

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'Électronique



Mémoire de Projet de Fin d'Études

présenté par

BELMEHDI Yousra

&

MESSILI Kenza

pour l'obtention du diplôme Master en Automatique

option : Automatique et informatique industrielle

Thème

Détection de Pathologies pour l'aide Au Diagnostic en Ophtalmologie

Proposé par : Pr N.BENBLIDIA & Dr F. Zohra REGUIEG

Année Universitaire 2019-2020

Remerciements

On remercie tout d'abord Dieu pour l'accomplissement de ce mémoire.

La réalisation de ce mémoire a été possible grâce à la contribution de plusieurs Personnes à qui on voudrait témoigner toute notre reconnaissance.

On remercie tout d'abord Pr N.BENBLIDIA la directrice de ce mémoire, pour nous avoir guidé, encouragé et conseillé tout au long de ce projet de fin d'étude.

Nos remerciements s'adressent aussi à Dr F. Zohra REGUIEG la Copromotrice de ce mémoire

On désire aussi remercier les professeurs de l'université de Blida 1, qui nous ont fourni les outils nécessaires à notre réussite dans nos études universitaires.

Mes remerciements sincères vont à Dr N.CHEGAGA. Je suis reconnaissante pour le temps qu'elle m'a consacré et son soutien moral pour moi tout au long de ce travail.

Nos vifs remerciements vont également aux membres de jury monsieur le président DJENDI.M et monsieur KABIR.Y pour l'intérêt qu'ils ont porté à notre recherche en acceptant examiner notre travail.

On remercie nos très chers parents qui ont toujours été là pour nous «Vous avez tout sacrifié pour vos enfants n'épargnant ni santé ni efforts. Vous avez donné un magnifique modèle de labeur et de persévérance .Nous vous sommes redevable d'une éducation dont on est fier»

On remercie nos frères et sœurs qui ont toujours été là pour leur encouragement et leur soutien inconditionnel.

Nous voudrions exprimer nos reconnaissances envers les amis et collègues qui m'ont apporté leur soutien moral et intellectuel tout au long de ma démarche.

On désire aussi remercier tout le corps professionnel et administratif de Département Électronique et la filière Automatique de l'université Saad Dehlab Blida1. Qui nous ont fourni les outils nécessaires à la réussite de nos études universitaires.

Dédicaces

Je dédie ce modeste travail

A mes chers parents, pour tous leurs sacrifices, leur amour,

leur tendresse,

Leur soutien et leurs prières tout au long de mes études.

A Hadjer, Mouad.

A toute ma famille pour leur soutien tout au long de mon

parcours universitaire.

A tous mes collègues de promotion 2015 et spécialement ceux

de la

Spécialité Automatique et Informatique Industrielle.

A tous les amis qui me connaissent de près ou de loin.

A tous ceux que j'aime je dédie ce travail.

À mon binôme Kenza pour

Tous les agréables moments passés ensemble.

BELMEHDI Yousra

Dédicaces

*Je dédie ce mémoire aux êtres qui me sont les plus chers :
A ma chère maman, de par son amour, son soutien, tous les
sacrifices consentis et ses*

*Précieux conseils, pour toute son assistance et sa présence
dans ma vie.*

*A mon cher grand frère Abdoulah, qui peut être fier et
trouver ici le résultat de longues*

*Années de sacrifices et de privations pour m'aider à
avancer dans la vie,*

Merci pour le soutien venu de toi.

A mes très chers frères Soufiane, Omar, Imad et Islam.

A ma chère sœur Amel et à sa petite famille.

*A mon amie et binôme Yousra, pour sa compréhension, et sa
tolérance lors de la*

Réalisation de notre projet.

Messili Kenza

ملخص:

اعتلال الشبكية السكري (DR) هو السبب الرئيسي للعمى في جميع أنحاء العالم. يعد اكتشاف هذا المرض مبكرًا من خلال الفحص المنتظم مهمًا بشكل خاص في منع فقدان البصر.

تقنيات التعلم الآلي هي حلول لتطوير الأدوات لمساعدة الأطباء في تشخيص الأمراض والتنبؤ بمخاطرها والوقاية منها. تتطلب الاختلافات والتعقيد في بيانات تصوير الشبكية التعلم من الأمثلة، وهذا أحد الاهتمامات الرئيسية في مجال التعلم العميق لوصف وتمثيل الآفات في البيانات.

