en coupes fines perpendiculaires au plan des hippocampes peut être utilisée. Elle peut permettre de chercher des anomalies de signal dans le lobe temporal médian, faisant suspecter une origine vasculaire ou infectieuse, non dégénérative, des troubles cognitifs.

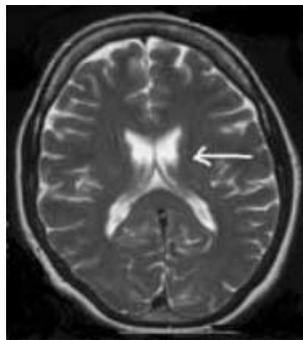


Figure 1.14: coupe axiale pondération T2 de liquide du système ventriculaire (flèche) est hypo intense. [27]

iii. La séquence FLAIR

La séquence FLAIR axiale détermine la possibilité de présence d'anomalies du signal de la substance blanche et/ou de lésions ischémiques.[28].

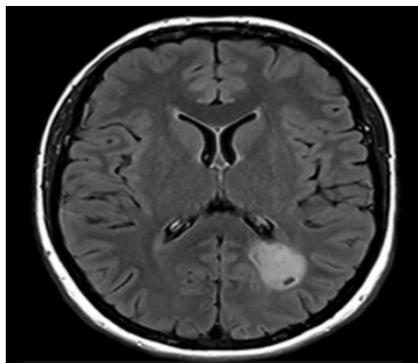


Figure I.15: séquence FLAIR montrant une lésion périventriculaire [29]

11. Imagerie cérébrale [30]

Sur la base de l'imagerie structurale par IRM, l'atrophie de certaines zones focales telles que les cortex temporal et pariétal dans leurs régions médiane et latérale sont des biomarqueurs utiles pour diagnostiquer la démence liée à la maladie d'Alzheimer et pour prédire la transition de la maladie d'Alzheimer et des affections connexes à la démence.

Il serait bénéfique que des méthodes utilisables dans la pratique quotidienne de la neuroradiologie puissent être rapidement développées pour fournir des valeurs quantitatives individuelles conformes aux valeurs normatives (au moins pour l'âge).

Un pas dans cette direction est franchi par les scores semi-quantitatifs proposés par Scheltens. De nombreuses autres métriques dans d'autres modes d'IRM offrent des possibilités d'élaboration de nouveaux biomarqueurs, soit du stade de l'atrophie, soit de stades plus en amont dans le processus physiopathologique.

12. Le Cerveau & l'intelligence Artificielle IA

Dans le but de développer de nouvelles approches mathématiques et informatiques pour étudier l'anatomie du cerveau humain et ses réseaux fonctionnels. La nécessité de formaliser les données d'imagerie brutes dans des modèles tels que des modèles géométriques de structure cérébrale, des modèles de population et des graphiques de connectivité est désormais essentielle pour définir de nouveaux biomarqueurs de pathologie, étudier les corrélations génétiques-symptômes et définir les réponses de la fonction cérébrale.

La vision par ordinateur permet à la machine de connaître précisément le contenu d'une image, puis de la classer automatiquement en fonction de son contenu, de sa couleur ou autre caractéristique. A l'aide des algorithmes qui sont capables d'optimiser leurs calculs au cours de leur traitement.

Il existe plusieurs points de vue opposés sur l'objectif ultime de l'IA. Certains veulent la domestiquer pour permettre de trouver des solutions à des problèmes réels, comme la détection des tumeurs sur des images IRM ou encore aider les chirurgiens à effectuer des interventions de grande précision.

D'autres y voient un moyen de recréer l'intelligence humaine pour mieux comprendre et corriger certains dysfonctionnements.

Enfin, d'autres souhaitent que l'IA permette d'augmenter les capacités cognitives de notre espèce. C'est notamment l'utopie transhumaniste, à laquelle adhère notamment l'entrepreneur Elon Musk. Le fondateur de Tesla (voitures) et de SpaceX (vols spatiaux) a également créé la société Neuralink, qui vise à atteindre une "intelligence augmentée" grâce à des implants intracérébraux. Nous sommes encore très loin, même si les premiers implants montrent des avancées intéressantes.[31].

13. Conclusion

Dans ce chapitre nous avons étudié l'anatomie de cerveau, nous avons présenté tout ce qui concerne l'anatomie du cerveau et le mécanisme physiopathologique des pathologies neurodégénératives en général et de la maladie d'Alzheimer en particulier pour être sûr d'avoir couvert la façon dont nous allons traiter et guider notre travail.

Cette maladie qui affecte les neurones du cerveau représentée par une démence, et nous avons décrit la procédure pathologique de cette maladie et le mécanisme de mort des neurones plus précisément et comment cette démence se propage dans le cerveau en générale et dans les neurones en particulier.

Dans le chapitre suivant de notre travail, nous passons par notre effort privé de notre propre approche et nous introduisons la méthodologie que nous avons adoptée pour la détection précoce des maladies neurodégénératives et tout ça pour mieux développer et des plus méthodes efficaces qui peuvent faire la différence au futur dans ce domaine.

Chapitre n°2 :

'Outils et Méthodes'

1. Introduction :

L'étude de la maladie d'Alzheimer base sur les images IRM cérébrale parce que les séquences appliquent dans IRM dont une résolution valable.

Dans ce chapitre, premièrement nous avons donne une vision historique sur l'avancement des chercheurs à propos de la classification de la maladie d'Alzheimer on va parler d'un historique à propos de la classification de la maladie d'Alzheimer. Deuxièmes nous avons citer les définitions des modalités utilisés dans l'algorithme que nous avons proposés. Selon ces modalités nous avons définir des méthodes des filtrage (réduction de bruit, isolation de cerveau, segmentation) et les modalités de classification (caractérisation et apprentissage)

2. Etat de l'art :

En 2022 :

B. Nicholas et al[30].ont utilisées la comparaison entre les différents descripteurs par des extracteurs de caractéristiques qui sont LBP (LocalBinaire Pattern), HOG (l'Histogramme de Gradient Orienté), LBDP (Local Bit Plane Decoded Pattern), LWP (Local Wavelet Pattern)avec des classificateurs KNN (K-Nearest Neighbour),et ils ont trouvé que la combinaison de KNN avec LBP donne a précision maximale de 91,21%.

En 2021

Murugan, S et al .[31]ont utilise le réseaux de neurones convolutif pour créer un model deep learning dédié au détection des caractéristiques spécifique de la maladie d'Alzheimer mettant en considération les stades de la maladie d'Alzheimer, leur neural network appelée DEMNET ou DEMentia NETwork a réalisé une précision de 95.23 % et une AUC (Area Under curve) de 97%

En 2020

Jinwang Feng et al[32]. ont utilisées la méthode qui est basée sur le caractéristiques d'énergie de transformation en ondelettes de l'image sIRM(Structurelle IRM), et par le classifieur NN pour identifier les patients AD et MCI à partir de sujets HC(témoins sains) en extrayant la caractéristique d'énergie de transformation des ondelettes WTEF(Wavelet

Transform Energie Filtre) de l'image sMRI. AD-WTEF transforme d'abord chaque balayage de l'image sMRI prétraitée par ondelettes pour obtenir ses sous-bandes directionnelles de même taille à différents niveaux de transformation. Et puis, sur la base de l'atlas d'étiquetage automatique anatomique (AAL), AD-WTEF construit un nouveau masque cérébral pour segmenter les sous-bandes dans la même direction et le même niveau de transformation en différentes régions énergétiques d'intérêt (EROI). Enfin, le classificateur voisin le plus proche (NN) est sélectionné et utilisé pour l'identification AD, et cette méthode donne une spécificité qui atteint 93,75 % et une précision de 93,93%.

En 2019

S.K, LSK et A. Khanna et al[34]., ont proposées 3 modules de détection qui contiennent le prétraitement l'extraction de caractéristiques, la sélection des fonctionnalités à l'aide de GGWO (Le Groupe Grey Wolf Optimisation) pour classer les maladies. Dans l'étape du pré-traitement ils ont choisi la région d'intérêt et le Filtrage gaussien associé. La 2ème étape d'extraction de caractéristiques concerne les Caractéristiques des textures (Matrice de cooccurrence de niveaux de gris, Matrice de longueur de plage de niveaux de gris), et la fonctionnalités d'histogramme, fonctions de transformation de caractéristiques invariantes à l'échelle et fonctionnalités de modèle binaire local, ils ont commencé dans l'étape 3 par l'Initialisation de l'ensemble de fonctionnalités puis fixer le modèle de regroupement et donc établir une fonction objectif, pour la mise à jour de la sélection de fonctionnalités y a 2 choses qui sont sélectionnées les vecteurs de coefficients et le comportement de chasse. Le modèle de classement appliqué est l'Arbre de décision (Entropie), et K plus proche voisin (KNN) et aussi le Réseau neuronal convolutif (CNN) (Processus de convolution) et comme des résultats ils ont obtenus une précision d'exécution 96,23%, une sensibilité 94,55% et une spécificité 96,23%

En 2018

T. Altaf et al[35]., ont proposé une méthode de 3 parties principaux modules sont le prétraitement, l'extraction des caractéristiques et la classification des maladies. Après le prétraitement ils ont extrait les caractéristiques ils ont basées sur la matrice de cooccurrence en niveaux de gris (GLCM) (Entropie, Homogénéité, Corrélation) Et la transformation de caractéristiques invariantes à l'échelle (SIFT), Afin de appliquer le modèle binaire local (LBP) ils ont calculer l'Histogramme de gradient orienté (HOGs) Et

le sac de mots .Pour la classification ils ont fondé sur plusieurs critères sachant que SVM(Séparation Vaste Merge) ,KNN, et L'Arbre de décision et l'ensemble La, et leur résultats ont atteints une Précision de 79,8%, Spécificité 80% et une Sensibilité 92%.

3. Méthodes et Outils :

3. 1. Prétraitement

3. 1. 1. Filtrage par ondelettes :

Pour des applications classiques telles que la compression d'images, l'élimination de bruit ou les méthodes de réduction de dimensionnalité Catégorique, l'outil utilisé est la décomposition en ondelettes de la fonction (Base orthogonale ou base bi orthogonale). Pour l'analyse d'images et la Caractérisation de la structure de l'image (contours, textures), les transformations redondantes apportent l'avantage d'informations plus faciles à analyser et à Interpréter.

1. Définition des ondelettes :

Les ondelettes sont des fonction développés par les mathématicien, des physicien quantique et des ingénieurs électriciens basent sur l'idée de l'analyse d'échelé, elles sont fournis pour certain exigence mathématique et la représentation des donnes, on compte plusieurs types des ondelettes , et le type qu'on a utilisé base sur le traitement d'image.

2. Ondelettes orthogonales:

On dit des ondelettes sont orthogonales lorsque les transformées en ondelettes discrètes sont des ondelettes orthogonales. En d'autres termes, la transformée en ondelettes inverse est la compagne de la transformée en ondelettes. Une personne peut en obtenir un lorsque les conditions s'affaiblissent. [36]

3. Condition d'admissibilité [36]:

Soit $\psi \in L^1 \cap L^2$ vérifiant la condition d'admissibilité suivante :

$$\int_0^{+\infty} \frac{|\hat{\psi}(w)|^2}{|w|} dw = \int_{-\infty}^0 \frac{|\hat{\psi}(w)|^2}{|w|} dw < +\infty \quad (1)$$

Notons que la condition d'admissibilité implique en particulier que $\widehat{\psi}(0) = 0$ donc $\int_{\mathbb{R}} \psi(t) dt = 0$. A cause de la difficulté à utiliser de cette condition, on va utiliser une condition suffisante d'admissibilité beaucoup plus simple à vérifier : ψ réelle, $\psi \in L^1 \cap L^2$, $t\psi(t) \in L^1$ et $\int_{\mathbb{R}} \psi(t) dt = 0$ [37]

4. La transformée en ondelette continue directionnelle [37] :

La transformée en ondelette continue directionnelle, en dimension 2 Pour une fonction donnée, cette transformation rend les coefficients correspondants dépendants de la position \mathbf{b} , de l'échelle a et de la direction α . Nous supposons plus tard que toutes les ondelettes sont des fonctions réelles.

i. La décomposition en ondelette [37]:

La décomposition en ondelettes d'une fonction $f \in L^2(\mathbb{R}^2)$ contre une ondelette d'analyse $g \in L^2(\mathbb{R}^2)$ est définie pour tout $a > 0$, $\mathbf{b} \in \mathbb{R}^2$, $\alpha \in$

$[0, 2\pi]$, par

$$W_g f(a, \mathbf{b}, \alpha) = \iint_{\mathbb{R}^2} f(\mathbf{x}) \frac{1}{a} g\left(r_{-\alpha}\left(\frac{\mathbf{x}-\mathbf{b}}{a}\right)\right) d\mathbf{x} \quad (2)$$

où $r_{-\alpha}$ désigne la rotation d'angle $-\alpha$ dans \mathbb{R}^2 .

ii. La reconstruction en ondelette [37]:

L'ondelette synthétique h permet alors de reconstruire f à partir de ses coefficients d'ondelettes $W_g f(a, \mathbf{b}, \alpha)$, fonction de $L^2(\mathbb{R}^2)$ vérifiant la condition d'acceptabilité :

$$C_{gh} = \iint_{\mathbb{R}^2} \frac{\hat{g}(\mathbf{k})\hat{h}(\mathbf{k})}{\|\mathbf{k}\|^2} d\mathbf{k} < +\infty \quad (3)$$

On obtient alors la formule de synthèse contre l'ondelette de reconstruction h :

$$f(\mathbf{x}) = \frac{1}{C_{gh}} \int_0^{+\infty} \iint_{\mathbb{R}^2} \int_0^{2\pi} W_g f(a, \mathbf{b}, \alpha) \frac{1}{a} h\left(r - \alpha \left(\frac{\mathbf{x}-\mathbf{b}}{a}\right)\right) \frac{da}{a^3} \mathbf{b} d\alpha \quad (4)$$

Dans le cas où l'ondelette d'analyse est auto-admissible, i.e.

Vérifie : $C_{gg} = \iint_{\mathbb{R}^2} \frac{|\hat{\theta}(\mathbf{k})|^2}{\|\mathbf{k}\|^2} \mathbf{d}\mathbf{k} < +\infty$, on a également la conservation de l'énergie :

$$\iint_{\mathbb{R}^2} |f(\mathbf{x})|^2 \mathbf{d}\mathbf{x} = \frac{1}{C_{gg}} \int_0^{+\infty} \iint_{\mathbb{R}^2} \int_0^{2\pi} |W_g f(a, \mathbf{b}, \alpha)|^2 \frac{da}{a^3} \mathbf{b} d\alpha \quad (5)$$

Cela signifie que la transformée en ondelettes continue est équidistante de $L^2(\mathbb{R}^2)$ dans $L^2\left(\mathbb{R}^+ \times \mathbb{R}^2 \times [0, 2\pi], \frac{da}{a^3} \mathbf{b} d\alpha\right)$. Notez que la fonction g , à la fois intégrable et au carré, est une ondelette auto-acceptable si et seulement si sa moyenne est nulle $\iint_{\mathbb{R}^2} g(\mathbf{x}) \mathbf{d}\mathbf{x} = 0$.

5. Les symlets [38]:

Pour un support donné, l'ondelette orthogonale dont la réponse en phase ressemble le plus à un filtre de phase linéaire est dite la moins asymétrique. Les symlets sont des exemples d'ondelettes les moins asymétriques. Ce sont des versions modifiées des ondelettes db classiques de Daubechies. Représenté dans la figure II.1

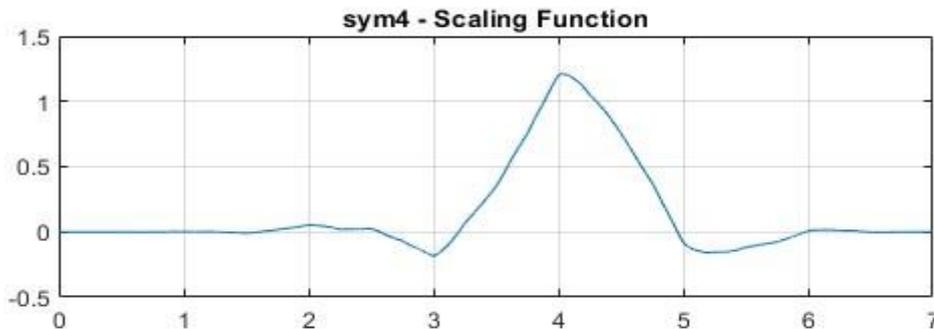


Figure II.1 : Fonction de mise à l'échelle des symlets [38]

The symaux function generates the scaling filter coefficients for the "least asymmetric" Daubechies wavelets..

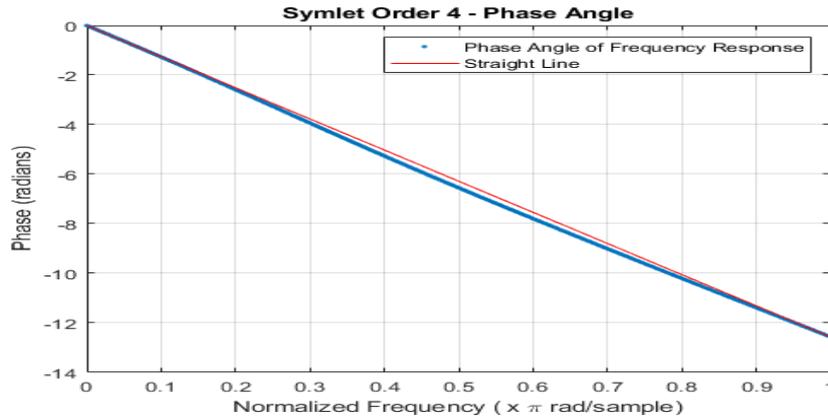


Figure II.2: L'angle de phase des symlets [38]

3. 1. 2. Extraction de région d'intérêt par morphologie mathématique :

1. Définition de la morphologie mathématique :

L'érosion et la dilatation sont deux opérations opposées de la morphologie mathématique. Alors que les filtres vus jusqu'à présent se concentrent sur la modification du niveau de gris d'un pixel, la morphologie mathématique tente de modifier la forme d'un objet. Ainsi, ce que fait l'érosion, c'est réduire la taille des objets dans l'image, tandis que la dilatation cherchera à les agrandir.

2. Dilatation :

L'opération de dilatation utilise la notion d'éléments structurants qui généralise la notion de fenêtres glissantes. L'idée est que pour pouvoir étudier la forme d'un objet, il faut pouvoir considérer des fenêtres coulissantes dont les formes sont plus complexes que des carrés.

La dilatation d'une image à niveaux de gris $f: \mathbb{Z}^2 \rightarrow \mathbb{R}$ par une image binaire $SE \subseteq \mathbb{Z}^2$ (l'élément structurant) est notée $f \oplus SE$ ou $\delta_{SE}(f)$. Après dilatation, la nouvelle valeur d'un pixel est donnée par la valeur maximale des pixels sous l'élément structurant [39]:

$$\forall x, (f \oplus SE)(x) = \delta_{SE}(f)(x) = \max_{p \in SE} f(x + p) \quad (6)$$

En pratique, l'élément structurant sera simplement une image binaire contenant la forme d'intérêt. Explique dans **Figure II.3**



Figure II.3 : Exemple de dilatations sur des images binaires.

