

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE

MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE



UNIVERSITE Dr. TAHAR MOULAY SAIDA



FACULTE : TECHNOLOGIE

DEPARTEMENT : INFORMATIQUE

MÉMOIRE DE MASTER

Option : Réseaux informatiques et systèmes répartis

la prédiction de la maladie d'Alzheimer dans la neuro-imagerie avec deep-learning

Présenté par :

Reffas Fatima Zohra

Chouiter Nour El Houda

Encadré par :

Dr Chaibi Hassen

Année Universitaire 2020-2021

Remerciements

Nous tenons tout d'abord à remercier Dieu le tout puissant et
miséricordieux,
qui nous a donné la force et la patience d'accomplir ce Modeste
travail.

En second lieu, Nous tenons à exprimer toute notre reconnaissance à
notre encadreur de mémoire, Dr. **CHAIBI** . Nous le remercions de
nous avoir encadrés.

Nos vifs remerciements vont également aux membres du jury pour
l'intérêt qu'ils ont porté à notre recherche en acceptant d'examiner
notre travail et de l'enrichir par leurs propositions.

Nos profonds remerciements vont à l'ensemble des enseignants qui
ont participé à notre formation.

Enfin, nous tenons également à remercier tous ceux qui ont
contribué de près ou de loin à l'élaboration de ce mémoire.

Dédicace

Je remercie Dieu

Merci à ma famille pour son soutien et en particulier mes très chers parents pour leurs encouragements durant toutes mes études. Ce travail est le fruit de tous vos sacrifices.

A toute la famille « **REFFAS** »

A mon frère et mes très chères sœurs

Qui m'avez toujours soutenu et encouragé durant ces années
d'étude

A toutes mes amies pour leur aide et supports

A mes camarades **Houda marwa**.

A tous ceux que j'ai connus durant mon cycle d'étude

Reffas Fatima Zohra

Dédicace

Je remercie Dieu

A ma chère famille, pour tous leurs sacrifices, leur amour, leur tendresse, leur soutien et leurs prières tout au long de mes études, a ma camarade Fatima et ma meilleure amie nessyrine .

Que ce travail soit l'accomplissement de vos vœux tant allégués, et le fruit de votre soutien infallible

Merci d'être toujours là pour moi.

Chouiter Nour El houda

LISTE DES Tableau	07
Résumés.....	10
I.Introduction générale.....	12
Problématique.....	12
Contribution et Organisation du manuscrit.....	12

Chapitre I La maladie d'Alzheimer et l'imagerie médicale

I.1 Introduction.....	15
I.2 Définition de la maladie d'Alzheimer :.....	15
I.3 Les type de la maladie d'Alzheimer :.....	16
I.4 Symptômes :.....	17
I.5 Diagnostique :	18
I.6 Traitement :	18
II.7 Présentation de l'imagerie médicales :	19
II.8 But du traitement d'image	19
I.9 l'imagerie IRM.....	20
I.10 principe général L'IRM.....	20
Conclusion	21

Chapitre II DEEP LEARNING

II.1 Introduction :.....	23
II.2 Histoire de Deep Learning :	23
II.3. MACHINE LEARNING VS DEEP LEARNING :.....	23
II.4 Définition de l'apprentissage profond (deep learning)	24
II.5 Pour quoi le deep learning	24
II.6 Les applications du Deep Learning.....	25
II.8 Comment ça marche ?.....	27
II.9 Quels sont les réseaux de neurones pour l'apprentissage en profondeur?	26
II.10 Réseaux de neurones.....	26
II.11 Principe de fonctionnement	26
II.12 L'apprentissage.....	28
II.13.1 Apprentissage supervise.....	28

II.12.2 Apprentissage non supervise	29
II.14 Réseaux de neurones convolutifs :	29
II.14.1 Principe générale.....	29
II.14.2 L'opération de convolution	31
II.14.3 La relation de la taille de l'image de sortie.....	31
II.15.4.La couche ReLU (rectification linéaire)	32
II.15.5 Le pooling	33
II.15.6 Le meanpooling (ou averagepooling)	33
II.15.7 Le flattening (ou mise à plat)	34
II.15.8 fully connected.....	34
II.15.9 le padding :	35
II.15.10.1 Fonction d'activation	36
II.15.10.2Softmax	36
II.15.10.3 Unité linéaire rectifiée ("RectifiedLinear Unit", ReLU).....	37
II. 15.10.4 Maxout	37
Conclusion	37

Chapitre III L'approche proposée

III.1 les base de données utilisées.....	39
III.2 les paramèdes modèles de deep-learning.....	39
III.3 les modèles de notre approche	41
IV.3.1 Modèle	41
III.3. le modèle 02.....	43
Conclusion	44

Chapitre IV Implémentats et Résultats

IV.1 Le langage de programmation	46
IV. 2 Les outils et les librairies utilisés	46
IV.3 les métriques utilisées.....	47
IV. 1 La matrice de confusion	47
IV.4 la phase de d'apprentissage des modèles	49
IV.5 la partie test des modèles.....	57

IV.5.1 les résultats du modèles n01	57
IV.5.2 les résultats du modèles n2.....	58
IV.5.3 Comparaison entre les deux modèles	61
CONCLUSION	62
Conclusion générale	63
Bibliographie	64

Liste des tableaux :

Tableaux N°	Titre de tableau	page
01	tableau de la matrice de confision modèle 01	57
02	tableau de la matrice de confision modèle 02	58
03	Comparaison entre les deux modèles	61

Liste des figures :

Figure	Titre	page
Figure n°1	coupe coronal du cerveau d'une personne normal et une personne atteinte de la maladie d'Alzheimer	16
Figure n°2	Evolution de la maladie d'Alzheimer	17
Figure n°3	Traitement d'image et domaines connexes	19
Figure n°4	Le principe et fonctionnement de l'IRM	20
Figure n°5	le relation entre AI, ML et DL	24
Figure n°6	Topologie de réseau de neurones avec une seule sortie	26
Figure n°7	Topologie de réseau de neurones profond	27
Figure n°8	La différence entre une vision par ordinateur et une vision humaine	30
Figure n°9	l'architecture général de la CNN	30
Figure n°10	comment fonctionne la convolution	32

Figure n°11	les fonctions d'activation ReLU et LeakyReLU et la différence entre elles	33
Figure n°12	la différence entre Max pooling et Averagepooling	33
Figure n°13	comment fonctionne le flattening	34
Figure n°14	la distribution des couches fully_connected	35
Figure n°15	un padding de 2 sur une matrice de taille 32×32	35
Figure n°16	representation d'un différenttypes de activation fonctions	36
Figure n°17	La fonction soft max	37
Figure n°18	Configuration et nombre de parametres modèle cnn ; Avec 3355348 paramètres divisé en deux (trainable params = 3352980, non trainable params = 2368)	42
Figure n°19	Configuration et nombre de parametres modèle cnn. Avec 2112196 paramètres divisé en deux (trainable params = 2112004, non trainable params = 192)	44
Figure n°20	Taux de classification illustré dans la matrice de confusion.	47
Figure n°21	Taux d'erreur illustré dans la matrice de confusion	47
Figure n°22	Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 10	49
Figure n°23	Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 30	50
Figure n°24	Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 100	51
Figure n°25	Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 200	52
Figure n°26	Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 10	53
Figure n°27	Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 30	54

Figure n°28	Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 100	55
Figure n°29	Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 200	56
Figure n°30	des images exemple de chaque cas dans la matrice de confusion du modèle le plus réussie	59
Figure n°31	comparaison entre les deux modèle	61

LISTE DES ABREVIATIONS:

DL : Deep Learning

RELU ::REctified Linear Unit

CPU :Central Processing Unit

GPU : Graphics processing unit

TPU :Tensor Processing Unit

CNN : Convolution Neural Network

ML :Machine Learning

IA : Intelligence Artificielle

VSC :Visual Studio Code

RÉSUMÉ:

La maladie d'Alzheimer est une maladie neurodégénérative qui affecte le cerveau plus précisément le système nerveux, entraînant la mort des cellules nerveuses résultant une perte progressive de neurone dans des régions responsables de la mémoire et donc la perte de cette dernière, ce processus pathologique induit aux modifications de la morphologie du cortex cérébral ce qui influe les capacités cognitives.

L'imagerie par résonance magnétique (IRM) est l'une des techniques d'imagerie médicale les plus puissantes, qui permet d'observer la structure des tissus dans différents plans de l'espace et la position exacte des lésions invisibles. Dans ce travail, nous nous concentrons sur l'utilisation de l'apprentissage profond et en particulier les réseaux de neurones convolutifs (CNN) pour classifier les images IRM afin de pouvoir potentiellement prédire la maladie d'Alzheimer à un stade précoce. Ce qui devra aider à prendre en charge ces malades. Nos résultats sont très satisfaisantes.

Mots clés : Alzheimer, IRM, apprentissage profond, CNN, classification

Abstract

Alzheimer's disease is a neurodegenerative disease that affects the brain more precisely the nervous system, causing the death of nerve cells resulting in a progressive loss of neurons in regions responsible for memory and therefore the loss of the latter, this pathological process induced changes in the morphology of the cerebral cortex, which influences cognitive abilities. Magnetic Resonance Imaging (MRI) is one of the most powerful medical imaging techniques, which makes it possible to observe the structure of tissues in different planes of space and the exact position of invisible lesions. In this work, we focus on using deep learning and in particular (CNN) networks to classify MRI images so that we can potentially predict early-stage Alzheimer's disease.

This should help take care of these patients. We results are very satisfactory.

Keywords: Alzheimer's, MRI, deep learning, CNN, classification

ملخص

مرض الزهايمر هو مرض تنكسي عصبي يصيب الدماغ بشكل أكثر دقة على الجهاز العصبي ، مما يتسبب في موت الخلايا العصبية مما يؤدي إلى فقدان الخلايا العصبية بشكل تدريجي في المناطق المسؤولة عن الذاكرة وبالتالي فقدان الأخير ، هذه العملية المرضية تسببت في تغييرات في التشكل. من القشرة الدماغية التي تؤثر على القدرات المعرفية. التصوير بالرنين المغناطيسي (MRI) هو أحد أقوى تقنيات التصوير الطبي ، مما يجعل من الممكن مراقبة بنية الأنسجة في مستويات مختلفة من الفضاء والموقع الدقيق للأفات غير المرئية. في هذا العمل ، نركز على استخدام التعلم العميق وعلى وجه الخصوص شبكات (CNN) لتصنيف صور التصوير بالرنين المغناطيسي حتى نتمكن من التنبؤ بمرحلة مبكرة من مرض الزهايمر. هذا من شأنه أن يساعد في رعاية هؤلاء المرضى. نتائجنا مرضية للغاية.

الكلمات المفتاحية: الزهايمر، الرنين المغناطيسي ، التعلم العميق ، CNN ، التصنيف .

INTRODUCTION GENERALE :



Contexte et Problématique :

La maladie d'Alzheimer reste un véritable problème de santé. Cette pathologie neurodégénérative est au cœur des nombreux projets de recherche scientifique dans des aspects physiopathologiques, neuropsychologique, d'imagerie ou thérapeutiques.

Les neurosciences tentent depuis plusieurs décennies de comprendre les mécanismes de son origine et de son évolution, afin d'arriver à freiner le plus précocement possible les atteintes cognitives, comportementales et la perte d'autonomie qui en découlent. Grâce à de nombreux progrès technologiques, en particulier en neuro-imagerie.

La maladie d'Alzheimer est la forme de démence la plus courante : 50 millions de personnes en sont aujourd'hui atteintes dans le monde. L'Organisation Mondiale de la Santé prévoit même que ce nombre pourrait augmenter et atteindre les 152 millions d'ici 2050.

Il n'existe actuellement aucun traitement efficace contre cette maladie, donc il faut la prédire avant qu'elle soit dans ses derniers stades

Contribution et Organisation du manuscrit :

Le récent succès de la vision par ordinateur a donné une impulsion à de nombreuses publications sur la modélisation de l'apprentissage en profondeur faisant état d'une précision supérieure à 90 %. Parmi les méthodes d'apprentissage profond les plus utilisées on trouve les réseaux de neurones convolutifs (CNN).

Le but de ce mémoire est l'utilisation de la puissance des réseaux CNN pour la classification des images pour prédire cette maladie. Nous disposant d'une base de données des images IRM, cette base contient des images neurologiques qui représentent différents stades de la maladie d'Alzheimer.

En l'absence de traitement pour la maladie d'Alzheimer, ce travail pourrait permettre d'identifier les personnes à risque afin de leur offrir un suivi particulier et initier des changements de style de vie susceptibles de retarder, voire d'empêcher totalement, les débuts de la maladie d'Alzheimer.

Afin de compléter ce travail, notre mémoire est organisée en quatre chapitres comme suit:

- Chapitre 1 : Donne un aperçu général sur la maladie d'Alzheimer et les images IRM.
- Chapitre 2 : Nous avons présenté le deep learning.
- Chapitre 3 : C'est la présentation de notre approche proposée.
- Chapitre 4 : L'implémentation de nos approches, les outils de développement, ainsi que les résultats obtenus.



Chapitre I



I.1 :Introduction :

Dans ce chapitre nous parlerons d'Alzheimer. Ensuite, nous aborderons le volé traitement des images dont l'objectif de l'utilisé pour mesurer l'aimantation des tissus biologiques et à reconstruire une image à partir de ces aimantations.

La maladie d'Alzheimer (MA) est la première cause de démence dans le monde, touchant plus de 20 millions de personnes. Son diagnostic précoce est essentiel pour assurer une prise en charge adéquate des patients ainsi que pour développer et tester de nouveaux traitements. La MA est une maladie complexe qui nécessite différentes mesures pour être caractérisée : tests cognitifs et cliniques, neuroimagerie, notamment l'imagerie par résonance magnétique (IRM)

I.2 : Définition de la maladie d'Alzheimer :

Selon l'OMS organisation mondiale de la santé en 1993 la maladie d'Alzheimer est définie en ces termes « la maladie d'Alzheimer est une maladie cérébrale dégénérative primaire, s'étiologie inconnue et qui présente des altérations neuropathologiques et neurochimiques caractéristiques. Elle commence, en général, de façon insidieuse et lente et évolue progressivement pendant plusieurs années » [1] La maladie d'Alzheimer est la plus fréquente des démences chez le sujet âgé. Le diagnostic repose sur des données cliniques (troubles de la mémoire associés à un ou plusieurs autres troubles cognitifs, retentissant sur l'autonomie) et sur l'exclusion d'autres diagnostics par des examens complémentaires simples (biologie sanguine, imagerie cérébrale). Il n'y a pas de traitement curatif et l'évolution se fait inéluctablement vers l'aggravation ; une prise en charge adaptée (médicale et sociale) permet de maintenir une qualité de vie acceptable pour le malade et son aidant, et d'éviter la survenue de troubles psycho- comportementaux.

Au début de la maladie, le diagnostic différentiel se pose surtout avec le vieillissement normal et la dépression. D'autres pathologies, neurodégénératives (démences front temporales, démences à corps de Loewy) ou non (démence vasculaire), sont aussi considérer. Leur présentation clinique, leur évolution et leur prise en charge diffèrent. Les démences dites curables (métaboliques, toxiques, hydrocéphalie chronique) sont en fait rares mais à envisager systématiquement. [2]

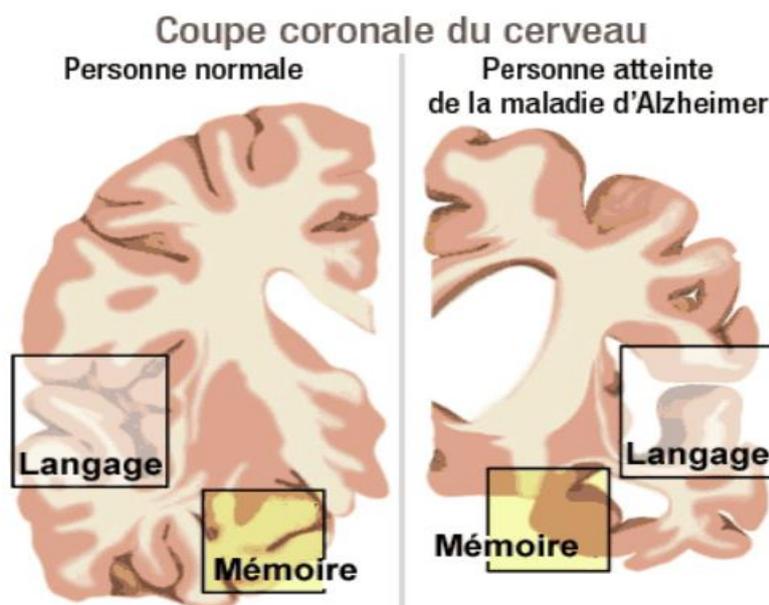


Figure I.1 : coupe coronale du cerveau d'une personne normale et une personne atteinte de la maladie d'Alzheimer [3]

I.3 : Les types de la maladie d'Alzheimer :

La maladie d'Alzheimer est une dégénérescence qui s'aggrave par effet cumulatif, en synergie avec les effets naturels du vieillissement. Son installation est progressive et son évolution est lente. Plus elle se développe, plus elle favorise les complications qui constituent son véritable danger et de là on distingue trois stades :

- **Léger** : Il y a des pertes de mémoires à court terme, occasionnelles, auquel le sujet s'adapte généralement en utilisant des aides mémoires. A ce stade, il n'est pas possible de différencier la maladie d'Alzheimer débutante d'un simple déclin cognitif lié à l'âge
- **Modéré** : Le déficit de mémoire est plus important, avec une difficulté à retenir l'information récente alors que les souvenirs anciens sont préservés. Apparaissent des difficultés de jugement. Gérer son argent ou planifier des activités quotidiennes devient un vrai problème. Avant l'installation du stade suivant, il apparaît des troubles de comportement qui se manifeste notamment dans le langage, avec parfois une agressivité.
- **Avancé** : A ce stade, il n'y a plus d'autonomie, une perte de mémoire généralisée et une désorientation. Surviennent également des troubles psychiatriques (hallucinations,

délires paranoïaques). Les malades entrent facilement en errance et présentent des comportements imprévisibles. [4] (Jacques. B. boislève, 2000, P.06)

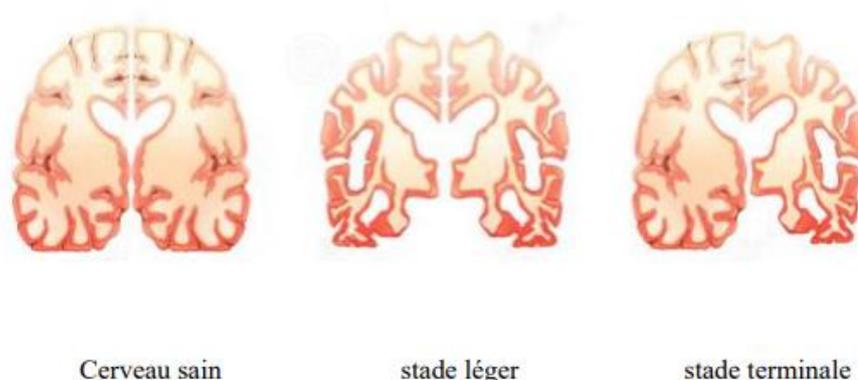


Figure I.2: Evolution de la maladie d'Alzheimer.

