

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire

وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة سعد دحلب البليدة
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الإلكترونيك
Département d'Electronique



Mémoire de Master

Filière: Genie Biomédicale

Spécialité : Instrumentation Biomédicale

Présenté par:

ZEMMOURI Rekia

&

LABDI Dounia

Détection des petites structures dans les images d'IRM Cérébrales

Proposé par : - Mr. Cherfa Yazid & M. Cherfa Assia

Année Universitaire 2020 / 2021

Dédicace

Nous tenons à dédier ce mémoire en particulier et en premier lieu à nos chers parents ;

Qui ont consacré leurs vies à l'éducation de leurs enfants,

Qui nous ont élevé avec amour et tendresse, et

Qui ont toujours cru en nous.

A nos chers frères et sœurs, à tous nos proches.

A tous les membres de la famille Zemmouri & Labdi ;

A toutes les personnes que nous portons dans notre cœur.

A tous nos amis(es) sans exception.

Aux étudiants de la spécialité génie biomédicale PROMO 2021.

Et à la fin, une dédicace spéciale à tous nos enseignants durant notre cursus scolaire,

du primaire à l'université.

Merci à toutes les personnes qui nous ont aidées de près ou de loin.

Remerciements

Tous d'abord nous remercions « ALLAH » de nous avoir donné la force et le courage pour réaliser ce modeste travail.

Nous exprimons nos vifs remerciements envers nos promoteurs

Mr. Y. CHERFA et Mme A. CHERFA qui nous ont guidé et suivi de très près, pour leur aide, leurs orientations, leur disponibilité et tous les conseils qu'ils nous ont généreusement prodigués durant l'accomplissement de ce travail.

Nous adressons nos plus vifs remerciements aux jurys pour l'honneur qu'ils nous ont fait en acceptant d'être rapporteur de notre mémoire.

Nous tenons à remercier l'ensemble des enseignants de la spécialité génie biomédicale.

Enfin, nous exprimons notre très grande reconnaissance à nos familles, nos pères, mères, sœurs et frères, sans oublier nos amis pour leurs encouragements, pour tous les soucis que nous leur avons causés et surtout pour avoir été toujours auprès de nous.

ملخص: مرض التنكس العصبي هو حالة مرضية تؤثر على الخلايا العصبية وتحكم عليها بالموت المؤكد. نقترح في عملنا نظام معالجة الصور، الهدف منه تحليل صور التصوير بالرنين المغناطيسي للدماغ، لتصنيف الصور وفقاً لوجود أو عدم وجود مرض تنكس عصبي، سنطبق نظامنا على ثلاث فئات (صحية، الزهايمر، صرع). يعتمد النظام المقترح على لتحقيق التصنيف الموصى به. يتم اختبار الخوارزميات المطورة على مجموعة Res-net التعلم العميق، وتم تطبيق بنية من الصور، مأخوذة من قواعد البيانات، ويتم تنفيذ تطور النتائج التي حصلنا عليها، من خلال تفسير الرسوم البيانية التي تم الحصول عليها.

الكلمات المفتاحية :

مرض التنكس العصبي، التصوير بالرنين المغناطيسي، التعلم العميق

Résumé : Une maladie neurodégénérative est un état pathologique, affectant les neurones, en les condamnant à une mort certaine. Nous proposons, dans notre travail, un système d'analyse des images d'IRM cérébrales, pour classifier les images, selon la présence, ou l'absence d'une maladie neurodégénérative. Nous allons considérer, dans notre cas, trois catégories (sain, Alzheimer, épilepsie). Le système proposé est basé, sur l'apprentissage profond, avec une architecture Res-net, utilisée pour réaliser la classification recommandée. Les algorithmes développés sont testés sur un ensemble d'images, issue de bases de données, et l'évaluation des résultats, que nous avons obtenus est effectuée, en faisant une interprétation à partir des graphes obtenus.

Mots clés : maladie neurodégénérative, IRM, apprentissage profond, Res-net.

Abstract:

A neurodegenerative disease is a pathological condition affecting neurons condemning them to certain death. We propose in our work an image processing system, the goal of which is to analyze brain MRI images, to classify the images according to the presence or absence of a neurodegenerative disease. We applied our system on three categories (healthy, Alzheimer's, epilepsy). The proposed system is based on deep learning, a Res-net architecture was applied to achieve the recommended classification. The algorithms developed are tested on a set of images, taken from databases, and the evolution of the results that we obtained is carried out, by making an interpretation from the graphs obtained.

Keywords : neurodegenerative disease, MRI, deep Learning, Res-net.

Table des matières

Dédicace

Remerciements

Résumé

Table des matières

Liste des figures

Liste des tableaux

Liste des abréviations

Introduction générale	1
1 Aspect Médical	
1.1 Système nerveux	3
1.1.1 Système nerveux central	3
1.1.2 Système nerveux périphérique	4
1.1.3 Rôle essentiel du SN	4
1.2 Description macroscopique	5
1.2.1 Hémisphère	5
1.2.2 Lobes	5
1.2.3 Méninges	6
1.2.4 Matière grise	7
1.2.5 Matière blanche	7
1.3 Description microscopique	8
1.3.1 Cellules gliales	8
1.3.2 Neurones	8
1.4 Maladies neurodégénératives	9
1.4.1 Conséquences	9

1.4.2	Principales maladies.....	9
1.5	Imagerie par Résonance magnétique.....	9
1.5.1	Imageur IRM.....	9
1.5.2	Principe de l'IRM	10
2 Etat de l'art		
2.1	Travaux antérieurs.....	15
2.2	Récapitulatif des algorithmes d'analyse d'IRM.....	25
	Discussion.....	28
3 Outils mathématiques		
3.1	Organigramme	29
3.2	Deep Learning	29
3.2.1	Neurone biologique	30
3.2.2	Neurone artificiel ANN	32
3.3	Outils de classification	33
3.3.1	Couche de convolution	35
3.3.2	Couche de maxpooling	36
3.3.3	Conversion en vecteur (Flatten)	37
3.3.4	Couches totalement connectées	37
4 Implémentation, résultats et interprétation		
4.1	Description des bases de données utilisées	39
4.1.1	Environnement et langage de programmation	40
4.1.2	Logiciel d'implémentation.....	40
4.1.3	Bibliothèque TensorFlow.....	41
4.1.4	Logiciel ITK-SNAP	42
4.2	Organigramme général du système proposé	43
4.3	Classification.....	44
4.3.1	Acquisition d'image.....	44
4.3.2	Système proposé	45
4.3.3	Evaluation des résultats.....	51

4.4	Présentation de l'interface	53
	Conclusion générale.....	59
	Bibliographie.....	61

Liste des figures

FIGURE 1.1: Illustration du système nerveux.....	03
FIGURE 1.2: Lien entre le système nerveux et les organes du corps.....	04
FIGURE 1.3: Deux hémisphères du cerveau.....	05
FIGURE 1.4: Différents lobes du cerveau.....	06
FIGURE 1.5: Trois couches de méninge.....	07
FIGURE 1.6: Matières grise et blanche du SN.....	07
FIGURE 1.7: Neurone.....	08
FIGURE 1.8: Acquisition par IRM.....	10
FIGURE 1.9: Phase de relaxation.....	11
FIGURE 1.10: Séquence IRM.....	12
FIGURE 1.11: Inhomogénéité RF.....	14
FIGURE 2.1: Pourcentage des algorithmes les plus utilisées.....	28
FIGURE 3.1: Réseau de neurone convolutif.....	29
FIGURE 3.2: Neurone biologique.....	31
FIGURE 3.3: Communication entre 2 neurones biologiques.....	31
FIGURE 3.4: Neurone biologique avec neurone artificiel.....	33
FIGURE 3.5: Couches principales de CNN.....	34
FIGURE 3.6: Architecture standard d'un réseau de neurone convolutionnel.....	35
FIGURE 3.7: Convolution.....	35
FIGURE 3.8: Max pooling.....	36
FIGURE 3.9: Conversion en vecteur.....	37
FIGURE 3.10: Couches entièrement connectées.....	38
FIGURE 4.1: Exemples d'images des deux bases de données utilisées.....	40
FIGURE 4.2: Distribution libre du langage de programmation python (PyCharm).....	41
FIGURE 4.3: Logo de la bibliothèque TensorFlow.....	42
FIGURE 4.4: Environnement ITK-SNAP.....	43

FIGURE 4.5: Organigramme général de la méthode proposée.....	44
FIGURE 4.6: Résultat de la visualisation des données.....	45
FIGURE 4.7: Graphe de la précision et de perte.....	48
FIGURE 4.8: Résultat de l'augmentation des données.....	49
FIGURE 4.9: Graphe de Accuracy et Loss.....	50
FIGURE 4.10: Matrice de confusion.....	51
FIGURE 4.11: Fenêtre principale.....	53
FIGURE 4.12: Représentation des résultats dans l'interface.....	57

Liste des tableaux

TABLEAU 2.1 : Récapitulatif des travaux.....	24
TABLEAU 4.1: Caractéristiques de chaque base de données.....	39
TABLEAU 4.2: Architecture utilisée.....	47
TABLEAU 4.3: Résultat de l'augmentation des données.....	49
TABLEAU 4.4: Performance de la méthode proposée par rapport aux méthodes existantes.....	52

Liste des abréviations

CNN	Convolutionnel Neural Network
FCM	Fuzzy C-Means
FN	Faux Négatif
FP	Faux Positif
IRM	Imagerie par Résonance Magnétique
MS	Multiple Sclérose
Res-Net	Res-Neural Network
SEP	Sclérose En Plaques
SVM	Support Vector Machine
VN	Vrai Négatif
VP	Vrai Positif

Introduction générale

L'imagerie médicale regroupe, les moyens d'acquisition et de restitution d'images du corps humains, à partir des différents phénomènes physiques, tels que la réfraction des rayons laser, l'absorption des rayons X, la radioactivité pour la scintigraphie, ...etc.

L'imagerie par résonance magnétique (IRM) est une technique d'imagerie médicale, qui utilise le champ magnétique, pour capturer des images tridimensionnelles, afin de visualiser les structures anatomiques du cerveau (cortex, structures sous-corticales ...etc.). En fonction des changements, qui se produisent au niveau des structures sous-corticales, les médecins peuvent diagnostiquer les maladies neurodégénératives, qui affectent le cerveau (maladie d'Alzheimer, l'épilepsie, ...etc.).

Une maladie neurodégénérative correspond, à une pathologie progressive, qui affecte le cerveau, ou plus globalement le système nerveux, entraînant la mort des cellules nerveuses. Les plus célèbres et les plus fréquentes, sont la maladie d'Alzheimer et la maladie de Parkinson, mais il en existe d'autres.

L'objectif principal de ce travail de recherche, est de développer un système d'analyse des images numériques d'IRM cérébrales, capable de classifier ces images, selon la présence, ou l'absence, d'une maladie neurodégénérative. Nous allons appliquer notre système sur trois catégories (sain, Alzheimer, épileptique). Cette classification va aider à déterminer le traitement optimal. Dans le cas où l'image correspond à un sujet atteint d'Alzheimer, le système donne le stade de la maladie.

Pour implémenter notre système, nous avons fait appel à un outil du domaine de l'intelligence artificielle : l'apprentissage profond (deep Learning), qui connaît un grand engouement des chercheurs, de différentes disciplines.

Ce document est divisé en quatre chapitres :

Dans le premier chapitre, nous présentons l'aspect médical de base, nécessaire pour la compréhension de la problématique proposée. L'anatomie générale du cerveau est décrite, puis une description des maladies neurodégénératives, suivie par les examens cliniques, nécessaires, pour faire un diagnostic.

Le deuxième chapitre sera consacré à l'étude bibliographique des différentes techniques, de segmentation des structures sous-corticales, ainsi qu'à un aperçu général, sur les différents travaux de recherche, portant sur la classification des maladies neurodégénératives (Normal, Alzheimer, épilepsie, sclérose en plaque, Parkinson), étudiés dans l'état de l'art (ou présentés par la communauté scientifique).

Dans le troisième chapitre, nous présenterons les outils mathématiques, utilisés dans le système d'analyse d'images proposé, avec une explication détaillée, de chaque outil utilisé, entre autres, la méthode de l'apprentissage profond, pour la classification.

Dans le quatrième chapitre, nous exposerons, les différents résultats obtenus par les techniques de classification choisies, sur certaines images d'IRM cérébrales, ainsi que leur interprétation. Différents outils d'évaluation des résultats, sont également présentés dans cette partie, ainsi qu'une brève présentation de l'interface réalisée.

En conclusion générale, nous présenterons un récapitulatif des étapes de notre travail, les difficultés rencontrés lors de l'implémentation de l'algorithme, et finalement, les perspectives que nous souhaitons proposer pour les travaux futurs.

PARTIE THEORIQUE

Chapitre₁

Aspect Médical

Ce chapitre a pour objectif de fixer le cadre applicatif que nous avons envisagé. Dans un premier temps, nous présentons quelques éléments d'anatomie du système nerveux central, de même que nous exposons de façon brève les principes physiques de l'IRM (l'imagerie par résonance magnétique), étant donné qu'il s'agit de la modalité que nous avons utilisée.

1.1 Système nerveux

Le système nerveux (SN) (Figure 1.1) est un système de régulation et de communication, qui déclenche tous les mouvements volontaires. Sa fonction est rapide et spécifique, mais elle est très complexe. Il comprend des milliards de neurones (cellules nerveuses), et de cellules gliales (cellules de soutien), qui forment un réseau complexe, et rigoureusement organisé [1]. Il est composé du système nerveux central (SNC), et du système nerveux périphérique (SNP).

1.1.1 Système nerveux central

Le système nerveux central est enchâssé dans des structures osseuses (osseux : crâne et canal rachidien), et est le centre de régulation et d'intégration, qui traite l'information sensorielle, et élabore des réponses motrices. C'est le siège de la pensée, des émotions et des souvenirs [1].




Figure 1.1 Illustration du système nerveux [7]

1.1.2 Système nerveux périphérique

Il est composé:

- De tissus du système nerveux, situés à l'intérieur de la cavité crânienne et du canal rachidien, donc à l'extérieur du système nerveux central. Ces tissus correspondent aux différents nerfs, rattachés à l'encéphale ou à la moelle épinière. Les nerfs qui se rattachent au tronc cérébral de l'encéphale sont appelés nerfs crâniens (12 paires), et ceux qui se rattachent à la moelle épinière nerfs rachidiens ou spinaux (31 paires), car ils émergent du canal rachidien.
- De ganglions et des récepteurs sensoriels [1].

1.1.3 Rôle essentiel du SN

Les différentes parties du SN (SNC-SNP), malgré leur rôle distinct, fonctionnent et interagissent continuellement entre elles. C'est ce qui permet à l'organisme de réagir aux douleurs, et aux différents aléas du quotidien (Figure 1.2) [2].

Il a pour rôle de :

- Recueillir toutes les informations extérieures ou intérieures, et les transmettre aux cibles centrales ;
- Intégrer les messages, et véhiculer les réponses vers les cibles concernées [1].

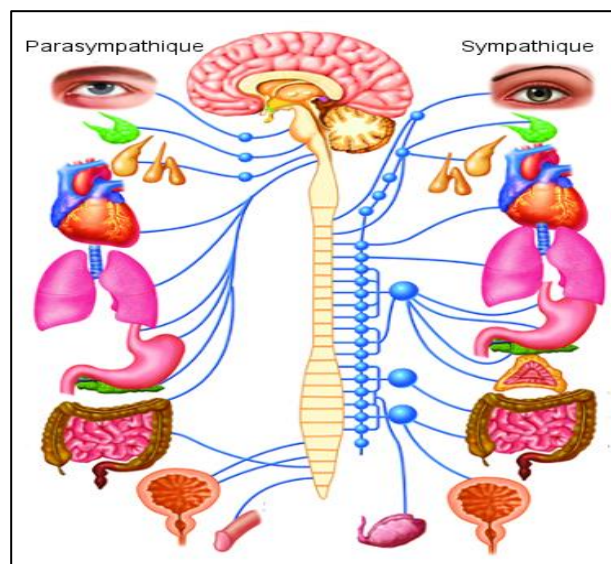


Figure 1.2 Lien entre le système nerveux et les organes du corps [8]

1.2 Description macroscopique

Le cerveau est très organisé, il est composé de plusieurs parties, qui ont chacune des rôles spécifiques, tout en étant complémentaires, les unes aux autres [3].

1.2.1 Hémisphère

Le terme cerveau comprend deux parties, appelées hémisphères cérébraux, qui forment les parties les plus volumineuses du cerveau. Ils sont en nombre de deux : l'hémisphère droit et l'hémisphère gauche (Figure 1.3).

Les hémisphères contrôlent l'ensemble de nos fonctions mentales supérieures : mouvements volontaires, pensées, apprentissage, mémoire, etc.

Chaque hémisphère est lui-même partagé en quatre zones, appelées « lobes » [3].




Figure 1.3 Deux hémisphères du cerveau [10]

1.2.2 Lobes

Le cerveau est constitué de quatre lobes (Figure 1.4) [4].

a) Lobes frontaux

Ils interviennent dans la parole et le langage, le raisonnement, la mémoire, la prise de décision, la personnalité, le jugement et le mouvement.