3. Erosion :

De même manière, on peut obtenir l'érosion en remplaçant le max par le min de la dilatation. Soient une image à niveau de gris $f: \mathbb{Z}^2 \rightarrow \mathbb{R}^{\text{et}}$ une image binaire $SE \subseteq \mathbb{Z}^2$ (l'élément structurant), l'érosion de f par SE est notée $f \ominus SE$ ou $\epsilon_{SE}(f)$ et est définie par [39]:

$$\forall x, (f \ominus SE)(x) = \epsilon_{SE}(f)(x) = \min_{p \in SE} f(x + p) \quad (7)$$

Contrairement à la dilatation afin pour vraiment afficher le résultat pour cette intervention il est encore simple pour se modérer aux images binaires sur seul premier moment. Regardez **Figure II.4**

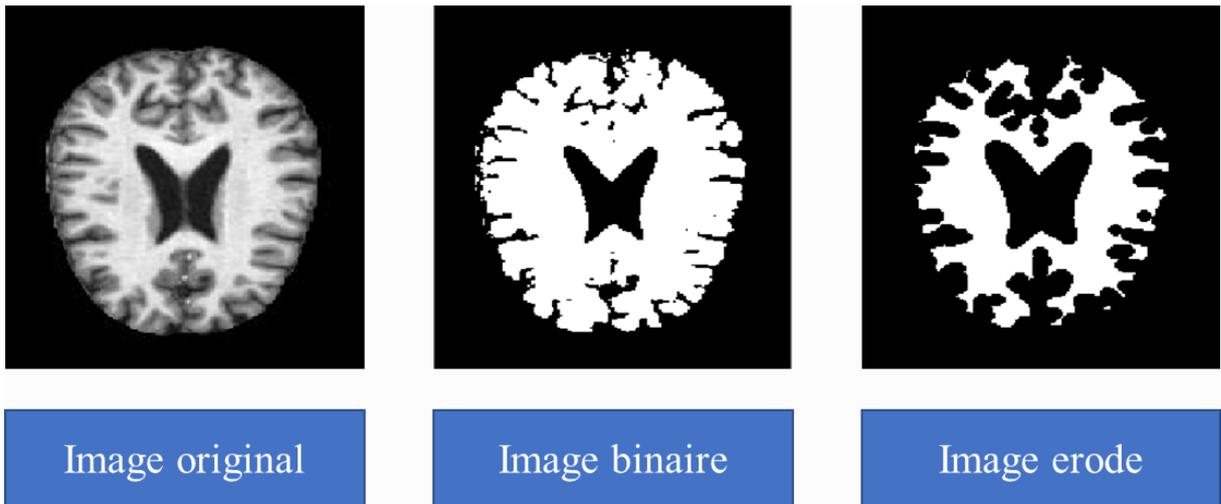


Figure II.4 : Exemple d'érosions sur des images binaires

4. Ouverture morphologique :

L'ouverture morphologique sert à faire une érosion suivie d'une dilatation avec le même élément structurant sur une image. Soit $X \subseteq \mathbb{Z}^n$ et $B \subseteq \mathbb{Z}^n$, on définit l'ouverture de X par B comme [39]

$$\gamma_B(X) = X \circ B = (X \ominus B) \oplus B = \delta_B((\varepsilon_B(X))) \quad (8)$$

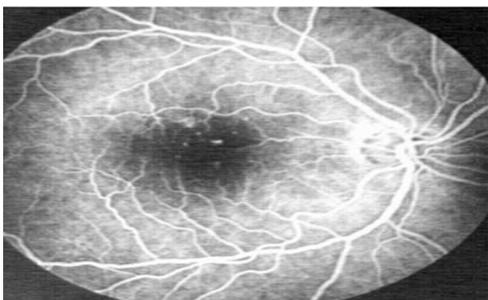
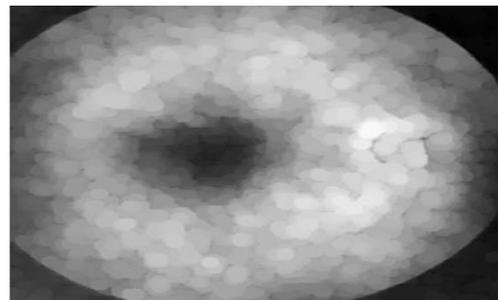


Image initiale



Ouverture

Figure II.5 : Ouverture morphologique sur une image de cornée

Intérêt :

L'érosion permet de supprimer d'une image toutes les structures ne contenant pas l'élément structurant (les petits objets) puis la dilatation récupère les objets d'intérêt. L'ouverture toujours supprime les petits éléments clairs sur une image en niveau de gris :

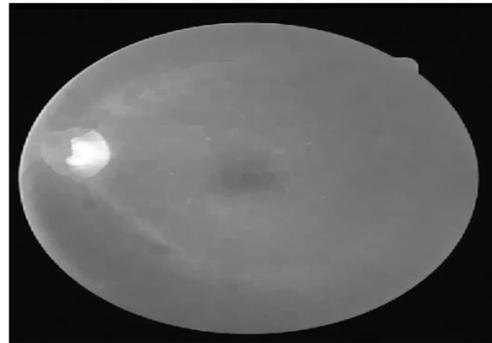
5. Fermeture morphologique :

Par contre, la fermeture morphologique est l'opération inverse de l'ouverture morphologique, qui consiste à faire une dilatation puis une érosion, Soit $X \subseteq \mathbb{Z}^n$ et $B \subseteq \mathbb{Z}^n$, on définit la fermeture de X par B comme [39]

$$\varphi_B(X) = X \cdot B = \varepsilon_B((\delta_B)) = (I \oplus E) \ominus \quad (9)$$



Image initiale en NG



Fermeture

Figure II.6 : Ouverture morphologique sur une image de cornée

Intérêt :

La récupération des dimensions et des détails disparus après l'ouverture de la région d'intérêt. Par contre, Sur une image en niveau de gris la fermeture va éclaircir les petites zones sombres

3. 1. 3. . Segmentation par K-means clustering

1. Définition de la segmentation [40]:

La segmentation est le processus le plus important dans le domaine d'traitement d'image qui sert a regrouper des pixels selon des critères définie, ces pixels sont toujours regroupé par région.

On définit plusieurs méthodes pour faire la segmentation comme, segmentation par seuillage, histogramme, région, contour, clustering, morphologie et par texture.

2. Définition de L'algorithme de K-means [41] :

L'algorithme K-Means est un algorithme de clustering non supervisé, sont rôle base sur le classement de données d'entrée en différentes classes basent sur leur distance inhérente. L'algorithme essaie de réaliser un regroupement naturel pour les caractéristiques des données forment un espace vectoriel.

$$V = \sum_{i=1}^k \sum_{x_j \in S_i} (x_j - \mu_i)^2 \quad (10)$$

où il y a k clusters S_i , $i = 1, 2, \dots, k$ et μ_i est le point du centre ou point moyen de tous les points $x_j \in S_i$ Dans le cadre de ce projet, l'implantation d'une version itérative de l'algorithme est faite

3. Etapes essentiel d'application de K-means [41] :

L'algorithme toujours suit ces différentes étapes :

- Le calcul de la distribution d'intensité (histogramme) des intensités.
- Mettre le point centre en état initial avec k intensités aléatoires. –
- Répétition des étapes citées pour fixer les étiquettes de cluster de l'image
- Regroupement des points en fonction de la distance de leurs intensités à Partir du point centre intensif. :

$$c^{(i)} := \arg \min_j \|x^{(i)} - \mu_j\|^2 \quad (11)$$

* Calcule de nouveau point centre pour chaque cluster.

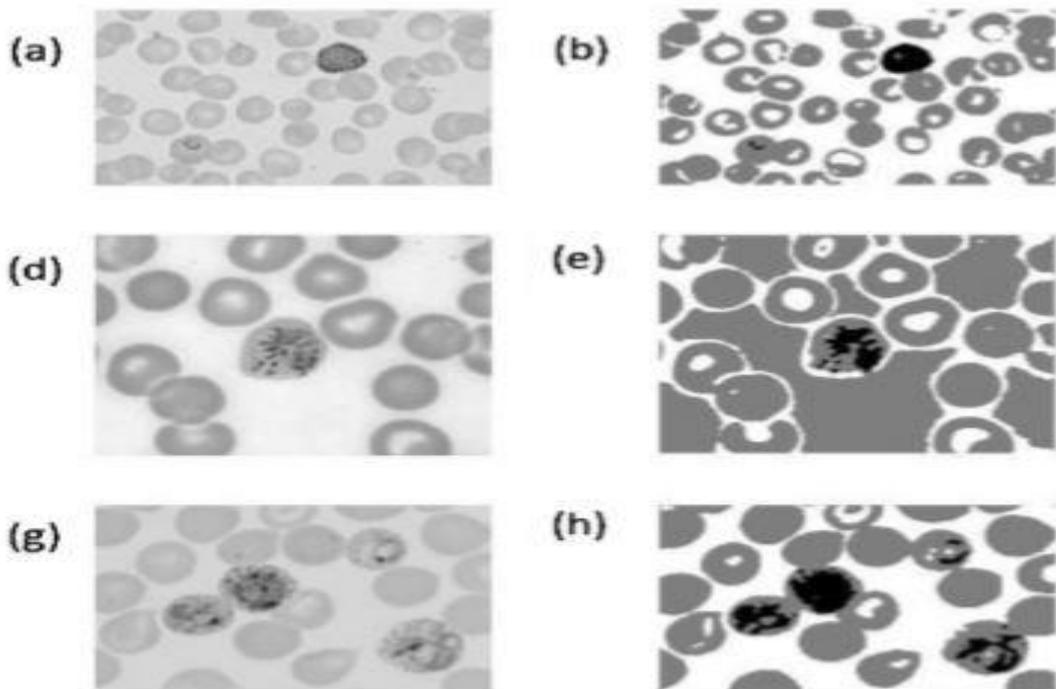
$$\mu_i := \frac{\sum_{i=1}^m 1\{c(i)=j\}x^{(i)}}{\sum_{i=1}^m 1\{c(i)=j\}} \quad (12)$$

Intérêt :

L'algorithme K-Means assure la disponibilité des informations sur les image segmentée (clarté des région), pour améliorer la précision de la classification et donner des résultats acceptables.

4. Résultat de segmentation par l'algorithme de k-means [42] ;

L'application de K-means donne plusieurs résultats la Figure II.7 représente un résultat de k-means sur une image des cellules



Images originaux

algorithme de k-means

Figure II.7 : segmentation par algorithme de K-means a 3 clusters

3. 2. Classification

La classification est une procédure permettant d'affecter à un objet la famille à laquelle il appartient, autrement dit de le reconnaître trouver une application de l'ensemble des objets à classer, décrits par les variables descriptives choisies, dans l'ensemble des classes à l'aide d'un classifieur.

3. 2. 1. Apprentissage automatique (Machine Learning) :

L'apprentissage automatique, également appelé apprentissage machine ou apprentissage artificiel et en anglais machine Learning, est une forme d'intelligence artificielle (IA) qui permet à un système d'apprendre à partir des données (petite BDD) et non à l'aide d'une programmation explicite. On définit deux types de machine Learning connu qui sont le SVM et K-NN

1. Extraction des caractéristiques :

L'extraction des caractéristiques dans la machine Learning est une étape très importante qui sert à extraire les informations qui identifient les images avant de les classer.

i. Définition de l'histogramme des gradients orientés (HOG) [43] :

Le HOG est un descripteur de fonctionnalité utilisé dans la vision par ordinateur et le traitement d'image dans le but de détecter des objets. La technique calcule les occurrences d'orientation du gradient dans des parties d'une image.

Le descripteur HOG présente quelques avantages clés par rapport aux autres descripteurs. Puisque cela fonctionne sur des cellules locales, il est invariant aux transformations géométriques et photométriques.

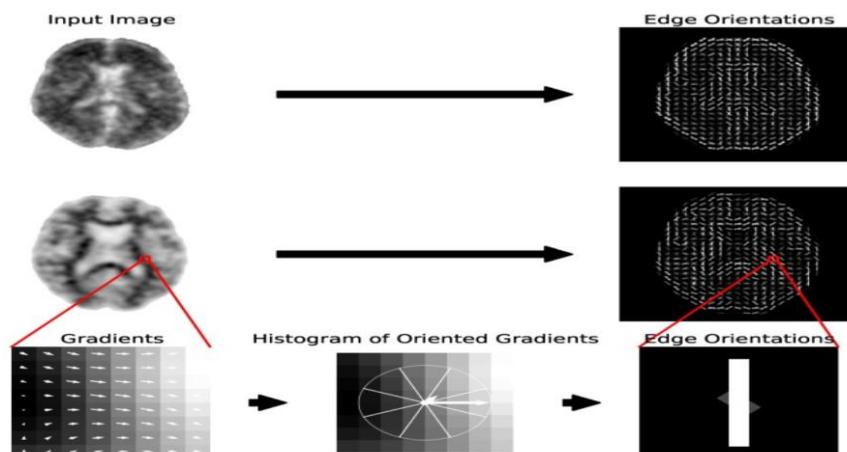


Figure II.8 : Une illustration des caractéristiques HOG 2D pour une coupe axiale [51]

ii. Définition de Modèle binaire local (LBP) [45] :

Le LBP se définit aussi comme une caractéristique qui résume la structure spatiale locale d'une image utilisée en vision par ordinateur, pour reconnaître des textures ou pour détecter des objets dans les images numériques.

Le LBP de base est défini par :

$$LBP(x_c, y_c) = \sum_{p=0}^{P-1} S(g_p - g_c) \times 2^p \quad (13)$$

Où : g_c est le niveau de gris du pixel central de coordonnées (x_c, y_c) . ($p = 0, 1, \dots, 7$) est le niveau de gris de chaque pixel voisin. Avec : $S(x)$ une fonction définie comme suit:

$$S(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad (14)$$

La propriété la plus importante de l'opérateur de LBP dans les applications du monde réel est sa robustesse aux changements d'échelle de gris monotones causés.

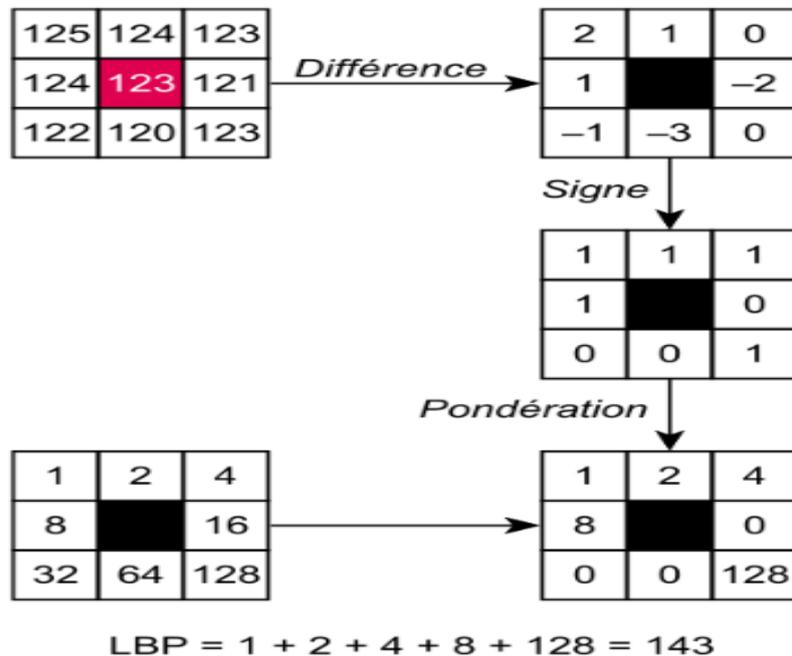


Figure II.9 : Schéma représente le principe de LBP [45]

iii. Définition de matrice co-occurrence de niveau de gris (GLCM) [46] :

Le GLCM et les mesures de texture qui en sont dérivées sont des statistiques descriptives, pour extraire les caractéristiques texturales d'images. Selon la matrice de cooccurrence, on définit quelques caractéristiques texturales mesurées à partir de la matrice de probabilité pour extraire les caractéristiques des statistiques de texture des objets distants.

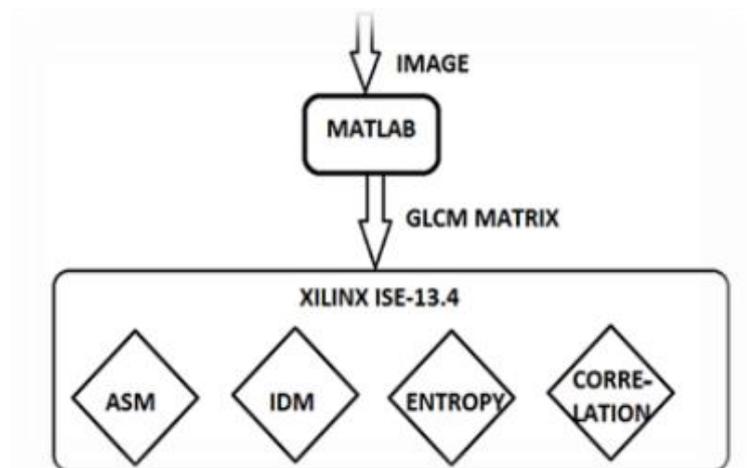


Figure II.10 : Quelques paramètres de textures obtenus par le GLCM [52]

2. Classification :

La classification dans le machine Learning est l'étape qui suit l'extraction de caractéristique, cette étape sert à donner des tâches à un classifieur pour apprendre les caractéristiques extraites et classifier ces caractéristiques selon les données d'entrée.

i. Multi-support vector machine (Multi-SVM) [47] :

Support Vector Machine (SVM) est un algorithme de classification d'apprentissage qui apprend à partir d'un ensemble de données d'apprentissage et tente de généraliser et de faire des prédictions précises sur de nouveaux ensembles de données. Ces algorithmes sont basés sur la recherche de l'hyperplan de marge optimale qui classe ou sépare correctement les données tout en étant le plus éloigné possible de toutes les observations. La figure suivante représente le principe de séparation de SVM

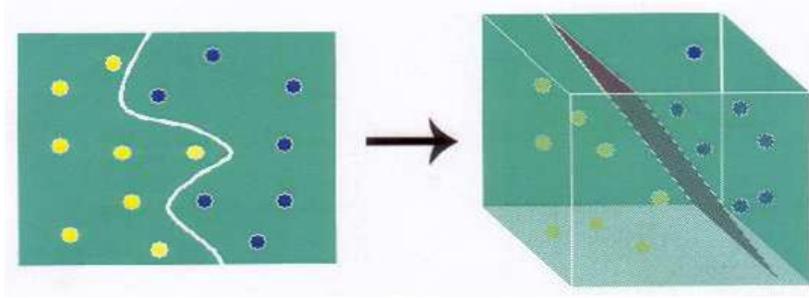


Figure II.11 : Séparation de merge optimale par SVM

Le multi-svm est un type de classification par principe de SVM, le modèle d'apprentissage automatique doit classer une instance dans l'une des trois classes ou plus. Comme le stade de la maladie d'Alzheimer. Représente dans la figure suivante

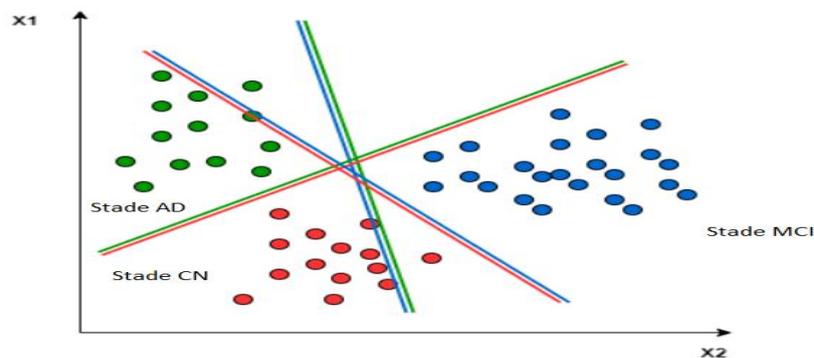


Figure II.12 : Classification multi-class par SVM

ii. K Nearest Neighbors (K-NN) [48]:

L'algorithme (K-NN) est un algorithme d'apprentissage automatique qui appartient à la classe des algorithmes d'apprentissage supervisé simples et faciles à mettre en œuvre qui peuvent être utilisés pour résoudre à la fois des problèmes de classification et de régression.

Son fonctionnement peut être assimilé à l'analogie suivante "dis-moi qui sont tes voisins, je te dirais qui tu es...", Pour effectuer une prédiction, l'algorithme K-NN va se baser sur le jeu de données en entier. En effet, pour une observation, qui ne fait pas parti du jeu de données, qu'on souhaite prédire, l'algorithme va chercher les K instances du jeu de données les plus proches de notre observation. Ensuite

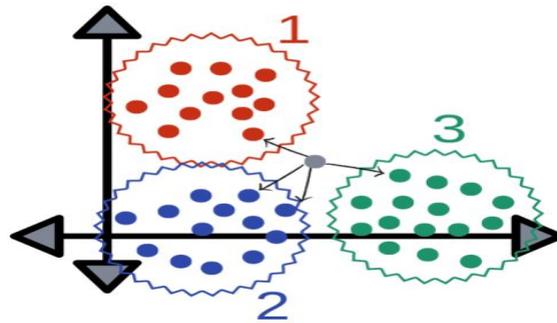


Figure II.13 : une prédiction de l'algorithme K-NN

3. 2. 2. Apprentissage approfondie (Deep Learning) :

Par contre, la technique de ce type d'apprentissage est inspirée du cerveau humain, qui contient un ensemble d'apprentissage automatique. Qui a besoin toujours d'une grande base de données ou du notre manière beaucoup d'information à apprendre. Le type de classification le plus connu de Deep Learning est le CNN.