I.4: Symptômes :

La maladie d'Alzheimer est comme une inversion du processus de vieillissement. Sans s'arrêter au sommet de la beauté et de la force, nous sommes cruellement repoussés dans l'enfance. D'abord disparaissent les souvenirs, ensuite la perception, les sentiments, le savoir et finalement, au dernier stade, notre langage et la capacité de nous occuper de nos besoins de base. Tout droit, nous glissons vers le septième âge de l'homme " sans dents, sans vue, sans tout ". Dans la maladie d'Alzheimer, les symptômes diffèrent d'une personne à l'autre et ne sont pas de la même sévérité chez tous les malades, cependant, les troubles de la mémoire sont ceux qui inquiètent fréquemment au début de la maladie et poussent la majorité des personnes à consulter un médecin généraliste. Nous tenons cependant à préciser que la maladie ne commence pas forcément par des pertes de mémoire, mais également par des autres troubles [5]

- **Trouble de mémoire :**
- ✓ **Apraxie :** Apraxie Troubles de l'activité gestuelle apparaissant chez un sujet dont les organes d'exécution sont intacts (n'ayant pas d'atteinte paralytique motrice ni coordinatrice) et qui possède la pleine connaissance de l'acte à accomplir (sans déficit intellectuel)
- ✓ **Aphasie :** Ensemble des troubles du langage consécutifs à une atteinte cérébrale

- ✓ **Iagnosie** : Atteinte des fonctions d'intégration perceptive caractérisée par une incapacité d'identifier certaines objets de formes [6]

I.5 Diagnostique :

- ✓ **Diagnostiquer grâce aux tests médicaux traditionnels :**

Pour poser le diagnostic, le médecin utilise les résultats de plusieurs examens médicaux. D'abord, il interroge le patient afin d'en savoir plus sur la manière dont ses pertes de mémoire et les autres difficultés qu'il vit dans le quotidien se manifestent. Des tests permettant d'évaluer les facultés cognitives sont effectuées, selon le cas : des tests de vision, d'écriture, de mémoire, de résolution de problèmes, etc [7]

- ✓ **Diagnostiquer grâce à l'imagerie médicale :**

Les médecins utilisent aujourd'hui de nombreuses méthodes pour établir le diagnostic de la maladie d'Alzheimer. Ils éliminent d'abord d'autres maladies connues qui peuvent causer une maladie neurodégénérative dont la maladie de parkinson. Puis font subir à la personne des tests psychologiques et de la mémoire qui sont en général suffisamment précis (90 a 95 %) pour permettre d'établir le diagnostic de la maladie d'Alzheimer. Les techniques d'imagerie cérébrale telles que l'imagerie par résonance magnétique (IRM) sont aujourd'hui plus courantes et permettent d'établir un diagnostic plus exact.

L'analyse morphologique IRM des structures encéphaliques permet de mettre en évidence des modifications visibles sous forme d'une atrophie focale ou d'anomalies de signal spécifiques de certaines démences dégénératives [8]

I.6 Traitement :

- ✓ **Traitements médicaux : Malheureusement**, à ce jour, il n'y a toujours pas de traitement curatif de la maladie d'Alzheimer, les soins ne sont que palliatifs. [9]
- ✓ **Traitements alternatifs** : Les traitements alternatifs par des compléments alimentaires, à savoir le fer, la vitamine D , les omega3, le curcuma qui améliore les maladies dégénératives [9]

I.7 : Présentation de l'imagerie médicale :

Le besoin en applications de traitement d'images se fait de plus en plus pressant à mesure que l'image numérique s'impose comme un support et une source d'information privilégiés. La multiplication des dispositifs d'acquisition conduit à la production d'un très grand nombre d'images qu'il devient difficile d'exploiter manuellement. Ces dispositifs permettent d'accéder à des informations jusqu'ici inconnues ou inaccessibles, qui prennent aujourd'hui une importance stratégique dans de nombreux domaines comme la biomédecine, la télésurveillance, le contrôle qualité.

Le traitement d'images s'inscrit dans un processus préliminaire destiné à préparer automatiquement les images à leur analyse, leur interprétation, leur restauration, leur archivage ou leur transmission. Il n'a aucun pouvoir décisionnel, mais son rôle est crucial puisqu'il consiste à extraire des images des informations qualitatives ou quantitatives par des procédures de réduction et d'abstraction de l'information initiale sans perte ni falsification de l'information pertinente.[10]

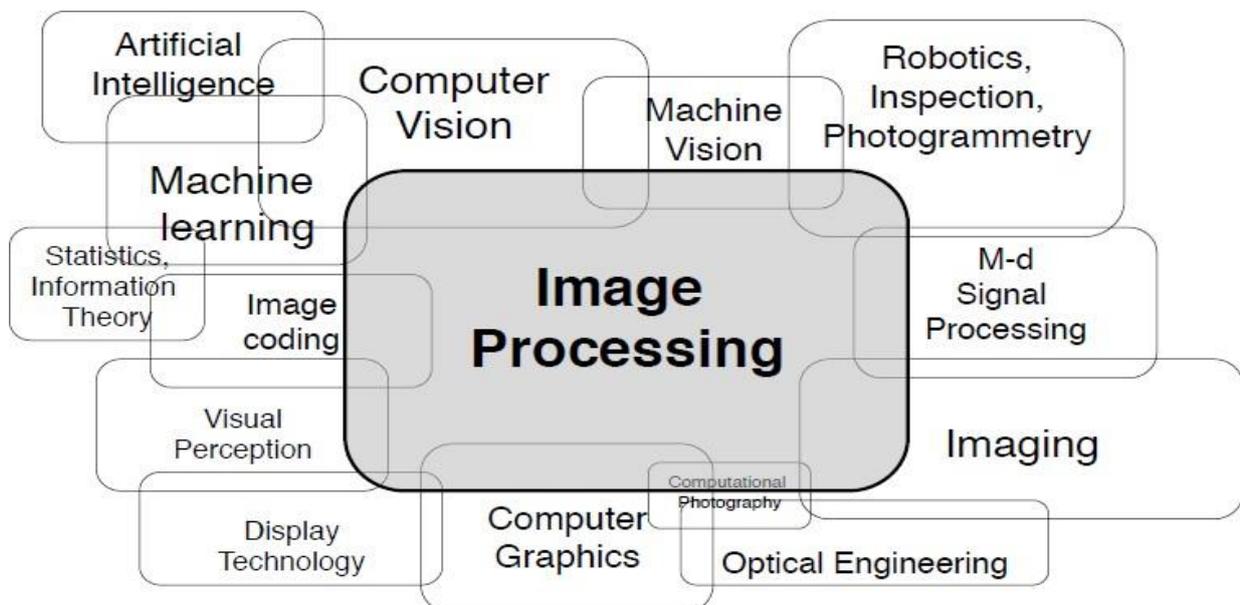


Figure I.3 : Traitement d'image et domaines connexes : [11]

I.8 : But du traitement d'image :

Le but du traitement d'image est divisé en 5 groupes [12]:

- ✓ Visualisation : Observez les objets qui ne sont pas visibles.
- ✓ Affinement de l'image et restauration : Pour créer une meilleure image.
- ✓ Récupération d'image : Recherchez l'image qui vous intéresse.
- ✓ Mesure du motif : Mesure divers objets dans une image.
- ✓ Reconnaissance d'image : Distinguez les objets dans une image.

I.9 : L'imagerie IRM :

L'IRM étant « non invasive », est devenue l'un des plus populaires outils de diagnostic dans la neuroradiologie. Cette technique est très utilisée dans le suivi de différentes pathologies : Alzheimer, Parkinson, ... etc. L'IRM est une technique d'imagerie médicale basée sur le principe de la résonance magnétique nucléaire RMN. Elle donne une description 2D ou 3D d'une partie du corps, notamment du cerveau (En pratique, les images IRM sont fournies sous forme d'un ensemble de coupes 2D qui, mises dans la bonne géométrie, vont former une image tridimensionnelle).[13]

✓ Principe de fonctionnement de l'IRM :

L'IRM est une technique basée sur l'observation de la résonance magnétique nucléaire (RMN) des protons de l'eau. En effet, l'eau constitue environ 70% du corps humain et le proton ^1H est naturellement abondant et très sensible en RMN.

L'intensité du signal observé va donc dépendre de la concentration en eau, mais aussi du temps de relaxation des spins nucléaires. Ainsi on pourra obtenir une image de la répartition en eau dans le corps du patient.

Le rôle des agents de contraste va être de diminuer ce temps de relaxation afin d'augmenter l'intensité des signaux. [14]

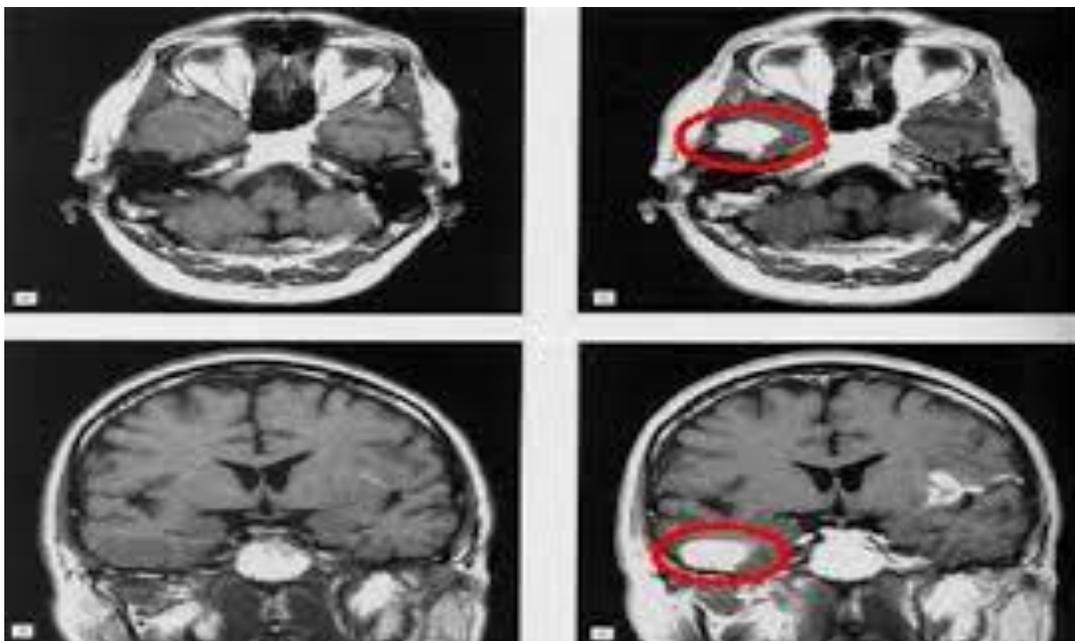


Figure I.4 :Le principe et fonctionnement de l'IRM

- **Conclusion :**

Pour conclure ce chapitre, nous soulevons ici les points de la prise en charge du maladie d'Alzheimer , et qui mériteraient une attention particulière du corps médical. Nous avons aussi discuté de l'aspect traitement d'image que planifions d'intégrer

Dans le chapitre qui suivra, nous aborderons Réseaux de neurones et apprentissage profond qui sera utilisé dans le traitement.



Chapitre II



II.1 :Introduction :

Dans le cadre de notre travail, la solution proposée est de reconnaître la pathologie à travers des techniques de reconnaissance de formes en utilisant des techniques d'apprentissage en profondeur. Dans ce chapitre, nous allons d'abord introduire des concepts sur l'apprentissage en profondeur et ensuite nous commencerons à clarifier les différences entre l'apprentissage en profondeur et l'apprentissage automatique. Ensuite, nous verrons ce qu'est le Deep Learning (DL) et quelle est son utilisation et comment cela fonctionne, nous couvrirons également la partie programmation et son essence générale de l'application de la classification. Enfin, nous mentionnons en détail la plupart des types de DL c'est CNN .

II.2:Histoire de Deep Learning :

Depuis 2012, les algorithmes à base de deep learning (apprentissage profond) semblent prêts à résoudre bien des problèmes : reconnaître des visages comme le propose DeepFace, vaincre des joueurs de go ou de poker ou bientôt permettre la conduite de voitures autonomes ou encore la recherche de cellules cancéreuses. Pourtant, les fondements de ces méthodes ne sont pas si récents : le deep learning a été formalisé en 2007 à partir des nouvelles architectures de réseaux de neurones dont les précurseurs sont McCulloch et Pitts en 1943.

Suivront de nombreux développements comme le perceptron, les réseaux de neurones convolutifs de Yann Le Cun et Yoshua Bengio en 1998 et les réseaux de neurones profonds qui en découlent en 2012 et ouvrent la voie à de nombreux champs d'application comme la vision, le traitement du langage ou la reconnaissance de la parole. Pourquoi maintenant ? parce que ces nouvelles techniques de machine learning profitent de données massives (big data) que l'on est désormais capables d'analyser ainsi que de capacités de calcul phénoménales notamment grâce aux processeurs graphiques. Preuve que chaque domaine irrigue les autres, c'est pour pouvoir utiliser les immenses promesses du deep learning que Google a mis au point les accélérateurs TPU. [15]

II.3:Machine learning vs Deep learning :

Beaucoup de gens s'inquiètent de l'IA, car ils ne pouvaient pas croire que les ordinateurs d'aujourd'hui puissent apprendre et prendre des décisions intelligentes. Cependant, les bases de l'intelligence artificielle sont aujourd'hui à la portée de tous . L'apprentissage automatique ML et l'apprentissage profond DL sont les deux concepts les plus importants qui rendent l'intelligence artificielle possible. On confond bien souvent ces deux termes, alors qu'ils désignent deux méthodes bien distinctes employées dans des champs d'application différents . Le ML et DL font partie de l'intelligence artificielle que les deux approches conduisent les ordinateurs à prendre des décisions intelligentes. et l'apprentissage en profondeur est une sous-catégorie de l'apprentissage automatique comme le montre l'image ci-dessous, l'utilisation du ML et du DL est devenue dans de nombreux domaines et conditions, dans lesquels la machine peut prendre des décisions intelligentes similaires à celles prises par les humains, les deux technologies nécessitent définitivement quantités de données, qu'il utilise comme base d'apprentissage, la similitude s'arrête là [16] .

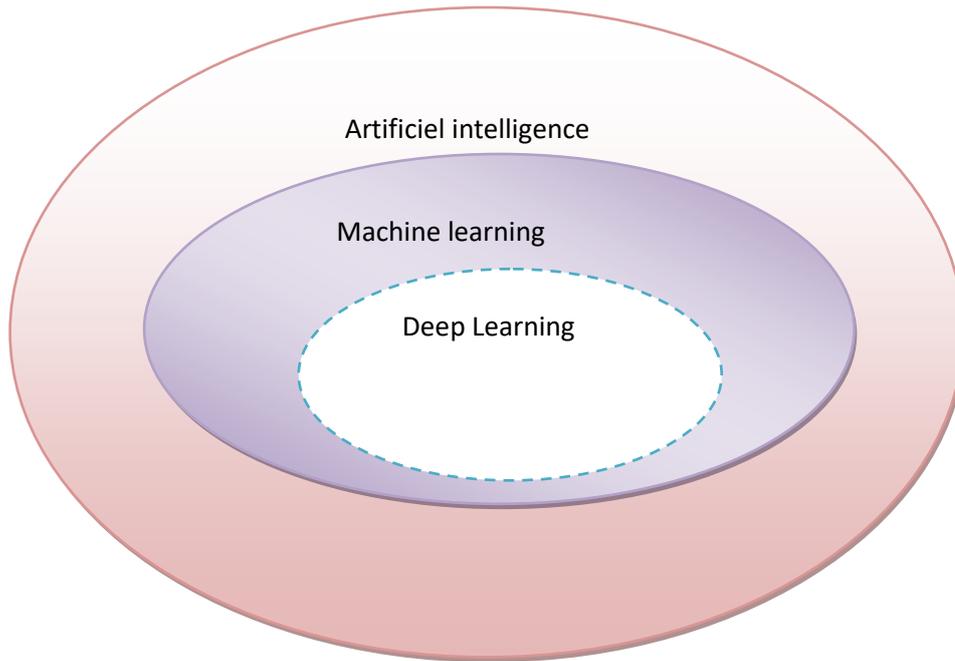


Figure II.5 : le relation entre AI, ML et DL

II.4: Définition de l'apprentissage profond (deep learning) :

L'apprentissage profond (« Deep Learning ») est un ensemble de techniques d'apprentissage automatique qui a permis des avancées importantes en intelligence. Dans l'apprentissage automatique, un programme analyse un ensemble de données afin de tirer des règles qui permettront de tirer des conclusions sur de nouvelles données. L'apprentissage profond est basé sur ce qui a été appelé, par analogie, des « réseaux de neurones artificiels », composés de milliers d'unités (les « neurones ») qui effectuent chacune de petites opérations simples. Les résultats d'une première couche de « neurones » servent d'entrée aux calculs d'une deuxième couche et ainsi de suite. [17] Par exemple, pour la reconnaissance visuelle, des premières couches d'unités identifient des lignes, des courbes, des angles. ,des couches supérieures identifient des formes, des combinaisons de formes, des objets, des contextes. . . Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données.

II.5: Pourquoi le deep learning ?