استلزم العدد القليل من الحالات المتاحة وخاصة البيانات غير المتوازنة معالجة أولية على مجموعة البيانات المستخدمة. ركز هذا العمل لاحقًا على تصميم نموذجين للشبكات العصبية العميقة: CNN وVGG16. أظهرت التجارب التي أجريت على أساس صور "Diabetic Retinopathy 224x224 Gaussian Filtered" الخاصة بشركة Kaggle قوة نموذج VGG16. اكتشف تطبيق الويب "EYE CARE" الذي تم تطويره كجزء من هذا المشروع، وتصنيف المراحل الخمس لاعتلال الشبكية السكري

الكلمات المفتاحية: اعتلال الشبكية السكري، صورة الشبكية، التعلم العميق، الشبكة العصبية التلافيفية، المساعدة التفسيرية.

Résumé :

La rétinopathie diabétique (RD) est la principale cause de cécité dans le monde. La détection précoce de cette maladie par un dépistage régulier est particulièrement importante pour prévenir la perte de la vision.

Les techniques d'apprentissage automatique constituent des solutions pour développer des outils permettant d'aider les médecins à diagnostiquer, à prédire le risque d'atteinte de maladies et à les prévenir.

Les variations et la complexité des données d'imagerie rétinienne, nécessitent un apprentissage à partir d'exemples, et cela constitue un des intérêts clés du domaine de l'apprentissage profond pour décrire et représenter les lésions dans les données.

Le nombre réduit de cas disponible et surtout les données déséquilibrées ont nécessité tout d'abord d'effectuer un prétraitement sur l'ensemble de données utilisé. Ce travail s'est concentré par la suite sur la conception de deux modèles de réseaux neuronaux profonds : les CNN et le VGG16. Les expérimentations menées sur la base d'images "Diabetic Retinopathy 224x224 Gaussian Filtered" de Kaggle ont montré la robustesse du modèle VGG16. L'application Web "EYE CARE" développée dans le cadre de ce projet a permis de détecter et classer les cinq stades de la rétinopathie diabétique

Mots clés : Rétinopathie Diabétique, Image Rétinienne, Apprentissage profond, Réseau Neuronal Convolutif, Aide à l'Interprétation.

Abstract:

Diabetic retinopathy (DR) is the leading cause of blindness worldwide. Detecting this disease early through regular screening is particularly important in preventing vision loss.

Machine learning techniques are solutions for developing tools to help physicians diagnose, predict the risk of and prevent disease.

The variations and complexity of retinal imaging data require learning from examples, and this is a key interest in the field of deep learning to describe and represent lesions in data.

The small number of available cases and especially the unbalanced data necessitated first pre-processing on the data set used. This work subsequently focused on the design of two models of deep neural networks: CNNs and VGG16. Experiments using Kaggle's ‘ ‘ Diabetic Retinopathy 224x224 Gaussian Filtered ‘ ‘ images have shown the robustness of the VGG16 model. The "EYE CARE" web application developed as part of this project detected and classified the five stages of diabetic retinopathy

Keywords: Diabetic Retinopathy, Retinal Image, Deep Learning, Convolutional Neural Network, Interpretation Aid. Blood vessels. A deep learning approach based on the convolutional neural network (CNN) can be used to automate the method of classifying stages of the disease. In this work, from color images of the fundus of the retina, RD is classified in to five stages using a CNN. The DR images are classified in to five groups according to the opinion of an ophthalmology expert. CNNs and VGG16 are deployed for classification by stage of RD.

Keywords: diabetic retinopathy; image classification; Deep Learning; convolutional neural network; Vgg16.