1. Réseaux de neurone convolutif (CNN) [49] :

i. Définition de CNN

Le réseau de neurones convolutifs ou CNN est un type de réseau de neurones artificiels largement utilisé pour la reconnaissance et la classification d'images/d'objets.

Maintenant, quand nous pensons à un réseau de neurones, nous pensons aux multiplications matricielles, mais ce n'est pas le cas avec le CNN. Il utilise une technique spéciale appelée Convolution. Comme est présentée dans **Figure II.14**

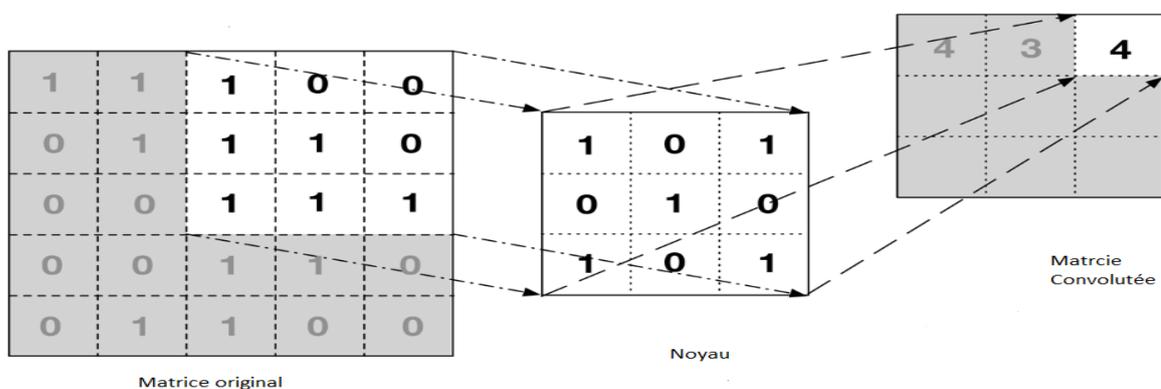


Figure II.14 : Principe de convolution matricielle de CNN

Les réseaux de neurones convolutifs sont composés de plusieurs couches de neurones artificiels. Chaque couche génère plusieurs fonctions d'activation qui sont transmises à la couche suivante. Passant vers l'étape de pooling pour généraliser les caractéristiques extraites par des filtres convolutifs et d'aider le réseau à reconnaître les caractéristiques indépendamment de leur emplacement dans l'image. Ces étapes sont présentées dans la figure suivante :

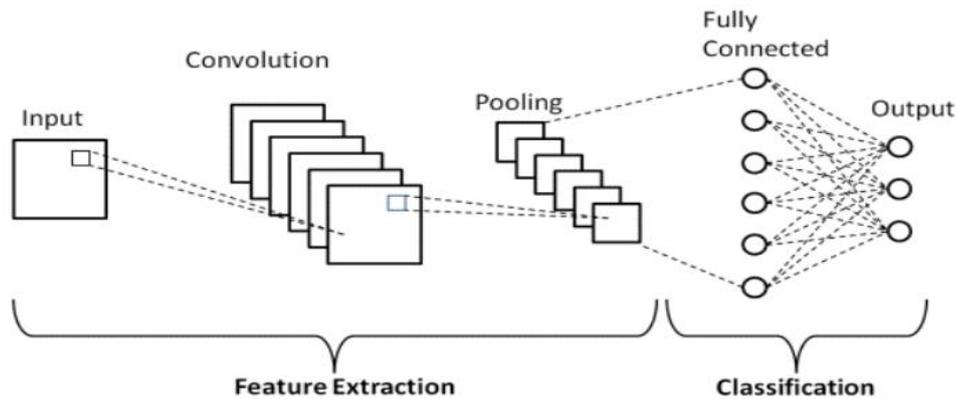


Figure II.15 : Architecture d'algorithme de CNN

ii. Les étapes de fonctionnement de CNN [50]:

- Couches de convolution :

Les couches convolutives sont un élément clé des réseaux de neurones convolutifs et sont toujours au moins leur première couche. Son but est d'identifier la présence ou l'absence d'un ensemble de caractéristiques dans une image reçue en entrée.

- Couches de pooling :

Les couches de regroupement sont utilisées pour réduire les dimensions des cartes d'entités. Ainsi, cela réduit le nombre de paramètres à apprendre et la quantité de calculs effectués dans le réseau. La couche de regroupement résume les caractéristiques présentes dans une région de la carte de caractéristiques générée par une couche de convolution.

- Couches entièrement connectées :

La couche entièrement connectée consiste simplement à alimenter les réseaux de neurones. Les couches entièrement connectées forment les dernières couches du réseau.

L'entrée de la couche entièrement connectée est la sortie de la couche de regroupement ou de convolution finale, qui est aplatie puis introduite dans la couche entièrement connectée.

3. 2. 3. Métrique d'évaluation de la classification :

- Précision :

Dans les domaines l'apprentissage et de la classification automatique, la précision est la proportion des élément pertinents de classe donnée parmi l'ensemble des élément classier par le classifieur. Représente dans la figure suivante

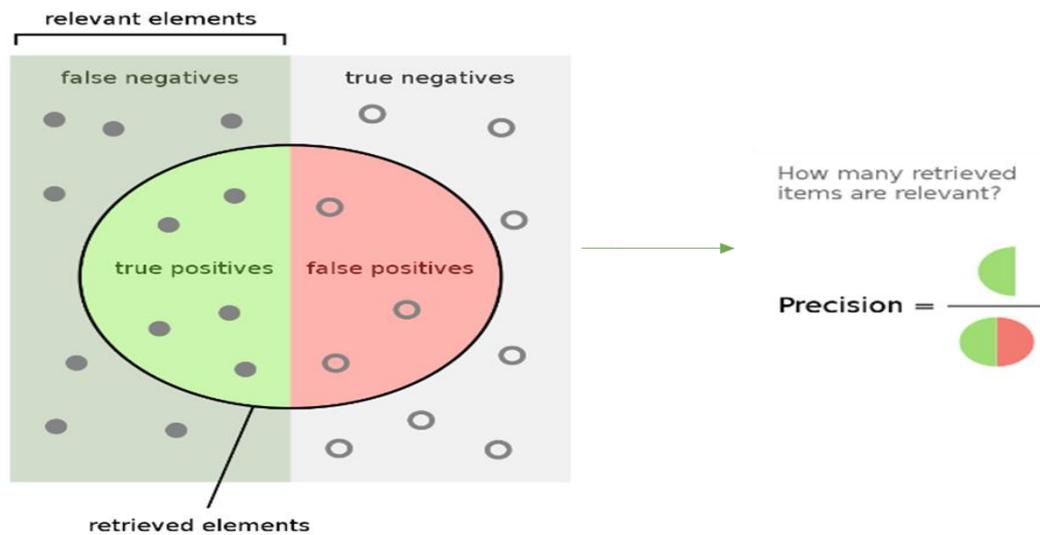


Figure II.16 : Principe de calcul de précision

- Sensibilité :

La sensibilité $Se(I)$ présente la probabilité de bonne classification de I représentée par l'équation suivante

$$Se(i) = \frac{vp(i)}{vp(i) + fn(i)}$$

- Spécificité :

La spécificité $Sp(I)$ présente une mesure de façon indirecte de la probabilité de fausse alarme, cette métrique sert à un calcul inverse de sensibilité ($1 - Sp$) représentée par l'équation suivante

$$Sp(i) = \frac{vn(i)}{vn(i) + fp(i)}$$

4. Conclusion

Dans ce chapitre avons citer le contenu théorique des différentes techniques applique sur notre étude, tels que les techniques de filtrage, caractérisation et classification.

Nous avons cité des techniques de filtrage de réduction de bruits comme la décomposition et reconstruction en ondelettes, et les multiples opérations de la morphologique dédiée à l'isolation de cerveau tels que la fermeture et l'ouverture morphologique, et la segmentation par région du K-means, citons aussi les types d'apprentissage tels que l'apprentissage automatique supervise et approfondie a l'objectif de donner des définitions théorique sur les différente types de caractérisation comme le HOG,LBP et GLCM et aussi les classifieur SVM et KNN dans l'apprentissage automatique supervise, et aussi le CNN et leur couche d'exécution qui appartient de apprentissage approfondie finalisons par un définition théorique des métrique d'évolution de classification.

Dans le chapitre suivant nous allons présenter et interprété les résultats réalisés dans notre travail, appliquons les méthodes et les techniques cite dans ce chapitre.

Chapitre n°3 :

‘Résultats & Discussion’

1. Introduction :

Les images IRM cérébrales contiennent des informations sur la morphologie du cerveau qui nous permettent de détecter l'amincissement du cerveau dans les différents stades de la maladie d'Alzheimer.

Dans ce chapitre, nous allons adopter plusieurs méthodes afin de prédire la maladie d'Alzheimer. Pour cela, nous avons divisé notre travail en deux parties.

Une partie dédiée à l'apprentissage automatique supervisé qui est une méthode d'apprentissage qui se base sur le choix du classifieur et le type des caractéristiques. Pour cette raison, nous avons étudié l'impact de différents types de caractéristiques sur les résultats de classification par le SVM et le KNN, en appliquant : le descripteur HOG, le descripteur LBP et les caractéristiques de texture. Et une deuxième partie dédiée à l'apprentissage approfondi, ce dernier ne nécessite pas une étape de caractérisation, par contre, il se base sur la taille des données et la complexité du modèle.

Les deux parties précédentes sont appliquées après une étape de prétraitement dans laquelle nous avons fait une phase d'extraction du cerveau et toute une étude comparative entre plusieurs types de filtres.

A la fin de ce chapitre, nous avons fait une comparaison entre les différentes méthodes mentionnées.

2. Matériels :

la réalisation de notre travail a nécessité un ensemble de matériels software et hardware au but de faciliter la réalisation.

2. 1. Hardware

- Le matériel utilisé pour l'exécution de ce travail est un Laptop Lenovo Thinkpad E590 des caractéristique suivantes :
- CPU : Intel(R) Core (TM) i7-8565U CPU @ 1.80GHz 2.00 GHz.
- RAM : 16 GB.
- Disque : 1TB.

- GPU : Intel HD graphics + AMD Radeon RX 550X.
- Microsoft WINDOWS 10.

2. 2. Software :

i. Langage de programmation.

Programmation de l'algorithme dédiée au notre travail était sous Matlab 2021a, Le Matlab est langage de programmation émulé, dédiée ou calculs numérique, traitement de signal et traitement d'images.

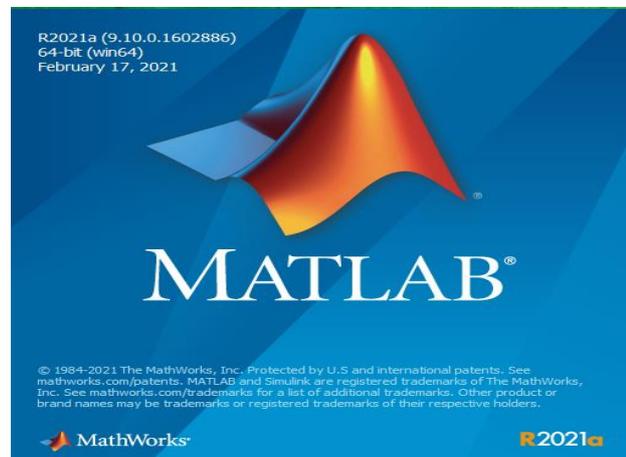


Figure III.1 : Le logo de langage de programmation Matlab

ii. Base de Données ADNI :

Notre travail se base sur l'utilisation d'une base de données publique des images IRM cérébrales de coupe frontale d'une format "image.PNG". Cette base contient 150 images de taille 2048*2048*3, divisée en trois classes de 50 images ; une classe représente le cas normal (CN), et les deux autres classes représentent le stade précoce (MCI) et le stade sévère (AD).

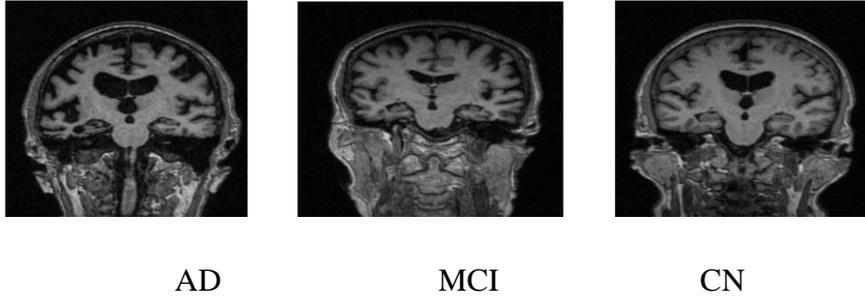


Figure III.2: Trois échantillons de notre base représentant chaque classe de la maladie d'Alzheimer

3. Méthodes développées :

L'objectif principale de ce travail est la détection précoce de la maladie d'Alzheimer afin de développer un système de diagnostic assisté par ordinateur qui pourrait fournir une aide importante au neurologue pour classer et identifier le stade de déficience cognitive légère de la maladie qui précisera le médicament et le traitement du patient. Pour atteindre cet objectif, nous avons étudié deux approches de l'intelligence artificielle : l'apprentissage automatique et l'apprentissage profonde afin de choisir la meilleure approche qui nous donne le meilleur score basé sur notre base de données.

Dans L'apprentissage automatique on a appliqué un process qui se compose des étapes suivantes :

1. Pré-traitement :
 - Isolation et Extraction de cerveau.
 - Rehaussement de contraste et Elimination de bruit.
2. Extraction de région d'intérêts :
 - Segmentation de tissu cérébrale par K-means.
3. Caractérisation : extraction des caractéristiques d'image
 - L'histogramme des gradients orientées (HOG)
 - Le modèle local binaire (LBP)
 - La texture de matrice de cooccurrence de niveaux de gris (GLCM)
4. La multi-classification (apprentissage automatique),
 - Le support de la machine vectorielle (SVM)

- K-les plus proches voisins (KNN)

Pour la deuxième étude : l'apprentissage approfondie nous avons investigué deux architectures de CNN. L'image ci-dessous résume l'étude de notre travail

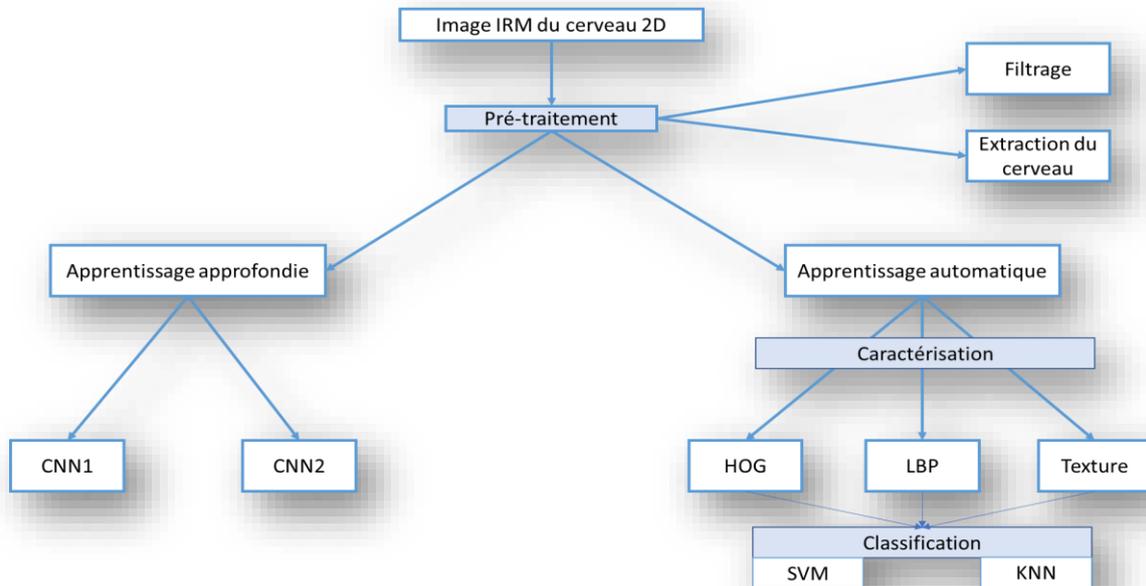


Figure III.3 : Représentation des taches mentionné dans ce chapitre

3. 1. Pré-traitement :

Dans la partie pré-traitement nous avons éliminé les informations inutiles telles que le crâne et le bruit par une étape d'extraction de cerveau et filtrage. La Figure III.4 illustre la partie du pré-traitement.

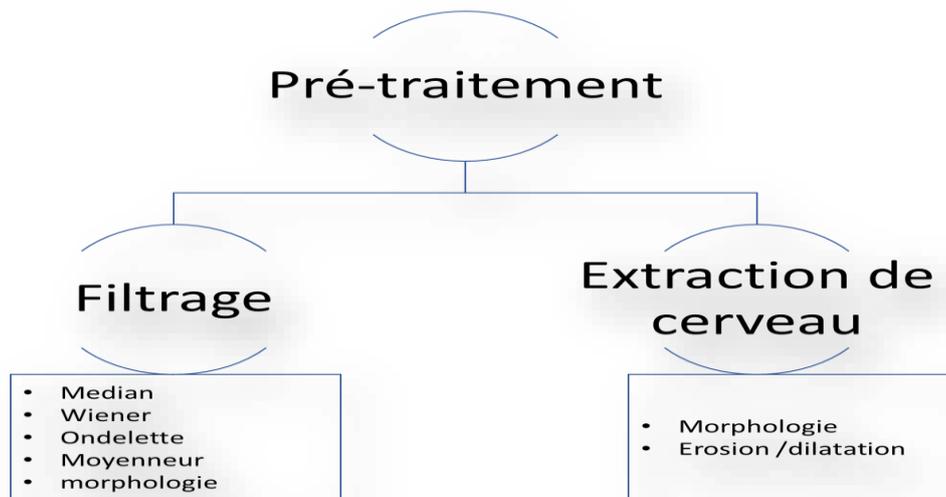


Figure III.4 : Plans de pré-traitement de l'image

3. 1. 1. Extraction de cerveau :

L'élimination des régions non importantes dans l'image facilite au classifieur de faire la différenciation entre les classes, visant cette théorie nous avons appliqué la morphologie mathématique pour extraire le cerveau, la figure suivante montre les étapes utilisées [53].

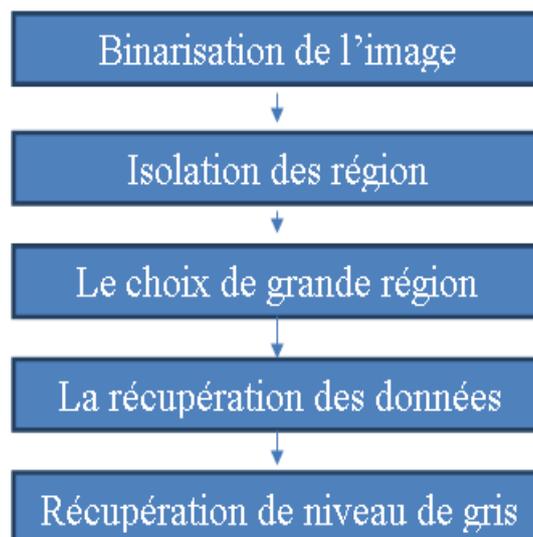


Figure III.6: Algorithme d'extraction de cerveau

3. 1. 2. Résultat de l'extraction de cerveau :

Suivant l'algorithme mentionné dans **Figure III.6** nous avons commencé par la binarisation des images pour pouvoir appliquer la morphologie mathématique sur le plan binaire. Comme elle est montré dans la Figure III.7.

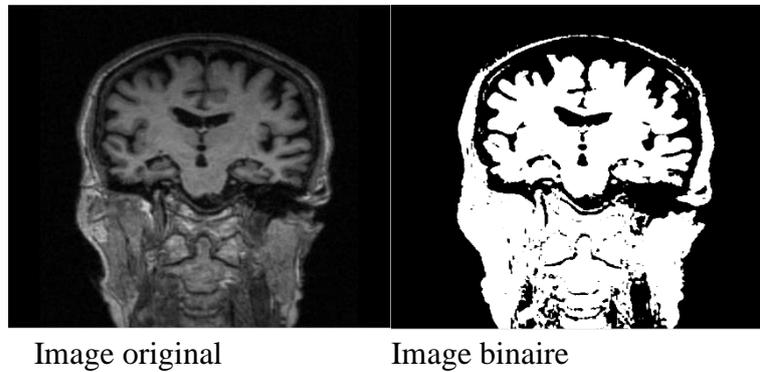


Figure III.7: Binarisation d'image

Après la binarisation nous allons à appliquer une ouverture et fermeture morphologique afin d'effectuer la séparation entre le cerveau et la crane et récupérer les contour perdu. **La figure III.8** présente la réalisation de ces étapes.