Le lobe frontal droit gère les mouvements du côté gauche du corps, et inversement, le lobe frontal gauche gère les mouvements du côté droit.

b) Lobes pariétaux

Leur fonction est pour (Ils sont dédiés à) la lecture, au repérage dans l'espace et à la sensibilité. Là aussi, le lobe pariétal droit gère la sensibilité du côté gauche du corps, et réciproquement.

c) Lobes occipitaux

Ils sont situés à l'arrière de la tête, et sont responsables de la vision.

d) Lobes temporaux

Ils génèrent la mémoire et les émotions, et analysent les événements immédiats, dans la mémoire à court terme, et à long terme. Ils emmagasinent, et rappellent les souvenirs, à long terme, et permettent de comprendre les sons et les images, ce qui permet de reconnaître les personnes et les objets, et d'intégrer l'audition et le langage.




Figure 1.4 Différents lobes du cerveau [11]

1.2.3 Méninges

Les méninges sont les membranes qui enveloppent le système nerveux central : encéphale et moelle épinière, la portion intracrânienne des nerfs crâniens, et les racines des nerfs spinaux.

Le cerveau est recouvert de trois méninges (Figure 1.5) :

- La dure-mère est la méninge la plus épaisse : toile fibreuse ;
- L'arachnoïde tapisse la face interne de la dure-mère ;
- La pie-mère tapisse la surface du cerveau, en épousant étroitement les replis, scissures et les circonvolutions du cerveau.

Entre l'arachnoïde et la pie mère, la pie-mère se trouve l'espace sub-arachnoïdien (sous arachnoïdien), qui est occupé par le liquide cébrospinal [4].

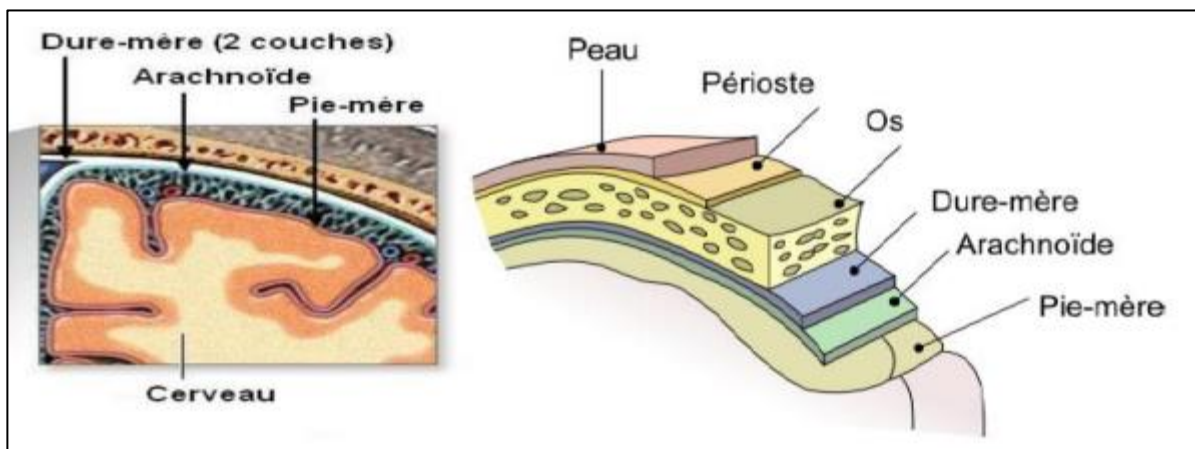


Figure 1.5 Trois couches de méninge [12]

1.2.4 Matière grise

La substance grise correspond au corps cellulaire des neurones. Elle permet la réception, l'élaboration et l'analyse des messages, qui permettent de déclencher une réponse. Cette substance grise se répartit, en une couche superficielle épaisse, recouvrant le cerveau, le cortex, et en noyaux profonds, les noyaux gris centraux (ou ganglions de la base) (Figure 1.6) [5].

1.2.5 Matière blanche

Le tissu neuronal, qui est principalement formé d'axones, entourés d'une gaine de myéline, est appelé substance blanche. Située dans la partie interne du cerveau et de la moelle épinière (Figure 1.6), la substance blanche représente, en quelque sorte, le câblage de l'encéphale. Généralement, la substance blanche peut être considérée comme la partie du cerveau, responsable de la transmission des informations, alors que la substance grise est responsable du traitement des informations (car elle est composée des corps cellulaires des neurones) [5].

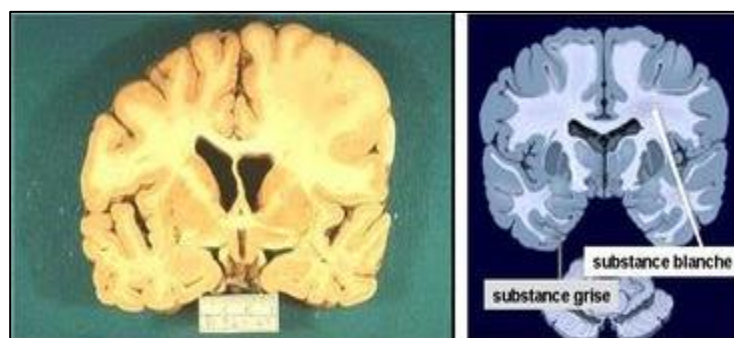


Figure 1.6 Matière grise et blanche du SN [13]

1.3 Description microscopique

1.3.1 Cellules gliales

Les cellules gliales (névroglie), jouent un rôle physiologique, aussi important que celui des neurones, dans la maîtrise de la fonction nerveuse, et participent directement au traitement de l'information dans le SNC [6].

Les cellules gliales ne sont donc plus envisagées, seulement comme des cellules de SNC, de second ordre, mais bien comme des partenaires, à part égale avec les neurones, dans l'installation de la douleur chronique. La mise en jeu des cellules gliales repose sur le fait que, le système nerveux est susceptible d'initier des signaux chimiques, qui modifient l'activité de ces cellules gliales, et qu'en retour ces cellules libèrent des facteurs, qui régulent l'activité de ces cellules nerveuses [6].

1.3.2 Neurones

Les neurones (Figure 1.7) représentent l'unité fonctionnelle de traitement et le transfert d'informations, au niveau du système nerveux [7].

Les neurones possèdent deux propriétés fondamentales :

- ✚ L'excitabilité : c'est la capacité de la membrane neurale, à maintenir une différence de potentiel transmembranaire, appelée potentiel de repos ;
- ✚ La conduction : c'est la capacité des axones, à transmettre les informations, sous formes de signaux électriques, appelés potentiels d'actions [7].

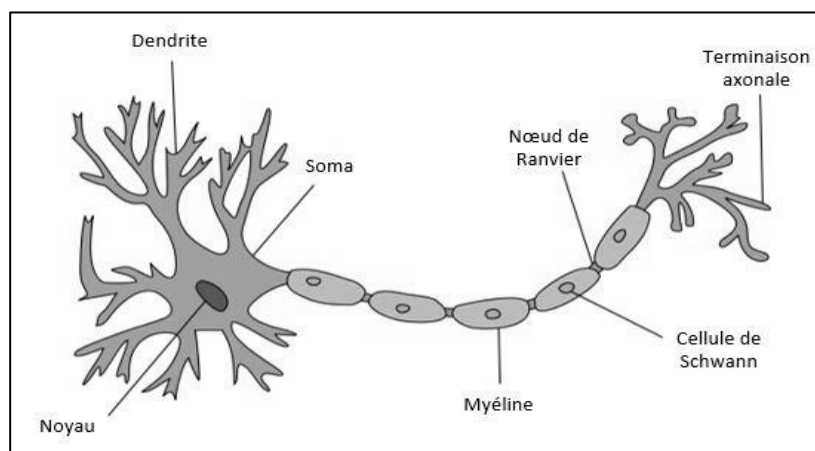


Figure 1.7 Neurone [14]

1.4 Maladies neurodégénératives

Elles se caractérisent par la destruction progressive, d'une population ciblée et délimitée, de cellules nerveuses. Cette mort neuronale est plus rapide que celle observée, lors du vieillissement normal, et intervient dans une région précise du système nerveux central. Ces familles de maladies sont déjà fréquentes, et risquent de le devenir encore plus, compte tenu de l'augmentation de l'espérance de vie [14].

1.4.1 Conséquences

Les maladies neurodégénératives (MND) représentent une cause majeure de dépendance, d'institutionnalisation, et d'hospitalisation. Elles ont un impact majeur, sur la qualité de vie des personnes atteintes, ainsi que sur celle de leurs proches et de leurs aidants, pour qui elles peuvent être particulièrement éprouvantes [14].

1.4.2 Principales maladies

Parmi les maladies du cerveau les plus connues et les plus fréquentes, nous pouvons citer :

- La maladie de Parkinson ;
- La maladie d'Alzheimer ;
- La sclérose en plaque.

Pour diagnostiquer ces maladies, les praticiens utilisent, de plus en plus, des techniques d'imagerie médicale [14].

1.5 Imagerie par Résonance magnétique

1.5.1 Imageur IRM

L'imagerie par résonance magnétique est une technique, relativement récente, qui permet de produire des images anatomiques, dans des plans multiples, et qui peut fournir des informations, sur la composition des tissus. La première acquisition d'IRM a été produite en 1973, par Lauterbur et Damadian. Cette technique a permis d'arriver, à des avancées technologiques et scientifiques majeures, notamment pour le dépistage des pathologies [15]. La figure 1.8 illustre un imageur IRM.



Figure 1.8 Acquisition par IRM

1.5.2 Principe de l'IRM

L'IRM est une technique d'investigation, très performante, parfaitement indolore, et sans danger. Elle n'utilise pas de rayons X, et est basée sur le principe de la résonance magnétique des protons du corps humain, au sein d'un champ électromagnétique. Ce dernier est créé par un aimant géant, en forme de tunnel, au sein duquel le patient est placé. Des ondes électromagnétiques provoquent une aimantation spécifique des noyaux d'hydrogène, présents en proportions diverses dans les tissus, selon leur teneur en eau. Le signal émis par les protons, lors de leur retour à leur état d'équilibre, est à l'origine de la création des images. Les images obtenues sont traitées, par de puissants logiciels, qui permettent de reconstruire les différentes coupes. Ces images sont visualisées sur un écran, puis transformées en clichés radiographiques [15].

a) Résonance

La résonance est un transfert d'énergie, entre deux systèmes, oscillants à la même fréquence. Pour faire basculer un proton, d'un état d'énergie E_1 , à un état E_2 , il faut lui apporter une quantité d'énergie ΔE .

Lors d'une expérience RMN (Résonance Magnétique Nucléaire), l'échantillon est soumis à une onde radiofréquence RF , créée par un champ magnétique B_1 , non colinéaire à B_0 , et tournant à la fréquence f_0 . Les protons, qui étaient alignés selon B_0 , reçoivent alors un apport d'énergie, sous la forme d'une onde, de pulsation égale à leur fréquence propre. Le vecteur d'aimantation macroscopique est basculé, de sa position d'équilibre M_0 , vers une position M ,

tant que B_1 dure. Ce phénomène est appelé la résonance [15].

b) Relaxation

A l'arrêt de l'onde B_1 , un signal, dit de précession libre, est enregistré. Il accompagne le retour, à la position d'équilibre (en spirale), du vecteur M .

Des projections de l'aimantation, sur le vecteur Uz (aimantation longitudinale $M_L = M \cdot Uz$), et sur le plan normal à ce vecteur (aimantation transversale $M_T = M - M_L$), sont mesurées (Figure 1.9). Seule M_T participe au signal, en générant un signal dans l'antenne réceptrice [15].




Figure 1.9 Phase de relaxation

c) Paramètres de séquences

Les paramètres de séquence, sont les paramètres que le manipulateur fixe sur la console, pour définir la séquence IRM. Ils permettent de contrôler l'influence des différents paramètres tissulaires T_1 , T_2 et densité de proton dans le signal, et de moduler ainsi le contraste dans l'image [16].

d) Les pondérations des images IRM

- Image pondérée en densité de proton (p)

Pour un TR long (de l'ordre de 2s), et un TE court (de l'ordre de 20ms), la différence de densité protonique, entre la substance grise et la substance blanche, s'accroît. On obtient une séquence, pondérée en densité de protons, qui reflète la localisation et la concentration des


noyaux d'hydrogène, des différentes structures. Les tissus sont ordonnés par niveaux de gris croissants du blanc au noir, en matière blanche (MB), matière grise (MG) et liquide cébrospinal (LCS). Et pour la pondération en T2, LCS, MB, MG avec le LCS en gris foncé [16].

- **Image pondérée en T2**

Pour des **TR** longs (de l'ordre de 2s), et des **TE** longs (environ 90ms), la décroissance du signal domine la différence de densité protonique entre tissus, et le signal est suffisant, pour réaliser une image, dite pondérée en **T2**, où les tissus sont ordonnés par niveaux de gris croissants, en MB, MG, LCS [16].

- **Image pondérée en T1**

Pour des **TR** courts (de l'ordre de 600ms), le contraste entre les tissus, dépend essentiellement de leur vitesse d'aimantation, donc de **T1**. Pour des **TE** courts (environ 20ms), les différences de décroissance du signal entre les tissus, n'ont pas le temps de s'exprimer, rendant le contraste indépendant de **T2**. Ainsi, on obtient une image pondérée en **T1**, où les tissus sont ordonnés, par niveaux de gris croissants, en LCS, MG, MB avec le LCS en noir [16].



(a)

(b)

(c)

Figure 1.10 Séquences IRM, (a) : Image pondérée en T1, (b) : Image pondérée en T2

(c) : Image pondérée en densité de protons

e) Défaut des images IRM (artefact)

Une image IRM peut être entachée de différents artefacts. Nous citons quelques-uns.

- **Bruit**

Le bruit a des origines multiples, liées en partie au bruit de l'appareillage. Dans les images par résonance magnétique, l'objectif est d'augmenter le contraste entre les tissus, tout en

conservant une bonne résolution, et un rapport signal/bruit élevé. Ces caractéristiques sont cependant contradictoires, et il est nécessaire de trouver un bon compromis, entre résolution et bruit. Ainsi, on peut doubler la taille des pixels, pour multiplier le rapport signal/bruit d'un facteur p , mais la résolution est divisée par deux. Le choix d'acquisition est donc un facteur déterminant [17].

- **Mouvement**

Le mouvement peut provenir de plusieurs sources. Il peut être lié au métabolisme, comme la circulation sanguine ou la respiration (déplacement chimique). Il peut également être lié au mouvement du patient, pendant l'acquisition. Dans tous les cas, le mouvement diminue la qualité de l'image, et pose des problèmes d'interprétation ; les mouvements de la tête sont responsables d'artefacts dans les IRM cérébrales [17].

- **Variations du champ magnétique (inhomogénéité RF)**

Les variations de champ ont pour conséquence une variation des intensités d'un même tissu, dans une direction quelconque de l'image (Figure 1.11). Ce phénomène est dû au fait que, le champ magnétique n'est pas parfaitement homogène, spatialement et temporellement, pendant une acquisition. Il existe de plus, des non-linéarités de gradient de champ magnétique.

Des approches ont été proposées, pour corriger les inhomogénéités du champ magnétique, dans le cadre de prétraitements [18]. Les distorsions de champ ont également été analysées en détail, et corrigées dans la littérature [19].

- **Effets de volume partiel**

Les effets de volume partiel sont directement liés au processus de numérisation du signal. Ainsi, si un pixel intersecte plusieurs objets, son niveau de gris sera une combinaison, des niveaux de gris, issus de chacun des objets traversés [18].

La prise en compte des effets de volumes partiels est nécessaire, dans le cadre d'approches de segmentation, dont l'objectif est d'effectuer des mesures, sur les différents tissus. Cet artefact n'est pas très gênant pour le clinicien, sauf dans des cas extrêmes, où le contraste entre différents tissus disparaît, par exemple [18].




Figure 1.11 Inhomogénéité RF.

(a) : Image affectée par une inhomogénéité RF, (b) : artefact RF isolé, (c) : image sans artefact

Discussion

Nous avons présenté dans ce chapitre les notions essentielles, liées à l'anatomie du cerveau, ainsi que les principes d'acquisition des images, par résonance magnétique, qui apporte une aide intéressante, en termes de diagnostic précoce, et de caractérisation des tissus cérébraux. Nous avons remarqué, qu'il y a des problèmes, liés à l'anatomie du cerveau humain, du fait de sa complexité, et qu'il peut avoir un dysfonctionnement lié à une maladie neurodégénérative, qui peut être observé de façon précoce au niveau des sous-corticales.

La détection des sous-corticales, et de leurs signes cliniques, grâce à l'analyse des images d'IRM cérébrale, peut limiter la progression des maladies neurodégénératives. L'objectif de ce projet est de développer et valider un système automatique, qui permet l'évaluation des maladies neurodégénératives, à partir des images d'IRM cérébrale.

Après avoir vu les différentes notions anatomiques et physiologiques de ce type de maladie, le chapitre suivant est consacré à la présentation des méthodes, offertes dans la littérature, pour la détection des petites structures (sous-corticales).

Chapitre₂

Etat de l'art

Ce chapitre présente une revue des connaissances, relatives à notre sujet de recherche. Nous allons présenter les principales méthodes récentes, reportées dans la littérature, pour la détection des petites structures, à partir d'images d'IRM cérébrales.

2.1 Travaux antérieurs

A partir de la bibliographie que nous avons collectée, nous avons organisé notre travail, de la façon suivante :

1. Prétraitement d'images d'IRM cérébrale ;
2. Segmentation des petites structures ;
3. Classification des images normales et pathologiques

L'état de l'art que nous présentons englobe, les différentes méthodes de segmentation et de classification, qui s'échelonnent sur un intervalle de temps, allant de 2006 jusqu'à 2021.