Table des matières

INTRODUCTION GENERALE	1
CONTEXTE MEDICAL.....	4
1.1 INTRODUCTION	4
1.2 DESCRIPTION GENERALE DE L'ŒIL	4
1.2.1 Anatomie du globe oculaire	4
1.3 LES PATHOLOGIES RETINIENNES	10
1.3.1 La Rétinopathie Diabétique (RD).....	10
1.3.2 Signes cliniques de la RD.....	11
1.4 GLAUCOME	14
1.5 CATARACTE	14
1.6 CLASSIFICATION DES STADES DE LA RD	14
1.7 DEGENERESCENCE MACULAIRE LIEE A L'AGE (DMLA)	15
1.7.1 Signes cliniques de la DMLA	15
1.7.2 Maculopathie liée à l'âge (MLA)	16
1.7.3 Forme atrophique.....	16
1.7.4 Forme exsudative	16
1.8 TECHNIQUES D'ACQUISITION DES IMAGES RETINIENNES	16
1.8.1 Rétinographie mydriatique (RM) et non mydriatique (RNM)	17
1.8.2 Angiographie a la fluorescence.....	17
1.8.3 Tomographie a Cohérence Optique (OCT).....	17
1.9 DEPISTAGE DE LA RD ET DMLA	18
1.10 CONCLUSION	18
REVUE DE CONNAISSANCES EN APPRENTISSAGE PROFOND.....	20
2.1 INTRODUCTION	20
2.2 RESEAUX DE NEURONES	21
2.2.1 Définition	21
2.2.2 Historique	22
2.2.3 Topologie.....	22
2.3 L'APPRENTISSAGE EN PROFONDEUR (DEEP LEARNING)	24
2.3.1 Définition	25
2.3.2 Historique	25
2.3.3 Pourquoi le choix du Deep Learning ?	26
2.4 LES DIFFERENTES ARCHITECTURES DU DEEP LEARNING	27
2.4.1 Les réseaux de neurones convolutifs	27
2.4.2 Réseau de neurones récurrents	28
2.4.3 Modèle génératif.....	28
2.5 RESEAUX DE NEURONES CONVOLUTIFS ET APPRENTISSAGE EN PROFONDEUR	28
2.5.1 Les différentes couches de CNN.....	29
2.6 OPTIMISATION POUR L'APPRENTISSAGE EN DEEP LEARNING	33
2.6.1 Méthodes d'optimisation	34
2.7 CONCLUSION	35
CONCEPTION D'UN SYSTEME DE CLASSIFICATION DES STADES DE LA RETINOPATHIE DIABETIQUE.....	38
3.1 INTRODUCTION	38
3.2 TRAVAUX CONNEXES	39
3.3 NOTRE SYSTEME.....	39
3.4 CONNAISSANCES PREALABLES	40
3.4.1 Apprentissage sans transfert à l'aide d'un CNN.....	41

Table des matières

3.4.2	Apprentissage par transfert à l'aide du VGG16.....	42
3.5	METHODOLOGIE PROPOSEE.....	44
3.5.1	Architecture de l'approche adoptée.....	44
3.5.2	Description des étapes de l'organigramme.....	47
3.5.3	Augmentation des données.....	49
3.5.4	Prétraitement.....	51
3.5.5	Classification.....	51
3.6	CONCLUSION.....	54
REALISATION ET EXPERIMENTATION.....		56
4.1	INTRODUCTION.....	56
4.2	CONFIGURATION MATERIELLE.....	56
4.2.1	Configuration matérielle distante (Google Colab).....	56
4.2.2	Configuration matérielle locale.....	57
4.3	ENVIRONNEMENT DE DEVELOPPEMENT LOGICIEL.....	57
4.3.1	Python.....	57
4.3.2	Anaconda.....	57
4.3.3	TensorFlow.....	58
4.3.4	Keras.....	58
4.3.5	Flask.....	59
4.4	MESURES DE PERFORMANCE.....	59
4.4.1	Matrice de confusion.....	59
4.4.2	Taux de bonne classification (Accuracy).....	60
4.4.3	La précision.....	60
4.4.4	Le rappel (Recall).....	60
4.4.5	F-Mesure (F1 score).....	60
4.4.6	Sensibilité et spécificité.....	61
4.5	DESCRIPTION DE LA BASE DE DONNEES.....	61
4.5.1	Dataset utilisé.....	62
4.5.2	Ensemble d'apprentissage (Training set).....	63
4.5.3	Ensemble de validation (Validation set).....	63
4.5.4	Ensemble de test (Testing set).....	64
4.6	EXPERIMENTATION PARAMETRIQUE.....	64
4.6.1	Comparaison des réseaux VGG 16 et CNN.....	64
4.7	PRECISIONS.....	67
4.7.1	Matrice de confusion.....	67
4.7.2	Rapport de classification.....	69
4.8	DISCUSSION.....	70
4.9	PRESENTATION DU DEROULEMENT DE L'APPLICATION.....	70
4.9.1	Création de notre d'application Web.....	70
4.9.2	Structure de notre projet de l'application Web.....	70
4.10	DEPLOIEMENT DE L'APPLICATION SUR LOCALHOST ET GOOGLE COLAB.....	71
4.11	CONCLUSION.....	73
CONCLUSION GENERALE.....		74
BIBLIOGRAPHIE.....		76