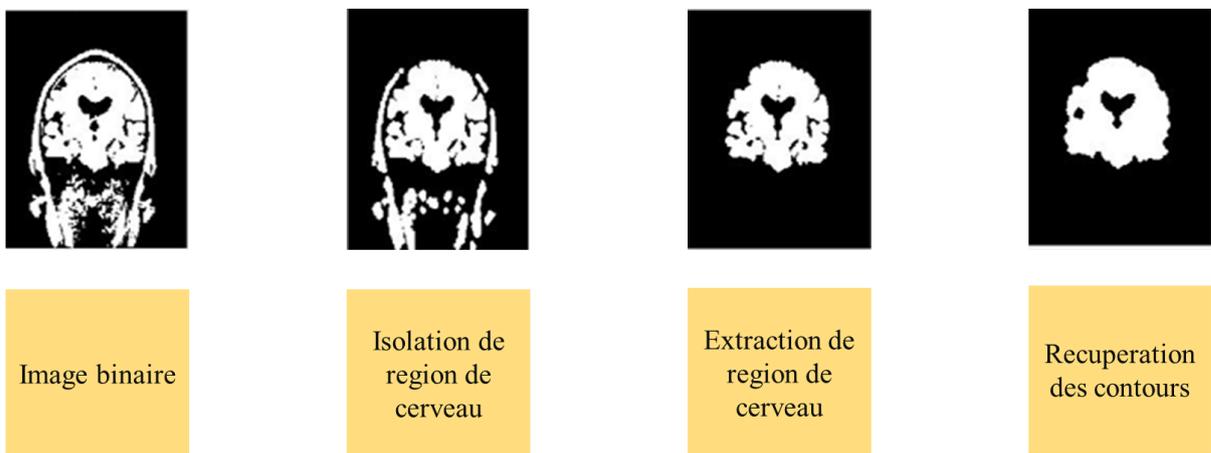


Figure III.8 : Les étapes d'extractions de cerveau

L'objectif d'appliquer la morphologie mathématique est l'obtention du masque du cerveau. Puis nous avons multiplié l'image originale et le masque obtenu, la figure ci-dessous représente l'opération de la multiplication.

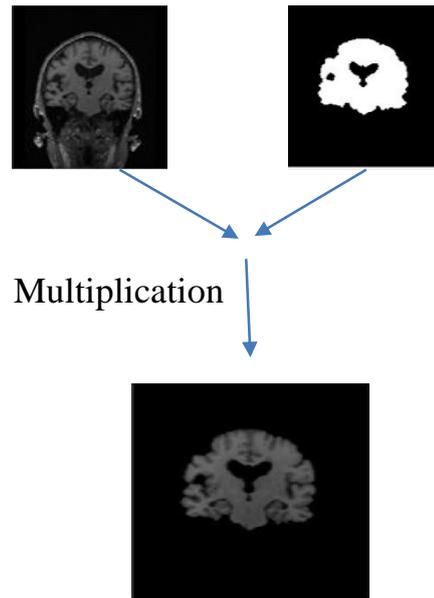


Figure III.9 : La multiplication entre le masque et l'image originale

3. 1. 2. Filtrage :

Le filtrage est une étape très importante dans le traitement d'image, sachant que les images IRM sont souvent bruitées, donc nous avons fait une étude comparative entre plusieurs filtres linéaires comme le filtre médian et non linéaires comme le filtre moyen. Cette étude a pour but de choisir le filtre approprié en se basant sur une évaluation qualitative et quantitative. La figure III.5 montre des images filtrées par chaque filtre.

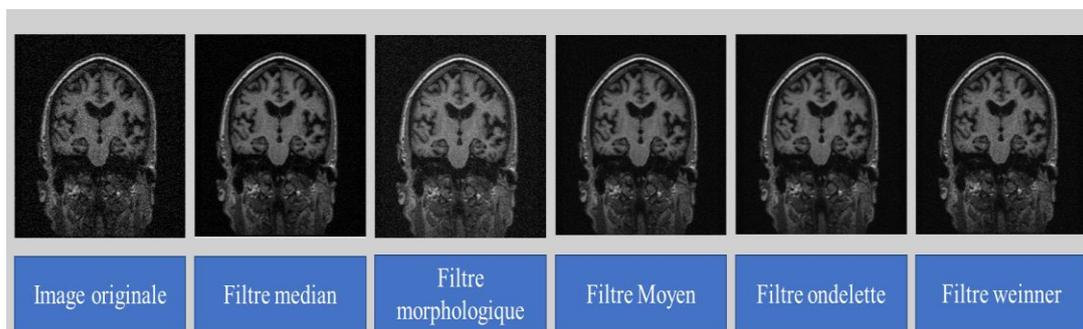


Figure III.5 : Application des multiples filtres sur une image

1. Définition des Métriques d'évaluation des filtres :

L'application des filtres ne peut pas être évaluée seulement avec l'œil humain, donc nous avons évalué le fonctionnement des filtres avec quelques métriques d'évaluation définis dans cette partie.

i. Peak Signal to Noise Ratio (PSNR):

Le PSNR est une mesure utilisée sur l'image numérique pour calculer la qualité d'une image filtrée ou compressée, est défini par :

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad (15)$$

ii. Similarité structurelle de l'image (SSIM) :

La similarité structurelle ou SSIM est une mesure de similarité entre deux images numériques. Défini par :

$$SSIM(x, y) = l(x, y) \cdot c(x, y) \cdot s(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_x\sigma_y + c_2)(cov_{xy} + c_3)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)(\sigma_x\sigma_y + c_3)} \quad (16)$$

iii. Entropie :

L'entropie d'une image est un indicateur de sa complexité. Qui donne la quantité d'information sur cette image est défini par :

$$ENT = \sum (-p(i, j) \log(p(i, j))) \quad (17)$$

Ou $p(i, j)$ est la Valeur du pixel de l'image .

iv. Erreur quadratique moyenne (MSE):

Une mesure évalue la précision, définit par :

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} [I(i,j) - K(i,j)]^2 \quad (18)$$

2. Evaluation des filtres :

Dans cette partie nous présentons les résultats du filtrage afin de choisir le meilleur filtre pour nos images. Le tableau suivant contient plus de détails à propos de ces résultats

<i>Images</i>	Filtres	Filtre médian	Filtre morphologique	Filtre Wiener	Filtre moyen	Filtre Ondelettes
<i>Stade AD</i>						
<i>Image 1</i> (Entropie originale 5.8486)	PSNR	36.3950	35.4957	40.0659	33.5640	37.5294
	MSE	14.9135	18.3448	6.4046	28.6206	1.7663 e-04
	SSIM	0.9799	0.9840	0.9804	0.9681	0.9653
	Entropie	5.7836	5.8392	5.8582	5.8417	5.9243
<i>Image 2</i> (Entropie originale 5.7175)	PSNR	39.6623	38.6834	42.1957	36.3965	34.6442
	MSE	7.0283	8.8053	3.9220	14.9084	3.76 e-03
	SSIM	0.9846	0.9871	0.9841	0.9758	0.9754
	Entropie	5.6199	5.6654	5.6644	5.6604	5.7035
<i>Image 3</i> (Entropie originale 5.8534)	PSNR	36.3124	35.5131	40.0088	33.5163	42.4567
	MSE	15.19	18.27	6.4893	28.9366	5.6798 e-05
	SSIM	0.98	0.9842	0.9806	0.9683	0.9822
	Entropie	5.7904	5.8436	5.8639	5.8475	5.9261
<i>Image 4</i> (Entropie originale 5.8796)	PSNR	37.1501	37.2317	39.6236	35.0105	37.1573
	MSE	12.53	12.30	7.0912	20.5130	1.9243 e-04
	SSIM	0.9739	0.9791	0.9769	0.9641	0.9610
	Entropie	5.7181	5.8059	5.7678	5.7402	5.7701
<i>Image 5</i> (Entropie originale 5.3775)	PSNR	34.6442	34.1876	37.3820	38.54	41.6941
	MSE	22.31	24.1876	11.8819	32.27	4.7700 e-05
	SSIM	0.9754	0.9804	0.9792	0.9637	0.9898
	Entropie	5.3489	5.4053	5.3840	5.3137	5.3815
<i>Stade CN</i>						
<i>Image 1</i> (Entropie originale 5.4357)	PSNR	40.7640	41.3439	42.9387	38.2268	38.2955
	MSE	5.4535	4.7719	3.3053	9.7814	1.4807 e-04
	SSIM	0.9804	0.9845	0.9816	0.9715	0.9551
	Entropie	5.2879	5.3599	5.3658	5.3286	5.4185

<i>Image 2</i> (Entropie originale 6.1081)	PSNR	36.9257	36.9713	39.0458	34.9062	34.3201
	MSE	13.1982	13.06	8.1003	21.01	3.69 e-04
	SSIM	0.9662	0.9750	0.9702	0.9550	0.9282
	Entropie	5.9883	6.0649	6.0400	6.0284	6.0575
<i>Image 3</i> (Entropie originale 5.8723)	PSNR	37.6242	37.8321	40.84	35.1077	37.4203
	MSE	11.2372	10.7120	5.34	20.0590	1.8112 e-04
	SSIM	0.9762	0.9818	0.9779	0.9656	0.9558
	Entropie	5.8046	5.8586	5.8593	5.8446	5.9109
<i>Image 4</i> (Entropie originale 5.8260)	PSNR	39.3485	39.4884	41.7942	36.730	37.8507
	MSE	7.5550	7.3155	4.3019	13.8064	1.6403 e-04
	SSIM	0.9795	0.9841	0.9811	0.9692	0.9594
	Entropie	5.7634	5.8099	5.8310	5.8191	5.8883
<i>Image 5</i> (Entropie originale 5.6422)	PSNR	38.9856	39.6727	41.8763	36.50	37.9697
	MSE	8.2133	7.0114	4.2214	14.5328	1.5960 e-04
	SSIM	0.9785	0.9840	0.9790	0.9684	0.9568
	Entropie	5.4892	5.5754	5.5870	5.5489	5.6639
<i>Stade MCI</i>						
<i>Image 1</i> (Entropie originale 5.5080)	PSNR	36.8184	36.4271	39.1809	34.9615	36.0219
	MSE	13.52	14.80	9.18	20.74	1.5531e-05
	SSIM	0.9667	0.9730	0.9712	0.9556	0.9485
	Entropie	5.4115	5.4530	5.4700	5.4530	5.5169
<i>Image 2</i> (Entropie originale 6.2635)	PSNR	39.226	39.4731	42.5591	36.6201	42.594
	MSE	7.774	7.34	9.6072	14.1602	5.854 e-05
	SSIM	0.928	0.9876	0.9850	0.9731	0.9832
	Entropie	6.1556	6.1643	6.1829	6.1643	6.1805
<i>Image 3</i> (Entropie originale 5.7768)	PSNR	36.551	37.08	38.8865	34.2925	34.2551
	MSE	14.385	12.72	8.4029	24.006	3.7540 e-04
	SSIM	0.9695	0.9774	0.9718	0.9583	0.9318
	Entropie	5.6829	5.7395	5.7476	5.7395	5.8434
<i>Image 4</i> (Entropie originale 5.3599)	PSNR	38.1831	37.333	41.3764	35.2378	37.9309
	MSE	9.8802	12.015	4.73	19.4670	1.6109 e-04
	SSIM	0.9817	0.9849	0.9813	0.9876	0.9611
	Entropie	5.2775	5.3210	5.3318	5.3210	5.3724
<i>Image 5</i> (Entropie originale 5.9331)	PSNR	40.3656	40.7399	42.9405	37.0523	42.9810
	MSE	5.94	5.4839	3.3039	12.8188	5.0338 e-05
	SSIM	0.9844	0.9873	0.9841	0.9757	0.9832
	Entropie	5.8011	5.7884	5.8135	5.7884	5.8262

Tableau III.1 : Résultat de plusieurs métriques d'évaluation de chaque filtre sur des images de base de données.

3. Interprétation des résultats de filtrage :

Comparant les résultats

- Le filtrage par filtre de Wiener donne la plus grande valeur du PSNR dans la majorité des images mentionnées dans le tableau cela affirme l'effet de filtre sur le changement d'information dans les images.
- L'évaluation de filtrage par la métrique de L'erreur quadratique moyenne a donné les meilleurs résultats en appliquant le filtrage par ondelettes par rapport aux autres filtres.
- Le résultat de la similarité d'image est presque la même valeur pour les multiples filtres (petite différence négligeable).
- Le résultat de filtrage avec les ondelettes donne la grandes valeurs de entropie entre tous les filtres mentionné avec une petite différence qui affirme la conservation de quantité d'information gardée lors de filtrage par ondelettes.

après ces résultats et la comparaison entre les filtres nous pouvons dire que chaque filtre à son intérêt et ses avantage et désavantage, la comparaison entre les métriques dites qu'il Ya pas d'une grande différence entre la valeur de similarité qui veut dire que nous ignore la comparaison sur ce point et nous basons sur l'erreur quadratique qui donne les meilleurs résultat sachant que le PSNR donne des meilleure résultat en fonction d la diminution de MSE cela nous nous mettre en considération, la supériorité des résultat par ondelettes par rapport au autres filtre , confirmons cette conclusion avec la grande valeur d'entropie obtenue par le filtrage par ondelettes .

4. Evaluation des multiples ondelettes de Filtrage :

D'après la comparaison précédente, nous constatons que le filtrage par ondelette nous donne des bons résultats. Pour cela nous avons réalisé une deuxième étude comparative afin de choisit l'ondelette appropriée. Il existe plusieurs types d'ondelette qui sont : Symlet, ondelettes de daubechies, les ondelettes bi-orthogonale et les coiflet, sachant que nous avons fixe le niveau de décomposition égale à 2. Le tableaux III.2 représente les résultats de PSNR de différentes ondelettes

	Symlet	Bi-orthogonales		Coiflet		Daubechies	
Sym1	34.49	Bior1.1	34.49	Coif1	35.51	db1	34.49
Sym2	35.49	Bior1.3	34.96	Coif2	36.08	db2	35.49
Sym3	35.89	Bior2.8	36.28	Coif3	36.25	db3	35.89
Sym4	36.07	Bior3.1	35.33	Coif4	36.33	db4	36.02
Sym8	36.034	Bior4.4	35.80	Coif5	36.37		
Sym16	36.44	Bior6.8	36.20				

Tableau III.2 : Résultat de PSNR de chaque ondelette sur la même image

Pour confirmer le choix de filtre utilisé visant la conservation d'information de l'image, nous allons faire un test d'entropie des ondelettes qui nous donne le meilleur PSNR.

classe	Image original	Sym16	Bior2.8	Coif5	Db4
	La valeur d'entropie				
MCI	6.0542	5.9950	5.9618	5.9889	5.9754
AD	5.8534	5.9141	5.8613	5.9049	5.8888
CN	5.8723	5.9045	5.8641	5.8967	5.8807

Tableau III.3 : Résultat d'entropie de chaque ondelette sur la même image

- Le filtrage par ondelettes de symlet présente une bonne conservation de la quantité d'information comparons entre l'image originale et l'image filtré.
- Le test d'entropie joue un rôle important dans l'évaluation des résultats de filtrage et surtout lorsque nous avons obtenu une différence légère entre les résultats de PSNR.
- Finalisant notre comparaison par une autre évaluation utilisant l'ondelette **sym16** appliqué sur notre base de données. Le tableau suivant représente les résultats obtenus par l'ondelette **sym16**.

	Stade CN	Stade AD	Stade MCI
PSNR	43.9881	35.6631	44.4284
MSE	3.9 e-05	2.7145 e-04	3.607 e-05
SSIM	0.9863	0.9492	0.9869
Entropie	5.6182	6.1814	5.9950
Entropie d'image avant filtrage	5.6135	6.2311	5.9725

Tableau III.4 : Résultat de paramètre d'évaluation sur le SYM16

3. 1. 3. Segmentation des tissus cérébrale par K-means

L'algorithme k-means se base sur le clustering, qui sert a identifié le centroïde de chaque cluster dans l'image. Dans notre cas nous avons toujours visé la structure de cerveau, donc nous définit 3 clusters dans l'algorithme (matière gris, blanche, le liquide encéphalorachdien)

i. Résultat d'application de K-means de notre base de données :

Dans la figure III.10 nous avons montré l'intérêt de choix de nombre de clusters dans l'algorithme k-means. La figure présente les résultats de la segmentation par k-means varionsle nombre de clusters en deux, trois et quatre clusters dans une image IRM prétraité

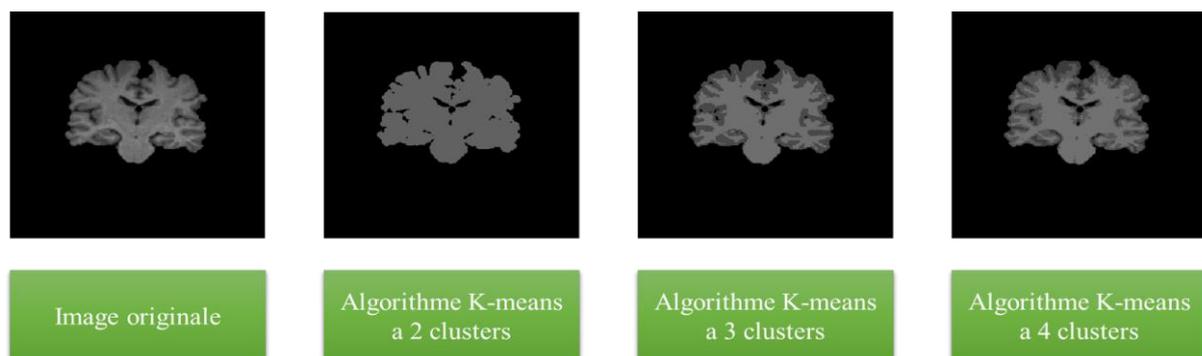


Figure III.10 Segmentation par K-means

ii. Interprétation :

Nous avons testé l'algorithme de K-means sur 3 expérimentations en changeons le nombre de cluster de 2 à 4, Nous avons précis la segmentation avec 3 clusters dans le k-means pour que nous recevons un résultat valable sur la segmentation des régions de l'image, afin d'étudier les caractéristiques sur les 3 régions dans notre image prétraitée qui sont le fond de l'image, matière grise, matière blanche. Les résultats présenter dans la figure III.10 montre la valabilité de k-means par 3 clusters sur notre image.

3. 2. Apprentissage automatique :

L'apprentissage automatique est un type d'apprentissage basé sur l'étape de caractérisation, dans cette partie nous avons réalisée des expérimentations sur trois différentes méthodes d'extraction de caractéristiques.

3. 2. 1. Extraction des caractéristiques :

Dans la partie d'extraction des caractéristiques nous allons appliquer plusieurs méthodes dans le but de réaliser une étude comparative sur l'impact de ce type de caractéristique sur la phase de classification. **Figure III.11** représente les différentes méthodes d'extraction de caractéristique réalisée.

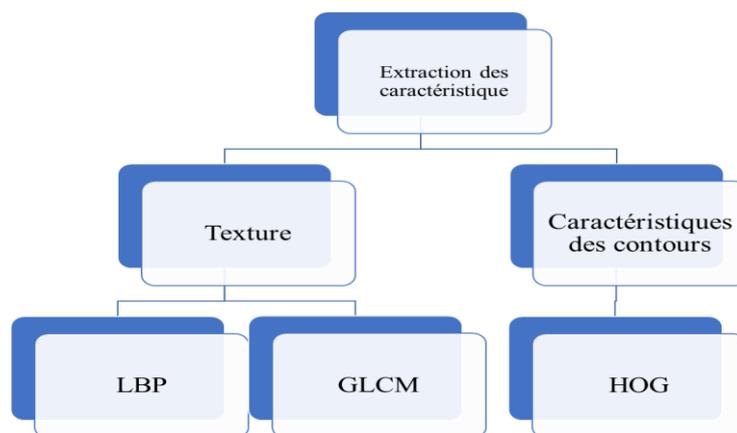


Figure III.11 : Modalités d'extraction de caractéristique

i. Caractérisation par le HOG (Histogramme des gradient orienté) :

Le HOG vise toujours la différenciation des niveaux de gris ou bientôt les gradients de l'image et marque l'information selon le changement de valeur et le positionnement de pixel, Figure III. 12 présente la superposition des caractéristiques extraites par le HOG sur une image prétraitée.