✚ **G. Dugas-Phocion (2006) [20]:** dans cette thèse, l'auteur s'est intéressé à l'analyse d'IRM cérébrales, notamment dans le cadre du suivi de patients, souffrant de sclérose en plaques (SEP). L'automatisation de cette caractérisation permettrait l'extraction automatique des critères de Barkhof, mais aussi, de pouvoir explorer de nouveaux algorithmes de segmentation, spécifiques à chaque catégorie : segmenter chaque type de lésion, de manière différente, semble indispensable, pour obtenir des résultats plus homogènes ($S = 83,8\%$, avec S est la sensibilité).

✚ **C. Ciofolo, C. Barillot 2006 [21]:** Ont conçu un système de décision floue, combinant les connaissances a priori, fournies par un modèle de forme, qui sert d'atlas anatomique, avec la distribution d'intensité de l'image, et la position relative des contours.

✚ **R. Khayati, M. Vafadust, F. Towhidkhah, et al. 2007 [22] :** Dans cet article, une approche est proposée, pour la segmentation, entièrement automatique, des lésions de SEP, dans la récupération d'inversion, atténuée par fluide (FLAIR) Magnétique Images de résonance (RM). L'approche proposée, basée sur un classificateur bayésien, utilise la méthode des mélanges adaptatifs (AMM), et le modèle de champ de Markov aléatoire (MRF), pour obtenir, et mettre à niveau la fonction de densité de probabilité conditionnelle des classes (CCPDF), et la probabilité a priori de chaque classe ($S_i = 0,75$.)

- ✚ **B. Scherrer (2008) [23]:** propose une nouvelle approche de segmentation des IRM cérébrales, dont l'originalité réside dans le couplage, de la segmentation des tissus, de la segmentation des structures, et de l'intégration de connaissances anatomiques, et la volonté de prendre en compte la localisation de l'information. La première approche propose des mécanismes intuitifs de coopération et de couplage, pour assurer la cohérence des modèles locaux, et la deuxième considère l'introduction d'un atlas statistique des structures. La reformulation du problème, dans un cadre bayésien, nous permet une formalisation statistique du couplage et de la coopération. La segmentation et le recalage local, réalisés de manière couplée, avec un algorithme EM et les modèles markoviens locaux distribués et coopératifs, apparaissent alors comme une approche prometteuse.
- ✚ **S. Bricq (2008) [24]:** l'objectif de ce travail, est de coupler les méthodes, dites bas niveau, aux approches plus modernes, qui s'appuient sur des modèles a priori, donc associer des modèles statiques markoviens, à des modèles a priori de haut niveau, de type atlas statistique. L'étape de segmentation est basée sur chaînes de Markov inclus l'infos a priori atlas probabiliste. Cette méthode a été utilisée pour la détection des Multiple sclerosis MS, en utilisant un estimateur robuste, ainsi qu'une méthode, basée sur les contours actifs statiques (minimisation de la complexité stochastique), pour la détection des structures anatomiques.
- ✚ **B. Li, W. Chen 2009 [25]:** dans ce travail, les résultats des tests, montrent que l'algorithme proposé est suffisamment robuste et précis, pour une utilisation clinique. Les régions circonscrites par la substance blanche, sont d'abord extraites, par segmentation, basée sur MRF et les méthodes de croissance de région. Les régions abstraites, sont ensuite à nouveau segmentées, en utilisant un algorithme, basé sur MRF.
- ✚ **J. Lecoœur (2010) [26]:** ce travail consiste, dans un premier temps, en une méthode, qui utilise la fusion de 3 modalités d'IRM. L'information de frontière est alors mise en balance, avec une information de région, par un algorithme de coupe de graphe. Dans un 2eme temps, trois variantes de cette méthode sont proposées. La première consiste

à trouver un espace spectral, qui donne naissance à une méthode de segmentation par apprentissage, ensuite, une automatisation de cette méthode (traitement des informations par EM), enfin l'utilisation d'atlas, pour la segmentation automatique de structures profondes du cerveau.

✚ **R. Wolz, P. Aljabar, J. V. Hajnal, et al. (2010) [27]:** Dans cette approche, un graphe 4D est utilisé, pour représenter les données longitudinales : les arêtes sont pondérées, en fonction d'a priori spatiaux, et d'intensité, et connectent des voxels voisins, spatialement et temporellement représentés, par des sommets dans le graphe. La résolution du problème min-cut/max-flow sur ce graphique, donne la segmentation, pour tous les points temporels, en une seule étape. En segmentant tous les points temporels simultanément, une segmentation cohérente et sensible à l'atrophie est obtenue. Les résultats démontrent un gain croissant de précision, de la nouvelle méthode, par rapport à la segmentation multi-atlas standard, avec une distance croissante, entre l'image cible et l'ensemble initial d'atlas, dans l'intégration des coordonnées, c'est-à-dire avec une plus grande différence, entre l'atlas et l'image, et un chevauchement moyen. Le coefficient de Dice obtenu, pour une référence manuelle, est de 0,85.

✚ **M. Achour (2010-2011) [28]:** son travail consiste à faire une segmentation, en se basant sur 2 méthodes très connues et efficaces, l'algorithme EM et la ligne de partage des eaux. Les objectifs de cette segmentation de l'hippocampe sont :

- le diagnostic de la maladie d'Alzheimer, de façon automatique, après un prétraitement ;
- une procédure de classification des images, en 3 régions d'intérêts (spécialement l'hippocampe), en utilisant la méthode EM,
- le choix de marqueurs, pour l'algorithme de LPE (2 marqueurs, choisis après l'étude).

On peut dire que les résultats de la segmentation par LPE dépendent des marqueurs choisis.

✚ **H. Wang, S. R. Das, J. Wook Suh, and all 2011 [29]:** le travail consiste à faire une segmentation automatique de l'hippocampe, avec un wrapper (un programme qui englobe d'autres composants logiciels), basé sur l'apprentissage. L'approche est basée, sur l'hypothèse, qu'une grande partie des erreurs, produites par la segmentation

automatique, sont systématiques, c'est-à-dire qu'elles se produisent, de manière cohérente, d'un sujet à l'autre. La méthode a été comparée avec 4 autres méthodes, et a générée moins de voxels mal segmentés que les autres méthodes. Des indices de Dice moyens de 0,964, 0,905 et 0,951 sont obtenus, pour l'extraction du cerveau, la segmentation de la matière blanche et la segmentation de la matière grise, respectivement.

- ✚ **K. Jafari-Khouzani, K. V. Elisevich and H. Soltanian-Zadeh (2011) [30]:** L'hippocampe a été la principale région d'intérêt, dans les investigations d'imagerie préopératoire, de l'épilepsie du lobe temporal mésial (mTLE). Ce travail a utilisé quel atlas, pour le protocole de segmentation automatique proposé, qui a été appliqué à une cohorte de 46 patients mTLE. Cette méthode a été comparée avec 2 autres méthodes de segmentation, et a montrée de meilleurs résultats, avec une précision de 74%.

- ✚ **N. Belmokhtar, N. Benamrane (2012) [31]:** ce travail propose une méthode, basée sur des machines à vecteurs de support binaire (SVM), pour distinguer entre, les patients atteints de la maladie d'Alzheimer (MA), ceux atteints de troubles cognitifs légers (MCI), et des sujets âgés témoins (CS), à partir de données, issues de l'imagerie par résonance magnétique (IRM). Afin de réduire le temps de calcul total, ils ont utilisé la plateforme multi-agents JADE (Java Agent Développement Framework), et ont obtenu une précision de 0,84.

- ✚ **D. Mortazavi, A. Z. Kouzani, H. Soltanian-Zadeh (2012) [32]:** Ce travail est une hybridation de toutes les méthodes ce qui paraît probable. Il représente un état de l'art des méthodes de segmentation de la sclérose en plaques (MS), et qu'ils sont arrivés à la conclusion que : l'intégration de méthodes, basées connaissances, telles que les approches basées l'atlas, avec les méthodes bayésiennes, augmente la précision de la segmentation. De plus, l'utilisation de classificateurs intelligents, tels que Fuzzy C-Means (FCM), Fuzzy Inference Systems (FIM) et les réseaux de neurones artificiels (ANN), réduit les voxels mal classés.

- ✚ **N. W. Sterling, G. Du, M. M. Lewis, et al. (2013) [33]:** La maladie de Parkinson (MP) est marquée, pathologiquement, par une perte terminale dopaminergique nigrostriatale. Des études structurelles antérieures, ont suggéré une réduction du volume striatal, et une atrophie de la tête du noyau caudé, chez les sujets

parkinsoniens. Le but de ce travail est de chercher à délimiter les emplacements spécifiques de l'atrophie, dans ces deux structures striatales. L'analyse de la forme a été réalisée, en utilisant des régions d'intérêt, doublement segmentées.

- ✚ **A. Ziouani (2014) [34]:** ce travail est basé sur la proposition d'une méthode de segmentation de l'hippocampe, pour le diagnostic de la maladie d'Alzheimer. Cette approche de segmentation est basée sur l'algorithme FCM, et le recalage, hybride automatique ou semi-automatique, de la région de l'hippocampe, sur des coupes IRM cérébrales.

- ✚ **F. Nemmi, U. Sabatini, O. Rascol, et al. (2014) [35]:** L'analyse de la forme des noyaux sous-corticaux, basée sur l'imagerie IRM, pondérée en T1, a été utilisée en pathologie de la MP. La présente étude, vise à tester l'hypothèse, selon laquelle, les changements de volume local, détectables avec l'imagerie pondérée en T1, sont concomitants avec la MP, et peuvent être utilisés comme biomarqueurs. La comparaison a été faite, en utilisant la densité de la matière grise, le volume, et la forme des noyaux sous-corticaux. Les résultats montrent des différences de volume, dans le putamen, et des différences de forme, dans le putamen et le noyau caudé. L'analyse de forme apporte des informations précieuses, aux investigations concernant les patients parkinsoniens, et aide à discriminer ces patients, des sujets témoins.

- ✚ **J. D. Rudie, J. B. Colby, N. Salamon (2015) [36]:** les auteurs utilisent des approches, appliquant des méthodes d'apprentissage automatique, aux données de neuro-imagerie, et cherchent à développer des mesures individualisées, qui aideront au diagnostic, et au traitement des troubles cérébraux, tels que l'épilepsie du lobe temporal (TLE). Ils ont classé automatiquement les mesial temporal sclerosis MTS, à l'aide de mesures de la morphologie corticale. Les résultats de la classification ont obtenu une précision de 81%.

- ✚ **M. El Azami, A. Hammers, J. Jung, et al. (2016) [37]:** Ce travail consiste à proposer, un système d'apprentissage automatique, basé sur un classificateur de machine à vecteur de support à une classe (OC-SVM), pour la détection d'anomalies, dans les images par résonance magnétique (IRM), appliqué aux patients atteints d'épilepsie. Le

système apprend les caractéristiques, associées aux sujets témoins sains, permettant une évaluation par voxel, de la déviation d'un modèle de sujet de test, par rapport aux modèles appris. Bien qu'un certain nombre de caractéristiques différentes, puissent être choisies et apprises, les auteurs se sont concentrés, dans ce travail, sur deux paramètres de texture, capturant les motifs d'image, associés aux lésions épileptogène, sur l'IRM cérébrale pondérée en T1. (Par ex, hétérotopie et zones floues, entre la matière grise et la matière blanche). La sortie CAD, consiste en des cartes 3D, spécifiques au patient, localisant des groupes de voxels suspects, classés par taille, et degré de déviation, par rapport aux modèles de contrôle. Le système a détecté 100% des lésions.

✚ **N.W. Sterlinga, M.M. Lewisa,b, G. Dua and X. Huang (2016) [38]:** L'atrophie corticale a été observée, à la fois dans la maladie de Parkinson (MP), et dans le vieillissement des personnes en bonne santé. Cependant, sa relation, avec les modifications de la substance blanche sous-corticale, est inconnue. Les associations significatives, entre la matière grise et la matière blanche, n'ont pas été trouvées, chez les témoins. Ainsi, contrairement au vieillissement en bonne santé, l'atrophie corticale, et les modifications de la substance blanche sous-corticale, peuvent ne pas être des événements indépendants, dans la MP.

✚ **I. Jyoti, Y. Zhang (2017) [39]:** La maladie d'Alzheimer perturbe le cerveau, et cause la perte de la mémoire, entre autres. Elle n'est pas curable, mais une détection plus précoce, peut aider à améliorer considérablement les symptômes. Les techniques d'apprentissage automatique, peuvent considérablement améliorer le processus de diagnostic précis de la maladie d'Alzheimer. Ces derniers temps, les techniques de Deep Learning, ont données de bons résultats, dans le domaine de traitement des images médicales. Cet article présente un nouveau modèle d'apprentissage en profondeur, pour la détection et la classification multi-classes, de la maladie d'Alzheimer, à l'aide de données d'IRM cérébrales. Les résultats obtenus sont très satisfaisants. Pour 5 époques, on trouve 71,25 % de performance, et pour 10 époques on trouve 73,25%.

✚ **K. S. Biju, S.S. Alfa, L. Kavya et al. (2017) [40]:** Dans cet article, les auteurs proposent une solution logicielle, de détection des anomalies cérébrales, pour la détection de la maladie d'Alzheimer. L'algorithme proposé donne une représentation

3D du cerveau, à partir des coupes IRM. Cette méthode est précise et fiable. Les coupes d'IRM subissent différents processus, tels que le débruitage, la segmentation, le slice-o-matic (construction 3D), et le calcul du volume résiduel des parties du cerveau. Il utilise le rapport matière grise/matière blanche, pour déterminer, si la personne est atteinte de la maladie d'Alzheimer.

- ✚ **S. Valverde, M. Salem, M. Cabezas et al. (2018) [41]:** Ce travail propose un nouveau logiciel, pour détecter de nouvelles lésions T2-w, dans la sclérose en plaques, en entraînant un classifieur de régression logistique, avec des caractéristiques de soustraction et de déformation. Le modèle proposé diminue les faux positifs, tout en augmentant les vrais positifs. En termes de détection, on remarque l'obtention d'un coefficient de similarité Dice moyen de 0,77, avec un taux de vrais positifs de 74,30 %, et un taux de détection de faux positifs de 11,86 %. En termes de segmentation, un coefficient de similarité Dice moyen de 0,56 a été obtenu. Les performances de ce modèle sont significativement supérieures, à celles des méthodes de pointe. La performance de la méthode proposée montre les avantages de l'utilisation d'opérateurs de déformation fields DF comme fonctionnalités, pour entraîner un modèle d'apprentissage supervisé.

- ✚ **O. Commowick, A. Istace, C. Barillot (2018) [42]:** Ce travail présente une étude des algorithmes de segmentation de la sclérose en plaques. Cela a permis l'évaluation automatique et indépendante d'une large gamme d'algorithmes, d'une manière juste, et complètement automatique. Les résultats démontrent, que le calcul d'un consensus, statistiquement robuste des algorithmes, est plus proche de l'expertise humaine sur un score (segmentation), tout en restant à la traîne sur les scores de détection.

- ✚ **B. F. Rousseau (2018) [43]:** L'auteur fait l'analyse des structures cérébrales, chez le nouveau-né, afin de disposer d'informations prédictives, sur le développement de l'enfant. Le cortex est, en particulier, une structure d'intérêt, observable en IRM (imagerie par résonance magnétique). Les données IRM néonatales, présentent toutefois des spécificités, qui les rendent complexes à traiter. Dans ce contexte, les approches multi-atlas constituent une stratégie efficace, tirant parti, des données traitées préalablement. La méthode, proposée dans cet article, repose sur une telle stratégie multi-atlas. Elle s'appuie notamment sur deux paradigmes : l'utilisation d'un modèle non local, à base de patches, et l'utilisation d'un schéma d'optimisation

itérative. L'usage couplé de ces deux concepts, permet notamment de considérer des patches, liés à l'image, ainsi qu'à sa segmentation courante. Cette stratégie, comparée à de précédentes méthodes multi-atlas de la littérature, aboutit à des résultats de segmentation corticale robustes.

- ✚ **G. Galisot, Z. Abu-Aisheh, Y. Kara et al. (2018) [44]:** La segmentation proposée consiste à combiner des atlas probabilistes, définis localement, au sein d'un graphe topologique, afin de mieux appréhender les variabilités de forme, de taille et de position, des différentes structures anatomiques à localiser. La structure de la forme à segmenter, est modélisée, à l'aide d'un graphe, à l'intérieur duquel, les nœuds correspondent aux régions, et les arcs modélisent les relations spatiales entre régions. Dans cette représentation, l'atlas, stocké à l'intérieur des nœuds, est un multi-atlas, au lieu d'un atlas probabiliste classique. Les résultats préliminaires obtenus ont été jugés encourageant.

- ✚ **M. Saim (2019) [45]:** Ce travail a pour but d'étudier, l'impact de la maladie d'Alzheimer, sur la forme corticale, précisément sur la matière grise. Pour cela, la matière grise a été extraite du cerveau isolé, et segmentée par les C-moyennes floues modifiées (Modify Fuzzy C-Means MFCM). Afin de fournir une mesure quantitative de la forme de cette matière, une méthode de caractérisation de forme (Normalized Multiscale Bending Energy : NMBE) a été appliquée, et un nouveau biomarqueur (Taux de performance (TP)) a été introduit, pour identifier la sévérité de la maladie.

- ✚ **B. S. Strnad, H. L. P. Orlowski, M. S. Parsons et al. (2019) [46]:** La sclérose temporale mésiale (SMT) est une cause importante d'épilepsie réfractaire. Un diagnostic, précoce et précis de la SMT, est essentiel pour fournir une thérapie curative, et pour changer la vie, qui peut être difficile, chez les enfants, chez qui l'impact du diagnostic est particulièrement élevé. L'objectif de ce travail, est d'évaluer les performances d'un algorithme de traitement d'image (Corrélatrice Image Enhancement [CIE]), pour détecter une anomalie du signal hippocampique, liée au MTS chez les enfants. Les résultats sont satisfaisants, et donnent une précision de 96,3%.