Les algorithmes de ML décrits dans la première partie fonctionnent bien pour une grande variété de problèmes. Cependant ils ont échoué à résoudre quelques problèmes majeurs de l'IA telle que la reconnaissance vocale et la reconnaissance d'objets. Le développement du Deep Learning fut motivé en partie par l'échec des algorithmes traditionnels dans de telle tâche de l'IA. Mais ce n'est qu'après que de plus grandes quantités de données ne soit disponibles grâce notamment au Big Data et aux objets connectés et que les machines de calcul soient devenues plus puissantes qu'on a pu comprendre le potentiel réel du Deep Learning. [18]

II.6 : Les applications du Deep Learning :

C'est une branche du Machine Learning très prometteuse. Que ce soit pour reconnaître des visages sur des images, analyser des textes et les interpréter automatiquement ou encore avoir des voitures qui conduisent toutes seules, les applications du Deep Learning sont nombreuses. Aujourd'hui, nous vous proposons un workshop qui va vous permettre de comprendre ce domaine et voir en quoi nous pourrions concrètement l'utiliser. [19]

- ✓ **La reconnaissance faciale :** Les yeux, le nez, la bouche, toutes autant de caractéristiques qu'un algorithme de Deep Learning vont apprendre à détecter sur une photo. Il va s'agir en premier lieu à donner un certain nombre d'images à l'algorithme, puis à force d'entraînement, l'algorithme va être en mesure de détecter un visage sur une image.
- ✓ **La détection d'objets :** Sur une image complexe où il y a plusieurs éléments, les algorithmes de détection d'objets vont être maintenant capables d'identifier et de localiser au pixel près un élément ou une personne. 800 millions d'images sont uploadées chaque jour sur Facebook : son algorithme Deep Learning est effectivement capable d'identifier telle ou telle personne sur une photo dès lors qu'elle est uploadée
- ✓ **Le Natural Language Processing :** Le Natural Language Processing est une autre application du Deep Learning. Son but étant d'extraire le sens des mots, voire des phrases pour faire de l'analyse de sentiments. L'algorithme va par exemple comprendre ce qui est dit dans un avis Google, ou va communiquer avec des personnes via des chatbots. La lecture et l'analyse automatique de textes est aussi un des champs d'application du Deep Learning avec le TopicModeling : tel texte aborde tel sujet.

II.8: Comment ça marche ?

Pour comprendre comment fonctionne le Deep Learning, nous allons utiliser un exemple concret de reconnaissance faciale. Imaginons que notre objectif soit de lui faire reconnaître les photos qui comportent une voiture. Pour pouvoir reconnaître une voiture, l'algorithme doit d'une part savoir distinguer tous les types de voitures existantes, mais aussi savoir identifier une voiture de manière précise et autonome, quel que soit l'angle sous lequel elle se trouve. Pour y arriver c'est assez simple : le réseau de neurones artificiels est entraîné en analysant des milliers d'images de voitures et apprend à les reconnaître au milieu de photos d'autres objets. Ces données vont ensuite être assignées à différentes informations permettant à l'algorithme intelligent de déduire si oui ou non se trouve une voiture sur l'image qu'il est en train d'analyser. Le réseau artificiel va également comparer cette réponse aux bonnes réponses indiquées par les humains. Si il a vu juste, l'algorithme de reconnaissance garde cette réussite en mémoire et s'en resservira plus tard pour reconnaître des voitures. Au contraire, s'il s'est trompé, il en prend note et corrige son erreur de lui-même la fois suivante. C'est en répétant ce système d'entraînement des milliers de fois que le réseau de neurones finit par être capable de reconnaître une voiture dans toutes circonstances (avec un degré de réussite proportionnel à la durée d'entraînement du réseau et au nombre de couches qu'il possède). Cette technique d'apprentissage est appelée apprentissage supervisé ou "supervised learning". [21]

II.9 : Quels sont les réseaux de neurones pour l'apprentissage en profondeur?

Un type d'algorithme d'apprentissage automatique avancé, connu sous le nom de réseaux de neurones artificiels, est à la base de la plupart des paradigmes d'apprentissage en profondeur, de sorte que l'apprentissage en profondeur peut parfois être appelé apprentissage neuronal profond ou réseau neuronal profond [22]

II.10 : Réseaux de neurones :

Nous détaillons dans cette partie beaucoup plus le fonctionnement de réseaux de neurones et les travaux que nous avons réalisés sur les modèles eux-mêmes et sur les méthodes d'apprentissage. [23]

II.11 : Principe de fonctionnement :

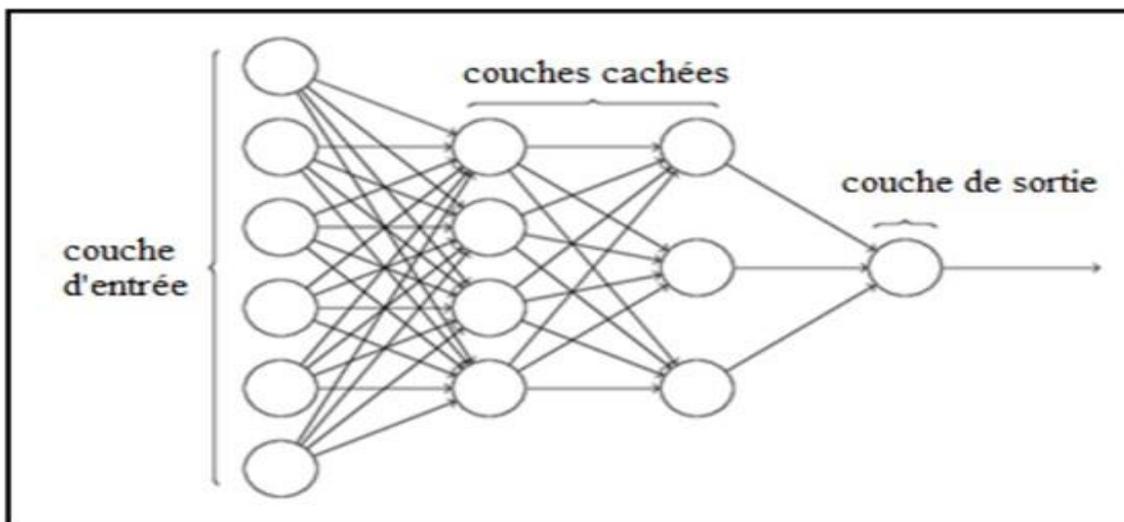


FIGURE II.6 : Topologie de réseau de neurones avec une seule sortie [24]

Le réseau comporte 3 composants : couche d'entrée, couche cachée ou couches et couche de sortie. Le terme « profond » se rapporte généralement au nombre de couches cachées du réseau de neurones. Les réseaux de neurones classiques ne comportent que 2 à 3 couches cachées, tandis que les réseaux profonds peuvent en compter jusqu'à 150. L'idée est d'utiliser la structure de couche de réseau neuronal en empilant plusieurs couches les unes sur les autres, de manière à faciliter le mécanisme de décomposition. Par conséquent, chaque couche d'un réseau de neurones profonds (Deep Neural Networks DNN) fonctionne comme une seule transformation pour extraire davantage les données. Le réseau de neurones le plus connu et le

plus simple à comprendre est le réseau de neurones multicouches à anticipation. Il contient un calque d'entrée, un ou plusieurs calques masqués et un seul calque de sortie. Chaque couche peut avoir un nombre différent de neurones et chaque couche est entièrement connectée à la couche adjacente. [25]

Un réseau de neurones est défini comme un ensemble de nœuds (appelés neurones) connectés via des liaisons dirigées (flèche), chaque flèche représente une connexion entre la sortie d'un neurone et l'entrée d'un autre (les flèches entrantes étant les entrées du neurone et les flèches sortantes étant les sorties du neurone), Chaque flèche porte un poids, reflétant son importance, chaque nœud étant une unité de traitement qui exécute une fonction de nœud statique sur son signal entrant pour générer une sortie de nœud unique. Les valeurs d'entrée, ou en d'autres termes, nos données sous-jacentes, sont transmises via ce «réseau» de couches masquées jusqu'à ce qu'elles convergent vers la couche de sortie. La couche en sortie correspond à notre prédiction : il peut s'agir d'un nœud si le modèle ne génère qu'un nombre ou de quelques nœuds s'il s'agit d'un problème de classification multi-classe. La forme à l'intérieur des neurones dans les couches centrales représente une fonction d'activation (typiquement un $1 = (1 + e^x)$) qui est appliquée à la valeur du neurone avant de le transmettre à la sortie. [24]

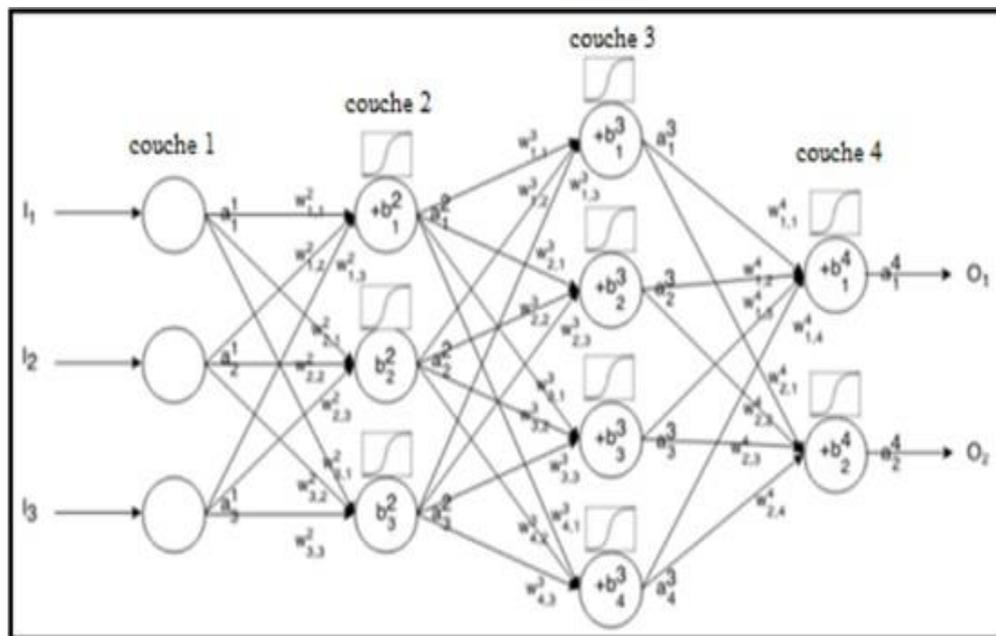


FIGURE II.7: Topologie de réseau de neurones profond. [26]

Les couches cachées d'un réseau de neurones apportent des modifications aux données pour éventuellement déterminer quelle est sa relation avec la variable cible. Chaque nœud a un poids et multiplie sa valeur d'entrée par ce poids. Pour déterminer ce que devraient être ces petits poids, nous utilisons généralement un algorithme appelé Back propagation.

II.12 : L'apprentissage :

En effet, les réseaux de neurones peuvent trouver le lien qui unit des valeurs de sortie à celles en entrée, et ce, même lorsqu'on ne connaît pas cette fonction a priori. Afin de parvenir à ce résultat, il faut « entraîner » le modèle, à l'aide d'un jeu de données initiales. Celui-ci est alors divisé en deux parties : une pour l'apprentissage, l'autre pour tester le réseau. Dans un premier temps, on va donc soumettre des données d'entraînement au programme, qui comprennent des valeurs d'entrée, ainsi que les valeurs de sortie attendues. Au début, le réseau de neurones va tenter de calculer les résultats, mais avec peu d'informations, et va donc commettre des erreurs. On va ensuite ajuster ses paramètres, de sorte à réduire ces écarts à chaque itération. Par exemple, un réseau de neurones peut être utilisé pour prévoir les risques d'apparition d'une maladie chez certains individus. En lui soumettant les caractéristiques de patients, le modèle va d'abord effectuer des prédictions aléatoires. Puis, en apprenant de ses erreurs, il sera de plus en plus pertinent dans son analyse. [27]

II.12.1 : Apprentissage supervise :

- ✓ La majorité des apprentissages automatiques utilisent un apprentissage supervise (supervised learning).
- ✓ L'apprentissage supervisé consiste en des variables d'entrée (x) et une variable de sortie (Y).
- ✓ Vous utilisez un algorithme pour apprendre la fonction de mapping de l'entrée à la sortie.
- ✓ $Y = f(X)$
- ✓ Le but est d'appréhender si bien la fonction de mapping que, lorsque vous avez de nouvelles données d'entrée (x), vous pouvez prédire les variables de sortie (Y) pour ces données.

C'est ce qu'on appelle l'apprentissage supervisé, car le processus d'un algorithme tiré de l'ensemble de données de formation (training set) peut être considéré comme un enseignant supervisant le processus d'apprentissage. Nous connaissons les réponses correctes, l'algorithme effectue des prédictions itératives sur les données d'apprentissage et est corrigé par l'enseignant. L'apprentissage s'arrête lorsque l'algorithme atteint un niveau de performance acceptable. [28]

II.12.2 : Apprentissage non supervisé :

L'apprentissage non supervisé (Unsupervised Learning) consiste à ne disposer que de données d'entrée (X) et pas de variables de sortie correspondantes. L'objectif de l'apprentissage non supervisé est de modéliser la structure ou la distribution sous-jacente dans les données afin d'en apprendre davantage sur les données.

On l'appelle apprentissage non supervisé car, contrairement à l'apprentissage supervisé ci-dessus, il n'y a pas de réponse correcte ni d'enseignant. Les algorithmes sont laissés à leurs propres mécanismes pour découvrir et présenter la structure intéressante des données. L'apprentissage non supervisé comprend deux catégories d'algorithmes : Algorithmes de regroupement et d'association. [29]

II.13 : Réseaux de neurones convolutifs :

II.13.1 : Principe générale :

Nous allons voir ensemble comment fonctionne le réseau convolutif, en abordant brièvement le principal outil mathématique caché derrière, ainsi que toutes les étapes de l'analyse faite par l'algorithme. En tant qu'êtres humains, nous pouvons distinguer des images de formes et de couleurs différentes, mais l'ordinateur n'a pas cette capacité, Au contraire il a la capacité d'effectuer des centaines de calculs en une fraction de seconde, ce que l'esprit humain est incapable de faire, L'ordinateur ne voit l'univers que par des nombres, si nous les endommageons, L'image ci-dessous en tant qu'êtres humains nous la voyons comme une image contenant trois chiens, Quant à l'ordinateur il le voit comme une matrice tridimensionnelle $n_w \times n_h \times n_c$ (n_h : hauteur, n_w : Largeur, n_c : profondeur) Quant à la profondeur (n_c) Il se compose de valeurs allant de 0 à 255 Ce sont simplement des pixels répartis sur la largeur et la largeur Quant à la profondeur elle nous renseigne sur le nombre de couleurs dans l'image (si $n_c = 1$: l'image est grayscale ou $n_c = 3$ l'image est RGB), Dans notre cas cette image est RGB [30]

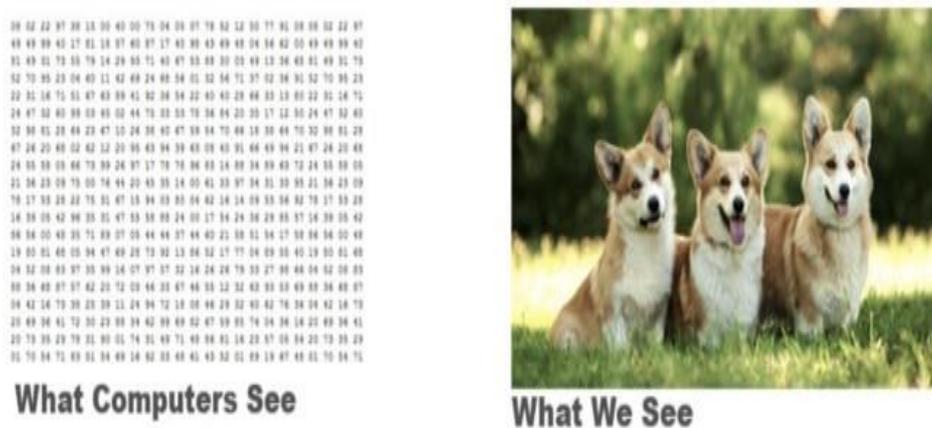


Figure.II.8 : La différence entre une vision par ordinateur et une vision humaine

Ainsi, les réseaux de neurones convolutions recevra cette image (figure 1), et un ensemble de processus lui sera appliqué pour identifier les formes qu'il contient aux fins d'utilisation dans une application particulière (figure 2), tel que ces processus sont divisés en deux catégories principales : Les filtres (l'extraction de l'information) : pour faire ressortir, par exemple, les arêtes verticales, les variations de coloration, etc..., sachant que plus les filtres interviennent tard dans l'enchaînement, plus ils permettent de détecter des formes complexes (et plus abstraites) Les simplifications (l'analyse de l'information) : pour alléger les calculs et dégager les informations principales Ensuite, il donnera la probabilité que cette image représente un robot, un chien , un humain...etc ,grâce à un réseau de neurones artificiels ANN[30].