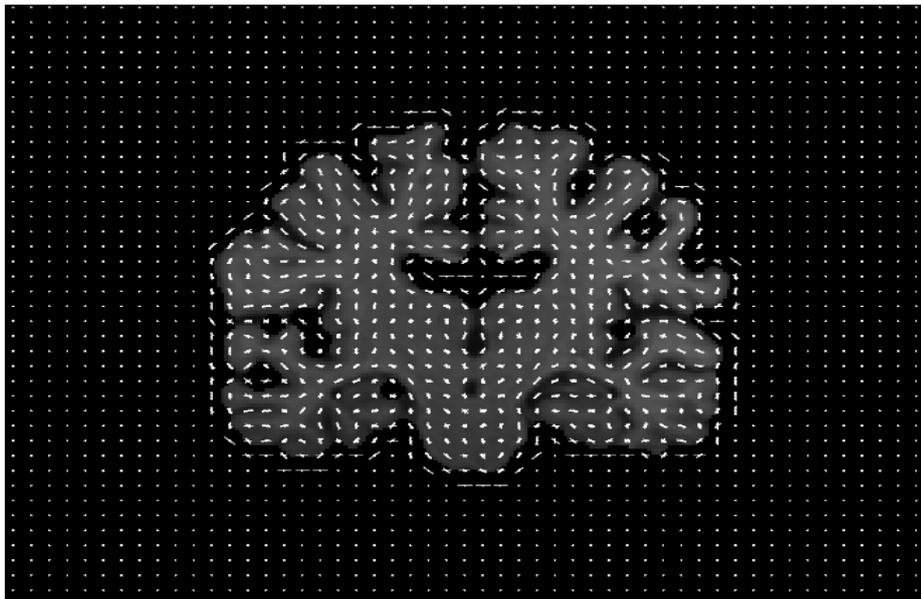


Figure III.12 : Les caractéristiques extraites par le HOG sur une image de cas MCI

Nous pouvons visualisée la région qui contient plus d'information et plus de variation par la superposition des informations extraite par le HOG sur l'image. Tenons en considération que le point signifie l'absence de l'information (aucune information extraite de cette régions) et les petites intersection (croix) montre qu'il existe des informations extraites à partir de cette région et ça signifier aussi qu'il existe une variation de gradient. Les Figure III.13,14,15 montre les résultats d'extraction de caractéristiques de différentes tailles de cellule de HOG chaque cellule.

Figure III.13,14,15 montre le résultat d'extraction de caractéristique de chaque cellule.

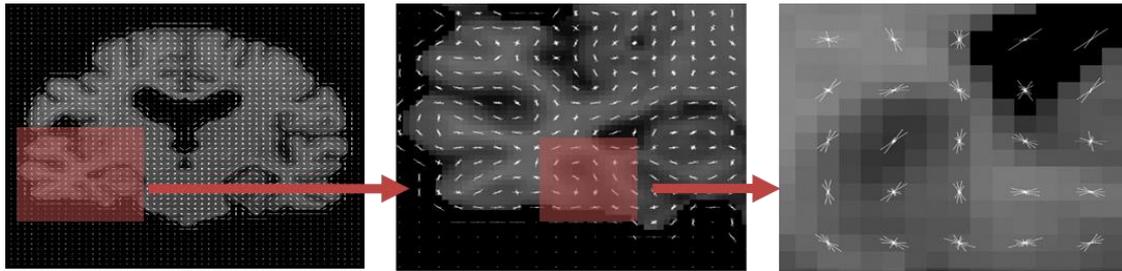


Figure III.13: Extraction de caractéristiques par une cellule de taille 3*3

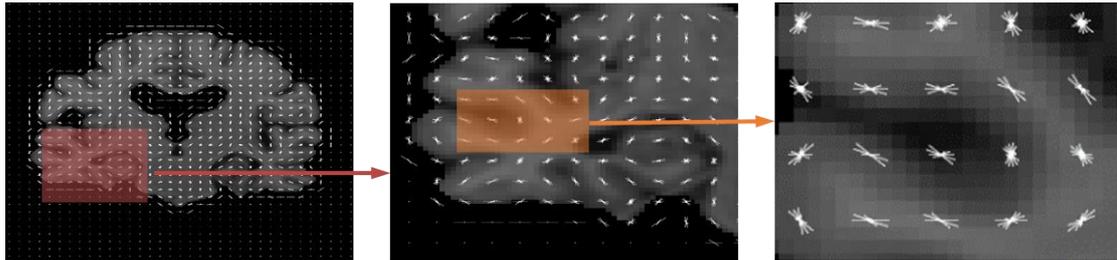


Figure III.14 Extraction de caractéristiques par une cellule de taille 5*5

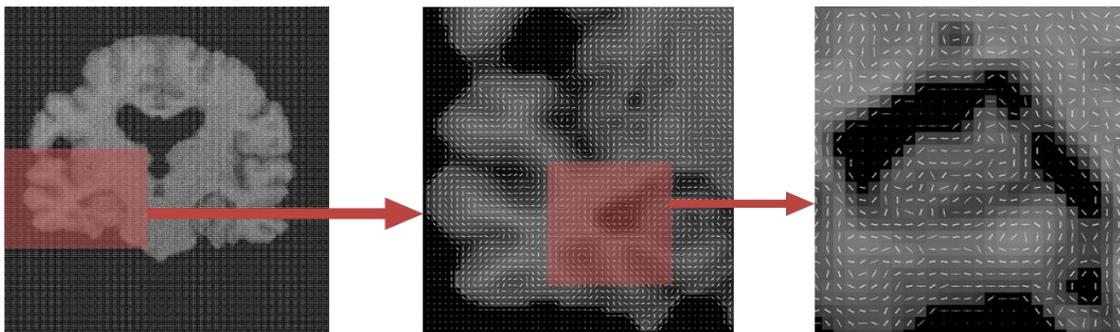


Figure III.15 : Extraction de caractéristiques par une cellule de taille 1*1

Le graphe présenté dans la **Figure III.16** présente le nombre de caractéristique extrait avec la procédure du HOG en changeant la taille de cellules de détection.

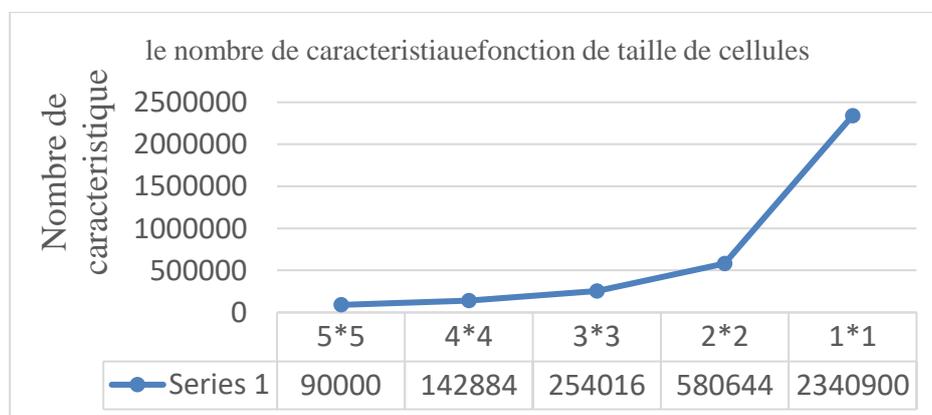


Figure III.16 : Nombre de caractéristiques obtenue par chaque cellule der HOG

Interprétation :

La base de fonctionnement de HOG est une cellule de détections qui nous permettent d'extraire des caractéristiques selon sa taille, comme représenter la figures III.16

Nous avons changé la taille de la cellule de taille 1*1 vers 5*5, en fixons le bloc de HOG, nous avons remarqué que la petite taille de la cellule nous donne plus de caractéristiques. (Plus de 2 millions caractéristique de taille 1*1).

Dans l'objectif de choisir la meilleure taille de cellules pour l'extraction les caractéristiques du HOG, nous avons testé les deux classifieur utilisant les caractéristiques de chaque taille de la cellule afin de voir laquelle qui touche toutes les caractéristiques de contour de la matière grise et l'hippocampe. Lorsque nous diminuons la taille de cellules ont obtenue plus d'information dans l'image et nous avons augmenté la sensibilité de détection des contours sur l'image.

ii. Le model binaire local (LBP) :

L'extraction des caractéristiques par le LBP est une procédure qui se base sur l'étude des caractéristiques de texture de l'image, les figures suivantes présente le nombre de caractéristique de LBP extraite de différentes tailles de cellule.

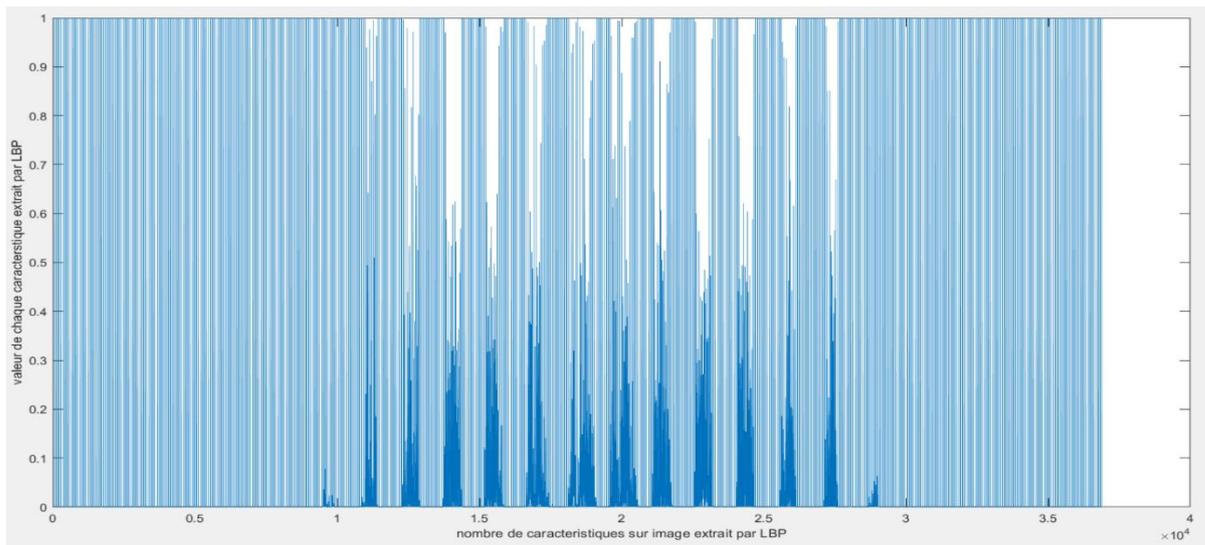


Figure III.17 : Un graphe présente les information extrait par LBP avec une cellules de taille 10*10

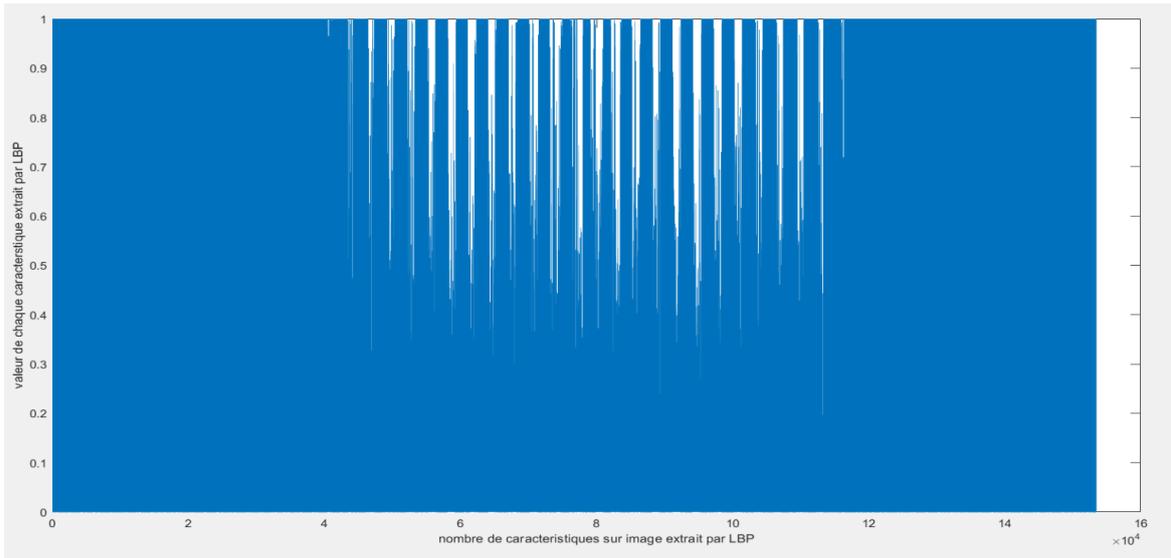


Figure III.18 : Un graphe présente les information extrait par LBP avec une cellules de taille 5*5

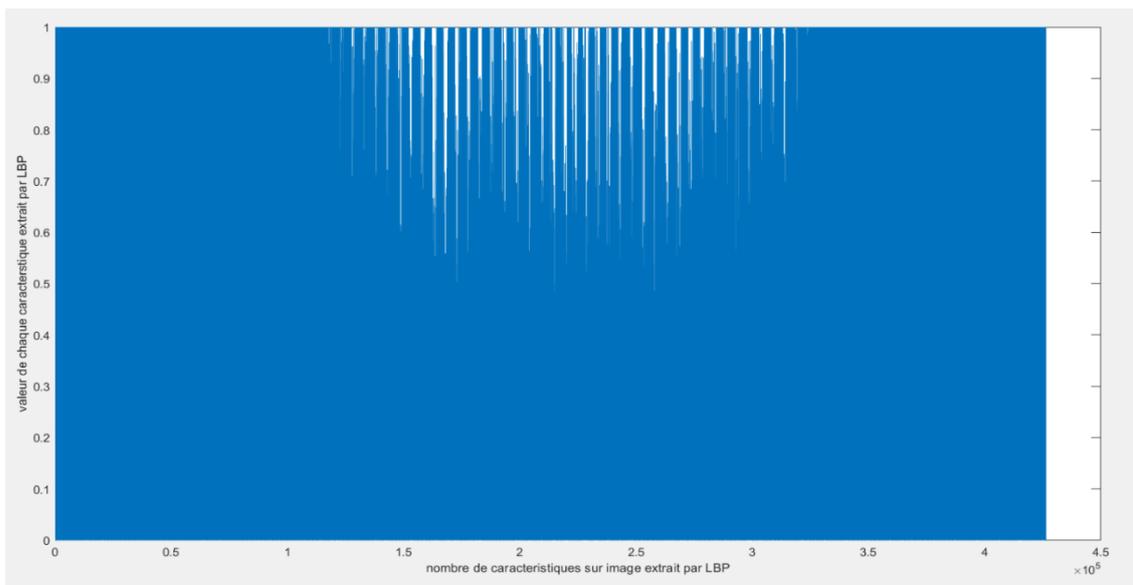


Figure III.19 : Un graphe présente les information extrait par LBP avec une cellules de taille 3*3

Nous constatons que lorsque nous diminuons la taille de cellules nous avons obtenue plus d'information dans l'image. Le tableau suivant présente le nombre de caractéristique extrait avec la méthode LBP en changeant la taille de cellules de détection.

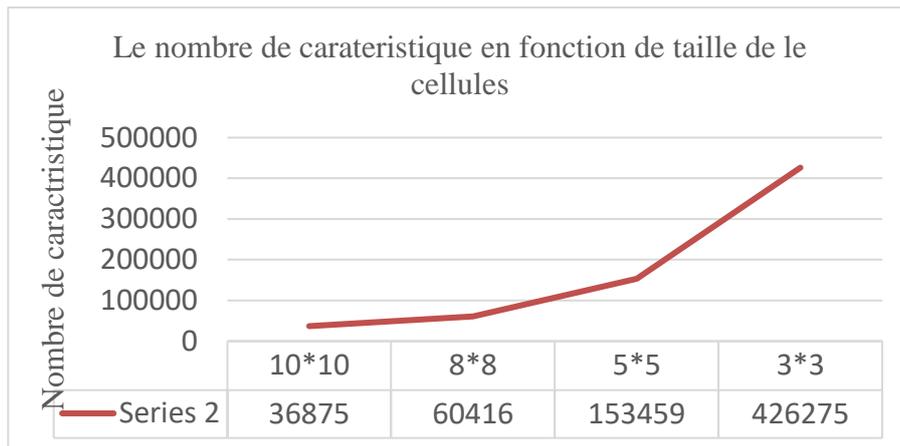


Figure III.20 : Nombre de caractéristiques obtenue par chaque cellule der LBP

Interprétation ;

- Comme le HOG, l'extraction des caractéristiques de LBP se base aussi sur la taille de la cellule, comme nous avons vu dans la figure III.20. Le nombre de caractéristique augmente jusqu'à 400000 sur la taille 3*3.

iii. Caractérisation par matrice Co-occurrence de niveau de gris (GLCM)

Nous avons fait une autre expérimentation sur La méthode d'analyse de texture qui se base sur l'étude des différents éléments textuelle, calculons les valeurs des éléments extraite par la matrice de co-occurrence. Nous avons calculé 7 éléments principale de texture montré dans le tableau III.5 avec les résultats obtenus par une image de notre base de données de chaque classe.

	Energie	Entropie	Contraste	Homogénéité	Corrélation	Ombre	Prominence
AD	0.7210	0.7415	0.0590	0.9758	0.9672	15.7040	89.1455
CN	0.6934	0.7799	0.0457	0.9792	0.9741	14.1943	75.86
MCI	0.6914	0.6599	0.0434	0.9877	0.9785	14.97	75.52

Tableau III.5: Les valeurs des éléments de texture appliquée par le GLCM sur une image

IRM

3. 2. 2. Classification

La classification est une méthode d'intelligence artificiel, dans cette partie nous avons réalisé des expérimentations utilisant deux classifieur : Le SVM et le KNN

i. *Expérimentation 1 : classification par le HOG :*

L'apprentissage automatique ou machine Learning dépend toujours au choix de caractéristiques pour classifier les différentes classes, nous avons extraire les caractéristiques de HOG de chaque image pour les 3 classes : MCI, CN et le cas AD. Puis nous avons lancé un apprentissage automatique avec le model SVM et KNN séparément, nous avons étudié l'impact de différent taille de cellules de HOG sur les deux classifieurs. Le tableau suivant montre la précision des classifieurs selon le nombre de caractéristique du HOG.