Liste des figures

Figure. I. 1 : le fond d'œil	5
Figure. I. 2 : Structure de la cornée	6
Figure. I. 3 : la rétine	8
Figure. I. 4 : Image rétinienne	9
Figure. I. 5 : Présence des micro-anévrismes et des hémorragies dans les images couleur	11
de la rétine (a) micro-anévrismes montrés par une flèche (b) hémorragies	11
Figure. I. 6 : Présence des AMIR et une occlusion veineuse rétinienne ;(a) : les AMIR ;(b) occlusion veineuse rétinienne	12
Figure. I. 7 : Présence d'une ischémie rétinienne et des exsudats durs ;(a) Ischémie.....	13
Rétinienne ;(b) Exsudats durs	13
Figure. I. 8 : Présence des nodules cotonneux et d'œdème maculaire	13
Figure. I. 9 : Néo-vascularisation	14
Figure. I. 10 : présence du glaucome et cataracte ;(a) : le glaucome ; (b) cataracte	14
Figure. I. 91 : Formes cliniques de la dégénérescence maculaire liée à l'âge	16
Figure. I. 102 : Rétinographie et angiographie à la fluorescence	17
Figure. I. 13 : images de l'OCT	18
Figure. II.1. : Neurone biologique. Inspirée de Chevalier (2017)	21
Figure. II.2. : Neurone artificiel	21
Figure. II.3. : Un Perceptron multicouche	23
Figure. II.4. : Un réseau de neurones bouclé	24
Figure. II.5. : La relation entre l'intelligence artificielle, le ML et le Deep Learning	24
Figure. II.6. : Schéma illustratif de DL avec plusieurs couches	25
Figure. II.7. : Comparaison entre le machine Learning et le Deep Learning.	27
Figure. II.8. : Une architecture exemplaire du réseau neuronal convolutif	29
Figure. II.9. : Différents types de convolutions ;(a) : une convolution de kernel ;(b) :.....	30
une dilated convolution ;(c) : une transposed convolution	30
Figure. II.10. : La fonction d'activation (ReLU)	31
Figure. II.11. : Exemple de description de la couche pooling	31
Figure. II.12. : Calcul du pooling sur une image 4x4	32
Figure. II.13. : Mise à plat d'une image	32
Figure III.1. : Architecture de CNN	41
Figure III.2. : Architecture en couches de VGG16	43
Figure III.3. Schéma global du modèle proposé de classification de la RD	45
Figure III.4. : Organigramme global proposé.....	46
Figure III.5. : Méthodologie proposée (Transfer Learning par VGG16).....	49
Figure III.6 : Image originale	50
Figure III.7 : Images après retournement horizontal et vertical	50
Figure III.8 : Images après rotation.....	50
Figure III.9. : Échantillon d'une image du dataset.....	51
Figure III.10 : Configuration de notre modèle VGG16.....	52
Figure III.11 : Configuration du modèle CNN élaboré	54
Figure. IV.1. : Matrice de confusion.	60
Figure. IV.2. : Les cinq stades de RD	62
Figure. IV.3. : Visualisation du tableau csv	63

Liste des figures

Figure. IV.4. : Représentation graphique du Dataset.....	63
Figure. IV.5. : Représentation graphique de l'ensemble d'apprentissage.	63
Figure. IV.6. : Représentation graphique de validation set.....	64
Figure. IV.7. . : Représentation graphique du Testing set.	64
Figure. IV.8. : Résultat de l'entraînement du modèle CNN.....	64
Figure. IV.9. : Résultat de l'entraînement du modèle VGG16.....	65
Figure. IV.10. : Représentation de la précision et la perte des modèle VGG16 et CNN	66
Figure. IV.11. : Matrice de Confusion pour le modèle CNN	67
Figure. IV.12. : Matrice de confusion pour le modèle VGG16.....	68
Figure. IV.13. : Représentation graphique du taux de classification des images.....	68
Figure. IV.14. : Illustration de la structure de l'application Web.	70
Figure. IV.15. : illustration du déploiement réussi du serveur principal.	71
Figure. IV.16. : Page d'accueil de l'application	72
Figure. IV.17. : Chargement des images du fond d'œil	72
Figure. IV.18. : Résultats de classification des stades de la RD par notre application	73