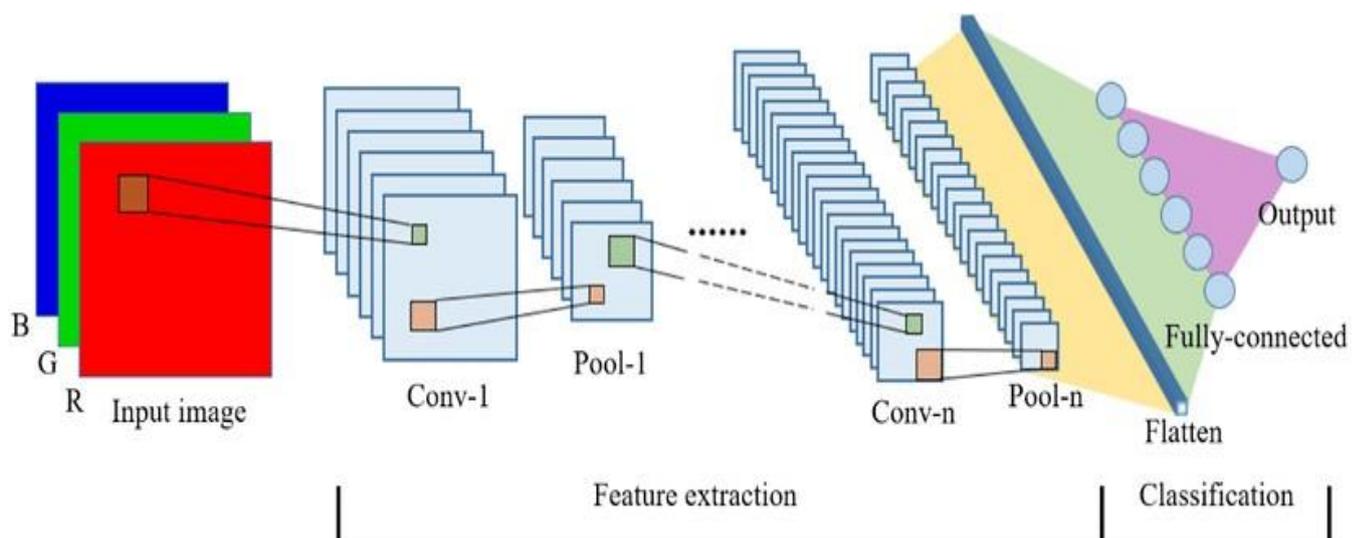


Figure.II.9 l'architecture général de la CNN

II.13.2 : L'opération de convolution :

La convolution est le cœur du réseau de neurones convolutif et à l'origine c'est une opération mathématique basée sur la multiplication de la matrice des nombres avec un filtre (également connu sous le nom de kernel), qui déterminerait la présence de certaines caractéristiques ou motifs dans l'image d'origine (revenu), puis il peut être utilisé plusieurs fois afin d'extraire différentes fonctionnalités et le filtre est de petite taille pour effacer toute l'image et appliquer les calculs appropriés entre les valeurs du filtre et les points de couleur (pixels) dans l'image, afin d'extraire des fonctionnalités. Ce processus se traduit par une nouvelle matrice avec des dimensions inférieures par rapport à l'image d'origine [30]

II.13.3 : La relation de la taille de l'image de sortie :

- ✓ nh' : taille de l'image de sortie (largeur).
- ✓ nh : taille de l'image d'entrée (largeur).
- ✓ k : taille du kernel utilisé (largeur)
- ✓ p : le padding appliqué
- ✓ s : le stride appliqué

Le calcul est relativement simple et peut être effectué manuellement, mais plus la taille de l'image est grande, plus le filtre(kernel) est grand, plus il devient complexe, ce qui nécessite une intervention informatique. En supposant que nous ayons une matrice dimensionnelle 3×4 et un kernel 2×2 et le stride=1, le calcul sera comme indiqué dans l'image.

Ensuite, pour calculer la deuxième valeur de l'image de sortie, on va utiliser le paramètre stride de la convolution qui représente le nombre de pixels de l'image d'entrée que nous allons convertir pour réappliquer la chaîne. Mais il peut arriver que la convolution dépasse de l'image si on choisit mal le kernel et le stride, Par exemple si nous prenons le même exemple précédent, mais que nous modifions la valeur de stride à 3, nous rencontrerons un problème après la première déformation. En outre, vous remarquerez que le résultat de l'habillage est une image plus petite que l'image d'entrée. Pour éliminer ces deux problèmes, on a un paramètre « padding » qui est utilisé dans les convolutions et qui, simplement, ajoute des 0 autour de l'image d'entrée, pour augmenter la taille de l'image de sortie ou éviter les dépassements [30]

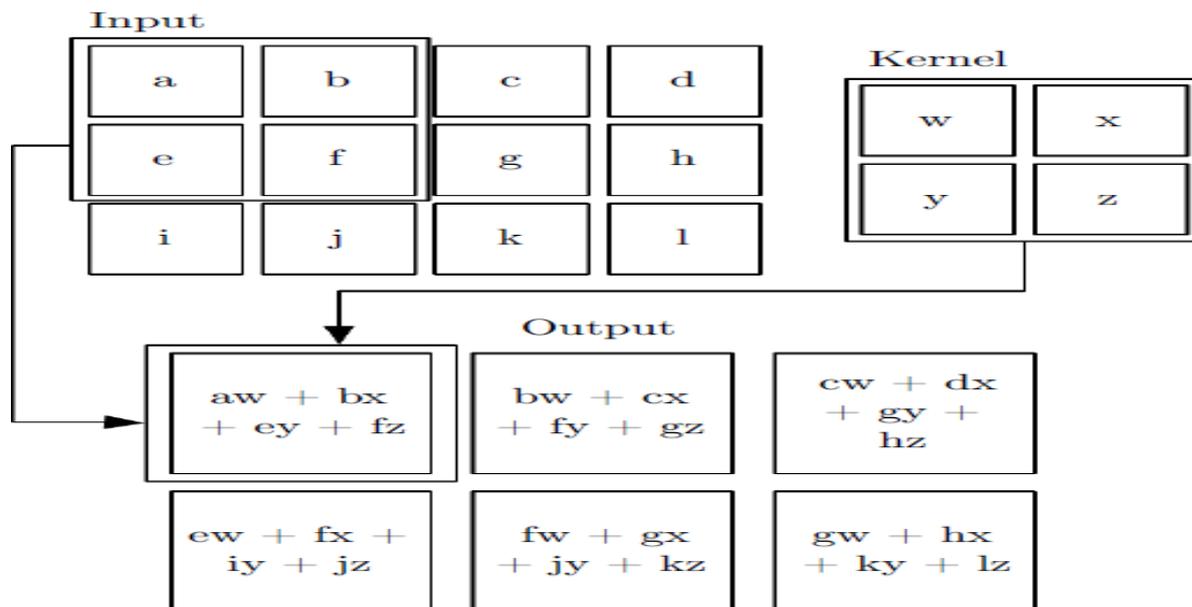


Figure.II.10 comment fonctionne la convolution

II.13.4 :La couche ReLU (rectification linéaire) :

La fonction d'activation ReLU est la fonction dite de «correction» largement utilisée dans le deep learning , C'est plutôt l'une des fonctions les plus utilisées de nos jours en raison de les caractéristiques la plus importante:

- 1- Le fait de ne pas activer tous les neurones en même temps permet également d'accélérer les calculs car les valeurs négatives sont mises à zéro, ce qui signifie que toutes les valeurs égales ou inférieures à zéro deviennent nulles , tandis que les valeurs positives restent les mêmes .
- 2- Comme on l'a vu, une convolution va réaliser des opérations d'additions/multiplications : les valeurs en sorties sont donc linéaires par rapport à celles en entrée.
- 3- dans une image, la linéarité n'est pas très présente ni importante (par exemple, les variations entre valeurs de pixels peuvent être importantes dans une région, l'image a des coins...).
- 4- En ne modifiant pas les données positives, ReLU n'impacte pas les caractéristiques mises en évidence par la convolution, au contraire : elle les met davantage en évidence en creusant l'écart (valeurs négatives) « entre » deux caractéristiques (par exemple le nez et les yeux). A noter qu'il existe d'autres ReLU comme par exemple LeakyReLU qui cassent moins la linéarité des données, même si ReLU est très largement préférée et utilisée [30].

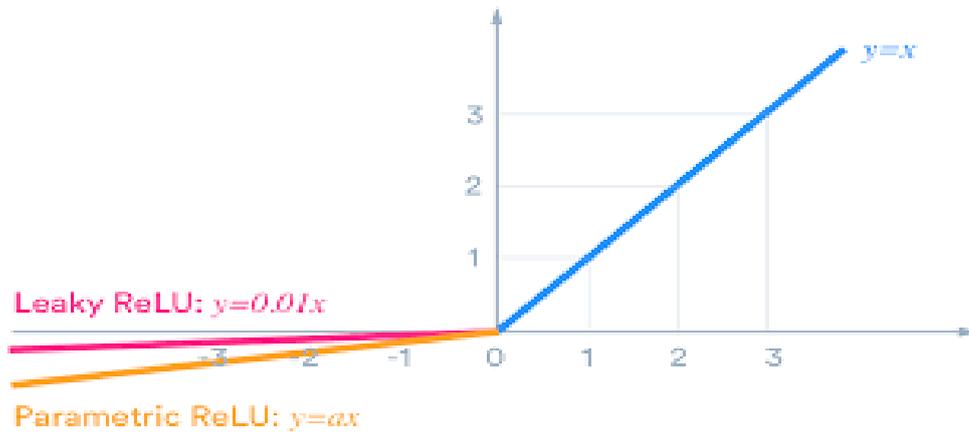


Figure.II.11 :les fonctions d'activation ReLU et LeakyReLU et la différence entre elles

II.13.5 :Le pooling :

Le pooling est une opération simple qui consiste à remplacer un carré de pixels (généralement 2×2 ou 3×3) par une valeur unique. De cette manière, l'image diminue en taille et se retrouve simplifiée (lissée), Non seulement cela réduit le nombre de calculs nécessaires, mais cela empêche également le sur-ajustement[12]. Pour appliquer le pooling, on commence par sélectionner un carré de pixels de taille 2×2 puis on calcule la valeur qui va venir remplacer ce carré, Ensuite on décale ce carré vers la droite de 1 cases si le stride (= pas) vaut 1 par exemple (généralement, il vaut 1 ou 2), Une fois arrivé au bout à droite, on recommence tout à gauche en décalant une fois vers le bas (d'un pas égal au stride) et en allant de nouveau vers la droite [31].

II.13.6: Le meanpooling (ou averagepooling) :

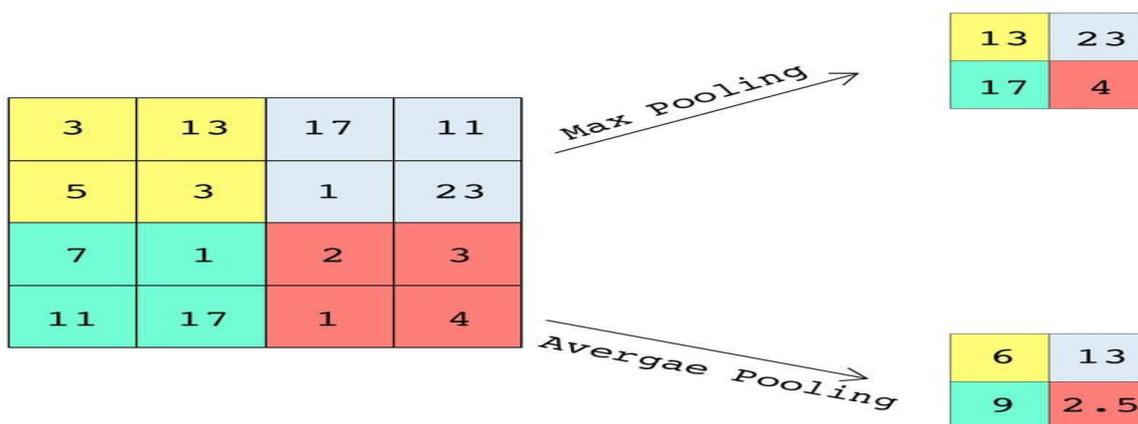


Figure.II.12 : la différence entre max pooling et Averagepooling

soit la moyenne des pixels de la sélection : on calcule la somme de toutes les valeurs et on divise par le nombre de valeurs. On obtient ainsi une valeur intermédiaire pour représenter ce lot de pixels [31].

II.13.7 :Le flattening (ou mise à plat) :

C'est la dernière étape de la partie « extraction des informations » L'entrée de cette couche est un matrices qui comprend des informations sur les emplacements des formes complexes spécifiques (motifs) dans l'image , Une opération d'aplatissement (flattening) fait de l'entrée (la matrice) que nous avons pour en faire un (long) vecteur de valeurs , chacune de ces valeurs représentant la probabilité d'un class de l'ensemble de classifications sur lesquelles le réseau est formé puis transmis à un réseau de neurones pour prédire la probabilité de la sortie [31]



Figure.II.13 :comment fonctionne le flattening

II.13.8 : fully connected :

Les réseau de neurones artificiels est un réseau qui contient des couches ça a appelé fullyconnectedlayers or dense , ces couches qui reçoit un vecteur de valeurs et renvoie des probabilités pour chaque classe de prédiction , cette couches contient des neurones , Il existe différents types de ces neurones [31]:

les neurones d'entrée : qui reçoivent la somme des signaux pondérés de la couche de flattening qui envoient leur valeur à tous les neurones de la couche suivante , Dans le cas du CNN ce sera la valeur d'un pixel précis pour chaque neurone

les neurones cachés : organisés en couches, qui vont envoyer la somme des signaux qu'ils reçoivent aux neurones de la couche suivante . **les neurones de sortie :** qui reçoivent la somme des signaux pondérés de la dernière couche cachée qui prédire la probabilité de la sortie , et Chaque neurone de sortie représente alors une prédiction spécifique. Par exemple, le premier neurone représente la prédiction « c'est un chat », le deuxième « c'est un chien »...

généralement le nombre de neurones dans cette couche (output layer) est égal le nombre de classifications , et cela selon le problème auquel nous allons trouver une solution ,et la conclusion de notre réseau dépend de quel neurone de sortie a le signal le plus fort [32].

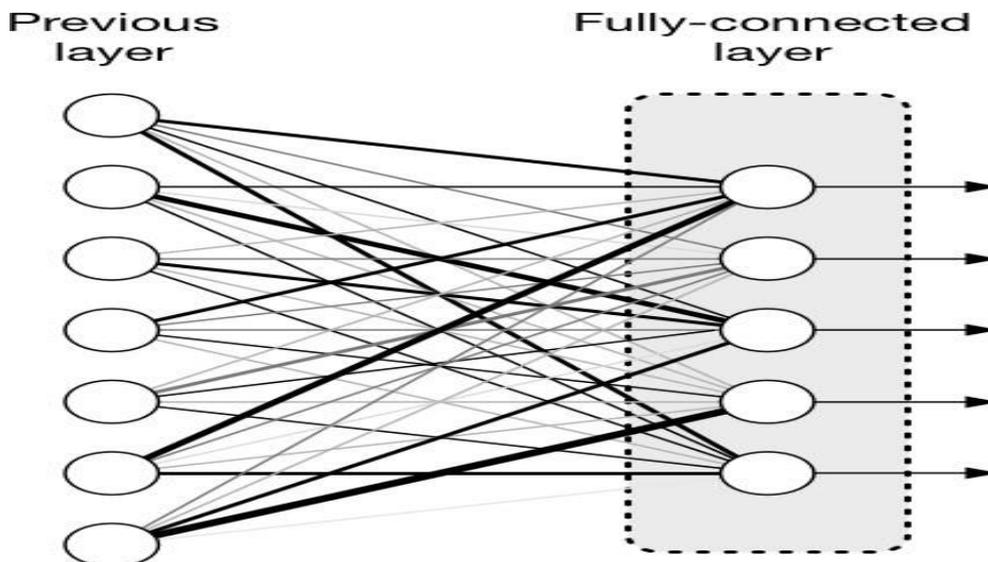


Figure.II.14 : la distribution des couches fully_conncteted

II.13.9 : le padding :

Chacun des la convolution et le pooling peuvent rendre la matrice d'entrée plus petite et cela peut faire disparaître les informations de l'image et comme solution pour cela il y a la méthode de padding il est consiste simplement à ajouter des zeros tout autour d'une matrice pour en augmenter la taille d'image comme indiqué sur l'image ci-dessous [30]

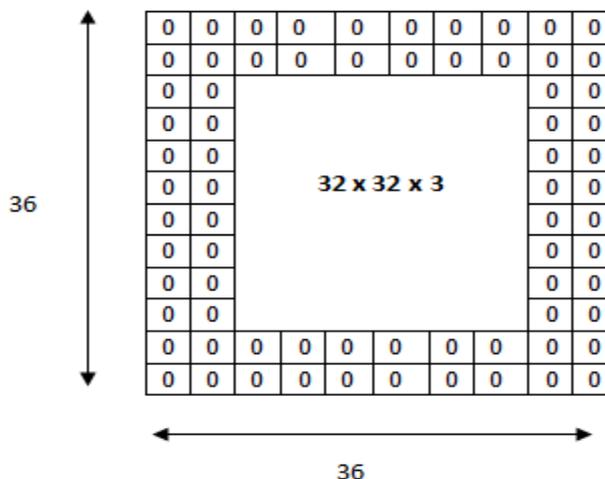


Figure.II.15 : un padding de 2 sur une matrice de taille 32x32

II.13.10.1 : Fonction d'activation :

Une fonction d'activation est une fonction mathématique utilisée sur un signal. Elle va reproduire le potentiel d'activation que l'on retrouve dans le domaine de la biologie du cerveau humain. Elle va permettre le passage d'information ou non de l'information si le seuil de stimulation est atteint. Concrètement, elle va avoir pour rôle de décider si on active ou non une réponse du neurone. Un neurone ne va faire qu'appliquer la fonction suivante :

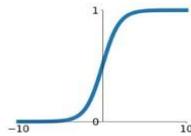
$X = (\text{entrée} * \text{poids}) + \text{biais}$ Voici quelques exemples des fonctions d'activation : 1 Sigmoid (logistic) : Fonction la plus populaire depuis des décennies. Mais aujourd'hui, elle devient beaucoup moins efficace par rapport à d'autres pour une utilisation pour les couches cachées.

Elle perd de l'information due à une saturation que cela soit pour la phase de feed forward ou de backpropagation, en donnant des effets non linéaires au réseau due à un paramètre unique. Elle a aussi des soucis de gradient 0 avec des entrées étant très large, même si le soucis est minimalisé avec les systèmes utilisant des batch par lots (mini batch). Utilisée en couche de sortie pour de la classification binaire. Intervalle de sortie : 0,1 [33]

Activation Functions

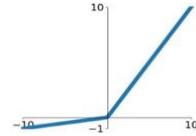
Sigmoid

$$\sigma(x) = \frac{1}{1+e^{-x}}$$



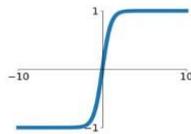
Leaky ReLU

$$\max(0.1x, x)$$



tanh

$$\tanh(x)$$

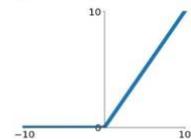


Maxout

$$\max(w_1^T x + b_1, w_2^T x + b_2)$$

ReLU

$$\max(0, x)$$



ELU

$$\begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases}$$

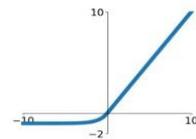


Figure. II.18 : représentation des différents types de « activation functions » [35]

II.13.10.2 : Softmax :

Utilisée pour de la multi classification en couche de sortie. Intervalle de sortie (- ;+). [33]

ReLU (Rectified Linear Unit) : Ce sont les fonctions les plus populaires de nos jours.