Taille de cellules	1*1	2*2	3*3	4*4	5*5
SVM					
Précision	50.1%	46.6%	42%	22.6%	45.3%
Sensibilité	48.5%	44%	44%	22%	50%
Spécificité	60 %	67%	73%	77%	71%
KNN					
Précision	49.01%	43.2%	40.6%	23.3%	43.3%
Sensibilité	62%	56%	38%	22%	48%
Spécificité	41%	57%	64%	77%	72%

Tableau III.6 : La précision de classification obtenue par chaque taille de cellule

La précision de classification augmente en fonction de la taille des cellules dont le classifieur obtient une grande quantité de caractéristiques de l'image de cerveau pour faire la différenciation entre les 3 stades de la maladie, Pour étudier un peu plus le facteur essentiel de la classification en machine Learning utilisant le descripteur du HOG nous avons appliqué se dernier sur les images segmentées par le k-means et nous obtenons les résultats montrés sur la **Figure III.21** et le **Tableau III.6**

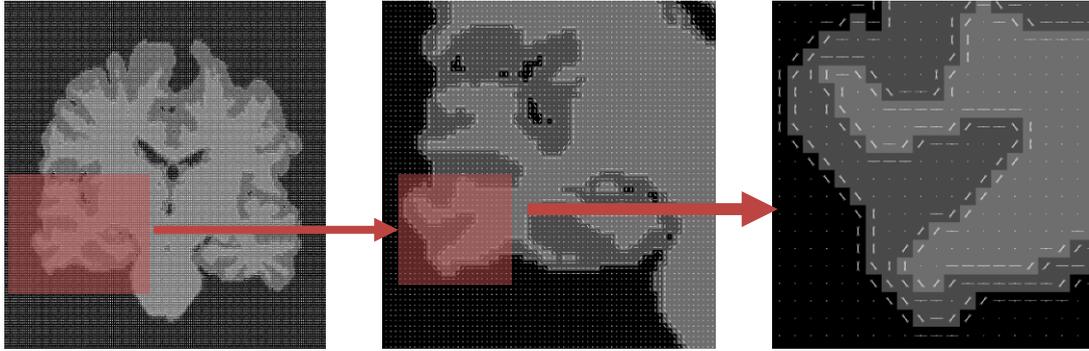


Figure III.21 : Extraction de caractéristiques d'une image segmentée par l'algorithme de k-means par une cellule de taille 1*1

Taille de cellules	1*1	
	SVM	KNN
Précision	44.1%	43.01%
Sensibilité	40.3%	45.2%
Spécificité	60.2%	55.1%

Tableau III.7: La précision de classification obtenue par chaque taille de cellule

Interprétation :

- La classification utilisant le SVM et KNN basés sur la caractéristique de HOG nous donne les meilleurs résultats utilisant la taille de cellule 1*1 avec une précision égale à 50% et 49% avec SVM et KNN respectivement.
- Le résultat réalisé par le HOG affirme que l'étude des gradients et les contours n'est pas suffisante pour le modèle SVM et KNN pour apprendre et faire la différenciation entre les stades de la maladie.
- L'application de la segmentation par K-means élimine l'information qui fait diminuer la précision de la classification. Prenons l'exemple de classifieur SVM 50% vers 44.1%.
- Le résultat de classification avec les images segmentées donne une théorie sur l'existence d'un effet de caractéristique de texture la classification de machine Learning.

ii. **Expérimentation 2** : classification par la caractérisation avec LBP :

D'après les résultats de l'expérimentation 1 nous avons passée vers l'étude de texture appliquons la méthode LBP, ainsi que le HOG le résultat de LBP dépends aux tailles de cellules, pour voir la différence des résultats entre la taille de cellules nous avons réalisée des tests changeons la taille de cellules, voir le **Tableau III.6**,

Taille de cellules	3*3	5*5	10*10
SVM			
Précision	54%	54%	53%
Sensibilité	56%	54%	60%
Spécificité	72%	72%	71%
KNN			
Précision	50.2%	51%	48.2%
Sensibilité	62%	54%	54%
Spécificité	65%	67%	67%

Tableau III.8: La précision de classification obtenue par chaque taille de cellule

Sachant que la segmentation k-means élimine les informations structurelles sur les régions, nous avons réalisé un test de LBP sur les images segmentée puis lancé la classification avec ses derniers caractères, voir la figure 7.5

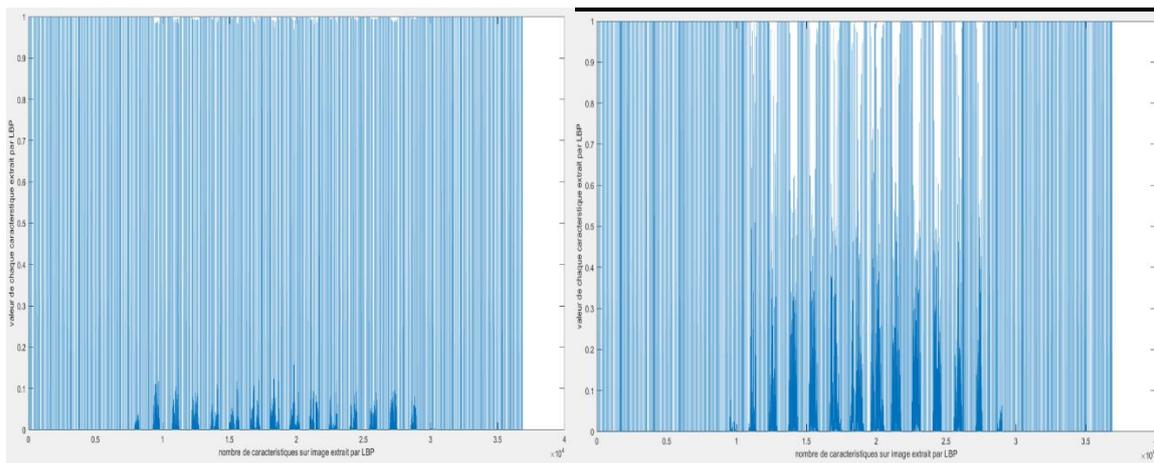


Figure III.22: Un graphe présente les information extrait par LBP avec une cellules de taille 10*10 sur une image segmentée a gauche et originale a droite

D'après la figure précédente nous remarquons une différence de valeur d'information (moins pour l'image segmentée) ; pour confirmer la valabilité de ces résultats nous avons

fait une classification selon ces caractéristiques utilisons les caractéristiques extraire par une cellule de taille 5*5 qui nous donne le meilleur résultat au début, les résultats sont présenté sur le **Tableau III**.

Taille de cellules	5*5
SVM	
Précision	43%
Sensibilité	25%
Spécificité	80%
KNN	
Précision	42%
Sensibilité	12%
Spécificité	97%

Tableau III.9: Résultats de classification obtenue par chaque taille de cellule LBP

Interprétation :

- Les résultats de classification de LBP est mieux que le HOG obtenons une précisions de 54 % avec le SVM et 51% de précision avec le KNN. Utilisons une taille de cellules de 5*5.
- Le résultat de classification avec la caractérisation de LBP ne développe pas en fonction de taille de cellules, affirmons cette théorie comparons entre les résultats obtenus par la taille de cellules 5*5 et 3*3.
- La texture d'image présente un facteur important pour l'identification de l'image dans la classification. Basons sur ce type de caractéristique extraites et pas sur le nombre des caractéristiques.

iii. Expérimentation 3 : Résultat de classification par la texture (GLCM) :

Basant sur l'interprétation de l'expérimentation 2 nous avons essaie d'enrichir notre étude sur la texture appliquant le GLCM et calculons 7 différents éléments de textures, après nous avons augmenté le nombre des éléments de textures vers 12 éléments pour voir la différence entre les résultats.

Les 7 éléments : Energie, entropie, contraste, homogénéité, corrélation, ombre, prominence.

Les 12 éléments : Energie, entropie, contraste, homogénéité, corrélation, ombre, prominence, dissimilarité, Deuxième moment angulaire, moment différent inverse, somme variance , somme entropie . (Voir les annexes B)

<i>Taille de cellules</i>	7 éléments	12 éléments
<i>SVM</i>		
<i>Précision</i>	38%	40%
<i>Sensibilité</i>	30%	44%
<i>Spécificité</i>	78%	68%
<i>KNN</i>		
<i>Précision</i>	32%	37%
<i>Sensibilité</i>	12%	36%
<i>Spécificité</i>	97%	66%

Tableau III.10 : Les résultats de précision selon les éléments de texture utilisé

La précision de classification s’augmente l’orsque n’a ajouter autres éléments de textures, cela confirme l’idée conclu dans l’extraction des caractéristiques par LBP que la texture aide le classifieur à bien apprendre.

iv. Comparaison :

- La cartérisation est la procédure la plus important de classification en apprentissage automatique, prenons l’expérimentation 1 et 2 la caractérisation avec le HOG n’était pas précise pour la classification comme la caractérisation par le LBP qui nous a donné une précision égale à 54 % et 51 % pour le SVM et KNN respectivement, et 50% et 47 % de précision utilisant les caractéristiques du HOG , qui nous affirme que les caractéristiques de texture sont très utiles dans la classification.
- Comparons l’expérimentation 2 et 3, les résultats de LBP est plus valable que les résultats de la méthode GLCM, expliquons ce resultat par la diffirance entre les types

de caractéristique de textures extrait par le LBP et GLCM, qui affirme le valabilité d'apprentissage lorsque on base sur la détection d'existence de texture avec le LBP.

3. 3. Apprentissage approfondie

Dans cette partie, nous avons créé des architectures CNN simple différents, au but de réaliser une étude comparative pour extraire les facteurs essentiels de deep Learning. Les réseaux de neurone convolutif ou le CNN est l'algorithme le plus utilisé dans le domaine d'apprentissage approfondie qui est spécifiée par des multicouche de convolution.

1. Expérimentation 1 : Application de deux couches de convolution (CNN1)

Dans cette expérimentation nous avons réalisé une classification avec un simple CNN de 2 couches de convolution. La **Figure III.23** représente la structure générale du CNN1

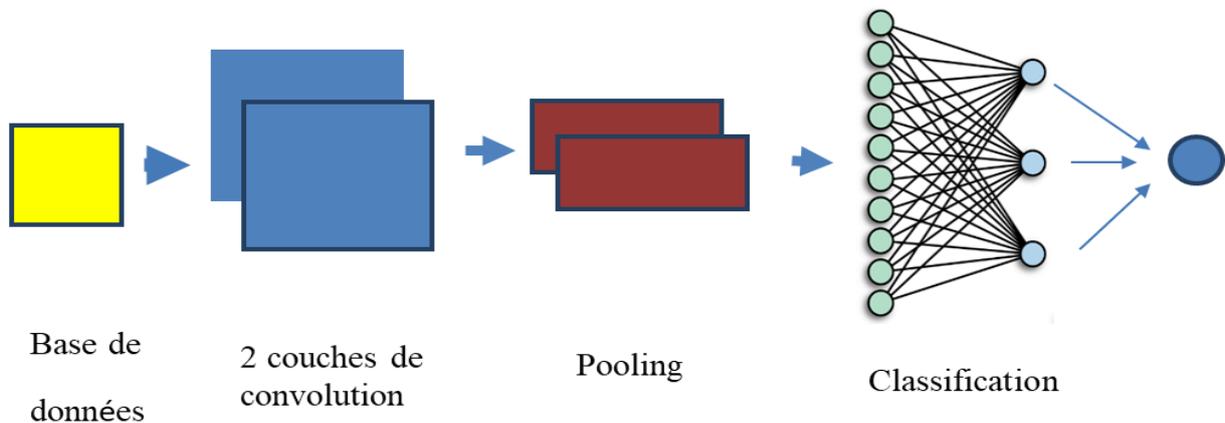


Figure III.23: La structure générale de CNN avec 2 couches utilisé

Résultats et discussion de CNN1 :

Dans cette partie nous présentons les résultats de classification de CNN1 tenons en considération que nous avons séparé la base de données en 75% pour la partie d'apprentissage et le reste pour le teste (validation). La figure suivante présente le résultat d'apprentissage de CNN1 :

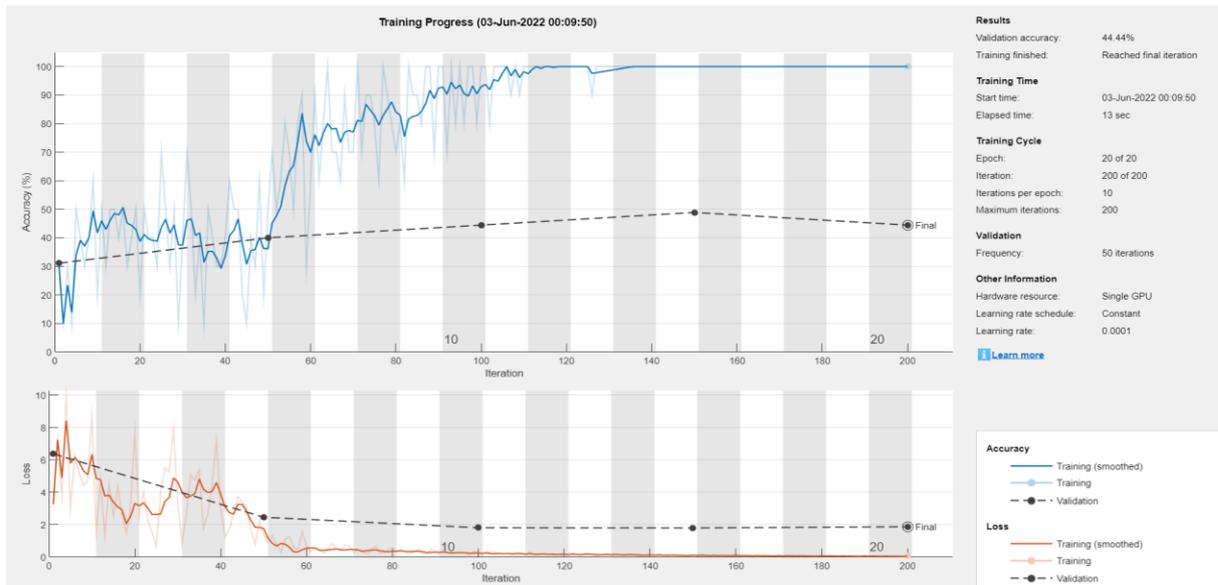


Figure III.24 : Développement de précision de CNN 1

A travers les résultats de multi classification obtenue par CNN1 voici les résultats de précision de chaque classe

	MCI	AD	CN
Précision			
CNN1	33.3%	57.1%	46.2%

Tableau III.11: Les résultats de précision de CNN1 sur les 3 stade de la maladie

Interprétation :

- Nous avons obtenu des résultats de précision total égale a 44% avec le CNN1 sachant que ce CNN nous donne une précision égale à 33.3% pour la classe MCI ,57.1% pour la classe AD et 46.2% pour la classe CN avec 13 secondes de temps d'exécution voyant les résultats de la figure III.24 et le tableau III.10 nous constatons que il y a une faible précision avec une grande différence entre le graphe validation et le graphe d'apprentissage , cela signifie que le CNN1 est un modèle sous-apprentissage (Under-fit),
- Prenons en considération le 2^{iem} graphe de perte (loss) lors de la classification, le résultat obtenu est une grande différence entre la validation est la perdre estime, qui nous affirme qu'il y a une perte d'information pour l'apprentissage de classifieur qui valide le résultat de précision obtenue.

Pour résoudre Le problème de sous-apprentissage qui était expose au classifieur de CNN1 nous proposons 2 solutions :

- Augmenter la complexité de CNN1 (voir l'expérimentation 2)
- Augmenter la taille de la base de données. (voir l'expérimentation 3)

2. Expérimentation 2 : l'application du CNN 2 de 3 couches de convolution sur la base de données

Basons sur les résultats de première expérimentation, nous avons augmenté la complexité de CNN1 ajoutons une autre couche de convolution et pooling donc nous avons obtenu un deuxième CNN : CNN2, pour faire une étude sur l'effet de la complexité de CNN sur les résultats de classification. La **Figure III.25** représente la structure générale de CNN2

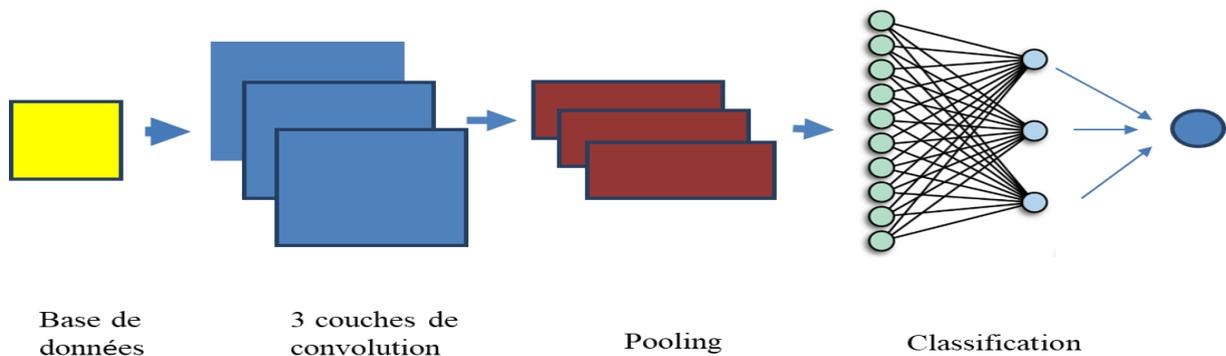


Figure III.25 : Structure de CNN en 3 couches de convolution utilisé

Après l'augmentation de la complexité du modèle nous avons eu un changement sur le résultat, les résultats présentés sont dans **Figure III.26**, qui montre le développement de précision dans le cas de 3 couches de convolution

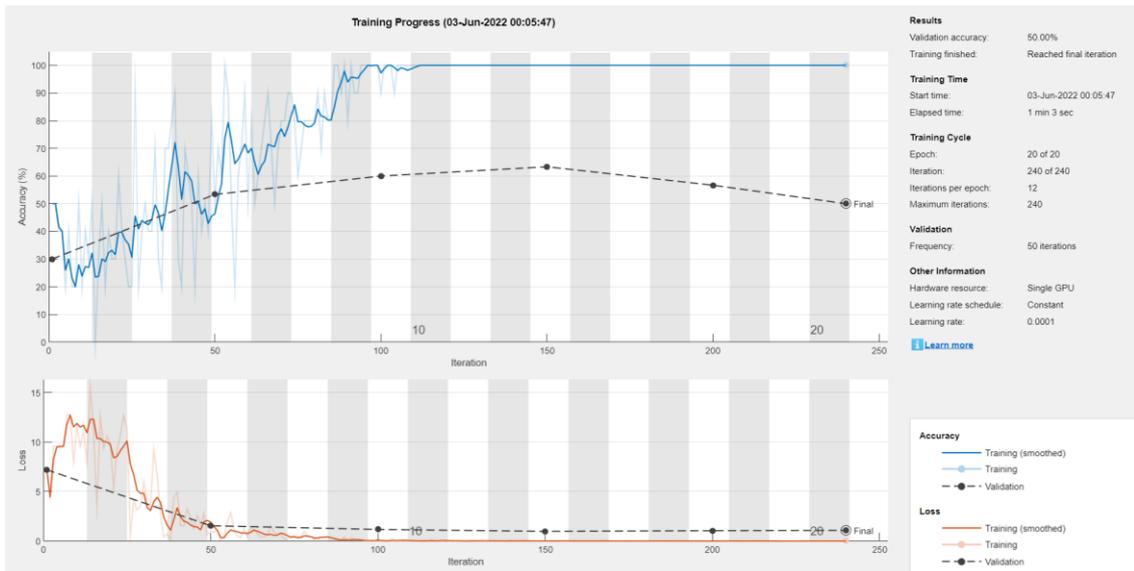


Figure III.26: Développement de précision et la perte

	MCI	AD	CN
Précisions			
CNN2	40%	50%	58%

Tableau III.12: Les résultats de précision de CNN2 sur les 3 stade de la maladie

Interprétation :

- Le changement de nombre de couches de convolution augmente la précision de CNN2 comparons avec le CNN1 sachant que la précision totale de CNN2 est égale à 50%.
- Le résultat de précision du CNN2 sur les trois stade est différent, nous avons obtenu 40%,50% et 58% de précision pour les classes MCI, AD et CN respectivement.
- L'augmentation des couches de convolution développe la complexité de CNN1, cette étape permet de CNN2 de mieux apprendre mais ça reste insuffisante pour donner des résultats précis.

L'augmentation de complexité de CNN2 est insuffisante pour résoudre le problème de sous-apprentissage pour cela nous avons passé vers la troisième expérimentation proposons une solution qui sert à l'augmentation de la base de données.

3. **Expérimentation 3** : l'application du CNN2 avec une augmentation de base de données :

Dans cette expérimentation nous allons essayer de continuer l'étude sur le rendement de CNN, l'expérimentation précédente nous a orienté pour base sur les données de l'entrée donc nous allons renommer le CNN2 avec '**Alzhnet**' et réaliser une augmentation de la base de données appliquons des opérations de recalage, rotation sur la base de données prétraité.