- ✚ **F. Dahi, M. S. Parsons, H. L. P. Orlowski, et al. (2019) [47]:** Ce travail cherche à savoir, si un algorithme de traitement d'image (Corrélatrice Image Enhancement [CIE]), conçu pour accentuer l'intensité des hippocampes malades, sur les images FLAIR, peut améliorer la précision du diagnostic, et la fiabilité inter observateur des radiologues, dans la détection de l'altération du signal hippocampique, liée à la sclérose temporale mésoiale. Le travail a donné de bons résultats, avec une précision de 72,5%.

- ✚ **P.-A. Ganaye (2019) [48]:** L'objectif de cette thèse est de développer des méthodes, permettant d'intégrer des a priori, dans des réseaux de neurones profonds, en ciblant la segmentation de structures cérébrales, en imagerie IRM. Elle propose une stratégie d'intégration, de la position spatiale du patch à classifier, pour améliorer le pouvoir discriminant, du modèle de segmentation. Ce permet de corriger considérablement les erreurs de segmentation, très éloignées de la réalité anatomique, en améliorant également la qualité globale des résultats. Il propose également une méthodologie, pour contraindre les relations d'adjacence, entre les structures anatomiques, et ce, directement lors de l'apprentissage des paramètres du réseau, dans le but de renforcer le réalisme des segmentations produites. La contrainte proposée corrige les adjacences non-admises, et améliore ainsi, la consistance anatomique des segmentations, produites par le réseau de neurones.

- ✚ **J. Kobold, E. W. Lang, A. M. Tomé et al. (2019) [49]:** L'auteur propose une méthode de détection automatique de thrombus, à partir d'une séquence d'imagerie par résonance magnétique (IRM), de l'angiographie, pondérée en fonction de la susceptibilité (SWAN), en utilisant trois réseaux de neurones U-Nets distincts, qui fonctionnent sur les plans, axial, coronal et sagittal. L'auteur est arrivé au fait que ce problème ne peut pas être résolu par une méthode 2D, et le contexte 3D est nécessaire, pour différencier les thrombus, d'autres objets similaires.

- ✚ **A. Fenneteau, P. Bourdoun, D. Helbert et al. (2020) [50]:** Ce travail représente une nouvelle méthode de segmentation, des lésions de sclérose en plaques (MS), basée sur les CNN, et l'auto-supervision. En étudiant la transférabilité, et en gelant les premières couches convolutives, les auteurs ont découvert que des améliorations sont obtenues, lorsque le CNN est ré-entraîné, à partir des premières couches. (Évaluation performance entre 0,75 et 0,8).

- ✚ **S. N. Yaakub, R. A. Heckemann, S. S. Keller, et al. (2020) [51]:** Le travail consiste à faire une évaluation de deux méthodes de segmentation (MAPER et FreeSurfer), pour la maladie de Parkinson, en utilisant trois bases de données d'atlas, accessibles au public (Hammers_mith, Desikan-Killiany-Tourville et MICCAI 2012 Grand Challenge).
- Les deux méthodes reposent, sur l'idée principale, de transférer des connaissances, d'un atlas vers une image cible. Un atlas, dans ce contexte, est la combinaison d'une image, et d'une segmentation de référence. D'après les résultats, MAPER donne des étiquettes, plus proches des segmentations manuelles, chez les témoins sains, alors que FreeSurfer réussit mieux, à faire la distinction, entre les cohortes de patients, et les témoins sains. Les deux méthodes de segmentation ont identifié, de manière fiable, les anomalies, connues dans chaque groupe de patients, avec une précision de 71%.
- ✚ **D. Castillo, R. Samaniego, Y. Jiménez, A. Sánchez, et al. (2020) [52]:** La sclérose temporale méssiale (SMT) est la principale cause d'épilepsie complexe. Les auteurs ont développé un algorithme, permettant la mesure automatique du volume hippocampique. L'algorithme développé, utilise un prétraitement des images, pour réduire les artefacts, et des techniques d'apprentissage automatique (machine à vecteurs de support), et d'analyse de texture, pour l'extraction des caractéristiques. Cet algorithme permet une optimisation du temps.
- ✚ **M. Rebsamen, Y. Suter, R. Wiest, et al. (2020) [53]:** Nous proposons une approche, basée sur l'apprentissage en profondeur, pour prédire les volumes des régions d'intérêt sous-corticales, anatomiquement délimitées (ROI), et les épaisseurs et courbures moyennes des zones corticales, directement à partir de l'IRM pondérée en T1. Les avantages sont, la disponibilité rapide des résultats, tout en maintenant une précision, cliniquement pertinente.

2.2 Récapitulatif des algorithmes d'analyse d'IRM

TABLEAU 2.1 Récapitulatif des travaux

Auteurs	Pathologie	Structures	Objectif	Performance
Fedde van der Lijn , Tom den Heijer, M. M. B. Breteler, et al. (2008)	Alzheimer	Hippocampe	Segmentation	/
R. Wolz, P. Aljabar, J. V. Hajnal et al. (2010)	Alzheimer	Hippocampe	Segmentation	/
M. Achour (2010-2011)	Alzheimer	Hippocampe	Segmentation Classification	/
H. Wang, S. R. Das, J. Wook Suh, et al (2011)	Alzheimer	Hippocampe	Segmentation	/
A. Ziouani (2014)	Alzheimer	Hippocampe	Segmentation	/
I. Jyoti,Y. zhang (2017)	Alzheimer	Hippocampe	Détection classification	71,25 % pour 5 epochs 73,25%.pour 10 epochs
M. Saim (2019)	Alzheimer	Hippocampe	Segmentation	/
G.-Zimring (1998)	Sclérose en plaques	Multiple sclerosis (MS)	Détection	87 %
R. Khayati, M. Vafadust, F. Towhidkhah, et al. (2007)	Sclérose en plaques	Multiple sclerosis (MS)	Segmentation	75%

B. Li, W. Chen (2009)	Sclérose en plaques	Multiple sclerosis (MS)	Segmentation	/
J. Lecoeur 2010	Sclérose en plaques	Multiple sclerosis (MS)	Segmentation	/
D. Mortazavi, A. Z. Kouzani, H. Soltanian-Zadeh (2012)	Sclérose en plaques	Multiple sclerosis (MS)	Segmentation	95%
O. Commowick, A. Istace, C. Barillot (2018)	Sclérose en plaques	Multiple sclerosis (MS)	Segmentation	/
A. Fenneteau, P. Bourdoun, D. Helbert, et al. (2020)	Sclérose en plaques	Multiple sclerosis (MS)	Segmentation	Entre 75% et 80%
J. D. Rudie, J. B. Colby, N. Salamon (2015)	Épilepsie	Hippocampe (TLE)	Classification	81 %
P. Fergus, A. Hussain, D. Hignett (2016)	Épilepsie	Cerveau entier	Detection	93 %
M. El Azami, A. Hammers, J. Jung, et al. (2016)	Épilepsie	Lésions épileptogéniques (lobe temporel, hippocampe)	Detection	99%
B. S. Strnad, L. H. P. Orłowski, M. S. Parsons, et al. (2019)	Épilepsie	Sclérose temporale méssiale (MTS) (hippocampe, amygdale)	Detection	96,3%

S. N. Yaakub, R. A. Heckemann, S. S. Keller, et al. (2020)	Épilepsie	Hippocampe sclérosés	Segmentation	71%
N. W. Sterling, G. Du, M. M. Lewis, et al. (2013)	Parkinson	Striatum Putamen Caudate,caudal	Segmentation	/

Le tableau 2.1, montre une représentation graphique des algorithmes les plus utilisés en IRM cérébrale, pour la détection des petites structures, d'après notre état de l'art, ainsi que la fréquence d'utilisation de chacun.

Dans notre recherche bibliographique, nous avons trouvé différentes méthodes de prétraitements, de segmentation et de classification. Les méthodes les plus utilisées, pour les lésions(sous-corticales), dues à la maladie d'Alzheimer, de sclérose en plaques (MS), d'épilepsie et de Parkinson. On peut remarquer que les chercheurs utilisent beaucoup plus la méthode de atlas, la méthode de FCM et l'algorithme EM, au paravent dans le domaine de la détection de sous-corticales. Mais, ils sont orientés vers les méthodes de machine learning dans les dernières années, à cause des bons résultats obtenus par ces méthodes surtout l'apprentissage profond qui présente une meilleure performance par rapport autre méthodes, c'est pour ça nous avons décidé de choisir la méthode de deep learning pour l'implémentation de notre algorithme.

La figure 2.1 montre les outils mathématiques utilisés pour la segmentation des sous-corticales et la classification des maladies neurodégénératives dans notre état de l'art.




Figure 2.1 Pourcentage des algorithmes les plus utilisés

Discussion

Le passage en revue de la littérature, présentée dans ce chapitre, a permis d'établir les limitations des méthodes actuelles, pour l'évaluation des petites structures. Nous avons trouvé plusieurs outils de traitements d'images, ou bien des algorithmes pour la segmentation et la classification des petites structures.

Dans le chapitre qui suit, nous allons présenter les méthodes et les fonctions que nous avons choisies, pour chaque étape de l'algorithme, que nous allons développer.

Chapitre₃ _____

Outils mathématiques

Dans les chapitres précédents, nous avons détaillé l'anatomie générale du cerveau, ainsi que les différentes méthodes, et les différents outils, qui ont été utilisés, pour la détection des petites structures.

Afin de mieux comprendre la méthode et l'algorithme, que nous allons établir dans ce chapitre, nous expliquons la théorie des différents outils de classification, que nous utiliserons, et notamment les réseaux de neurones.

3.1 Organigramme

Notre travail consiste à concevoir un algorithme, qui permet, à partir de l'image IRM d'un patient, de classer celui-ci, en sujet sain, en sujet atteint d'une épilepsie, ou en sujet atteint de la maladie d'Alzheimer. Dans ce dernier cas, l'algorithme donne le stade de la maladie. Nous avons pour cela, utilisé un réseau de neurone convolutif (Figure 3.1).




Figure 3.1 Réseau de neurone convolutif

3.2 Deep Learning

L'intelligence artificielle (IA) va avoir un impact sur notre société, que l'on ne peut encore imaginer. Des algorithmes prétendent déjà pouvoir identifier les meilleurs candidats pour un emploi, assister les médecins, ou aider les avocats devant les tribunaux. Tout cela n'est pas totalement nouveau, puisque déjà, dans les années 1980, des systèmes experts assistaient les humains, avec un haut niveau d'expertise. Ce qui est nouveau aujourd'hui, c'est que les ordinateurs parviennent, de manière autonome, à exécuter des tâches, extrêmement complexes, mais sans que leur concepteur ne comprenne parfois, ce qui s'est passé dans la « boîte noire » de l'apprentissage profond (deep Learning) [54].

Au sein de la révolution, que connaît l'intelligence artificielle aujourd'hui, l'apprentissage profond (deep Learning) occupe une place de tout premier plan. Il est au cœur des technologies, qui permettent, aujourd'hui, de réaliser des tâches, encore impensables, il y a quelques années,

comme la conduite automatique, ou la conversation avec des assistants vocaux. La réussite du deep Learning, repose à la fois, sur des avancées, en termes de modélisation des représentations de l'information, sur des méthodes d'apprentissage statistiques, exploitant des données massivement annotées, et sur des calculateurs très puissants, adaptés à ces architectures [55].

Les modèles de deep Learning sont bâtis, sur le même modèle. Cependant, il convient de souligner, que les différentes couches intermédiaires sont plus nombreuses.

Chacune des couches intermédiaires, va être subdivisée en sous partie, traitant un sous problème, plus simple, et fournissant le résultat à la couche suivante, et ainsi de suite. Ainsi, dans le cadre du traitement du langage, imaginons un extrait audio, parlant de l'équipe d'Algérie de football ; les différentes couches pourraient se hiérarchiser de cette façon :

- Couche 1 : Sport ;
- Couche 2 : Sport collectif ;
- Couche 3 : Football ;
- Couche 4 : Equipe d'Algérie.

Cette manière d'ordonner les déductions, amènent les modèles de Deep Learning, à se rapprocher un peu plus, du mode de fonctionnement du cerveau humain, en ajoutant, au fur et à mesure, un contexte, de plus en plus précis, au sujet sur lequel le modèle opère [56].

3.2.1 Neurone biologique

Le système nerveux est composé de milliards de cellules : c'est un réseau de neurones biologiques. En effet, les neurones ne sont pas indépendants les uns des autres, ils établissent entre eux des liaisons, et forment des réseaux, plus ou moins complexes [57].

Le neurone biologique est composé de trois parties principales, illustrées dans la figure 3.2 [57] :

- Le corps cellulaire, constituant centre de contrôle, traitant les informations reçues par les dendrites ;
- Les dendrites sont les récepteurs, par lesquels transitent l'information, venue de l'extérieur, vers le corps cellulaire ;
- L'axone est le fil conducteur, qui conduit le signal de sortie, du corps cellulaire vers d'autres neurones ;

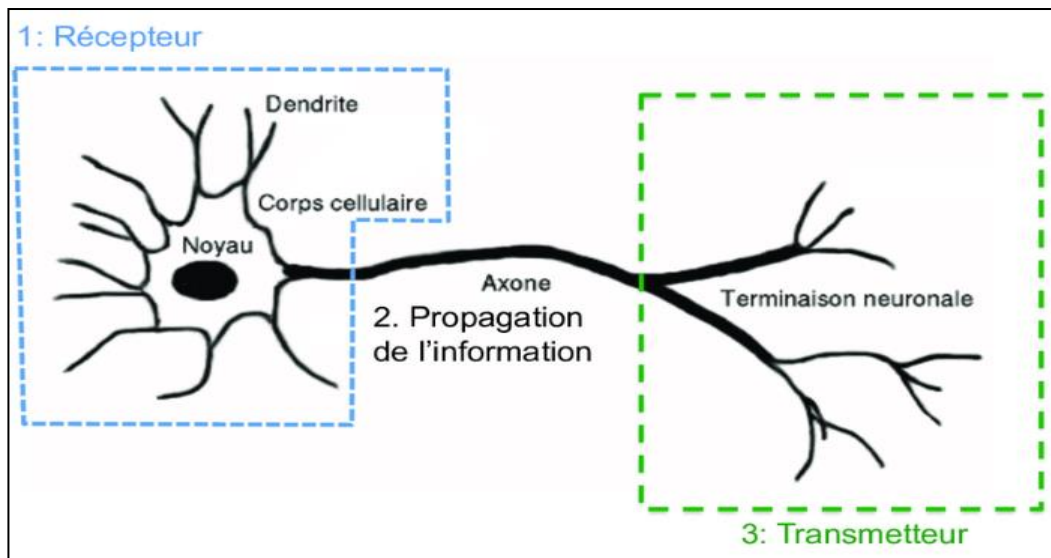


Figure 3.2 Neurone biologique

- Quant aux synapses, elles font effet de liaison, et de pondération entre neurones, et permettent donc aux neurones de communiquer entre eux (Figure 3.3) [57].

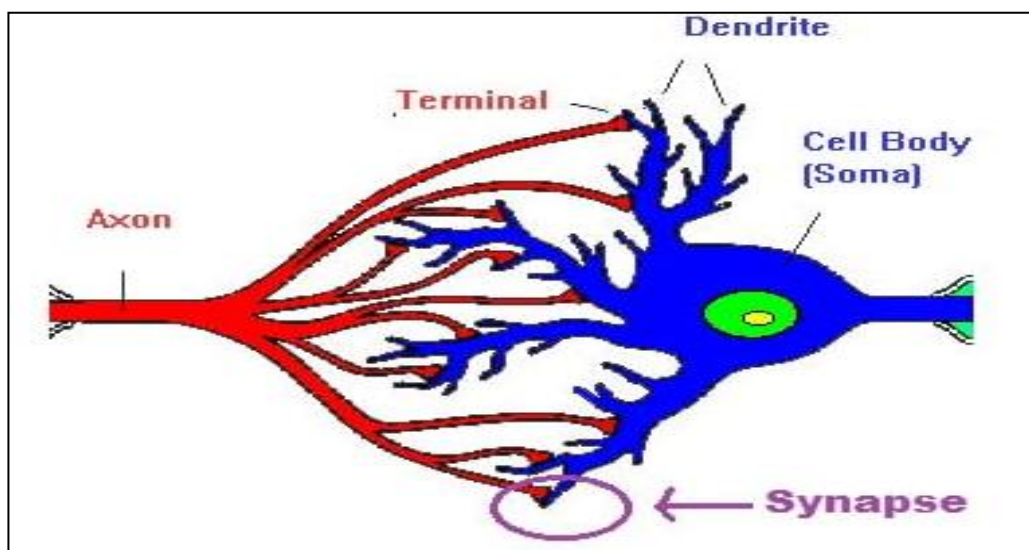


Figure 3.3 Communication entre 2 neurones biologiques

Les neurones biologiques disposent d'un centre de contrôle (appelé cellule somatique, ou soma, ou corps cellulaire), faisant la somme des informations, recueillies par les dendrites. Ensuite, le centre de contrôle retourne un potentiel d'action, en suivant les règles suivantes [57] :

- Si la somme en entrée ne dépasse pas le seuil d'excitation : pas de message nerveux, via l'axone ;

- Si la somme en entrée dépasse le seuil d'excitation : un message nerveux, qui est en fait une impulsion, est émis, via l'axone

3.2.2 Neurone artificiel ANN

Les réseaux de neurones, communément appelés réseaux de neurones artificiels, sont des imitations simples, des fonctions d'un neurone, dans le cerveau humain, pour résoudre des problématiques d'apprentissage de la machine (Machine Learning). Le neurone est une unité, qui est exprimée généralement, par une partie de la fonction sigmoïde (3.1) [58].

$$\boxed{f(x) = \frac{1}{1 + e^{-x}}} \quad (3.1)$$

Les domaines d'application, des réseaux neuronaux, sont souvent caractérisés par une relation entrée-sortie, de la donnée d'information :

- La reconnaissance d'image ;
- Les classifications de textes ou d'images ;
- L'identification d'objets ;
- La prédiction de données ;
- Le filtrage d'un ensemble de données.