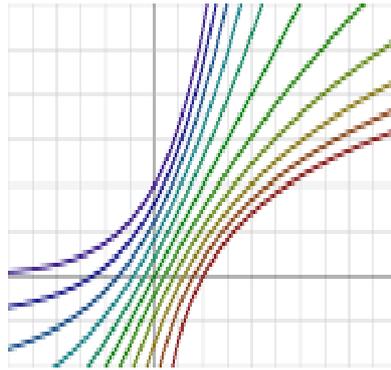


FIGURE .II.16 : La fonction soft max

Elles permettent un entraînement plus rapide comparé aux fonctions sigmoid et tanh, étant plus légères. Attention au phénomène de ‘Dying ReLU’, auquel on préférera les variations de ReLU. Plus d’informations en fin d’article. Très utilisé pour les CNN, RBM, et les réseaux de multi perceptron. Intervalle de sortie (0 ;+). [34]

II.13.10.3 : Unité linéaire rectifiée ("RectifiedLinear Unit", ReLU) :

Cette fonction d'activation (et ses variantes) est fréquemment utilisée en apprentissage profond. • Fonction utilisée pour les couches cachées ("hiddenlayers") des réseaux de neurones. • Avantages et inconvénients :

→ Coût de calcul faible et fonction facile à optimiser.

→ Convergence plus rapide que sigmoïde ou tanh. → Améliore la propagation du gradient. → Si $x < 0 \Rightarrow$ poids non actualisés \Rightarrow pas d'apprentissage. → Non différentiable à zéro. → Pas centrée en zéro et non bornée. II.7.5 Variantes de ReLU Softplus ou SmoothReLU : Autres variantes de ReLU:LeakyReLUs, Noisy ReLUs, PReLUs ("ParametricReLUs"),

ELUs ("ExponentialLinear Unit")

II. 13.10.4: Maxout :

La matrice de pondération de cette fonction est un tableau à 3 dimensions dans lequel la 3ème dimension correspond à la connexion entre couches voisines [40].

Conclusion :

Dans ce chapitre, différentes techniques d'apprentissage en profondeur appliquées pour la classification qui constitue notre système de reconnaissance de maladie d'Alzheimer, qui est basée sur les réseaux de neurones convolutionnel pour classer les images et les menaces, et pour cela nous avons parlé des différents types des algorithmes de la machine Learning.

Nous avons fait une comparaison entre les techniques d'apprentissage en profondeur et les techniques d'apprentissage, et en présentant les différents types de couches utilisées dans la classification. et aussi les méthodes de régularisation.



Chapitre III



III.1: La base de données utilisées :

Les données sont constituées d'images IRM. Ces images présentent quatre classes [36] :

- ✓ **Mild Demented:** sont des problèmes courants chez les personnes âgées. Les fournisseurs de soins primaires sont le premier point de contact pour la plupart des patients atteints de ces troubles et doivent connaître leur diagnostic, leur pronostic et leur prise en charge. Les troubles cognitifs légers et la démence légère sont caractérisés par des preuves objectives de troubles cognitifs.
- ✓ **Moderate Demented:** Les personnes atteintes de démence modérée auront probablement besoin de plus d'aide dans leur vie quotidienne. Il devient plus difficile d'effectuer des activités quotidiennes régulières et de prendre soin de soi à mesure que la démence progresse.
- ✓ **Non Demented:** des lésions liées à la maladie d'Alzheimer au moins légères à modérées, et rarement même sévères, représentant probablement une maladie d'Alzheimer préclinique asymptomatique et/ou des pathologies .
- ✓ **Very Mild Demented:** Les gens connaîtront un déclin mental supplémentaire ainsi qu'une aggravation de leurs capacités physiques une fois que la maladie progressera jusqu'à une démence sévère.

Les données se présentent dans deux répertoires, Les données d'apprentissage et de test. Et dans chaque répertoire se trouve un sous-dossier pour chaque classe.

III.3 : Les paramètres des modèles de deep-learning

- ✓ **Batch size :** La taille du lot est un terme utilisé dans l'apprentissage automatique et fait référence au nombre d'exemples de formation utilisés dans une itération. La taille du lot peut être l'une des trois options suivantes: mode batch : où la taille du lot est égale à l'ensemble de données total, ce qui rend les valeurs d'itération et d'époque équivalentes.

Mode mini-lot : où la taille du lot est supérieure à un mais inférieure à la taille totale de l'ensemble de données. Généralement, un nombre qui peut être divisé par la taille totale de l'ensemble de données. Mode stochastique : où la taille du lot est égale à un. Par conséquent, le gradient et les paramètres du réseau de neurones sont mis à jour après chaque échantillon. [37]

- ✓ **Nombre d'Epoch :** Une époque est un terme utilisé dans l'apprentissage automatique et indique le nombre de passes de l'ensemble de données d'entraînement complet que l'algorithme d'apprentissage automatique a effectué.

Les ensembles de données sont généralement regroupés en lots (en particulier lorsque la quantité de données est très importante). Certaines personnes utilisent le terme itération de manière vague et se réfèrent au passage d'un lot dans le modèle en tant qu'itération. [38]

- ✓ **Optimizer :** Les algorithmes d'optimisation sont utilisés dans l'apprentissage automatique pour réduire une fonction appelée fonction de perte ou fonction d'erreur.

En minimisant la fonction de perte, les algorithmes d'optimisation peuvent atteindre une différence minimale ou nulle entre la sortie réelle et prévue, ce qui rend notre modèle plus précis pour une tâche. Il existe différents types d'algorithmes d'optimisation utilisés dans les réseaux de neurones : variantes de descente en pente (gradient descent) descente de gradient par lots descente de gradient stochastique descente de gradient mini-lot Gradient accéléré Nesterov (moment Nesterov) algorithmes avec des taux d'apprentissage adaptatifs AdaGrad AdaDelta RMSprop Adam [39]

- ✓ **Loss function** : Une fonction de perte est une fonction mathématique couramment utilisée en statistique. Les fonctions de perte sont fréquemment utilisées pour créer des algorithmes d'apprentissage automatique. La fonction de perte calcule l'erreur pour un seul exemple d'apprentissage contrairement à une fonction de coût, qui est la moyenne des fonctions de perte de chaque exemple dans l'ensemble de données d'apprentissage.

Les fonctions de perte sont utilisées dans l'apprentissage automatique pour mesurer la distance mathématique entre les valeurs prédites et les valeurs réelles [40]

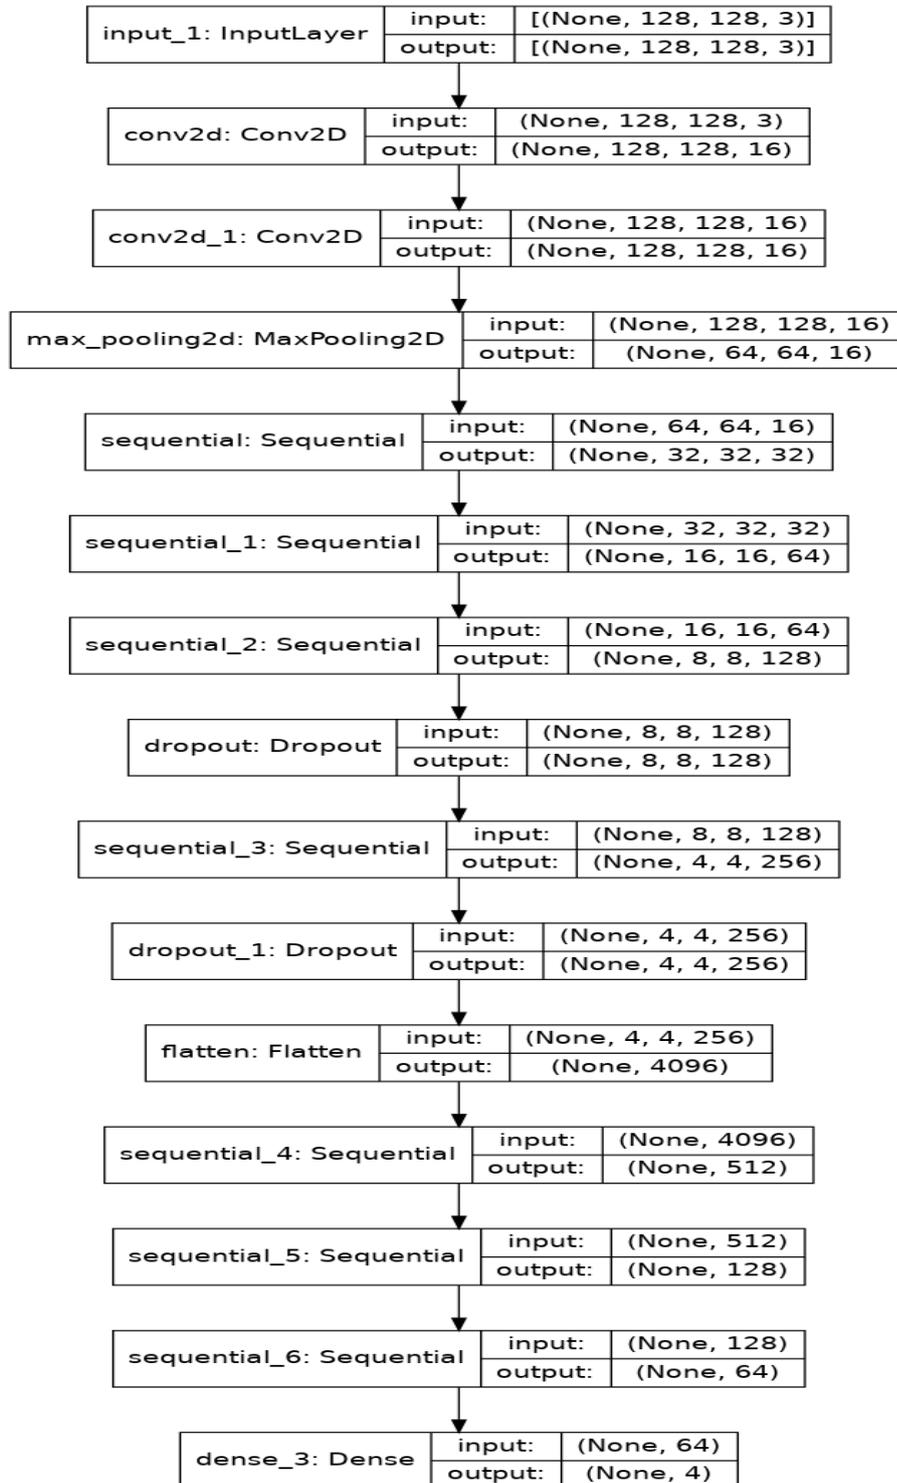
- ✓ **Activation function** : les fonctions d'activation effectuent une transformation sur une somme pondérée d'entrées plus des biais sur un neurone afin de calculer sa sortie. En utilisant une analogie biologique, la fonction d'activation détermine la « cadence de tir » d'un neurone en réponse à une entrée ou à un stimulus. Ces fonctions introduisent des non-linéarités dans les réseaux de neurones leur permettant d'effectuer des tâches complexes telles que la reconnaissance d'images et le traitement du langage.

Sans fonctions d'activation non linéaires, les réseaux de neurones artificiels se comportent comme de simples modèles de régression linéaire. Ces fonctions comprennent : fonction sigmoïde fonction d'unité linéaire rectifiée (ReLU) fonction tangente hyperbolique (Tanh). [32]

IV. Les Modèles de notre approche :

Nous avons proposé 2 modèles pour prédire la maladie :

IV.1 Le Modèle N° 1 :

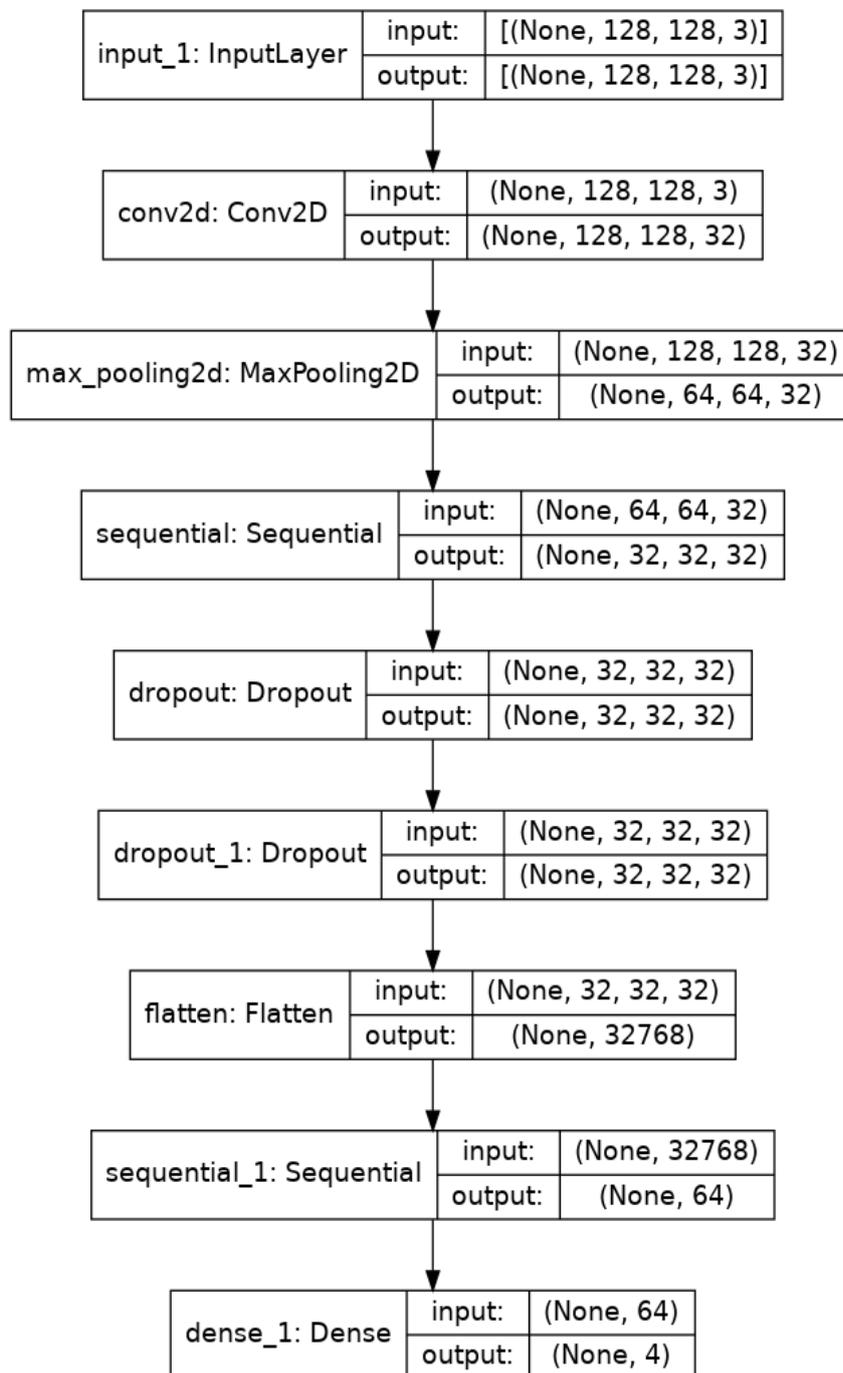


```

Model: "cnn_model"
-----
Layer (type)                Output Shape                Param #
-----
conv2d (Conv2D)              (None, 128, 128, 16)       448
conv2d_1 (Conv2D)            (None, 128, 128, 16)       2320
max_pooling2d (MaxPooling2D) (None, 64, 64, 16)         0
sequential (Sequential)      (None, 32, 32, 32)         14016
sequential_1 (Sequential)    (None, 16, 16, 64)         55680
sequential_2 (Sequential)    (None, 8, 8, 128)          221952
dropout (Dropout)            (None, 8, 8, 128)          0
sequential_3 (Sequential)    (None, 4, 4, 256)          886272
dropout_1 (Dropout)          (None, 4, 4, 256)          0
flatten (Flatten)            (None, 4096)                0
sequential_4 (Sequential)    (None, 512)                  2099712
sequential_5 (Sequential)    (None, 128)                  66176
sequential_6 (Sequential)    (None, 64)                   8512
dense_3 (Dense)              (None, 4)                    260
-----
Total params: 3,355,348
Trainable params: 3,352,980
Non-trainable params: 2,368

```

FIGURE III.21 : Configuration et nombre de paramètres modèle cnn ; Avec 3355348 paramètres divisé en deux (trainable params = 3352980, non trainable params = 2368)

IV.2 Modèle 2 :

```

Model: "cnn_model"
-----
Layer (type)                Output Shape                Param #
-----
conv2d (Conv2D)             (None, 128, 128, 32)      896
max_pooling2d (MaxPooling2D) (None, 64, 64, 32)        0
sequential (Sequential)     (None, 32, 32, 32)        18624
dropout (Dropout)           (None, 32, 32, 32)        0
dropout_1 (Dropout)         (None, 32, 32, 32)        0
flatten (Flatten)           (None, 32768)              0
sequential_1 (Sequential)   (None, 64)                  2097472
dense_1 (Dense)             (None, 4)                   260
-----
Total params: 2,117,252
Trainable params: 2,117,060
Non-trainable params: 192

```

FIGURE III.22 : Configuration et nombre de paramètres modèle cnn. Avec 2112196 paramètres divisé en deux (trainable params = 2112004, non trainable params = 192)

- **Conclusion :**

Dans ce chapitre nous avons vu les différentes variations de paramètres et en déduit le meilleur modèle parmi les modèles proposés.



Chapitre IV



IV.1 : Le langage de programmation :

Python est un langage de programmation de haut niveau interprété pour la programmation à usage général. Créé par Guido van Rossum et publié pour la première fois en 1991, Python repose sur une philosophie de conception qui met l'accent sur la lisibilité du code, notamment en utilisant des espaces significatifs. Il fournit des constructions permettant une programmation claire à petite et grande échelle. Python propose un système de typage dynamique et une gestion automatique de la mémoire. Il prend en charge plusieurs paradigmes de programmation, notamment orienté objet, impératif, fonctionnel et procédural, et dispose d'une bibliothèque standard étendue et complète.

Les interpréteurs Python sont disponibles pour de nombreux systèmes d'exploitation. CPython, l'implémentation de référence de Python, est un logiciel open source et dispose d'un modèle de développement basé sur la communauté, comme le font presque toutes les autres implémentations de Python. Python et CPython sont gérés par l'association à but non lucratif Python Software Foundation. [41]

IV. 2: Les outils et les bibliothèques utilisés :

Tensorflow TensorFlow : est une bibliothèque open source de Machine Learning, Créé par l'équipe Google Brain en 2011, sous la forme d'un système propriétaire dédié aux réseaux Learning, est une bibliothèque de logiciels open source pour le calcul numérique utilisant des graphes de flux de données. Les noeuds des graphes représentent des opérations mathématiques, tandis que les arêtes des graphes représentent les tableaux de données multidimensionnels (tenseurs) qui circulent entre eux. Cette architecture flexible vous permet de déployer des calculs sur un ou plusieurs processeurs ou GPU sur un ordinateur de bureau, un serveur ou un périphérique mobile sans réécrire le code.