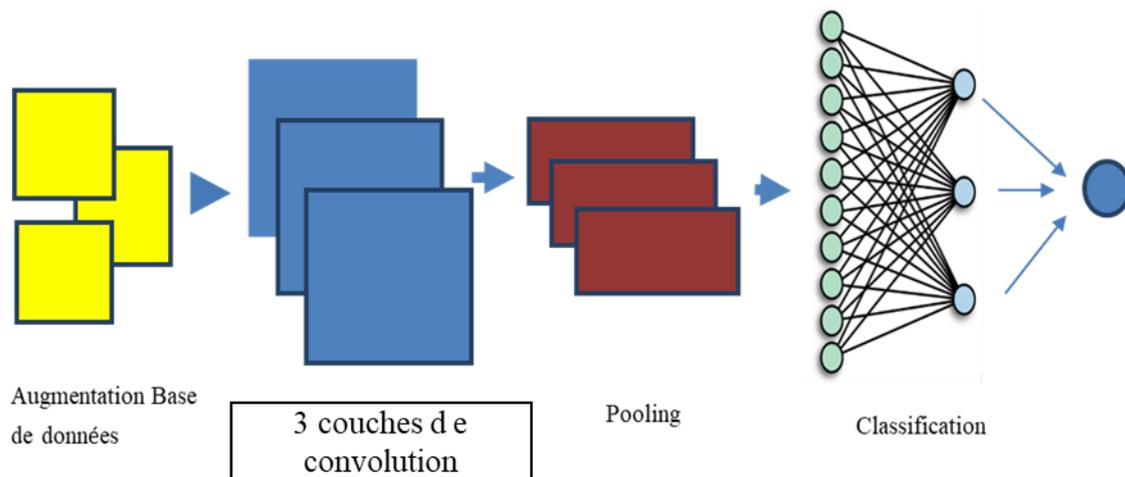


Figure III.27: Structure générale de Alzhnet.

Résultat et discussion La figure III.28 représente les résultats d'apprentissage de model *Alzhnet* sur la base de données augmentée

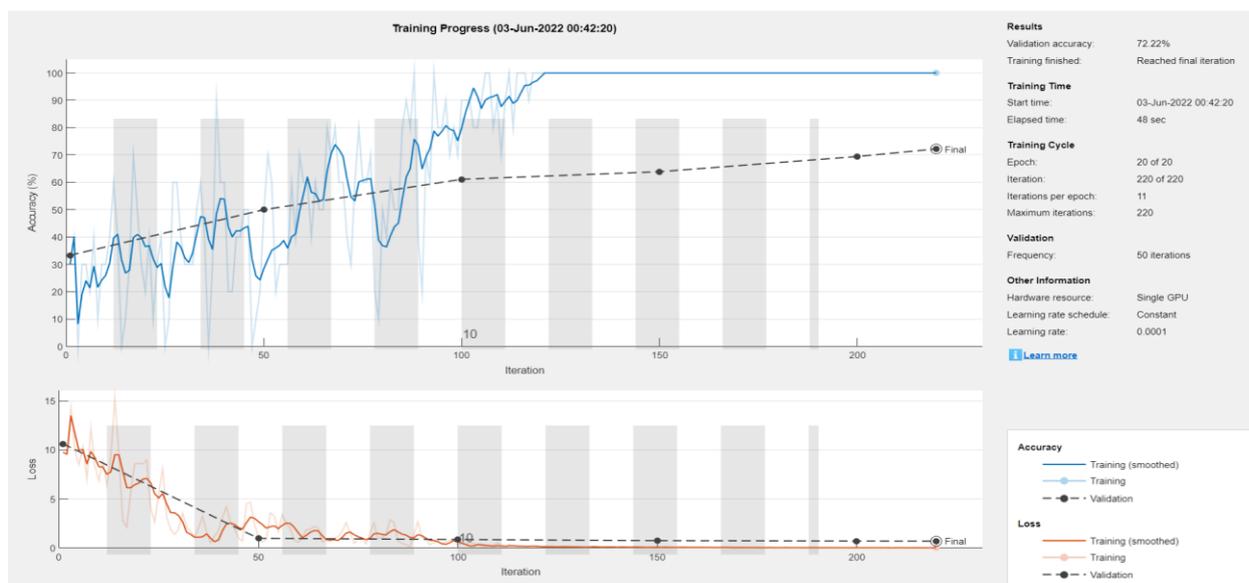


Figure III.28: Développement de précision et la perte

Le tableau III.12 représente les résultats de précision obtenus par *Alzhnet* pour chaque classe

	MCI	AD	CN
Précisions			
CNN2	83.3%	73.3%	66.7%

Tableau III.13: Les résultats de précision de *Alzhnet* sur les 3 stade de la maladie

Interprétation :

- Nous avons obtenu une précision totale égale à 72.22% avec le model *Alzhnet* et une précision égale à 83.3% de stade MCI, et une précision égale 73.3% et 66.7% pour le stade AD et CN respectivement.
- Cette grande différence par rapport au expérimentations précédente, revient à l'augmentation de base de données qui nous affirme que la taille de la base de données influe sur le rendement de CNN.
- L'augmentation de base de données, donne un champ très riche d'information, qui donne au *Alzhnet* la possibilité de collecter les informations suffisantes pour différencier entre les 3 stades de la maladie.

Les résultats suivante affiche le teste de Alzhnet sur des images quelconques pour les 3 stade

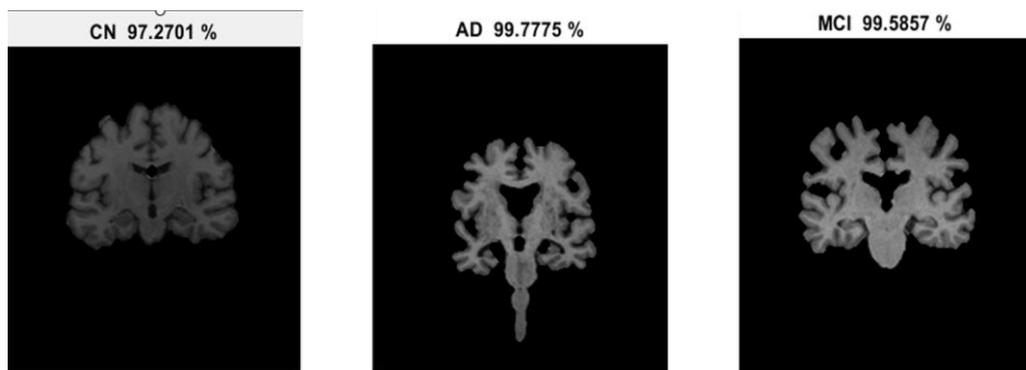


Figure III.29: Résultat de teste d Alzhnet

La figure III.29 représente les résultats de taux de prédiction pour des échantillons donnée au *Alzhnet* , à travers ces résultats nous constatons que le model *Alzhnet* nous a donné des résultats valables avec un taux de prédiction pour les 3 classes égale: 97.27% pour le cas normal (CN),99.7775% pour le cas Alzheimer (AD) et 99.55 % pour le cas précoce (MCI) .

Notez que le model Alzhnet est traine sur des images prétraité (filtre et sur un cerveau isole) de taille 256*256, nous avons teste aussi notre modèle par des images non traité, les résultats est présenté dans la figure III.30



Figure III.30: Résultat de teste d Alzhnet sur des images non traites

A travers ces expérimentations sur le modèle *Alzhnet* nous constatons que l'étape d'isolation de cerveau nous permettons de bien classer la phase MCI.

4. Comparaison :

Dans le but d'étudier l'impact de la complexité de modèle de deep Learning et la taille de base de données nous avons réalisé les trois expérimentations, sachant que dans l'expérimentation 1 et 2 nous avons étudié l'impact de complexité de modèle CNN et dans l'expérimentation 3 l'impact de la taille de base de données sur le modèle.

Nous avons obtenu une précision égale à 44% dans l'expérimentation 1, et lorsque nous avons augmenté la complexité de modèle avec une seule couche de convolution et de pooling nous avons obtenu une précision égale à 50% ça signifie que la complexité de modèle joue un rôle important pour la classification. Par contre, l'expérimentation 3 nous a confirmé que la taille de base de données est un élément crucial pour la phase d'apprentissage sachant que lorsque nous avons augmenté la base de données gardons les mêmes propriétés de CNN2, nous avons obtenu une précision de 72.22%. Cette comparaison confirme que le facteur essentiel pour entraîner un modèle de deep Learning est la taille de base de données prenons en considération la complexité du modèle.

4. Comparaison entre deep learning et machine learning

L'apprentissage automatique et approfondi (machine Learning et deep Learning) sont de types de classification différentes selon le principe de fonctionnement et les effets sur le rendement de classification, prenons les résultats de l'expérimentation faite dans ce chapitre le ML basé sur la qualité et le type des caractéristiques de l'image, dans la partie 1 nous avons eu une meilleure précision de 54% par le ML avec les caractéristiques de LBP donc ce type d'apprentissage donne de bons résultats utilisant une petite base de données. Par contre le rendement de l'apprentissage approfondi dépend de 2 paramètres qui sont la taille de la base de données (input) et la complexité du modèle, ce type d'apprentissage a besoin d'une grande base de données et la complexité pour qu'il donne ses meilleurs résultats, lorsque nous avons augmenté le nombre de couches de convolution et la base de données dans le *Alzhnet*, nous avons eu 72.22% de précision.

La comparaison entre le résultat de ML et DL nous donne des points positifs et négatifs sur chaque type d'apprentissage, débutant par ML qui a besoin juste d'une petite base de données et une caractérisation des images selon la texture pour donner de meilleures performances (la figure III.3.A), mais ce rendement reste le meilleur juste dans le cas d'une

petite base de données, comme nous avons conclu au début. Le DL peut donner des résultats mieux que le ML en fonction de changement de ces paramètres, l'augmentation de nombre de couche de convolution reste insuffisante pour dépasser le rendement de ML (figure III.30.B), l'augmentation de base de données a un impact très efficace sur l'augmentation de rendement de Deep Learning par rapport au machine Learning ou nous pouvons mettre le point de différence entre les deux types d'apprentissage.

A la fin, nous pouvons confirmer que l'apprentissage approfondi reste le meilleur choix de types de multi-classification, mettons en considération son niveau de complexité et la taille de base de données.

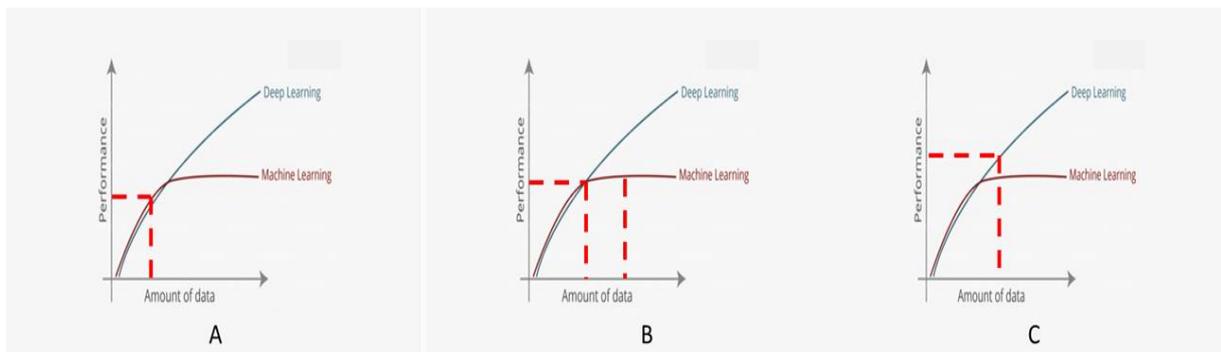


Figure III.31 : Comparaison entre le DL et ML

A- Le point où le ML donne des meilleures performances

B- La constance de performance de ML malgré l'augmentation de la base

C- Le résultat de performance de DL par rapport ML augmentons la base de

5. Interface graphique de Alzhnet

Basés sur les résultats de classification obtenus avec le 'Alzhnet', nous allons réaliser une interface graphique à l'aide de **APPDESIGNER. Matlab**, cette interface a pour objectif de classer la maladie d'Alzheimer et précisément le cas précoce, la figure suivante montre la forme de notre base,

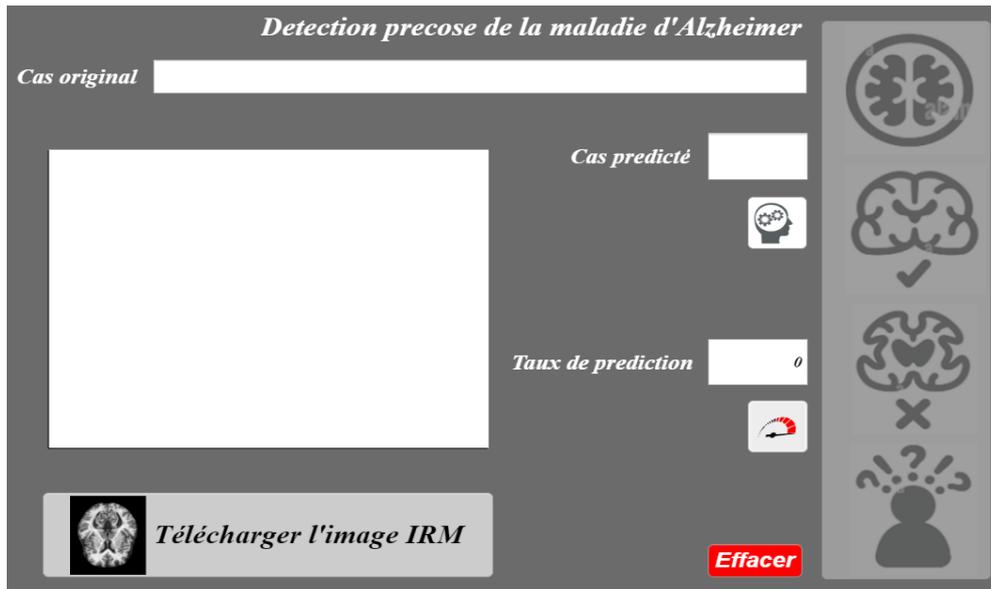


Figure III.32 : Interface graphique de détection précoce de la maladie d'Alzheimer

Après que nous avons réalisé cette interface, nous allons teste une image de cas MCI en vérité terrain montrons les résultats sur la figure III.33

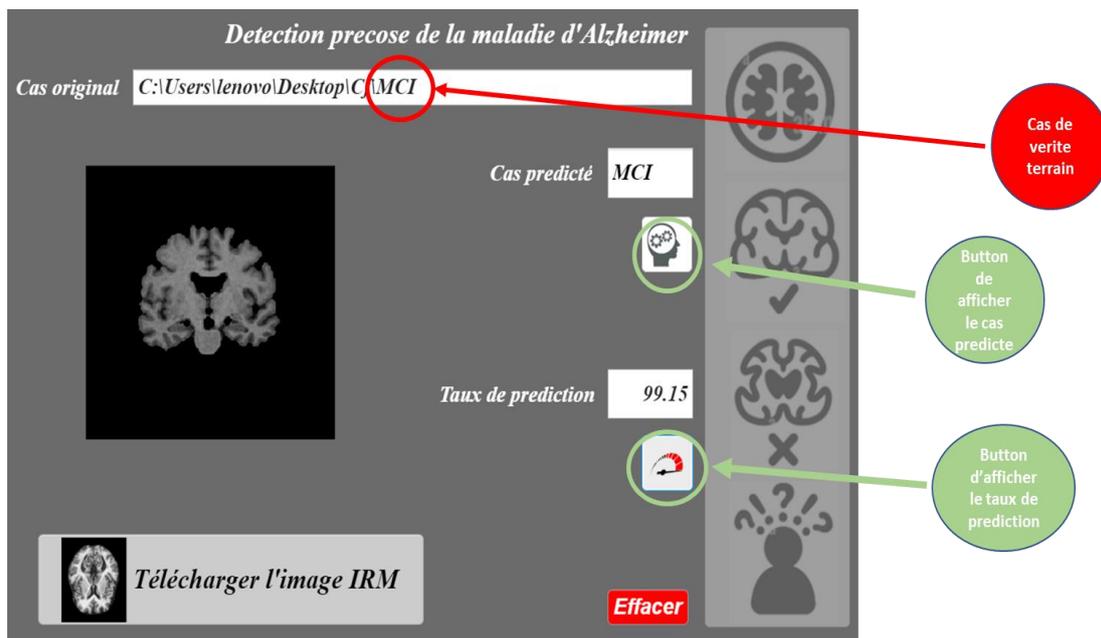


Figure III.33 : Interface graphique de détection précoce de la maladie d'Alzheimer

6. Conclusion

L'objectif de ce chapitre était d'appliquer les méthodes de l'intelligence artificiel afin de classer les stades d'une maladie d'Alzheimer. Dans ce but nous avons réalisé plusieurs études comparatives premièrement pour choisir le bon filtre. La comparaison entre les métriques de classification et caractérisation pour que nous pouvons classifier l'état précoce de la maladie d'Alzheimer, dans la partie de caractérisation et machine Learning nous conclut que la caractérisation de gradient de l'image par le HOG n'a pas un grand impact sur le taux de classification au machine Learning, contrairement pour la texture extrait par le LBP qui représente un facteur important pour l'identification de l'image lors de la classification.

Dans la partie de deep Learning, nous avons conclu que les l'application de deep Learning toujours besoin une grande base de données pour données des performance valable et nombre de couche de convolutions ou la complexité de convolution, compatible avec le type des données et l'apprentissage pour que nous évite le Under-fit upper-fit contrairement pour la machine Learning qui se base précisément sur la caractérisation et le type des caractéristiques.

*‘Conclusion
General’*

Conclusion générale

La maladie d'Alzheimer est une maladie neurodégénérative entraînant la mort des neurones et la perte progressive de la mémoire et de certaines fonctions intellectuelles (cognitives) qui affectent les activités de la vie quotidienne. Cette situation a incité la communauté scientifique à mener plusieurs études qui pourraient contribuer à réduire l'incidence de la maladie et sa progression. Dans notre travail, nous avons étudié les deux approches de l'intelligence artificielle pour la détection précoce de la maladie d'Alzheimer qui sont l'apprentissage automatique et l'apprentissage profond. L'objectif est d'étudier l'impact de la taille de la base de données sur la phase d'apprentissage dans les méthodes mentionnées ci-dessus, en outre, nous avons étudié les méthodes utilisées dans le domaine de la vision par ordinateur plus précisément dans la détection des objets tels que le HOG et le LBP en tant que descripteur combiné avec le Machine Learning pour prédire la maladie. Pour les deux approches nous avons réalisé une phase de pré-traitement afin d'augmenter la qualité des images IRM et garder les informations essentielles, en conséquence, nous avons réalisé une étude comparative de différents filtres pour choisir le meilleur filtre qui élimine le bruit et conserve les informations de l'image IRM. Avec cela, nous avons appliqué une phase de décapage du crâne pour ne garder que le cerveau, ce qui nous aidera à prédire la phase MCI.

Interprétant les résultats, nous avons mis une conclusion à-propos de machine Learning et deep Learning, cette conclusion affirme que le deep Learning est le meilleur type de classification, qui donne des résultats acceptables est un taux de prédiction valable, notons que cette valabilité des informations revient pour la taille de la base de données grandes et le niveau de complexité compatible, et que la caractérisation et précisément l'extraction de caractéristique de texture, est la meilleure pour le machine Learning basés sur l'interprétation des expérimentations de la première partie de chapitre 3.

Perspective :

Ce projet présente un essai de classification de la maladie d'Alzheimer et précisément la détection de cas MCI de la maladie, et qui peut être exposé d'un développement selon les méthodes utilisées pour donner un meilleur rendement.

L'augmentation de la base de données utilisant le Deep Learning est le facteur important pour augmenter les performances de détection précoce de la maladie d'Alzheimer.

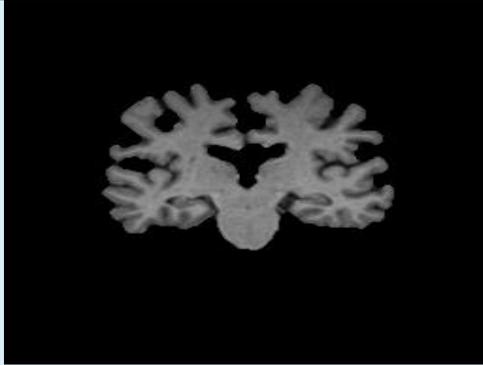
L'extraction des caractéristiques présente l'étape importante de machine Learning, donc l'application d'une concaténation des types d'extraction de caractéristiques peut donner plus de possibilités d'apprentissage valable qui augmentent la précision.

La segmentation utilisée dans ce travail n'était pas valable sur la classification, il est possible d'appliquer la segmentation par Fuzzy means qui donne des meilleurs résultats de classification.