Procédons à une comparaison simple, des étapes principales de l'algorithme du perceptron, avec les éléments constitutifs des neurones biologiques. Ce choix d'algorithmes se justifie, car il se rapproche au mieux, du fonctionnement des neurones biologiques (3.4) [57] :

- Les synapses/dendrites : pondération w_i de chaque élément en entrée x_i ;
- Corps cellulaires : application d'une fonction d'activation f , à la somme des entrées pondérées ;
- Axone : sortie de notre modèle

$$\boxed{\text{Output} = f(\sum_i^n w_i x_i)} \quad (3.2)$$




Figure 3.4 Neurone biologique avec neurone artificiel

Le vocabulaire spécifique, aux réseaux de neurones artificiels est le suivant [57] :

- Le vecteur w porte le nom du vecteur de poids (qui s'ajuste lors de l'entraînement) ;
- Le vecteur x porte le nom du vecteur d'entrée ;
- f porte le nom de la fonction d'activation.

3.3 Outils de classification

Classifier une image est une tâche, ou une série de méthodes appliquée sur l'image. Il est souvent important de traduire l'information de fréquence, contenue dans les images, en information thématique portant, sur les structures cérébrales ou des pathologies du cerveau

L'objectif de la classification d'images est d'élaborer un système, capable d'affecter un classement automatique d'images. Ainsi, ce système permet d'effectuer une tâche d'expertise, qui peut s'avérer coûteuse à acquérir, pour un être humain, en raison notamment de contraintes physiques, comme la concentration, la fatigue, et le temps nécessaire, pour un volume important de données images.

Pour notre méthode de classification, nous avons suivi les étapes données par la figure 3.5 :

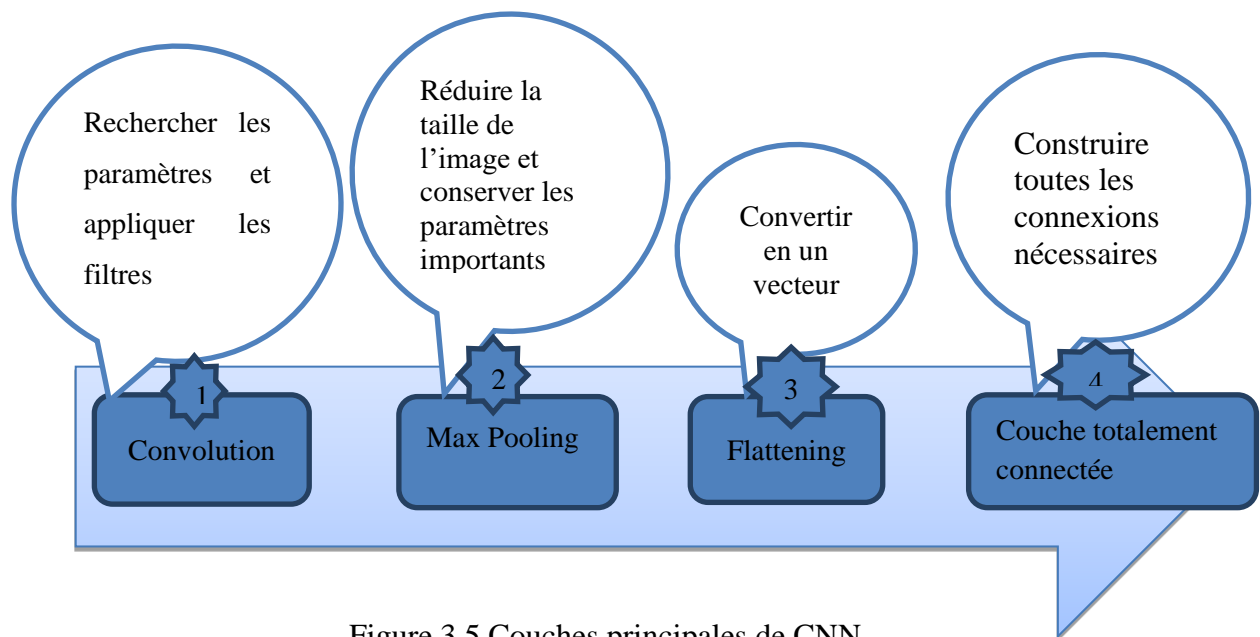


Figure 3.5 Couches principales de CNN

Les réseaux de neurones convolutionnels sont, à ce jour, les modèles les plus performants, pour classer des images. Désignés par l'acronyme CNN, de l'anglais Convolutional Neural Network, ils comportent deux parties bien distinctes. En entrée, une image est fournie, sous la forme d'une matrice de pixels. Elle a 2 dimensions, pour une image en niveaux de gris. La couleur est représentée par une troisième dimension, de profondeur 3, pour représenter les couleurs fondamentales [Rouge, Vert, Bleu].

La première partie d'un CNN est la partie convolutive, à proprement parler. Elle fonctionne comme un extracteur de caractéristiques des images. Une image est passée, à travers une succession de filtres, ou noyaux de convolution, créant de nouvelles images, appelées cartes de convolutions (Figure 3.6). Certains filtres intermédiaires, réduisent la résolution de l'image, par une opération de maximum local. Au final, les cartes de convolutions sont mises à plat, et concaténées en un vecteur de caractéristiques, appelé code CNN [59].

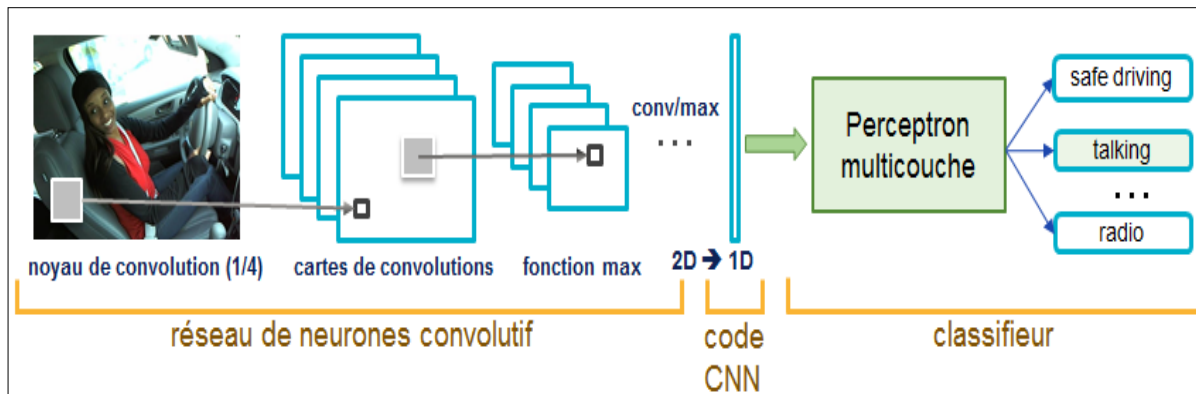


Figure 3.6 Architecture standard d'un réseau de neurone convolutionnel

3.3.1 Couche de convolution

La convolution est la partie la plus importante des CNN. Elle va opérer sur une image en 3 dimensions, qui a donc une longueur, une largeur et une profondeur. La profondeur peut être égale 0, dans le cas, où l'image est en noir et blanc, et égale à 3, si elle est en couleur (R G B). En d'autres termes, notre image est, soit une matrice à 2 dimensions, si elle est en noir et blanc, soit un bloc à 3 dimensions, si elle est en couleurs.

La convolution consiste à faire dérouler un filtre, de taille donnée, sur cette image (figure 3.7). La question qui se pose maintenant est : qu'est-ce qu'un filtre ? Si on prend l'exemple d'une image en couleurs (profondeur =3), alors un filtre est lui aussi un bloc, de largeur et de hauteur, inférieures à celle de l'image, mais de même profondeur ; ce filtre, on va le faire passer sur le bloc de départ (image) [59].




Figure 3.7 Convolution

La formule, pour calculer le tenseur de la sortie, du featuremaps de la couche, est donnée par (3.3) :

$$f^{(l)}[n, i, j] = b^{(l)}[n] + \sum_{c=1}^C \sum_{p=1}^K \sum_{q=1}^K \Phi^{(l)}[c, i + p, j + q] \cdot w^{(l)}[n, c, p, q] \quad (3.3)$$

$\forall l = 1 : L$ (nombres de couches de convolution)

$\forall n = 1 : N$ (nombres des sorties des featuremaps)

$\forall i = 1 : I_x$ (ligne des featuremaps)

$\forall j = 1 : I_y$ (colonnes des featuremaps)

- $f^{(l)}$ le tenseur de la sortie du featuremaps de la couche (l) ;
- $b^{(l)}[n]$ le biais appliqué au featuremaps ;
- $\Phi^{(l)}$ le tenseur d'entrée du featuremaps de la couche (l) ;
- $w^{(l)}$ le tenseur du filtre pré-appris.

3.3.2 Couche de maxpooling

Le max pooling est une opération, qui permet de réduire progressivement, la taille spatiale de la représentation. Ceci, pour réduire le nombre de paramètres et de calculs dans le réseau, sans perdre les informations les plus importantes (figure 3.8), et donc de contrôler également l'overfitting. Le principal avantage du pooling, est qu'il est efficace, lorsque l'on souhaite détecter des signaux faibles, comme pour le cas de la stéganalyse [59].




Figure 3.8 Max pooling

La fonction pour le calcul est donnée par l'équation (3.4) :

$$f^{(l)}[n, i, j] = \max_{p, q \in [1:K]} \left(\Phi^{(l)}[n, i + p, j + q] \right) \quad (3.4)$$

- $\forall l = 1 : L$ (nombre de couches de pooling) ;
- $\forall n = 1 : N$ (nombres de sorties featuremaps) ;
- $\forall i = 1 : I_x$ (ligne du featuremap) ;
- $\forall j = 1 : I_y$ (colonne du featuremap).

3.3.3 Conversion en vecteur (Flatten)

Cette couche reprend les couches, que nous avons précédemment créées dans max pooling, et transformé en vecteur, pour que nous puissions travailler avec (figure 3.9), et que l'on puisse le mettre, dans le réseau neuronal.

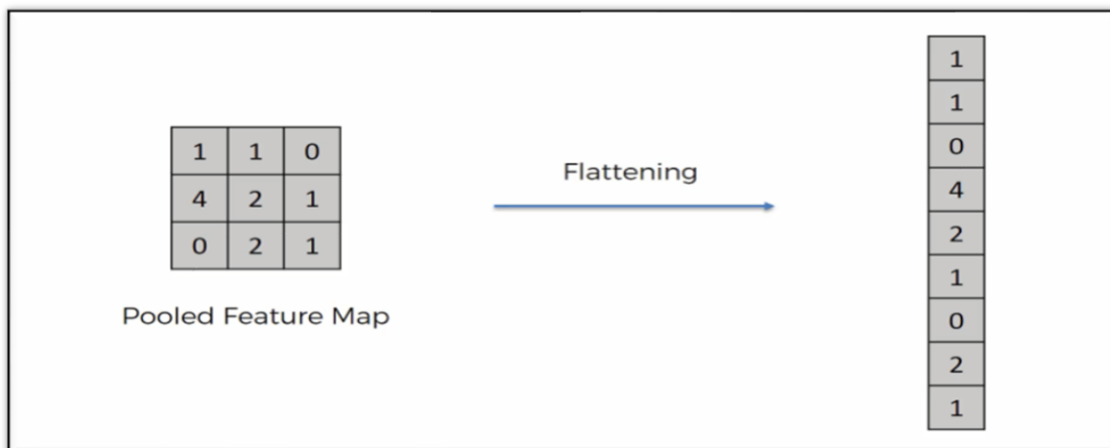


Figure 3.9 Conversion en vecteur

3.3.4 Couches totalement connectées

Enfin, après les couches de convolution et pooling, le raisonnement de haut niveau dans le réseau neuronal, se fait, via des couches totalement connectées.

Dans les réseaux de neurones convolutifs, chaque couche agit comme un filtre de détection, pour la présence de caractéristiques spécifiques, ou de motifs présents, dans les données d'origine.

Les premières couches d'un réseau convolutif, détectent des caractéristiques, qui peuvent être reconnues et interprétées facilement. Les couches ultérieures, détectent de plus en plus des

caractéristiques plus abstraites. La dernière couche du réseau convolutif est capable de faire une classification ultra-spécifique, en combinant toutes les caractéristiques spécifiques, détectées par les couches précédentes, dans les données d'entrée.

Les couches totalement connectées font les mêmes tâches, que celles des ANN standard, et Tentent de produire des notes de classe, à partir des activations, pour les utiliser pour la classification (figure 3.10). Il est également suggéré d'utiliser Relu (une fonction d'activation qu'est un élément essentiel de la conception d'un réseau neuronal, elle signifie la transformation de l'entrée à l'aide d'une somme pondérée vers la sortie) entre ces couches, pour améliorer les performances [60] .




Figure 3.10 Couches entièrement connectées

Discussion

Dans ce chapitre, nous avons présenté les outils essentiels de notre algorithme, pour la classification multi classes, que nous avons appliqué, pour les cas d'Alzheimer et d'épilepsie, ainsi qu'une classification multi classe, sur les 3 stades d'Alzheimer.

Nous n'avons pas appliqué un prétraitement, puisque la méthode de deep Learning, que nous avons utilisé, n'en nécessite pas, et elle élimine le bruit.

Nous avons appliqué la méthode de deep Learning, pour la phase de classification. Finalement, une architecture Res-net est réalisé, pour classer chaque coupe d'IRM cérébrale, dans une 1^{ère} classification, dans l'une des trois classes : sujet sain, sujet Alzheimer ou sujet épileptique. Par la suite, et dans une 2^{ème} classification, elle sera classifiée dans l'un des trois stades d'Alzheimer.

Dans le chapitre qui suit, nous présenterons l'implémentation de notre algorithme sur logiciel.

PARTIE PRATIQUE

Chapitre₄ _____

Implémentation, résultats et interprétation

Dans ce chapitre, nous allons présenter les différentes étapes de notre algorithme, les résultats obtenus à chaque étape, et leur interprétation, ainsi que l'interface graphique, qui regroupe les fonctions implémentées.

4.1 Description des bases de données utilisées

Les bases de données d'images sont une ressource essentielle, dans le développement des algorithmes d'analyse d'images. Dans cette section, nous présentons les deux bases de données, utilisées pour notre travail (Tableau 4.1), pour la classification.

Nous avons travaillé avec des images en 2D, en niveau de gris, en format PNG et JPG, avec des tailles différentes. Environ 6550 images ont été analysées et traitées, dont une partie, a été obtenue, au niveau du centre d'imagerie de Birtouta d'Alger, et qui a été fournie par un médecin diabétologue Dr Merazka, le reste des images a été téléchargé, à partir de bases de données sur le web (site kaggle) [61].

Les formats PNG et JPG, permettent de stocker des images, en niveaux de gris (jusqu'à 16 bits par pixels de profondeur de codage). Nous avons choisi ces deux formats, car ils permettent de nous offrir une meilleure netteté des images, avec une bonne qualité.

La figure (4-1) représente quelques exemples de notre base de données.

TABLEAU 4.1 Caractéristiques de chaque base de données.

	Base 1	Base 2
Taille d'images	176x208	349x311
Format d'images	JPG	PNG
Résolution	3.2 micromètres	3.9 micromètres
Nombre d'images	6400	150
Catégories	Normal, Alzheimer (MildDemented, ModerateDemented, VeryMildDemented)	Epilepsie




Figure 4.1 Exemples d'images des deux bases de données utilisées.

(a) Première base ;(b) Deuxième base.

4.1.1 Environnement et langage de programmation

4.1.2 Logiciel d'implémentation

Le langage de programmation, avec lequel nous avons programmé, est le python, version 3, (Figure 4.2). Python est un langage « Open source », qui peut être utilisé dans de nombreux contextes, et qui s'adapte à tout type d'utilisation, grâce à des bibliothèques spécialisées.

Il favorise la programmation structurée, fonctionnelle et orientée objet. Il est particulièrement répandu dans le monde scientifique, et possède de nombreuses bibliothèques optimisées, destinées au calcul numérique, comme OpenCV, tflearn et sckiti-image.

Les principales utilisations de python par les développeurs sont :

- La programmation d'application ;
- La création des services web ;
- Les jeux vidéo ;
- Le domaine du traitement d'image.