Keras Keras : est une API de réseaux de neurones de haut niveau, écrite en Python et capable de s'exécuter sur TensorFlow, CNTK ou Theano. Il a été développé pour permettre une expérimentation rapide . -Permet un prototypage simple et rapide (convivialité, modularité et extensibilité). - Prend en charge les réseaux convolutionnels et les réseaux récurrents, ainsi que les combinaisons des deux . - Fonctionne de manière transparente sur CPU et GPU [42]

Visual Studio Code : Visual Studio Code est un éditeur de code open-source développé par Microsoft supportant un très grand nombre de langages grâce à des extensions. Il supporte l'autocomplétion, la coloration syntaxique, le débogage, et les commandes git. [43]

Machine utilisé :

- ✓ Processeur : Intel(R) Core(TM) i3-5005U CPU @ 2.00GHz 2.00 GHz
- ✓ RAM : 4,00 Go
- ✓ Type du système : Système d'exploitation 64 bits, processeur x64
- ✓ System exploitation : windows 10

IV. 3 -Les métriques utilisées :

1-La matrice de confusion : La matrice de confusion, appelée également matrice d'erreur, est un tableau qui présente différentes prévisions et résultats de tests, en les comparant avec des valeurs réelles. Ces matrices sont utilisées dans les statistiques, le data mining, les modèles d'apprentissage automatique et d'autres applications de l'intelligence artificielle. [36]

Taux de classification : Le taux de classification est le nombre de prédictions correctes faites par le modèle sur toutes les sortes de prédictions effectuées.

		Actual	
		Positives(1)	Negatives(0)
Predicted	Positives(1)	TP	FP
	Negatives(0)	FN	TN

Figure .III.19 : Taux de classification illustré dans la matrice de confusion.

Dans le numérateur, nos prédictions correctes (vrais positifs et vrais négatifs) (marquées en rouge dans la figure ci-dessus) et dans le dénominateur, sont le genre de toutes les prédictions faites par l’algorithme (correctes ou non).

Taux d’erreur L’erreur : dans les problèmes de classification est le nombre de prédictions incorrectes faites par le modèle sur tous les types de prédictions effectuées.

		Actual	
		Positives(1)	Negatives(0)
Predicted	Positives(1)	TP	FP
	Negatives(0)	FN	TN

Figure. III. 20 : Taux d’erreur illustré dans la matrice de confusion

Dans le numérateur, nos prédictions incorrectes (faux positifs et faux négatifs) (marquées en rouge dans la figure ci-dessus) et dans le dénominateur, sont le genre de toutes les prédictions faites par l’algorithme (correctes ou non).

2-Métrique utilisée : ACCURACY : Est une mesure pour évaluer les modèles de classification. De manière informelle accuracy est la fraction des prédictions que notre modèle a obtenues. Formellement, accuracy a ce qui suit :

$$\text{Accuracy} = \frac{\text{Number of correct predictions}}{\text{Total number of predictions}}$$

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

où TP = True Positives, TN = True Negatives, FP = False Positives, and FN = False Negatives. [50]

- ✓ **True Positive (TP)** : la prédiction et la valeur réelle sont positives.
Exemple : Une personne malade et prévu malade.
- ✓ **True Negative (TN)** : la prédiction et la valeur réelle sont négatives.
Exemple : Une personne saine et prévu saine.
- ✓ **False Positive (FP)** : la prédiction est positive alors que la valeur réelle est négative.
- ✓ **False Negative (FN)** : la prédiction est négative alors que la valeur réelle est négative. [51]

IV. 4 La phase d'apprentissage des modèles :

Les résultats d'apprentissage du Modèle N° 1 :

Variation du nombre d'époches :

Epoche=10

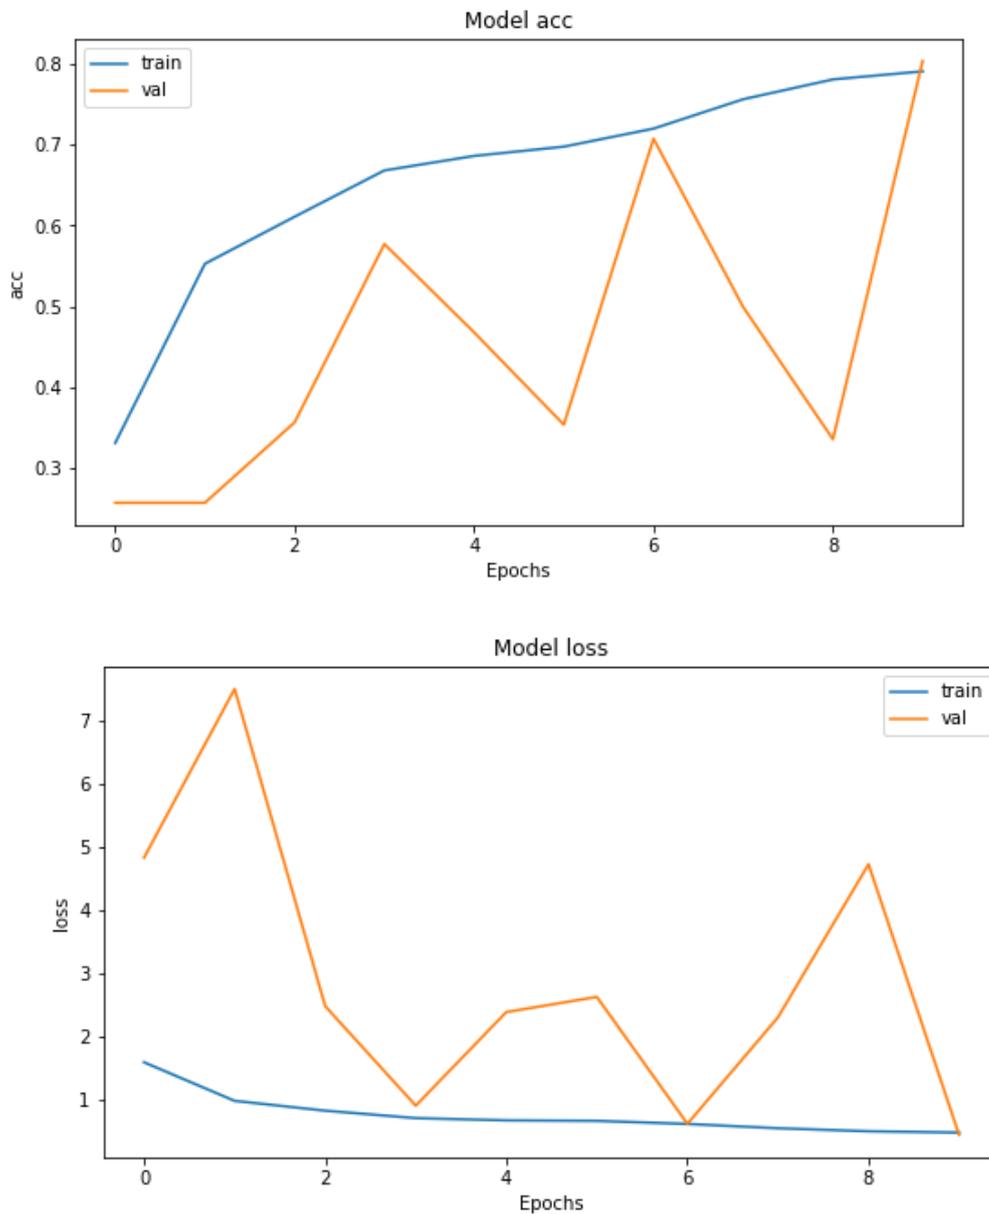


FIGURE IV.24 : Courbes accuracy, val accuracy, loss, val loss avec nombre d'époches = 10

- Le nombre d'époche joue un rôle très important d'après les résultats de la figure précédente on remarque qu'il y a du overfitting ; le nombre d'erreurs de validation est élevé alors que celui des erreurs d'apprentissage est faible.

Epoche=30

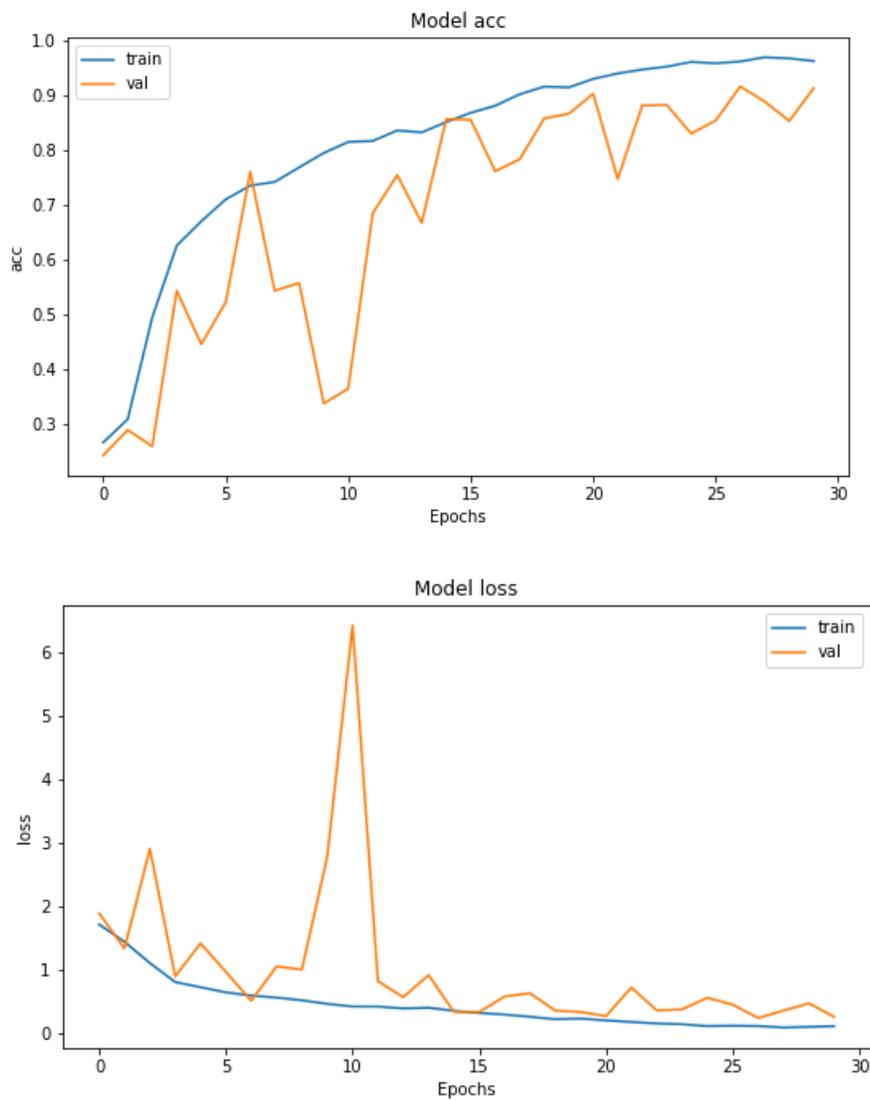


FIGURE IV.25 : Courbes accuracy, val accuracy, loss, val loss avec nombre d'époques = 30

- on remarque du overfitting quand le nombre d'époche=10 les résultats s'améliorent après

Epoche=100

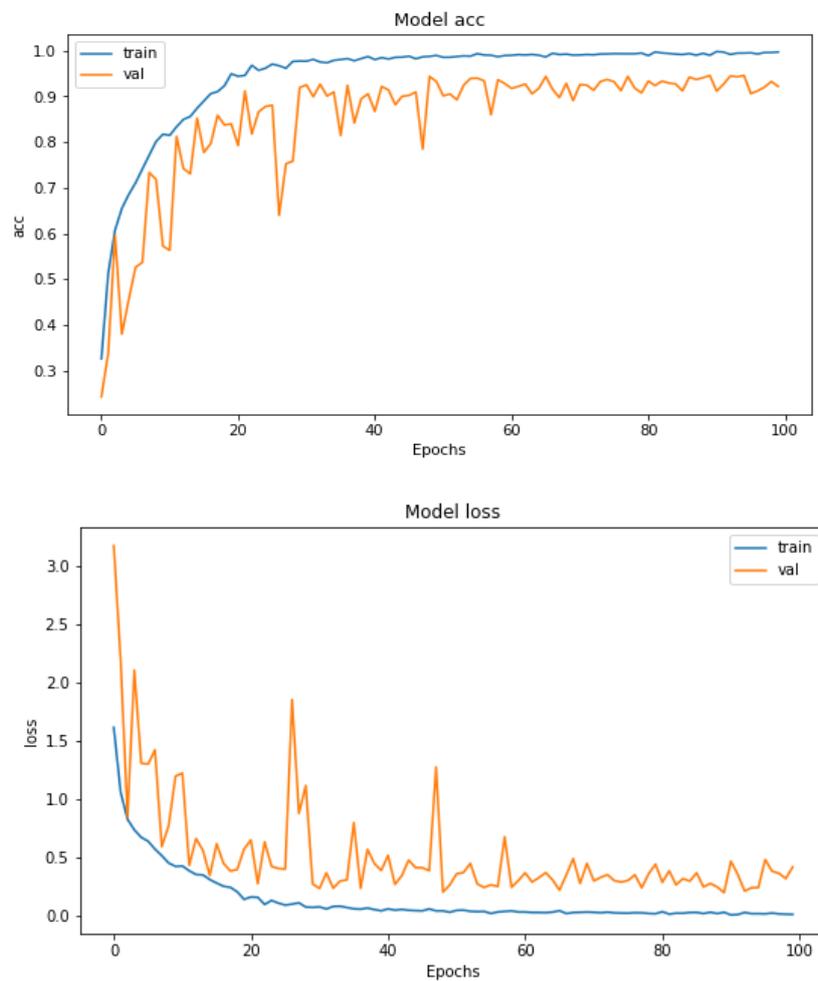


FIGURE IV.26 : Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 100

- on remarque qu'il ya du overfitting au début de la courbe mais les résultats s'améliorent après

Epoch=200

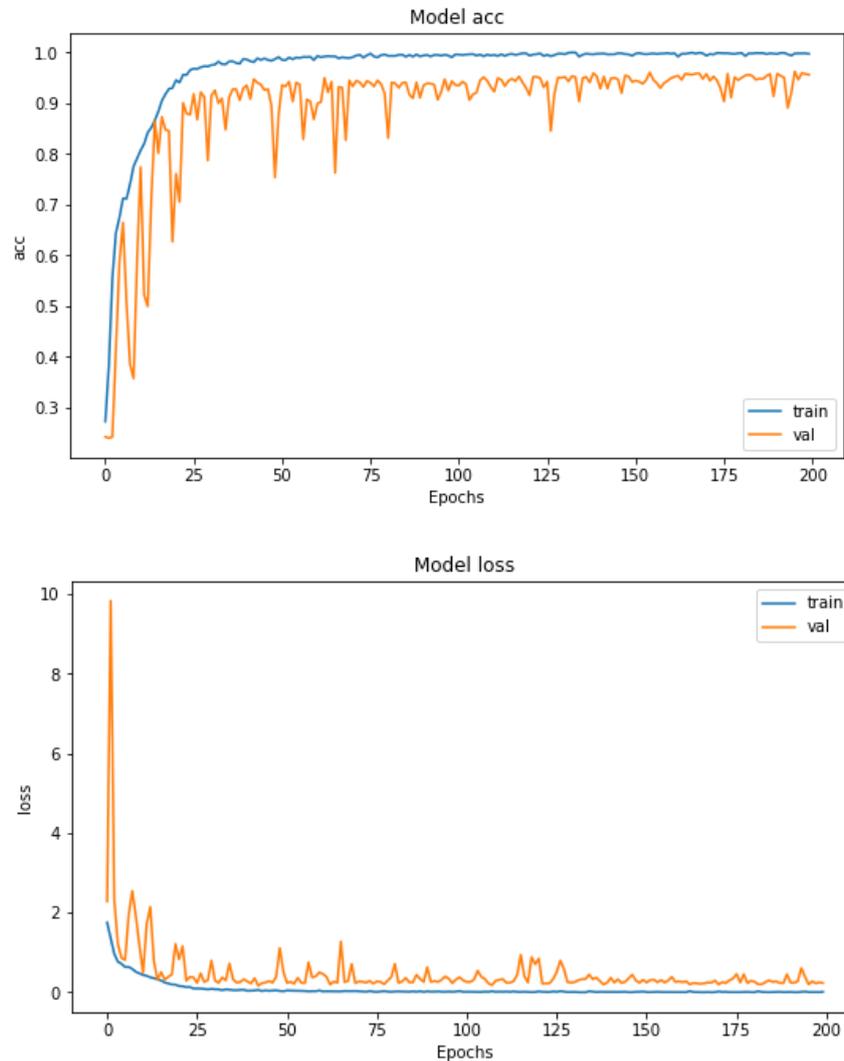


FIGURE IV.27 : Courbes accuracy, val accuracy, loss, val loss avec nombre d'epoches = 200

- on remarque clairement que les résultats s'améliorent après nombre d'epoche = 10 jusqu'à obtenir une accuracy = 0.94 avec nombre d'epoche = 200. Cette situation est expliquée par le fait que l'optimizer commence à générer moins d'erreur après nombre d'epoche = 10.