Annexes

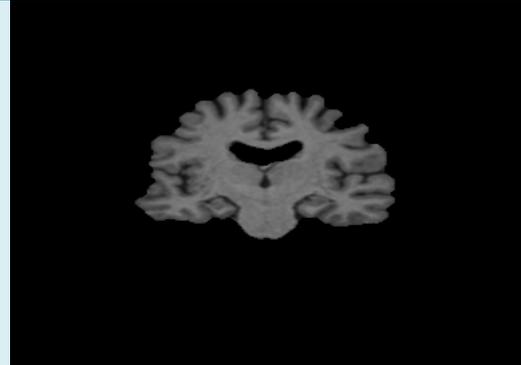
Annexe A

Cas precoce de la maladie (MCI)



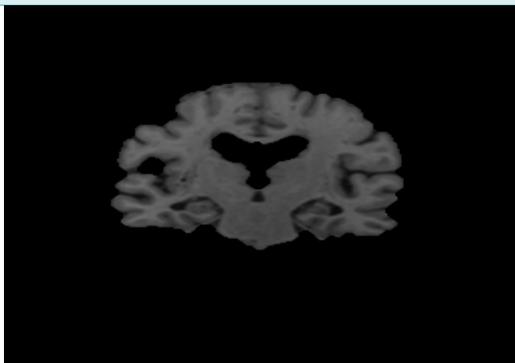
Patient 1

Image 1



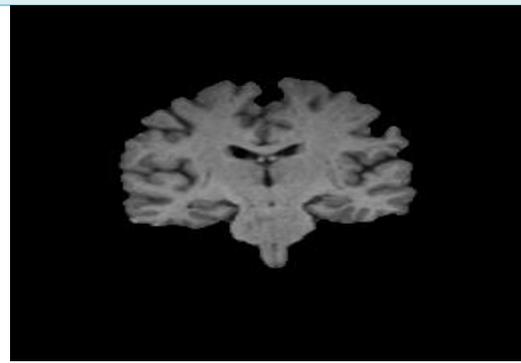
Patient 2

Image 2



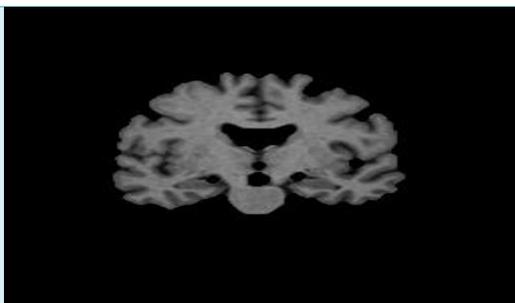
Patient 3

Image 3



Patient 4

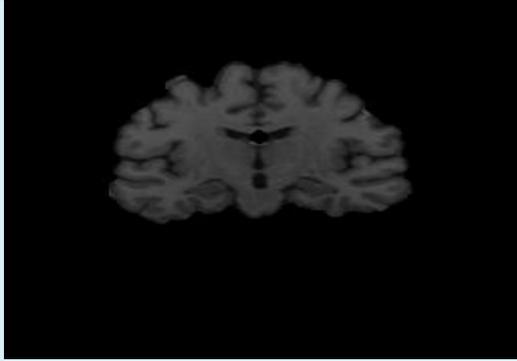
Image 4



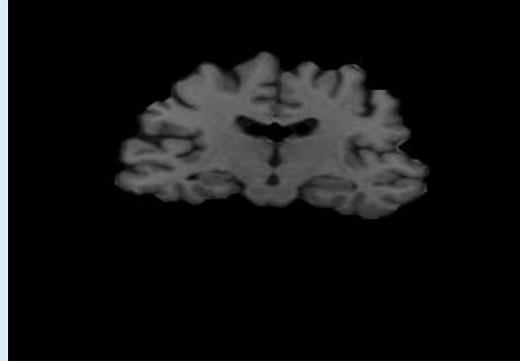
Patient 5

Image 5

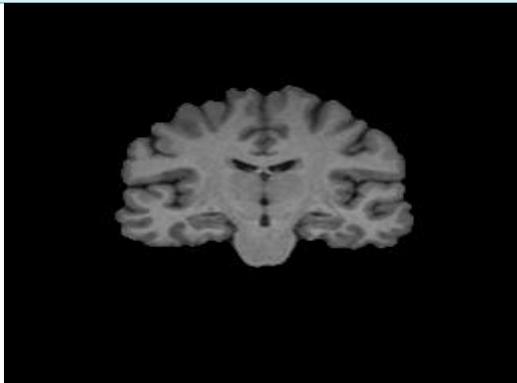
Cas normal(CN)



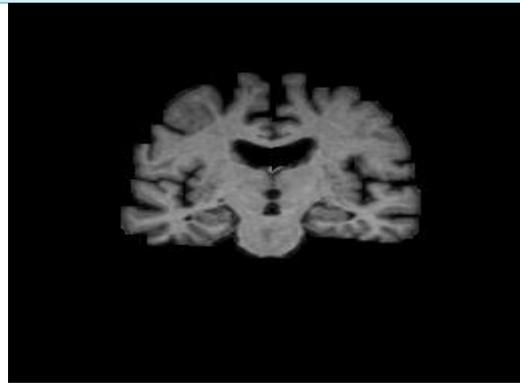
Patient 1
Image 1



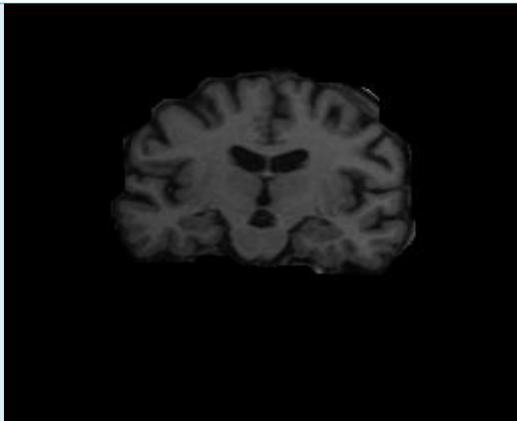
Patient 1
Image 1



Patient 3
Image 3

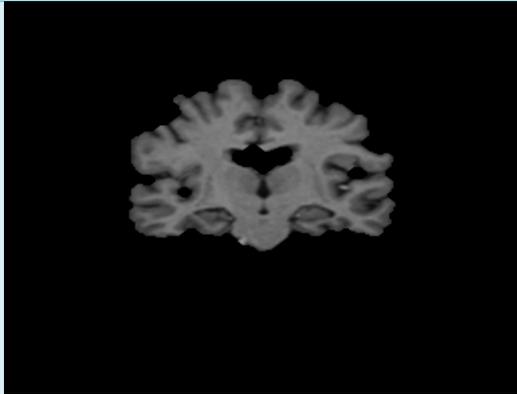


Patient 4
Image 4



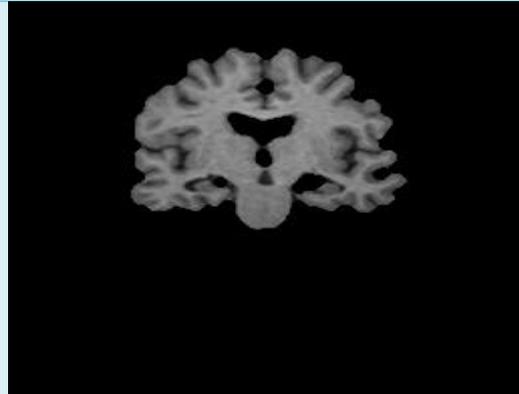
Patient 5
Image 5

Cas maladie d'Alzheimer (AD)



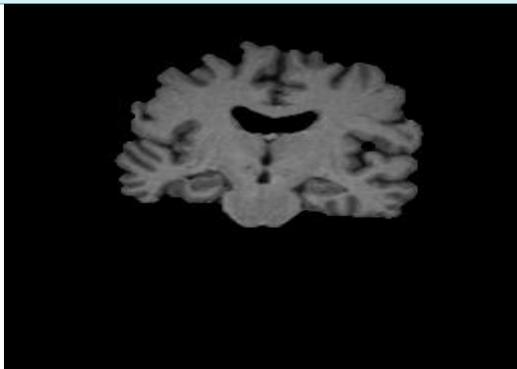
Patient 5

Image 5



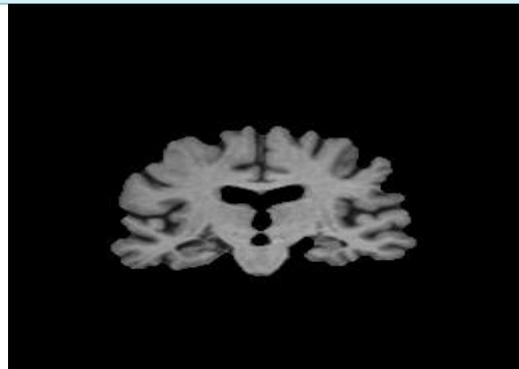
Patient 5

Image 5



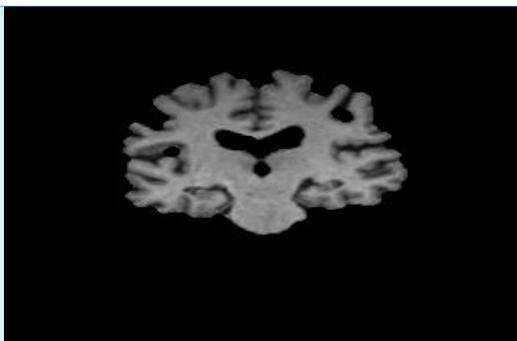
Patient 5

Image 5



Patient 5

Image 5



Patient 5

Image 5

Annexe B

Element de texture	Equation
Entropie	$(-\sum_{j \in D_j} P_j \cdot \log(P_j))$
Contraste	$\sum_{i,j=0}^{N-1} P_{ij}(i-j)^2$
Homogénéité	$\sum_{i,j=0}^{N-1} \frac{P_{ij}}{1+(i-j)^2}$
Energie	$\sum_{i,j=0}^{N-1} (p_{ij})^2$
Ombre	$\text{sgn}(A) A ^{1/3}$
Prominence	$\text{sgn}(B) B ^{1/4}$
Correlation	$\sum_{i,j=0}^{N-1} P_{ij} \frac{(i-\mu)(j-\mu)}{\sigma^2}$
dissimilarité	$\sum_{i,i=0}^{N-1} P_{i,j} i-i $
Deuxieme moment angulaire	$\sum_{i=1}^G \sum_{j=1}^G \{p(i,j)\}^2$
Moment different inverse	$\sum_{i,j} \frac{P_{i,j}}{1+(i-j)^2}$
Some entropie	$-\sum_{i=2}^{2Ng} p_{x+y}(i) \log(p_{x+y}(i))$
Some variance	$\sum_{i=2}^{2Ng} (i-f_{14})^2 p_{x+y}(i)$

Les références

- [1] Gall, F. J. (1810). *Anatomie et physiologie du système nerveux en général, et du cerveau en particulier: Atlas* (Vol. 1).
- [2] (<https://cancer.ca/fr/cancer-information/cancer-types/neuroblastoma/what-is-neuroblastoma/the-nervous-system>) 20-05-2022
- [3] (<https://cancer.ca/fr/cancer-information/cancer-types/brain-and-spinal-cord/what-is-a-brain-or-spinal-cord-tumour/the-brain-and-spinal-cord>) 20-05-2022
- [4] Luys, J. (1878). *Le cerveau et ses fonctions* (Vol. 19). Baillière.
- [5] (<http://www.psychomedia.qc.ca/neurologie/2009-06-18/matiere-grise-et-matiere-blanche-du-cerveau-definitions>) 02-06-2022
- [6] Nógrádi, A., & Vrbová, G. (2006). Anatomy and physiology of the spinal cord. In *Transplantation of neural tissue into the spinal cord* (pp. 1-23). Springer, Boston, MA.
- [7] (<https://www.larousse.fr/encyclopedie/medical/encéphale/12760>) 20-05-2022
- [8] (<http://www.psychomedia.qc.ca/neurologie/2009-06-18/matiere-grise-et-matiere-blanche-du-cerveau-definitions>) 21-05-2022
- [9] (<http://www.psychomedia.qc.ca/neurologie/2009-06-18/matiere-grise-et-matiere-blanche-du-cerveau-definitions>) 21-05-2022
- [10] (<https://www.futura-sciences.com/sante/dossiers/medecine-voyage-cerveau-525/page/3/>) 21-05-2022
- [11] (<https://planet-vie.ens.fr/thematiques/sante/pathologies/les-maladies-neurodegeneratives>) 22-05-2022
- [12] Morrison, J. H., & Hof, P. R. (1997). Life and death of neurons in the aging brain. *Science*, 278(5337), 412-419.
- [13] (<https://planet-vie.ens.fr/thematiques/sante/pathologies/les-maladies-neurodegeneratives>) 21-05-2022
- [14] Cotman, C. W., & Su, J. H. (1996). Mechanisms of neuronal death in Alzheimer's disease. *Brain pathology*, 6(4), 493-506.
- [16] (<https://institutducerveau-icm.org/fr/actualite/comprendre-le-cerveau-et-son-fonctionnement/>) 02-06-2022
- [17] (<https://www.revmed.ch/revue-medicale-suisse/2017/revue-medicale-suisse-582/demences-frontotemporales-mise-a-jour>) 25-05-2022

- [18] (Soler, C., F., Giatrakou, V., Papa, S., Scheffler, M., Frisoni, G., B. (2017), Démences frontotemporales : mise à jour, *Rev Med Suisse*, 3, no. 582, 1917-1923. <https://doi.org/10.53738/REVMED.2017.13.582.1917>) 25-05-2022
- [19] du CHU, D. (1984). *Etude de la pertinence du diagnostic biologique de la maladie d'Alzheimer à partir de l'expérience* (Doctoral dissertation, UNIVERSITE DE LIMOGES).
- [20] ([https://fr.wikipedia.org/wiki/Hippocampe_\(cerveau\)](https://fr.wikipedia.org/wiki/Hippocampe_(cerveau))) 07-06-2022
- [21] Vellas, B., FITTEN, L., & ALBAREDE, J. (2007). Maladie d'Alzheimer. *L'année gériatrique*, 8.
- [22] Cummings, J. L., & Cole, G. (2002). Alzheimer disease. *Jama*, 287(18), 2335-2338.
- [23] sante journal des femmes 'atrophie cortico sous-corticale définition et causes'
- [24] e-semio.org/spip.php?page =tableautype12&id_rubrique=2286
- [25](<http://www.sfrnet.org/formation/mediatheque/Textes/07%20-%20Neuroradiologie/article.phtml?id=rc%2Forg%2Fsfrnet%2Fhtm%2FArticle%2F2011%2F20110601-081135-921>) 08-06-2022
- [26] (https://www.info-radiologie.ch/resonance_magnetique.php) 08-06-2022
- [27] Kastler, B., Anstett, P., Kastler, B., & Vetter, D. (2011). *Comprendre l'IRM*. Elsevier Health Sciences France.
- [28]<http://www.sfrnet.org/formation/mediatheque/Textes/07%20-%20Neuroradiologie/article.phtml?id=rc%2Forg%2Fsfrnet%2Fhtm%2FArticle%2F2011%2F20110601-081135-921>) 08-06-2022
- [29] (<https://www.edimark.fr/ressources/sclerose-plaques-m-146-a-brise-c-156-ur-1re-irm-sequence-flair-montrant-lesion-periventriculaire>) 08-06-2022
- [30] (<https://www.futura-sciences.com/tech/definitions/informatique-intelligence-artificielle-555/>). Et :[<https://www.cortex-mag.net/lintelligence-artificielle-pourrait-elle-un-jour-egaler-lintelligence-humaine/>) 08-06-2022
- [30] Nicholas, B., Jayakumar, A., Titus, B., & Remya Nair, T. (2022). Comparative Study of Multiple Feature Descriptors for Detecting the Presence of Alzheimer's Disease. In *Ubiquitous Intelligent Systems* (pp. 331-339). Springer, Singapore.

- [31] Murugan, S., Venkatesan, C., Sumithra, M. G., Gao, X. Z., Elakkiya, B., Akila, M., & Manoharan, S. (2021). DEMNET: a deep learning model for early diagnosis of Alzheimer diseases and dementia from MR images. *IEEE Access*, 9, 90319-90329.
- [32] Garg, N., & Chaudhary, M. (2021, November). Implementation of Dual Tree Complex Wavelet Transform with Mean Energy Features to detect Alzheimer's Disease. In *2021 7th International Conference on Signal Processing and Communication (ICSC)* (pp. 188-193). IEEE.
- [33] Feng, J., Zhang, S. W., Chen, L., Zuo, C., & Alzheimer's Disease Neuroimaging Initiative. (2022). Detection of Alzheimer's Disease Using Features of Brain Region-of-Interest-Based Individual Network Constructed with the sMRI Image. *Computerized Medical Imaging and Graphics*, 102057.
- [34] Shankar, K., Lakshmanaprabu, S. K., Khanna, A., Tanwar, S., Rodrigues, J. J., & Roy, N. R. (2019). Alzheimer detection using Group Grey Wolf Optimization based features with convolutional classifier. *Computers & Electrical Engineering*, 77, 230-243.
- [35] Altaf, T., Anwar, S. M., Gul, N., Majeed, M. N., & Majid, M. (2018). Multi-class Alzheimer's disease classification using image and clinical features. *Biomedical Signal Processing and Control*, 43, 64-74.
- [36] Delyon, B. (1993). *Ondelettes orthogonales et biorthogonales* (Doctoral dissertation, INRIA).
- [37] jean-Frederic Gerbeau & Stephane Labbe, Editor ESAIM: PROCEEDINGS, July 2007, Vol.18, 216-228 MURENZI (maintenant ministre de l'Education et de la Recherche au Rwanda!).
- [38] <https://www.mathworks.com/help/wavelet/ref/symwavf.html>
- [39] Beucher, S. (1990). *Segmentation d'images et morphologie mathématique* (Doctoral dissertation, Ecole Nationale Supérieure des Mines de Paris).
- [40] <https://perso.esiee.fr/~perretb/I5FM/TAI/morpho/index.html>
- [41] Dhanachandra, N., Manglem, K., & Chanu, Y. J. (2015). Image segmentation using K-means clustering algorithm and subtractive clustering algorithm. *Procedia Computer Science*, 54, 764-771. [42] Tatiraju, S., & Mehta, A. (2008). Image Segmentation using k-means clustering, EM and Normalized Cuts. *Department of EECS*, 1, 1-7.
- [43] Tomasi, C. (2012). Histograms of oriented gradients. *Computer Vision Sampler*, 1-6.
- [44] Cattell, L., Platsch, G., Pfeiffer, R., Declerck, J., Schnabel, J. A., Hutton, C., & Alzheimer's Disease Neuroimaging Initiative. (2016). Classification of amyloid status using machine learning with histograms of oriented 3D gradients. *NeuroImage: Clinical*, 12, 990-1003

- [45] Mémoire de Fin d'Etudes de MASTER ACADEMIQUE Spécialité : Commande des systèmes Présentés par Aghiles GOUNANE Samira SADI
- [46] Hall-Beyer, M. (2017). GLCM texture: A tutorial v. 3.0 March 2017.
- [47]. Xue, H., Yang, Q., & Chen, S. (2009). SVM: Support vector machines. In *The top ten algorithms in data mining* (pp. 51-74). Chapman and Hall/CRC.
- [48] Peterson, L. E. (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883.
- [49] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., ... & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8(1), 1-74.
- [50] Gurucharan, M. (2020). Basic cnn architecture: Explaining 5 layers of convolutional neural network. URL:<https://www.upgradcom/blog/basic-cnn-architecture>.
- [51] Cattell, L., Platsch, G., Pfeiffer, R., Declerck, J., Schnabel, J. A., Hutton, C., & Alzheimer's Disease Neuroimaging Initiative. (2016). Classification of amyloid status using machine learning with histograms of oriented 3D gradients. *NeuroImage: Clinical*, 12, 990-1003.
- [52] Mohanaiah, P., Sathyanarayana, P., & GuruKumar, L. (2013). Image texture feature extraction using GLCM approach. *International journal of scientific and research publications*, 3(5), 1-5.
- [53] MEMOIRE DE PROJET DE FIN D'ETUDES pour l'obtention du Diplôme de MASTER en GENIE BIOMEDICAL Spécialité : Imagerie Médicale Présenté par : Saim Meriem Analyse des images IRM pour le diagnostic de la maladie d'Alzheimer, université de Tlemcen, département de GBM.
- [54] Kenigsberg, P. A., Ersek, K., Gulácsi, L., Karpati, K., JACQUES, A., Gustavsson, A., ... & Wimo, A. (2009). IMPACT SOCIO-ÉCONOMIQUE DE LA MALADIE D'ALZHEIMER. *Gérontologie et société*, (128/129), 297.