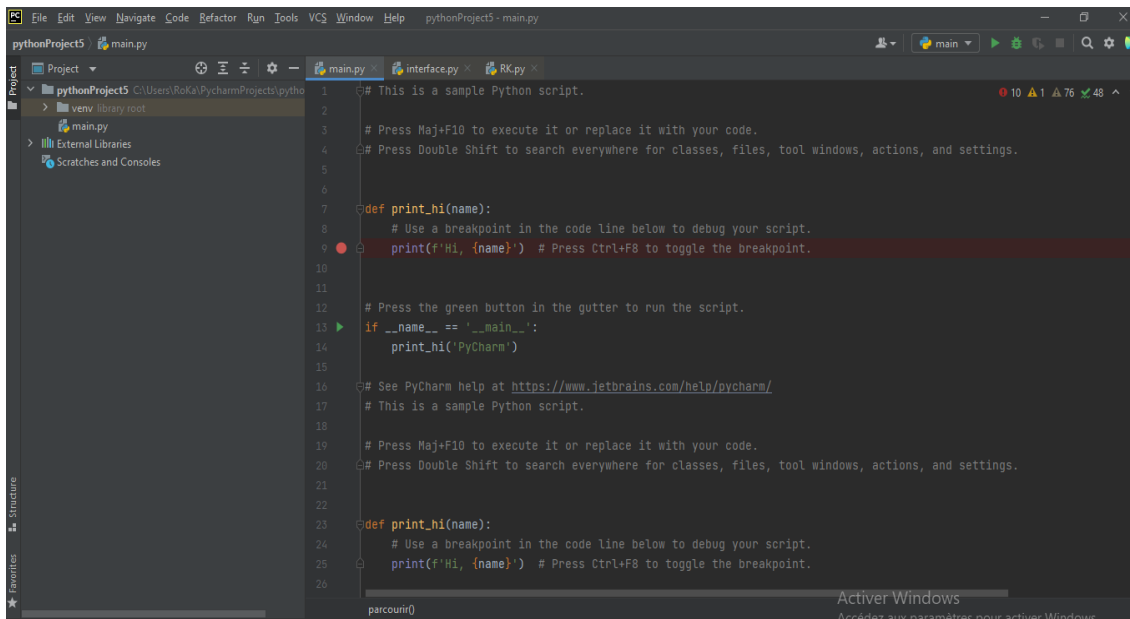


Figure 4.2 Distribution libre du langage de programmation python (PyCharm).

4.1.3 Bibliothèque TensorFlow

TensorFlow est une bibliothèque de Machine Learning. Il s'agit d'une boîte à outils, permettant de résoudre des problèmes mathématiques, extrêmement complexes, avec aisance. Elle permet aux chercheurs, de développer des architectures d'apprentissage expérimental, et de les transformer en logiciels (Figure 4.3).

TensorFlow regroupe un grand nombre de modèles, et d'algorithmes de Machine Learning et de Deep Learning. Son développement d'applications, repose sur le langage de programmation Python, tandis que l'exécution de ces applications, s'effectue en C++ haute-performance.

Cette bibliothèque permet notamment, d'entraîner et d'exécuter des réseaux de neurones, pour la classification de chiffres écrits à la main, la reconnaissance d'images, les réseaux de neurones récurrents, les modèles sequence-to-sequence, pour la traduction automatique, ou encore le traitement naturel du langage.



Figure 4.3 Logo de la bibliothèque TensorFlow

4.1.4 Logiciel ITK-SNAP

Le logiciel ITK-SNAP est un logiciel 'open source', utilisée pour segmenter des structures, dans des images médicales 3D. Il fournit une segmentation semi-automatique, à l'aide de méthodes de contours actifs, ainsi qu'une délimitation manuelle, et une navigation d'image. En plus de ces fonctions de base, SNAP fournit un certain nombre d'utilitaires de support (Figure 4.4) .

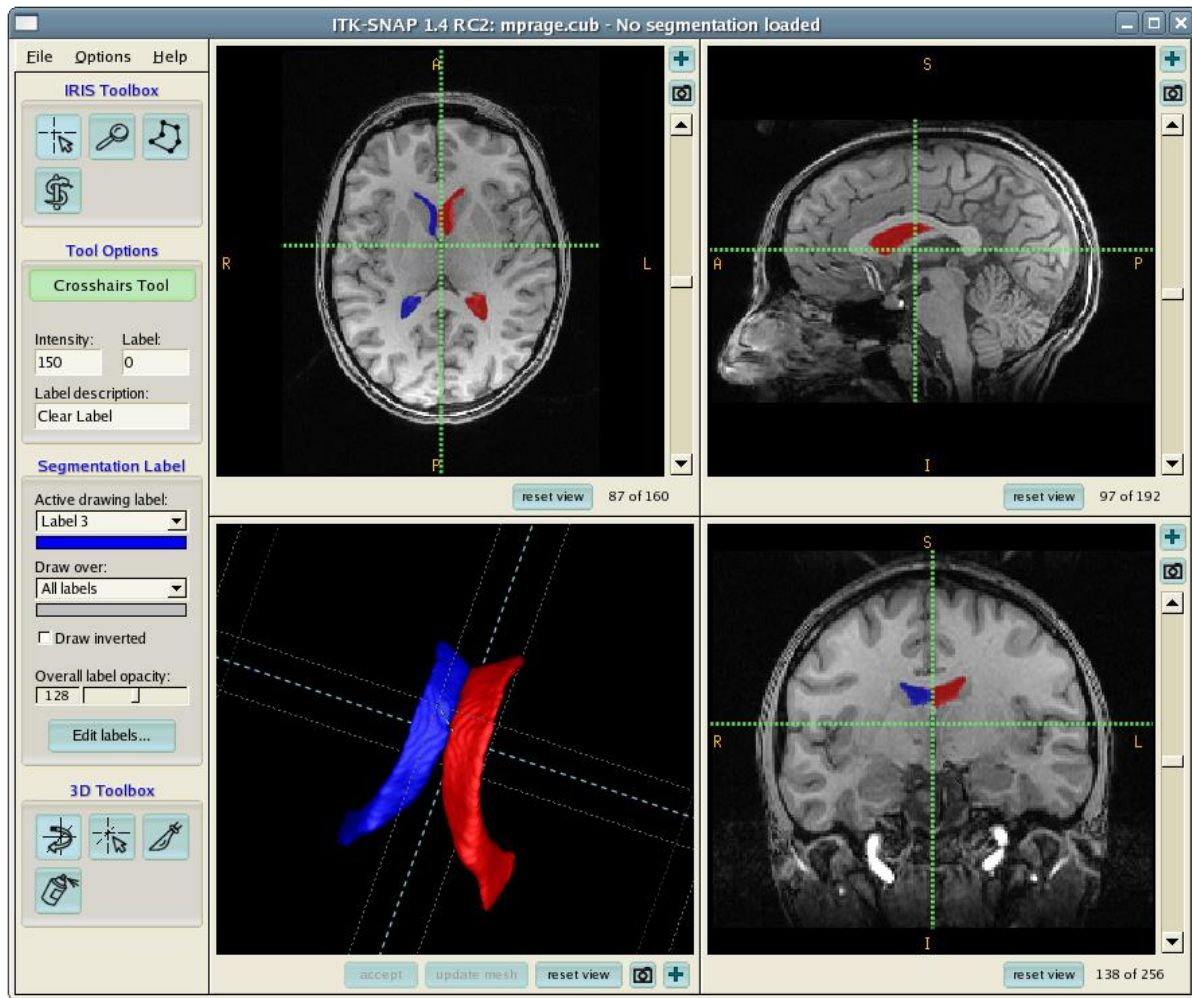


Figure 4.4 Environnement ITK-SNAP

Dans notre travail, nous avons utilisé ce logiciel, pour tirer des images 2D, à partir des images 3D, obtenues du centre d'imagerie médicale.

Pour cela, nous avons suivi les étapes suivantes : File => Export => Screenshot Series => Sagittal.

Ensuite, un dossier contenant les coupes désirées, sera enregistré, selon un chemin bien défini.

4.2 Organigramme général du système proposé

Nous présentons brièvement notre algorithme, avant de fournir une description détaillée de chaque étape du système proposé, dans les sous-sections suivantes. L'organigramme de notre algorithme est illustré en Figure 4.5. Il comprend les opérations essentielles, appliquées aux images IRM cérébrales d'entrée pour implémenter notre algorithme.

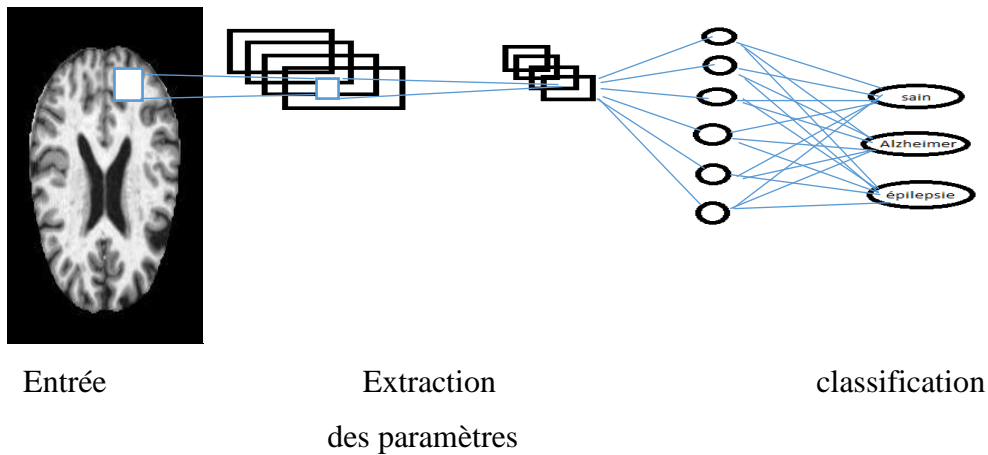


Figure 4.5 Organigramme général de la méthode proposée

- **Acquisition d'image** : nous avons utilisé les images d'IRM cérébrales. Ces images sont prises par un imageur IRM.
- **Classification** : les paramètres sont extraits, pour réaliser la classification des images en trois classes : images saines, images d'épilepsie ou images Alzheimer.

4.3 Classification

La classification d'images, est une application de la reconnaissance de formes, qui consiste à attribuer automatiquement, une classe à une image, à l'aide d'un système de classification. La figure 4.5, présente le synoptique de la classification, par la méthode de l'apprentissage profond.

4.3.1 Acquisition d'image

La lecture des dossiers des images, pour l'entraînement, est obtenue, grâce à la commande de la bibliothèque TensorFlow de python :

```
'tf.keras.preprocessing.image_dataset_from_directory',
```

La lecture des images des bases de données, est obtenue, grâce à la commande de la bibliothèque OpenCV de python :

```
'cv2.imread'
```

4.3.2 Système proposé

Nous proposons un système, pour la détection des petites structures du cerveau, à partir d'images IRM cérébrales, à l'aide de l'apprentissage profond (deep Learning).

Il s'agit de développer un système d'apprentissage profond, rapide et fiable. Son objectif principal, est de diminuer l'intervention humaine, augmenter le taux de contrôle, et réduire les défauts de diagnostic. En fait, le but de notre travail est de faire un diagnostic des maladies neurodégénératives, à partir des images IRM cérébrales.

Nous avons choisi d'appliquer notre méthode sur 2 pathologies : la maladie d'Alzheimer et l'épilepsie.

- **Visualisation des données**

La figure 4.6 représente l'affichage, après la visualisation des données. Pouvoir visualiser ses données lorsqu'on les manipule est une nécessité. Observer des graphes nous permet d'anticiper certains problèmes et de mieux peaufiner nos futures analyses.




Figure 4.6 Résultat de la visualisation des données

- **Normalisation des données**

La normalisation est une approche, de conception de base de données, utilisée dans les bases de données relationnelles, pour éviter la redondance. Cette étape n'est pas fondamentale. Mais, elle permet d'avoir des résultats fiables.

- **Architecture implémentée**

Après l'état de l'art que nous avons fait, l'architecture implémentée a été Res-net, attribué à l'utilisation des réseaux de neurones très profonds, qui est généralement utilisé, dans le cas de la classification. Cette architecture contient :

1. L'extraction des paramètres, et l'application des filtres, grâce à la commande de la bibliothèque TensorFlow de python :

```
'Conv2D ()'
```

Cette étape a pour but, de repérer la présence d'un ensemble de paramètres (features), dans les images reçues en entrée, en appliquant des filtres.

2. Importance des paramètres, qu'a pour but de sélectionner les paramètres les plus pertinents et réduction des informations à traiter), ceci, grâce à la commande de la bibliothèque TensorFlow de python :

```
'MaxPooling2D ()'
```

Cette étape a pour but, de choisir les paramètres les plus importants, et de réduire la taille de l'image, pour diminuer le temps d'exécution.

3. Transfert (La conversion des matrices) en vecteur, grâce à la commande de la bibliothèque TensorFlow de python

```
'Flatten ()'
```

Cette étape a pour but de transformer l'image 2D, en un vecteur 1D, afin de le préparer, pour la prochaine étape.

4. Application du réseau de neurones, qui est un ensemble de couches cachées, grâce à la commande de la bibliothèque TensorFlow de python

'Dense ()'

Cette étape a pour but, de définir les neurones de notre architecture.

TABLEAU 4.2 Architecture utilisée

Couche	Taille de filtre	Nombre de couche	Fonction d'activation
Image d'entrée	----	-----	-----
convolution	3x3	5 couches	Relu
Maxpooling	2x2	5 couches	-----
Caché	128	1 couche	Relu
Image de sortie	----	-----	-----

- **Apprentissage et classification**

Un algorithme d'apprentissage peut être défini comme suit : c'est un algorithme, qui prend en entrée un ensemble de données, contenant les informations nécessaires, pour caractériser un problème donné, et qui doit être capable de prédire l'étiquette de nouveaux objets, en fonction de leurs valeurs d'entrée.

Dans notre travail, nous avons développé un système d'aide au diagnostic, pour classier les sujets normaux, les sujets affectées par la maladie d'Alzheimer, et ceux atteints par l'épilepsie. Pour cela, nous avons utilisé une base d'apprentissage, et une base de test, composées respectivement, d'environ 5000 images et 500 images.

Dans notre phase d'apprentissage, le temps d'exécution a pris 2 heures et demi pour l'apprentissage des deux bases de données avec un pc i3 SSD 5ème génération .

Pour évaluer et interpréter notre programme nous allons afficher les graphes des deux fonctions suivantes :

- La fonction de précision (Accuracy) : c'est la fraction des prédictions, que notre modèle a tirée de toutes les prédictions. Cela signifie que nous additionnons, le nombre de prédictions correctement prédites, comme positives (TP), ou correctement prédites, comme négatives (TN), et le divisons par tous les types de prédictions, correctes (TP, TN) et incorrectes (FP, FN).
- La fonction de perte (Loss) : c'est une valeur, qui représente la somme des erreurs, dans notre modèle. Il mesure, à quel point, notre modèle se porte bien (ou mal). Si les erreurs

sont élevées, la perte sera élevée, ce qui signifie que le modèle ne fait pas bien la classification. Sinon, plus il est bas, mieux notre modèle fonctionne.

- **Interprétation**

La figure 4.7 représente les graphes d'entraînements et de validation, "Accuracy et Loss ", qui montre que notre programme a subi un surapprentissage, et donc, notre étape d'entraînements, n'était pas suffisante, pour résoudre ce problème. Pour cela, nous allons faire une augmentation des données dans la prochaine étape.

Figure 2




Figure 4.7 Graphes de la précision (Accuracy) et de perte (Loss).

- **Augmentation des données**

Cette étape peut être définie, comme un processus d'augmentation de la quantité de données d'entraînement, par la création de nouvelles données, à partir des données existantes en faisant

subir des transformations aux données existantes, telles que des rotations, translations...(figure 4.8).

Figure 1




Figure 4.8 Résultat de l’augmentation des données

- **Interprétation, après augmentation des données**

D’après notre étude le nombre d’epochs est un facteur très important pour l’augmentation de la précision, pour cela nous avons fait un test pour montrer l’importance de ça.

Après l’augmentation de data, nous avons faites deux tests sur des différents nombre d’epochs.

Résultats de test sont exprimés dans le tableau 4.3.

TABLEAU 4.3 Résultats d’accuray et loss en fonction de nombre d’epochs

Nombre d’epochs	Accuracy	Loss
10	71%	75%
15	74.5%	65%

La figure 4.9 représente les graphes d’entrainements et de validation "d’accuracy et loss "après l’augmentation des données avec 15 epochs.

Nous remarquons que l'étape d'entraînements a été bien améliorée, après l'augmentation des données, car les valeurs des graphes d'entraînements et de validation montrent un accroissement, et en parallèle, une décroissance de la fonction Loss, ce qui signifie, que l'étape d'entraînement a été bien améliorée.

Remarque : Les pics qui apparaissent sur les graphes de validation, indique l'application d'un nouveau filtre.

Figure 2





Figure 4.9 Graphes de « Accuracy » et « Loss ».

4.3.3 Evaluation des résultats

Les performances de la classification des données, ont été évaluées par la matrice de confusion. C'est un outil, qui permet de mesurer la qualité d'un système de classification, comme le montre la figure 4.10. Sur la diagonale de la matrice, nous trouvons les exemples bien classés, les autres sont mal classés.

Sachant que :

- **VP** : représente le nombre d'individus malades, classés malades ;
- **FP** : représente le nombre d'individus sains, classés comme malades ;
- **FN** : représente le nombre d'individus malades, classés comme sains ;
- **VN** : représente le nombre d'individus sains, classés sains.

		Réponse de l'expert	
		p	n
Réponse du classifieur	Y	Vrai Positif	Faux Positif
	N	Faux Négatif	Vrai Négatif

Figure 4.10 Matrice de confusion

Les matrices de confusion sont conçues, pour donner plus de détails, sur la classification des échantillons, d'une classe donnée. A partir d'une matrice de confusion, nous pouvons calculer des mesures statistiques, telles que la précision (P), la spécificité (S) et la sensibilité (Se).