Les résultats d'apprentissage du Modèle N° 2 :

Variation du nombre d'époques :

Epoche=10

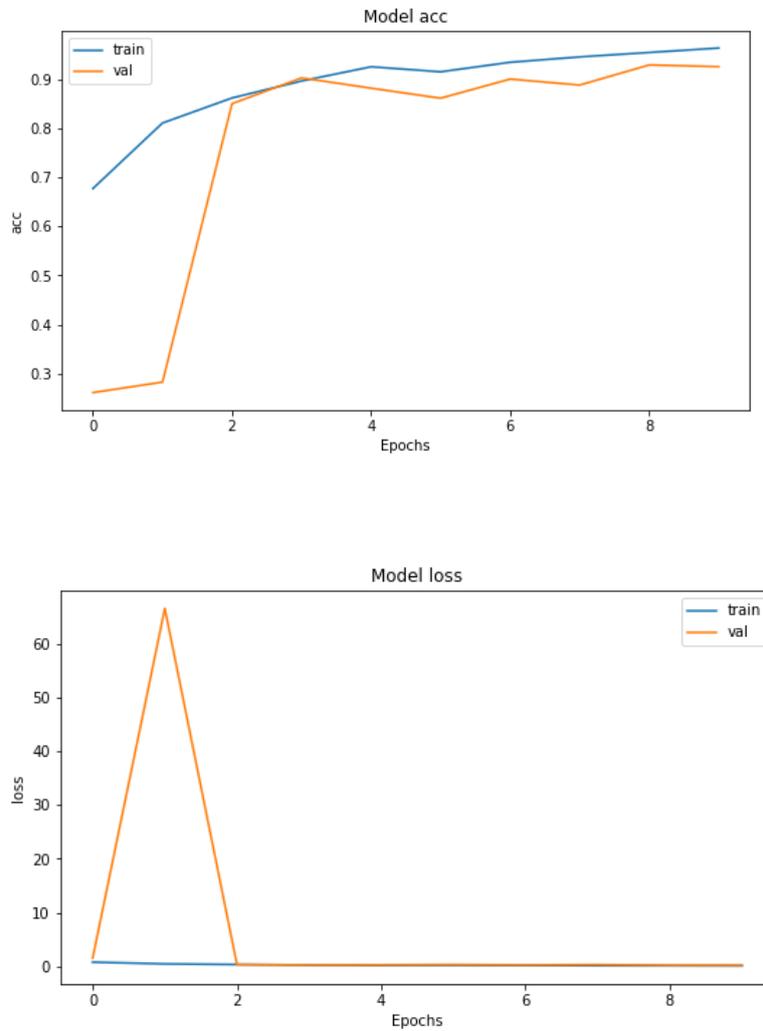


FIGURE IV.28 : Courbes accuracy, val accuracy, loss, val loss avec nombre d'époques = 10

- on remarque du overfitting quand le nombre d'époche=10 , les résultats s'améliorent après

Epoche=30

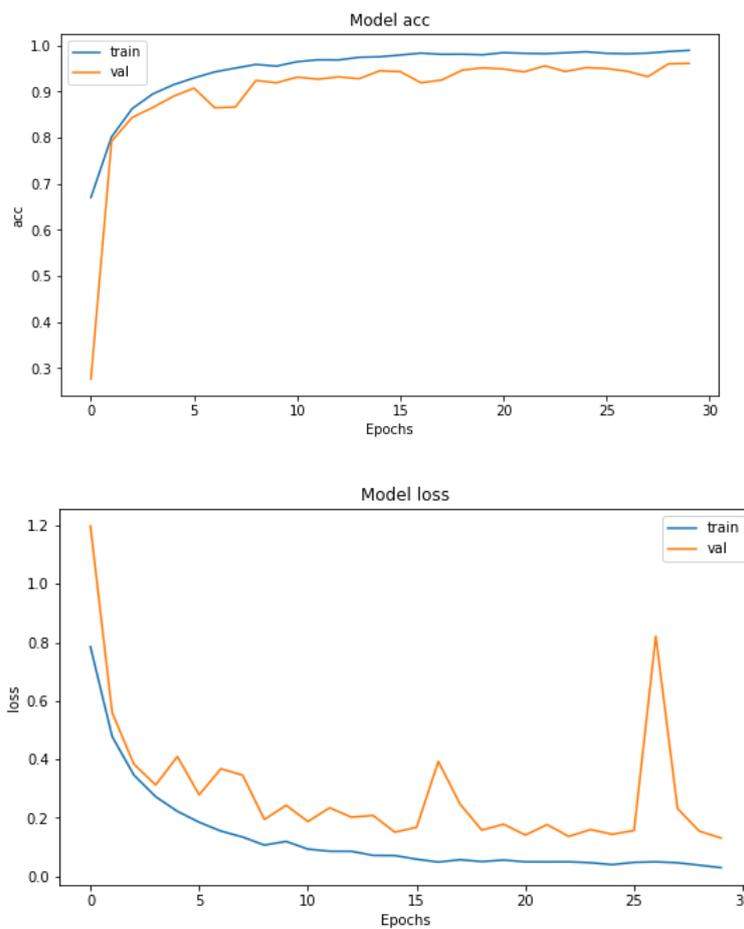


FIGURE IV.29 : Courbes accuracy, val accuracy, loss, val loss avec nombre d’époques = 30

- le nombre d’erreurs de validation est faible, mais légèrement supérieur à celui des erreurs d’apprentissages.

Epoche=100

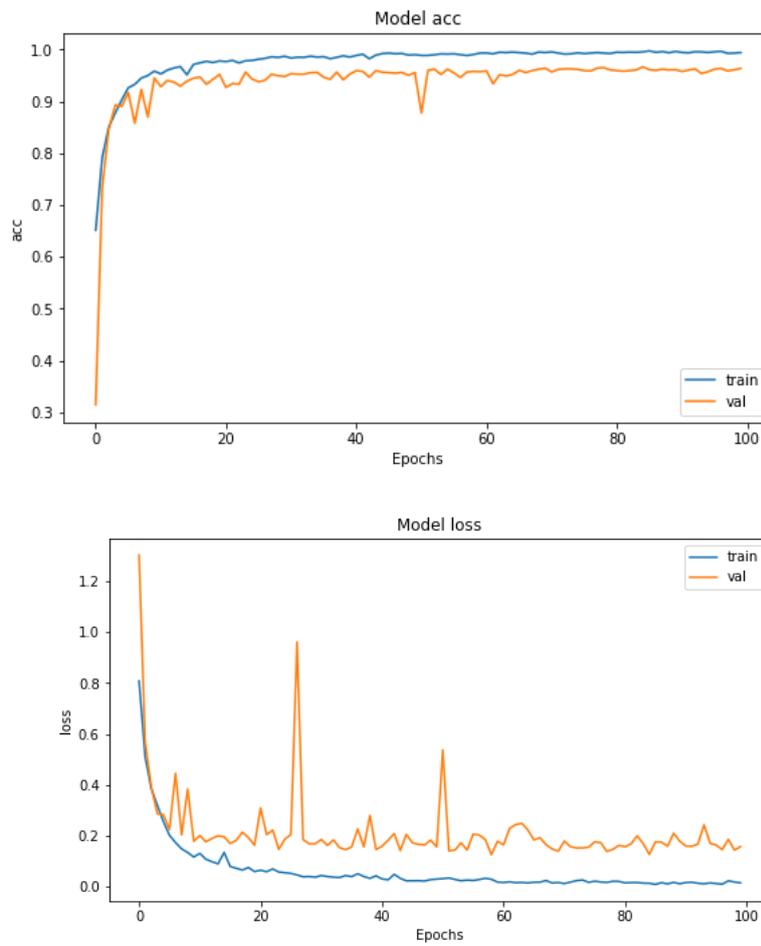


FIGURE IV.30 : Courbes accuracy, val accuracy, loss, val loss avec nombre d'époques = 100

- le nombre d'es erreurs de validation est élevé alors que celui des erreurs d'apprentissage est faible avant epoche=50 les résultats s'améliorent après.

Epoche=200

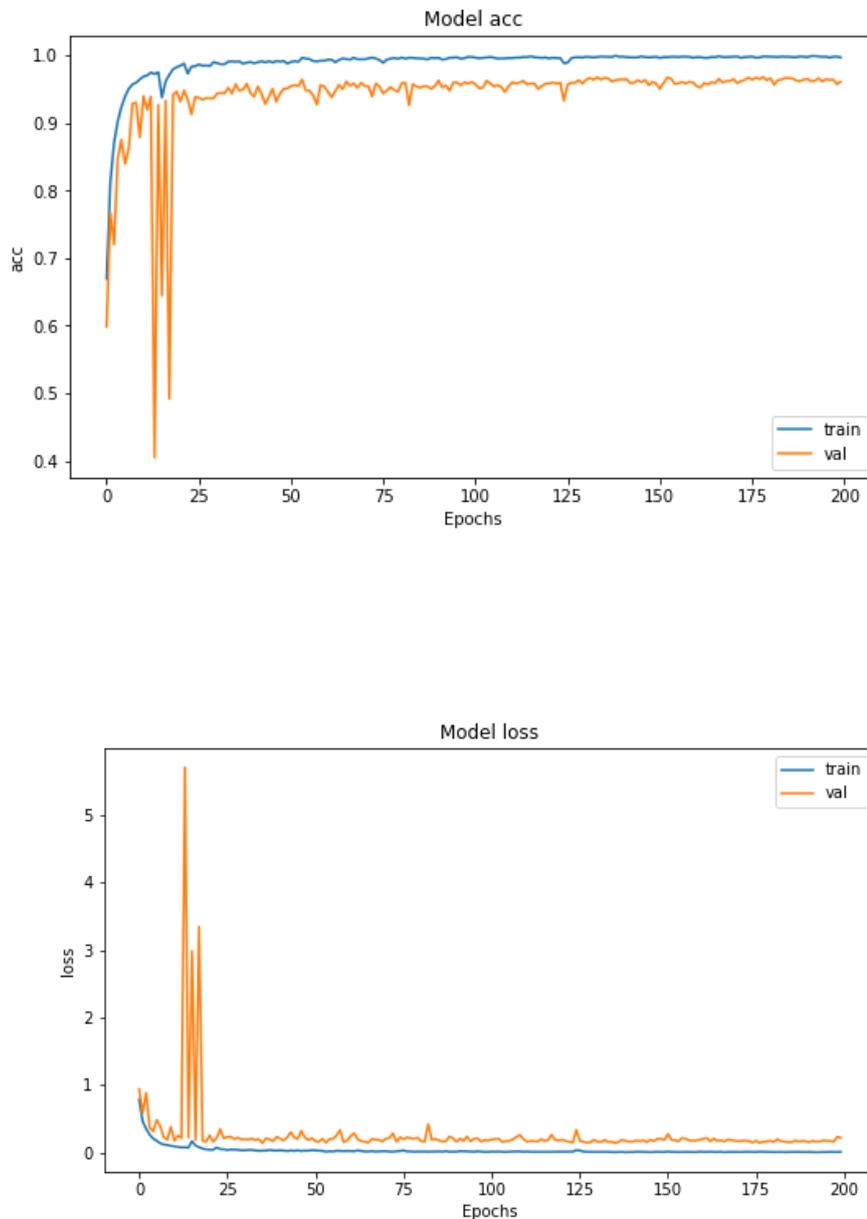
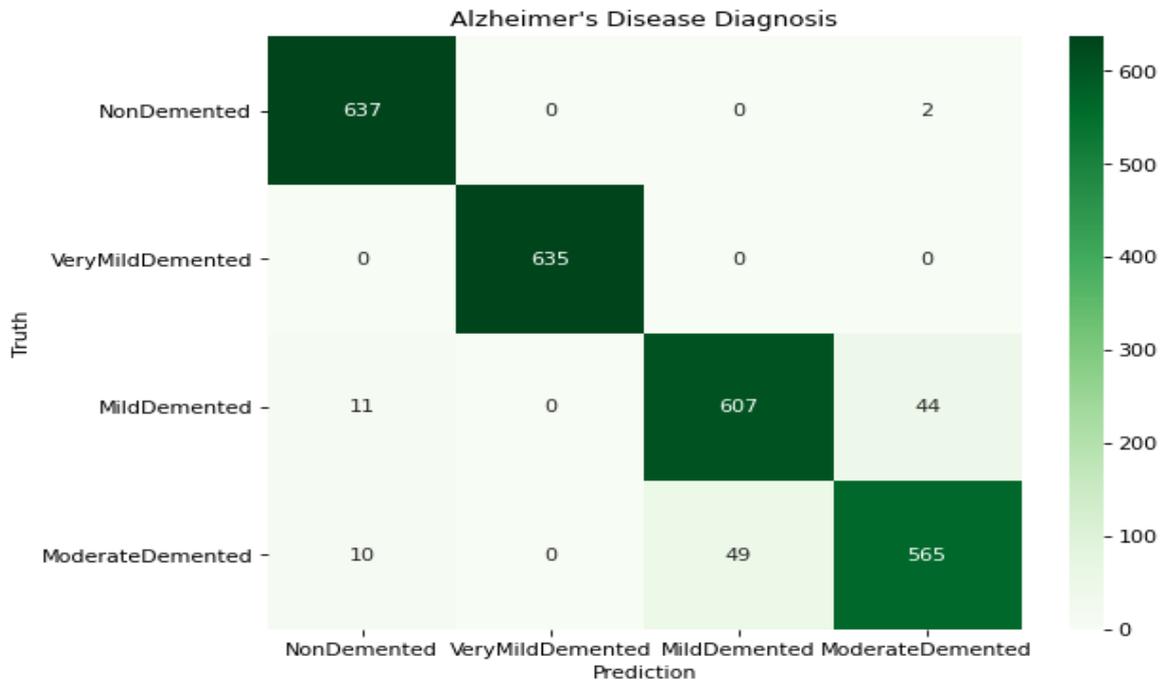


FIGURE IV.31 : Courbes accuracy, val accuracy, loss, val loss avec nombre d'époques = 200

- on remarque clairement que les résultats s'améliorent après nombre d'époche = 20 le nombre d'erreurs de validation est faible, mais légèrement supérieur à celui des erreurs d'apprentissages.jusqu'à obtenir une accuracy = 0.9 avec nombre d'époche = 200. Cette situation est expliquée par le fait que l'optimizer commencent a générer moins d'erreur après nombre d'époche =20. Au début il y'a un surapprentissage causé par le mal réglage du paramètres nombre d'poche.

IV. 5 : La partie Test des modèles :

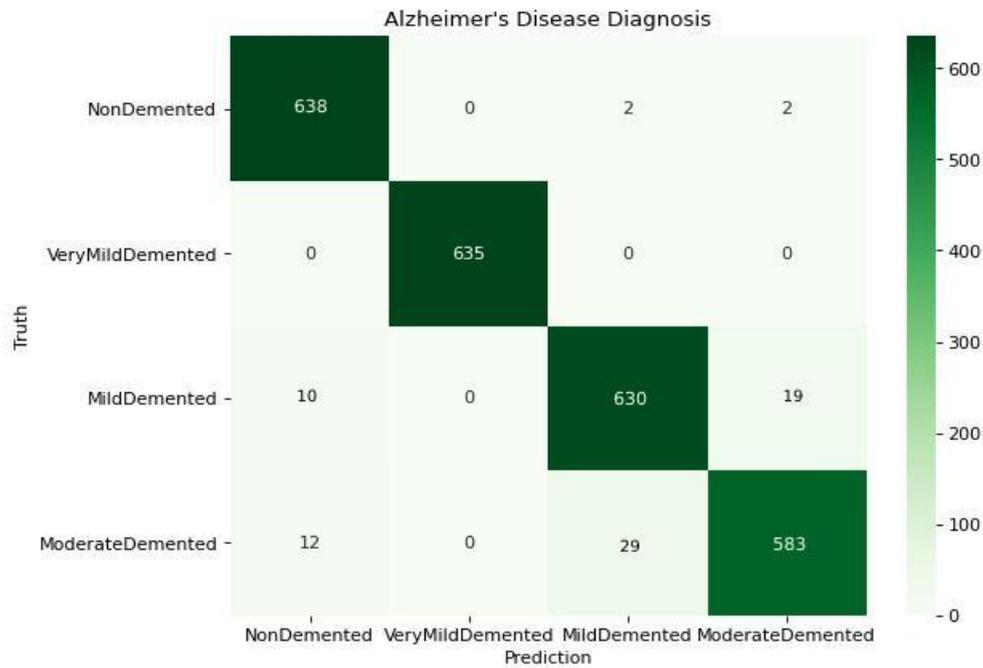
IV.3.2 : Les résultats du Modèle N° 01 :



Tabl IV.01 : tableau de la matrice de confusion du modèle 01

- Accuracy : 94.53%
- **le nombre de prédictions correctes pour chaque classe :**
 - Non demented : 637
 - Very mild demented : 635
 - Mild demented : 607
 - Moderate demented : 565
- **le nombre de prédictions incorrectes pour chaque classe :**
 - Non demented : 2
 - Very mild demented : 0
 - Mild demented : 55
 - Moderate demented : 59

IV.3.3 :Les résultats du modèle N° 2 :



Tabl IV.02 : tableau de la matrice de confision modèle 02

Accuracy = 97.10%

- le nombre de prédictions correctes pour chaque classe :

- Non demented : 638
- Very mild demented : 635
- Mild demented : 630
- Moderate demented : 583

- le nombre de prédictions incorrectes pour chaque classe :

- Non demented : 4
- Very mild demented : 0
- Mild demented : 29
- Moderate demented : 41

Exemple des cas ou notre système a fait des erreurs de classification :