- **La précision** : c'est le pourcentage de sujets correctement classés, calculé par l'équation 4.1 :

$$P = \frac{VP + VN}{VP + FP + FN + VN} \times 100 \quad (4.1)$$

- **La spécificité** : c'est la capacité d'obtenir un résultat négatif, alors que la maladie est absente ; elle est calculée par l'équation 4.2 :

$$S = \frac{VN}{VN+FP} \times 100 \quad (4.2)$$

- **La sensibilité** : c'est la capacité d'obtenir un résultat positif, alors que la maladie est présente ; elle est calculée par l'équation 4.3 :

$$Se = \frac{VP}{VP + FN} \quad (4.3)$$

Résultats

Selon la base de test utilisée, nous avons obtenu la matrice de confusion suivante :

$V_P = 35$	$F_P = 5$
$F_N = 3$	$V_N = 27$

Pour mieux évaluer la fiabilité de l'approche proposée, nous comparons nos résultats, par rapport aux méthodes existantes dans la littérature (Tableau 4.4)

TABLEAU 4.4 Performance de la méthode proposée par rapport aux méthodes existantes

Auteurs	Précision	Spécificité	Sensibilité
N. Belmokhtar et al	84.9%	----	----
I. jyoti et al	73.25%	----	----
Notre méthode	88,57%	89,37%	92,1%

La sensibilité présente un taux de 92,1%, ce qui correspond à la capacité de classer un sujet malade, lorsque la maladie est présente, tandis que la spécificité présente un taux de 89,37%. Enfin, la précision ou le taux des sujets correctement classés, est de 88,57%.

La méthode de classification proposée, basée sur l'apprentissage profond, a donnée des résultats satisfaisants. Pour avoir un résultat plus significatif, il faut utiliser plus d'images.

4.4 Présentation de l'interface

Dans cette partie, nous présentons notre logiciel, et nous exposons le contenu du menu réalisé. Ce logiciel est constitué d'une interface principale, avec un menu déroulant, et une fenêtre, qui permet l'affichage de l'image à traiter, et les résultats de deux étapes de classification. Nous présentons dans la figure 4.11, les différents aspects (élément) de notre application.

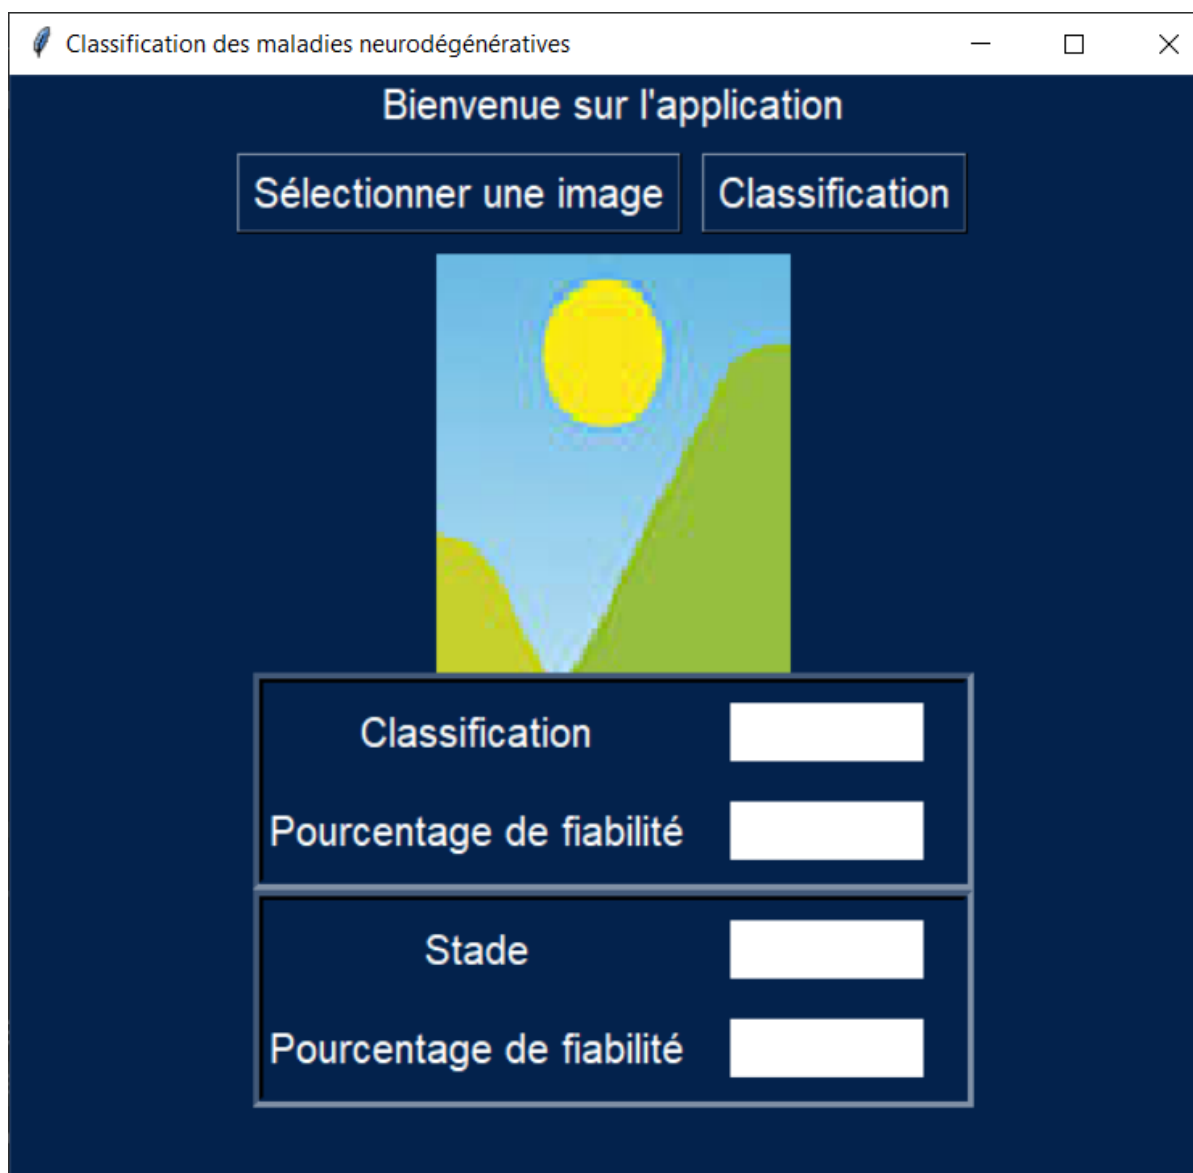


Figure 4.11 Fenêtre principale

➤ **Composition de la fenêtre**

L'interface est composée de :

1. Deux boutons :

- **Sélectionner une image** : pour lire l'image à traiter ;
- **Classification** : pour diagnostiquer l'état du patient, et afficher les pourcentages de fiabilité.

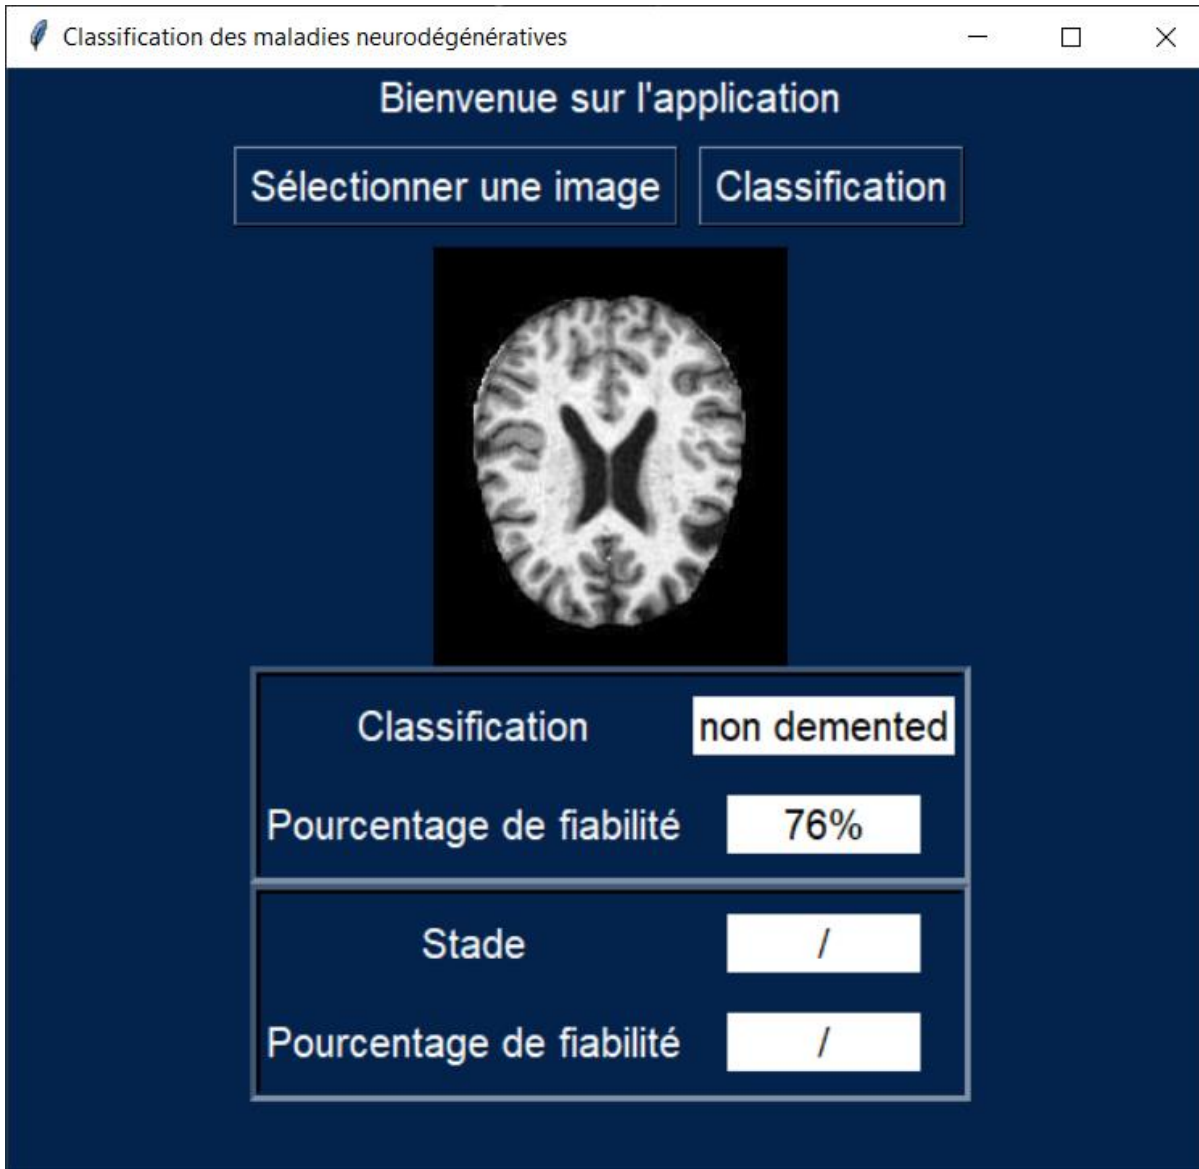
2. Fenêtre d'affichage :

- **Image originale.**

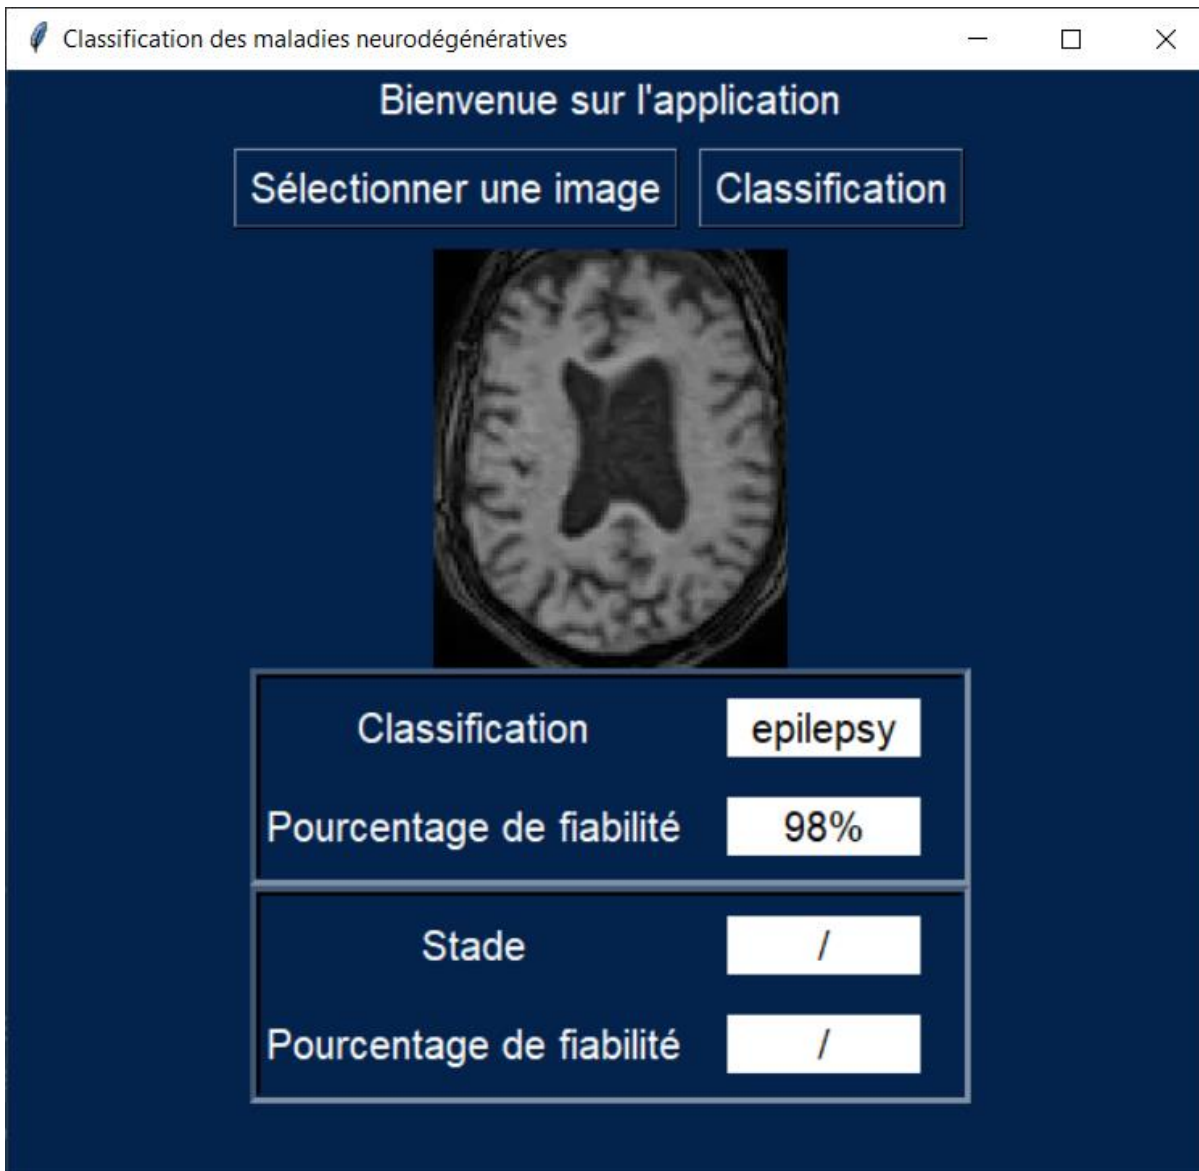
➤ **Aperçu des résultats dans l'interface**

Les figures 4.12(a), (b) et (c) donnent respectivement, la représentation des résultats obtenus, pour quelques patients.

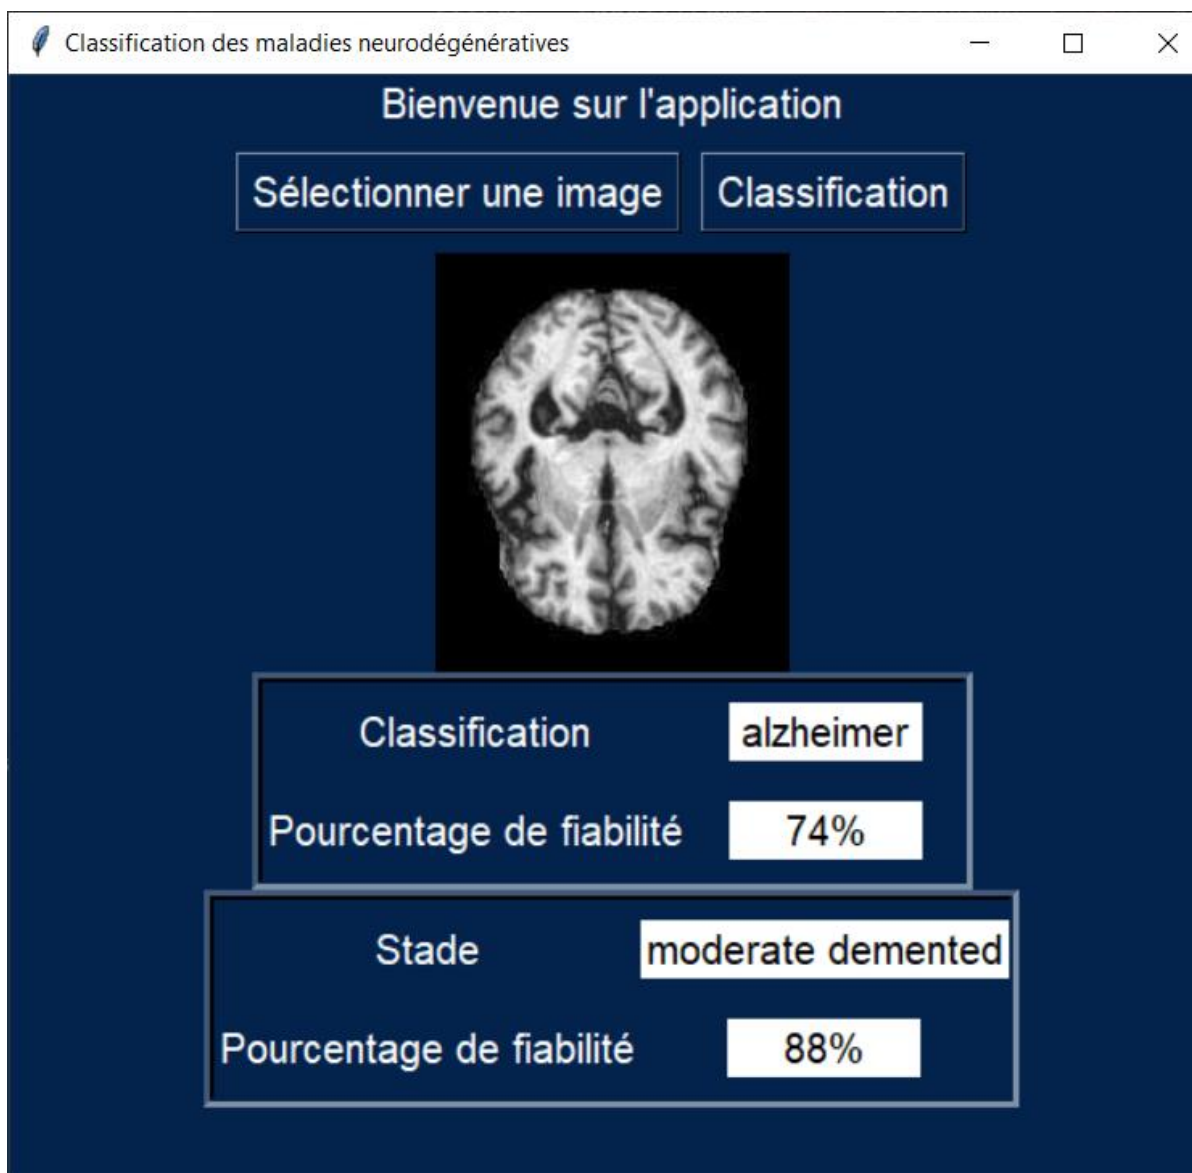
- **Résultats**



(a)



(b)



(c)

Figure 4.12 Représentation des résultats dans l'interface.

(a) Patient 1 (sujet sain), (b) Patient 2 (sujet épileptique), (c) Patient 3 (sujet Alzheimer)

Discussion

Dans ce chapitre, nous avons présenté l'algorithme de notre méthode, et nous avons expliqué chaque étape de cet algorithme. Nous avons donné et interprété les résultats obtenus, à chacune de ces étapes, sur quelques images, de patients, sain, atteint d'Alzheimer et atteint d'épilepsie. Nous avons fait une classification, pour différencier entre les sujets sains, les sujets Alzheimer et les sujets épileptiques, ainsi qu'une classification, pour différencier entre les trois stades

d'Alzheimer. Nous avons évalué quantitativement cette classification. Nous avons terminé notre travail par la présentation de l'interface graphique, que nous avons réalisée.

Conclusion générale

L'objectif de ce mémoire était, la conception et le développement d'un algorithme d'analyse d'images cérébrales, qui permette de faciliter, et d'améliorer le diagnostic, des maladies neurodégénératives.

Nous avons présenté l'algorithme, que nous avons développé, dans le but de classifier les patients automatiquement, en trois catégories : sains, Alzheimer et épilepsie, et aussi, de définir les stades de la maladie dans le cas d'Alzheimer.

L'analyse d'images peut fournir des outils, pour un meilleur suivi des maladies. L'algorithme qui a été présenté, en tenant compte de l'apprentissage profond que nous avons présenté, basé sur l'apprentissage profond, est une méthode moderne, et très efficace, qui ne nécessite pas une phase de prétraitement.

Nous avons développé un algorithme, qu'est inutile l'apprentissage profond, avec une architecture Res-net, qui est semblé le meilleur choix, pour le cas de la classification.

Elle se constitue principalement :

- D'une couche de convolution, qui permet l'extraction des paramètres, en appliquant des filtres, avec une taille bien déterminée sur nos images ;
- D'une couche de maxpooling, qui permet de conserver les paramètres les plus importants, et de réduire la taille d'images, pour réduire le temps d'exécution ;
- Du « Flatten », qui permet de transformer l'image en vecteur ;
- D'une couche totalement connectée (Fully connected), qui permet de construire toutes les connexions, nécessaires à notre réseau de neurone.

Le système proposé permet une bonne prédiction automatique, des maladies neurodégénératives, et peut être utilisé par des médecins neurologues, pour l'aide au diagnostic, afin de leur fournir un second avis.

En perspectives, nous recommandons comme travaux de recherche futurs, d'améliorer la base de données utilisée, en définissant les stades d'épilepsie, ou bien même l'ajout d'autres

Conclusion Générale

bases de données, qui contiennent d'autres types de maladies neurodégénératives, comme la sclérose en plaque.

Nous proposons aussi, d'ajouter une phase de segmentation des sous-corticaux, comme une étape complémentaire au diagnostic.

Bibliographie

- [1] Ait yahia, département de biologie, Oran, 2019-2020, consulter le 04 juin 2021.
- [2] R Gigère, journal, 2011, consulter le 04 juin 2021.
- [3] www.République française instituts national du cancer.com, consulter le 15 avril 2021.
- [4] www.Formation initiale Paramédicale.com , consulter le 05 juin 2021.
- [5] A. Messé, mémoire de master en imagerie médicale « Caractérisation de la relation structure-fonction dans le cerveau humain à partir de données d'IRM fonctionnelle et de diffusion : méthodes et applications cognitive et clinique », 2013.
- [6] B. Calvino, mémoire en physique et chimie industriel, « douleur : évaluation-diagnostic-traitement », paris, France, 2011.
- [7] B. Benarab, Benahmed, faculté du médecine, université badji mokhtar, Annaba, 2012-2013
- [8] www.psychomedia.com, consulté le 16 juin 2021.
- [9] C. Marie-Laure. Livre en Petite encyclopédie illustrée du langage des gestes. Editions ESI, 2013. 152 p. consulter le 16 juin 2021
- [10] O. Güntürkün , www.Ruhr à Bochum/ biopsychologie.com, journal, consulter le 18 juin 2021.
- [11] B. Scherrer, thèse en imagerie médicale « Segmentation des tissus et structures sur les IRM cérébrales : agents markoviens locaux coopératifs et formulation bayésienne », France, 12 décembre 2008.
- [12] T .faiza, mémoire de master en imagerie médicale « L'extraction des structures anatomiques en images IRM cérébrales », Tlemcen, Algérie, 2018-2019.
- [13] S. nataf, www. Lyon/système nerveux central.com, consulter le 28-06-2021.
- [14] S. E. Ghamri, magister en Électronique « Commande Neuronale d' un Robot Mobile Non-Holonome avec glissement des roues » , Batna, Algérie, 2016.
- [15] J. Bittoun. Basic. « Principles of Magnetic Resonance Imaging ». In 15th Annul Scientific Meeting of the European Society for Magnetic Resonance in Medecine and Biology, 45–53. Geneva. Springer , 1998.
- [16] M. Bosc, Thèse de doctorat «Contribution à la detection des changements dans les sequences IRM 3D multimodales ». Université Louis Pasteur Strasbourg,2003.

- [17] G. Laurence. Thèse de doctorat « Trois principes de coopération pour la segmentation en imagerie de résonance magnétique cérébrale » .université Joseph Fourier 1999.
- [18] J.G. Sled, A.P. Zijdenbos, and A.C. Evans 1998. « A Nonparametric Method for Automatic Correction of Intensity Nonuniformity in MRI Data ». IEEE Transactions on Medical Imaging, 17(1), pp. 87–97.
- [19] S. Langlois, M. Desvignes, J.M. 1999. « A simple Approach to Correcting the effects of non-linear gradient fields ». Journal of Magnetic Resonance Imaging, 9(6), pp. 821–831.
- [20] G. Dugas-Phocion, ‘Segmentation d'IRM cérébrales multi-séquences et application à la sclérose en plaques’, thèse de doctorat en informatique (2006).
- [21] C. Ciofolo, C. Barillot, ‘Shape Analysis and Fuzzy Control for 3D Competitive Segmentation of Brain Structures with Level Sets’.2006, Computer Vision – ECCV 2006 pp 458-470.
- [22] R. Khayati, M. Vafadust, F. Towhidkhan, et al., ‘Fully automatic segmentation of multiple sclerosis lesions in brain MR FLAIR images using adaptive mixtures method and Markov random field model’.In : Computers in Biology and Medicine .Vol. 32, Issue 2, 2008, Pages 124-133.
- [23] B. Scherrer, ‘Segmentation des tissus et structures sur les IRM cérébrales : agents markoviens locaux coopératifs et formulation bayésienne’, thèse de doctorat en Techniques de l'Ingénierie Médicale et de la Complexité - Informatique, Mathématiques et Applications, Grenoble (2008)
- [24] S. Bricq, ‘Unifying framework for multimodal brain MRI segmentation based on Hidden Markov Chains’.In : Medical Image Analysis. Vol. 12, Issue 6, 2008, Pages 639-652.
- [25] B. Li, W. Chen, ‘Electrochemical lithiation/delithiation performances of 3D flowerlike MoS₂ powders prepared by ionic liquid assisted hydrothermal route’.In : Journal of Alloys and Compounds.Vol. 471, Issues 1–2, 5 2009, Pages 442-447.
- [26] J. Lecoeur, ‘Segmentation d'IRM cérébrales multidimensionnelles par coupe de graphe’. These de doctorat, Institut National de la Santé et de la Recherche Médicale, Bretagne Atlantique (2010).
- [27] R. Wolz, P. Aljabar, J. V. Hajnal, et al. ‘LEAP: Learning embeddings for atlas propagation’.In : NeuroImage.Vol. 49, Issue 2, 2010, Pages 1316-132.
- [28] M. Achour, ‘segmentation de l'hippocampe est le diagnostic de l'Alzheimer de façon automatique’.doctorat en imagerie médicale (2010-2011).
- [29] H. Wang, S. R. Das, J. Wook Suh, et al. ‘A learning-based wrapper method to correct systematic errors in automatic image segmentation : Consistently improved performance in

hippocampus, cortex and brain segmentation'. In : NeuroImage. Vol. 55, Issue 3, 2011, Pages 968-985.

[30] K. Jafari-Khouzani, K. V. Elisevich and H. Soltanian-Zadeh. 'Dataset of Magnetic Resonance Images of Nonepileptic Subjects and Temporal Lobe Epilepsy Patients for Validation of Hippocampal Segmentation Techniques'. In : Neuroinformatics .vol. 9, 2011 , pages 335–346.

[31] N. Belmokhtar, N. Benamrane, 'Classification of Alzheimer's Disease from 3D Structural MRI Data'. In : International Journal of Computer Applications (0975 – 8887) .Vol. 47– No.3, 2012.

[32] D. Mortazavi, A. Z. Kouzani, H. Soltanian-Zadeh, ' Segmentation of multiple sclerosis lesions in MR images: a review'. In : Neuroradiology .vol. 54, 2012, pages 299–320.

[33] N. W. Sterling, G. Du, M. M. Lewis, et al. 'Striatal shape in Parkinson's disease '. In : Neurobiology of Aging. Vol. 34, Issue 11, 2013, Pages 2510-2516.

[34] A. Ziouani, ' Segmentation Des Images Cérébrales Des Patients Atteints De La Maladie D'Alzheimer'. these de doctorat en Informatique : Universite mohamed boudiaf des sciences et de la technologie d'oran, (2014).

[35] F. Nemmi, U. Sabatini, O. Rascol, et al., ' Parkinson's disease and local atrophy in subcortical nuclei: insight from shape analysis. In : Neurobiology of Aging. Vol. 36, Issue 1, 2015, Pages 424-433.

[36] J. D. Rudie, J. B. Colby, N. Salamon, ' Machine learning classification of mesial temporal sclerosis in epilepsy patients'. In : Epilepsy Research. Vol. 117, 2015, Pages 63-69.

[37] M. El Azami, A. Hammers, J. Jung, et al., ' Detection of Lesions Underlying Intractable Epilepsy on T1-Weighted MRI as an Outlier Detection Problem', thèse de doctorat Imagerie médicale, 2016.

[38] N.W. Sterlinga, M.M. Lewis, G. Dua and X. Huang, ' Cortical gray and subcortical white matter associations in Parkinson's disease '. In : Neurobiology of Aging. Vol. 49, 2017, Pages 100-108.

[39] I. Jyoti, Y. Zhang, 'A Novel Deep Learning Based Multi-class Classification Method for Alzheimer's Disease Detection Using Brain MRI Data '. In : Brain Informatics, 2017, pp 213-222.

[40] K. S. Biju, S.S. Alfa, L. Kavya et al., ' Alzheimer's Detection Based on Segmentation of MRI Image'. In : Procedia Computer Science. Vol. 115, 2017, Pages 474-481.

[41] S. Valverde, M. Salem, M. Cabezas et al., ' A supervised framework with intensity subtraction and deformation field features for the detection of new T2-w lesions in multiple sclerosis'. In : NeuroImage: Clinical. Vol. 17, 2018, Pages 607-615.

- [42] O. Commowick, A. Istace, C. Barillot, 'Objective Evaluation of Multiple Sclerosis Lesion Segmentation using a Data Management and Processing Infrastructure'. In : Scientific Reports. vol. 8, Article number: 13650 (2018).
- [43] B. F. Rousseau , 'Synthesis and evaluation of an 18F-labeled boramino acid analog of aminosuberic acid for PET imaging of the antiporter system xC'. In : Bioorganic & Medicinal Chemistry Letters. Vol. 28, Issue 22, 1 December 2018, Pages 3579-3584.
- [44] G. Galisot, Z. Abu-Aisheh, Y. Kara et al. doctorat en imagerie médicale (2018).
- [45] M. Saim , 'segmentation de cerveau par MFCM pour extraire MG '. these de doctorat en imagerie médicale (2019).
- [46] B. S. Strnad, H. L. P. Orłowski, M. S. Parsons et al., ' An image processing algorithm to aid diagnosis of mesial temporal sclerosis in children: a case-control study'. In : Pediatric Radiology .vol. 50, 2020, pages 98–106.
- [47] F. Dahi, M. S. Parsons, H. L. P. Orłowski, et al., ' Image Processing to Improve Detection of Mesial Temporal Sclerosis in Adults'. In : American Journal of Neuroradiology ,2019, 40 (5) 798-801.
- [48] P.-A. Ganaye , ' Removing segmentation inconsistencies with semi-supervised non-adjacency constraint'. In : Medical Image Analysis. Vol. 58, 2019, 101551.
- [49] J. Kobold, E. W. Lang, A. M. Tomé et al., ' Stroke Thrombus Segmentation on SWAN with Multi-Directional U-Nets'. In : IEEE.2019.
- [50] A. Fenneteau, P. Bourdoun, D. Helbert et al. , ' Learning a CNN on multiple sclerosis lesion segmentation with self-supervision '. In : Electronic Imaging, 3D Measurement and Data Processing 2020, pp. 3-1-3-7(7).
- [51] S. N. Yaakub, R. A. Heckemann, S. S. Keller, et al., ' On brain atlas choice and automatic segmentation methods: a comparison of MAPER & FreeSurfer using three atlas databases'. Scientific Reports volume 10, Article number: 2837 (2020).
- [52] D. Castillo, R. Samaniego, Y. Jiménez, A. Sánchez, et al. 'Assessment of mesial temporal sclerosis through MRI processing'. In : Proceedings .Vol. 11469, Emerging Topics in Artificial Intelligence 2020,114690W.
- [53] M. Rebsamen, Y. Suter, R. Wiest, et al. , ' Brain Morphometry Estimation: From Hours to Seconds Using Deep Learning'. In : Front. Neurol., 2020.
- [54] <https://experiences.microsoft.fr/business/intelligenceartificielle-ia.com>, consulté le 09/02/2019.
- [55] Y .MAJ, Mémoire en imagerie médicale « l'intelligence artificiel au service de la recherche clinique », 20 septembre 2019.

[56] www.Rapport De Synthèse/France Intelligence Artificielle.com, 2017.

[57] <https://blogs.msdn.microsoft.com/mlfrance/2016/04/28/une-premiere-introduction-au-deep-learning/>, consulté le 09 septembre 2021 .

[58] B .Thomas, [www. reseau de neurone deeplearning/biologiques ou artificiels.com](http://www.reseau de neurone deeplearning/biologiques ou artificiels.com), article, consulté le 12 aout 2021.

[59] D. Belhaouci, www.Juri'Predis.com, article, consulter le 21 aout 2021.

[60] M. M. Zakaria, memoires en imagerie médicale « Classification des images avec les réseaux de neurones convolutionnels », tlemcen, algerie, 2017.

[61] www.kaggle.com, consulté le 14 Avril 2021.