Actual \neq predicted

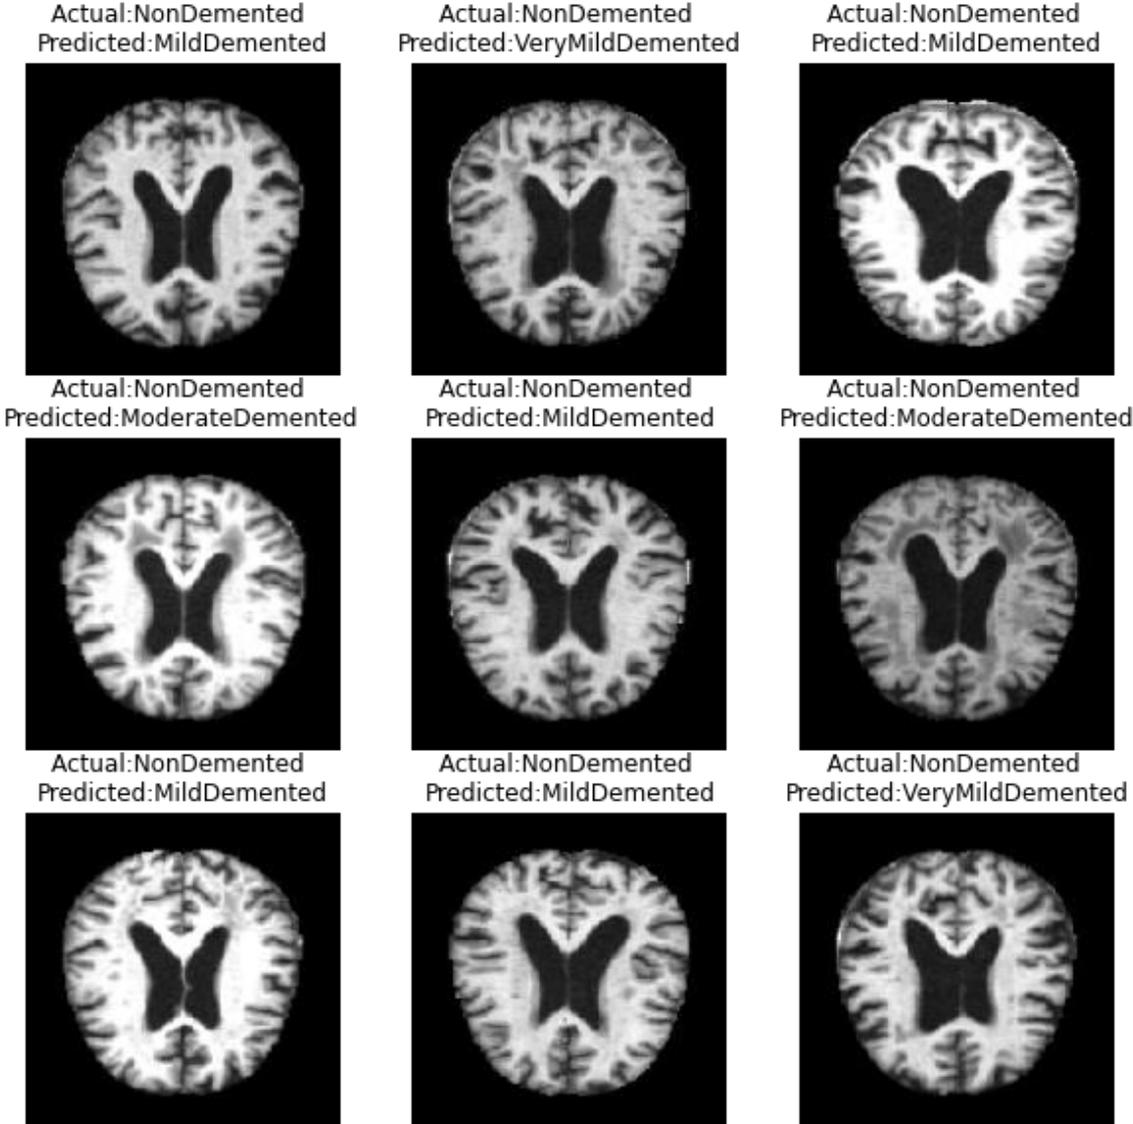
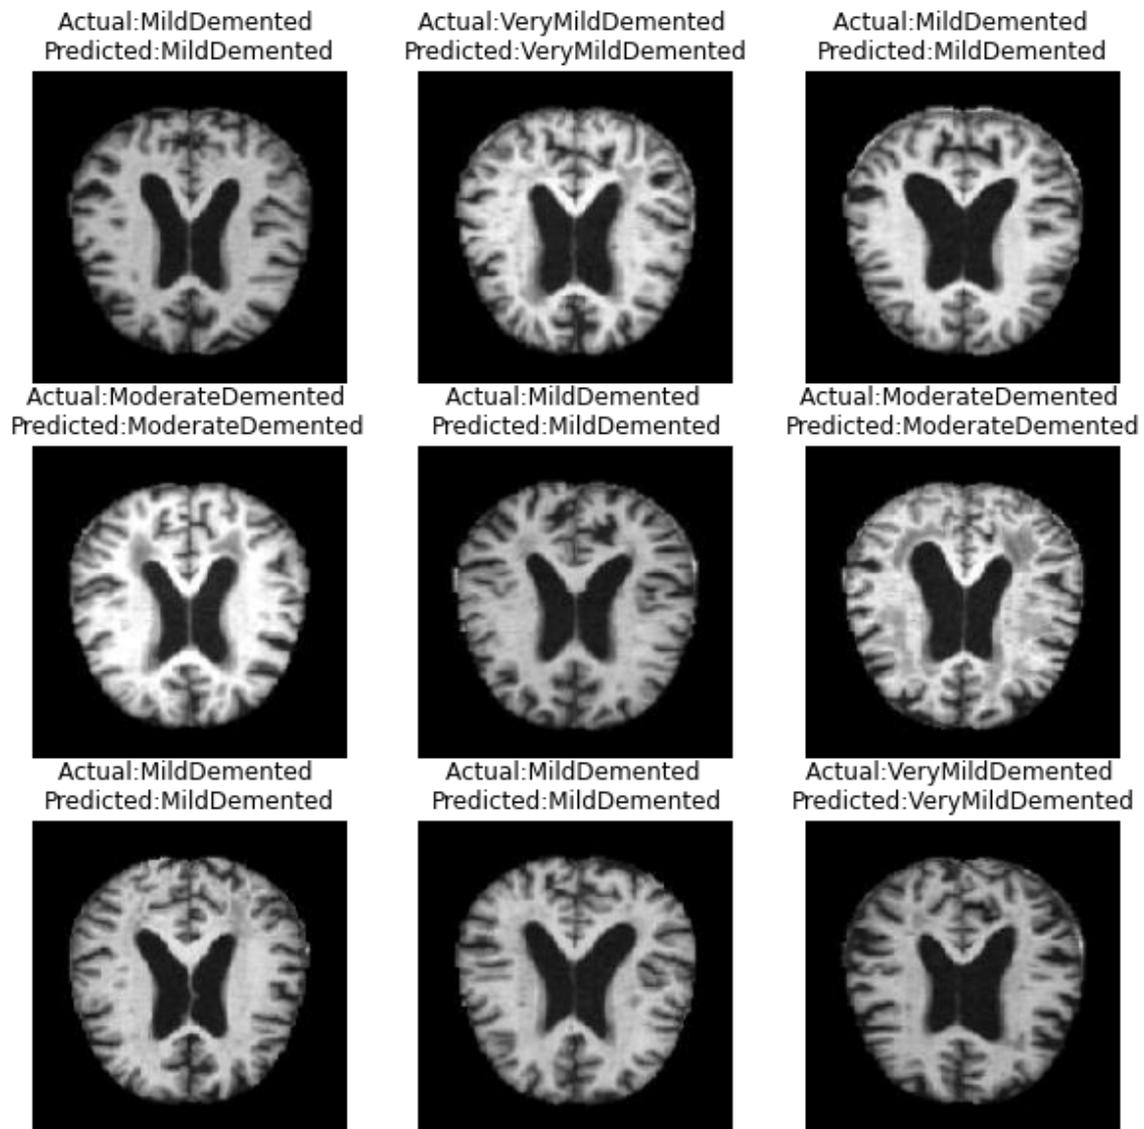


Figure IV.32 : des images exemple de chaque cas dans la matrice de confusion du modèle le plus réussie

Exemple des cas où notre système n'a pas fait des erreurs de classification :

Actual = predicted



-des images exemple de chaque cas dans la matrice de confusion du modèle le plus réussie

IV.3.4 : Comparaison entre les deux modèles :

	Modèle 01	Modèle 02
Taille de l'image	<i>128</i>	<i>128</i>
Nbr de couches		
Temps d'apprentissage	<i>30 Heures</i>	<i>10 Heures</i>
Resultats du test	<i>94.53%</i>	<i>97.10%</i>
optimizer	<i>adam</i>	<i>adam</i>
fonction d'activation	<i>ReLU</i>	<i>ReLU</i>
Nbr des filtres	<i>16+16</i>	<i>32</i>
Taille des filtres	<i>3*3</i>	<i>3*3</i>

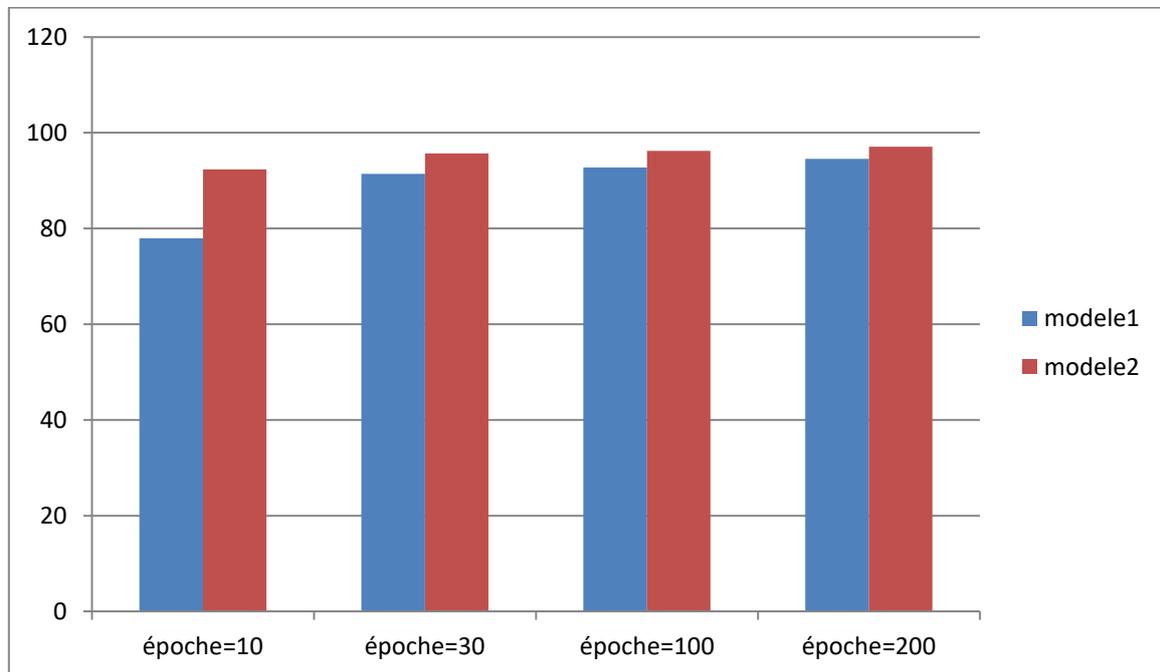


FIGURE IV.32 : comparaison entre les deux modèles

- **Conclusion :**

Dans ce chapitre, nous avons élaboré une implémentation pour la prédiction du maladie d'Alzheimer en utilisant une approche de classification basée sur le réseau de neurone convolutionnel, nous avons proposé deux modèles, ou nous avons détaillé les caractéristiques de ces derniers ainsi que toutes les techniques utilisées, La comparaison des résultats trouvés a montré que le nombre d'epochs, la taille de la base et la profondeur de réseaux, sont des facteurs importants pour l'obtention de meilleurs résultats.

Nous avons été confrontés à certains défis. L'un d'eux est que nous n'avons pas pu exécuter plus d'époque car il y avait un manque de matériel, donc l'exécution a pris beaucoup de temps.

Conclusion générale :



Depuis une dizaine d'années, la neuro-imagerie a pris une place grandissante dans la recherche sur la maladie d'Alzheimer. Au-delà des aspects diagnostiques, les images IRM présentent également un intérêt particulier pour mesurer l'évolution de la maladie au cours du temps. Dans ce projet, nous avons essayé d'ajouter une autre utilité à cette imagerie, c'est la prédiction précoce de la maladie d'Alzheimer. Pour cela nous avons basé notre approche sur les techniques d'apprentissage profond.

Nous avons discuté des notions fondamentales de l'apprentissage profond, des algorithmes les plus populaires, des réseaux de neurones en général et des réseaux de neurones convolutionnels en particulier afin de classer des images IRM en quatre classes. Cette classification permettra de prédire le stade de la maladie d'Alzheimer. Nous avons introduit ces réseaux de neurones convolutionnels en présentant les différents types de couches utilisées dans la classification (couche convolutionnelle, couche de correction, couche de pooling et couche fully connected).

On a implémenté deux modèles de réseaux neurones convolutifs avec différentes architectures, et on a appliqué pour chacun de ces modèles des tests qui consistent à changer le nombre d'époques à chaque fois, calculer le temps d'exécution pour chacun des tests et afficher à la fin la matrice de confusion pour récupérer le résultat des images bien et mal classées.

En travaillant sur cette recherche, nous avons été confrontés à certains défis. L'un d'eux est la nécessité d'avoir une machine puissante, d'équiper d'une carte graphique. Ce type de machine est indispensable pour développer des algorithmes de deep-learning.

Ce projet nous a permis de se rapprocher des technologies du deep-Learning, et de s'initier aux traitements des images et en particulier l'imagerie médicale.

Finalement Pour améliorer le travail réalisé dans ce mémoire, il serait intéressant de penser à utiliser d'autres modèles et d'algorithmes de deep-learning.

Bibliographie :

[1].Selmés. J, la maladie d'Alzheimer : accompagnez votre proche au quotidien, édition John libbey Eurotext, paris 2011.pp.[14-15]

[2].Selmés. J, la maladie d'Alzheimer : accompagnez votre proche au quotidien, édition John libbey Eurotext, paris 2011.pp.[16-17]

[3].(<http://www.linternaute.com/science/biologie/dossiers/06/0602-erveau>) ;(10/06/2021)

[4]. BOISLEVE Jacques B, la maladie d'Alzheimer, www.sante-vivante.fr; (23/06/2021)

[5]. Lise Lückner, Frédérique Hovaguimian, Arnaud Naville, Fabienne Groebli, 2003. Immersion en communauté, Faculté de Médecine, Genève.

[6]. Bloch, H./ Didier Casalis. . Dictionnaire fondamental de la psychologie. Paris: Larousse. Harvard. (1997)

[7].<https://www.msmanuals.com/fr/professional/sujets-speciaux/prise-de-decision-clinique/comprehension-des-examens-medicaux-et-des-resultats-des-examens>(10/06/2021)

[8].C Delmaire, service de neurologie CHU de Lille, Article issu du quotidien de JFR 210 .Samedi 23 octobre mis à jour le 5 juillet 2011 par la SFR.

[9]. <http://chimie.sup.pagesperso-orange.fr/IRM.html>(20/10/2021)

[10].Une méthode de développement d'applications de traitement d'images.

Régis Clouard

[11].Digital Image Processing.

[12]<https://www.engineersgarage.com/articles/image-processing-tutorial-applications>(25/06/2021)

[13].Traitement de l'image De la numérisation à l'archivage et la communication ; Coordonné par Olivier Hélénon/Joël Chabrais/Bernard Gibaud/Denis Mariano-Goulart[14] <https://www.kaggle.com/tourist55/alzheimers-dataset-4-class-of-images> (21/07/2021)

[15] H. LAROCHELLE AND Q. SHERBROOKE, Historique de travail, Études, 3, p. 2Y5.

- [16] <https://www.ionos.fr/digitalguide/web-marketing/search-engine-marketing/deep-learningvs-machine-learning/> (02/07/2021)
- [17] D. LEARNING, Deep learning, High-Dimensional Fuzzy Clustering, (2020).
- [18] É. BRUNET AND L. VANNI, Deep learning et authentification des textes, *Texto! Textes et Cultures*, 24 (2019), pp. 1–34.
- [19] P. YAO, H. HUANG, W. TANG, Q. SHI, R. WU, AND C. ZHANG, Fuzzing smt solvers via two-dimensional input space exploration, in *Proceedings of the 30th ACM SIGSOFT International Symposium on Software Testing and Analysis*, 2021, pp. 322–335.
- [20] Y. LECUN, Y. BENGIO, AND G. HINTON, Deep learning, *nature*, 521 (2015), pp. 436–444.
- [21] C. TOUZET, les réseaux de neurones artificiels, introduction au connexionnisme, Ec2, 1992
- [22] <https://actualiteinformatique.fr/intelligence-artificielle/definition-deep-learning> (22/08/2021)
- [23] A. GRIDI AND T. GUERRAM, Un outil de deep learning pour les données textuelles, (2020). (02/07/2021)
- [24] s. boubaya, d. berbit, et al., deep learning pour la segmentation d’images, phd thesis, university of m’sila, 2021
- [26] B. DYHIA AND I. THANINA, Classification d’images agricoles avec le Deep Learning., PhD thesis, Université Mouloud Mammeri, 2019.
- [27] F. TORRE, Globo : un algorithme stochastique pour l’apprentissage supervisé et non-supervisé, in *Actes de la Première Conférence d’Apprentissage*, Citeseer, 1999, pp. 161–168.
- [28].Traitement de l’image De la numérisation à l’archivage et la communication ; Coordonné parOlivier Hélénon/Joël Chabriaais/Bernard Gibaud/Denis Mariano
- [29] A. BUHOT, Etude de propriétés d’apprentissage supervisé et non supervisé par des méthodes de physique statistique, PhD thesis, Université Joseph-Fourier-Grenoble I, 1999.
- [30] <https://penseeartificielle.fr/focus-reseau-neurones-convolutifs/> (21/07/2021)
- [31] <https://www.aliens-sci.com/convolutional-neural-network-cnn/> (21/07/2021)
- [32] <https://penseeartificielle.fr/focus-reseau-neurones-artificiels-perceptron-multicouche/> (23/07/2021)
- [33] https://www.researchgate.net/figure/AlexNet-CNN-architecture-layers_fig1 (23/07/2021)
- [34] J. WU, Introduction to convolutional neural networks, National Key Lab for Novel Software Technology. Nanjing University. China, 5 (2017), p. 495.

- [35] <https://penseeartificielle.fr/focus-reseau-neurones-artificiels-perceptron-multicouche/> (05/08/2021)
- [36] <https://www.lemagit.fr/definition/Matrice-de-confusion>(15/09/2021)
- [37] L. BALLEs, J. ROMERO, AND P. HENNIG, Coupling adaptive batch sizes with learning rates, arXiv preprint arXiv :1612.05086, (2016).
- [38] I. DJELLOUL AND K. LATRECHE, Optimisation et simulation du fonctionnement d'un système de production sous labview pour réaliser la technique de surveillance par approche neuroflou, in International Conférence on Systems and Processing Information, 2013.
- [39] A. TATO AND R. NKAMBOU, Improving adam optimizer, (2018).
- [40] S. S. LIEW, M. KHALIL-HANI, AND R. BAKHTERI, Bounded activation functions for enhanced training stability of deep neural networks on visual pattern recognition problems, Neurocomputing, 216 (2016), pp. 718–734.
- [41] V. ZOCCA, G. SPACAGNA, D. SLATER, AND P. ROELANTS, Python deep learning, Packt Publishing Ltd, 2017.
- [42]<https://developers.google.com/machine-learning/crash-course/classification/accuracy?hl=fr>(21/09/2021)
- [43] <https://framalibre.org/content/visual-studio-code> (21/07/2021)