Liste des tableaux

Liste des tableaux

Tab. I. 1 : Lésions de la RD	11
Tab. I. 2 : Classification des stades de la RD	15
Tab. IV.1. : Résultats d'entraînement des deux modèles.....	65
Tab. IV.2. : Comparaison des résultats de VGG16 et de CNN	65
Tab. IV.3. : Comparaison du taux de classification des deux modèles.....	69
Tab. IV.4. : Comparaison de la précision et du rappel des deux modèles	69

Liste des acronymes et abréviations

Liste des acronymes et abréviations

AMIR	Anomalies Micro vasculaires Intra rétiniennes
ANN	Artificial Neural Network
CNN	Convolutional Neural Network
DL	Deep Learning
DMLA	Dégénérescence maculaire liée à l'âge
IA	Intelligence artificielle
ML	Machine Learning
MLA	Maculopathie liée à l'âge MLA
OBVR	Occlusion d'une branche veineuse rétinienne
RD	Rétinopathie diabétique
RM	Rétinographe mydriatique
RNN	Recurrent neural network
RNM	Rétinographe Non Mydriatique

Introduction générale

Le diabète est caractérisé par une augmentation chronique du glucose dans le sang. Il est devenu l'une des menaces de la santé les plus croissantes à travers le monde. Cette maladie a de nombreux effets néfastes sur le système nerveux, le cœur, les reins et d'autres organes ; mais le plus susceptible d'être touché est l'œil. En effet, le diabète provoque de nombreuses complications sur les yeux et affecter ainsi la vision. Parmi celles-ci, citons : une augmentation de la fréquence de la cataracte, le glaucome, une augmentation des infections oculaires et une atteinte grave de la rétine et de la macula : il s'agit de la rétinopathie diabétique (RD).

Par ailleurs, au cours des dernières décennies, l'imagerie médicale est devenue indispensable dans le diagnostic et la thérapie des maladies oculaires. Avec l'avènement des systèmes rétinien numérisés, il est possible d'analyser de manière automatique les images du fond d'œil, en particulier les images rétinien en couleur, car leur acquisition est simple, peu coûteuse et non invasive.

Les bases d'images médicales deviennent de plus en plus volumineuses, nécessitant de nouvelles méthodes de traitement. Les variations et la complexité des données d'imagerie médicale, nécessitent un apprentissage à partir d'exemples, et cela constitue un des intérêts clés du domaine de l'apprentissage machine pour décrire et représenter des objets tels que des lésions et des anatomies dans des données.

Les techniques d'apprentissage automatique constituent des solutions pour développer des outils permettant d'aider les médecins à diagnostiquer, à prédire le risque d'atteinte de maladies et à les prévenir.

Ce travail de recherche se focalise sur l'analyse et le traitement des images du fond d'œil, dans le but de proposer un système d'aide au diagnostic de la rétinopathie diabétique. Ce système, basé sur l'apprentissage profond, permettra de réduire le temps du diagnostic et d'aider l'ophtalmologue dans sa prise de décision.

Introduction générale

La tâche de la classification de la RD est difficile, en raison de la complexité des images. Elle nécessite un réseau profond avec une bonne représentation, pour extraire les caractéristiques. Dans ce cadre, les modèles du deep Learning ont la capacité d'effectuer cette tâche avec une haute performance. Par conséquent, ce mémoire propose deux architectures : un modèle de réseau neuronal convolutif profond (CNN), et le modèle VGG16 pour classer les images rétiniennes selon ses différents stades.

Organisation du mémoire

Pour mener à bien notre travail, nous avons organisé notre travail, comme suit :

- Le chapitre 1 est consacré au contexte médical.
- Le chapitre 2 est dédié à l'apprentissage profond et à l'architecture des réseaux de neurones convolutifs.
- Le chapitre 3 porte sur la conception du système de la classification d'images et, les approches proposées.
- Le chapitre 4 est dédié à l'illustration des différents résultats obtenus, à l'évaluation des performances, ainsi qu'au déploiement sur le web du système réalisé,

Ce mémoire sera finalisé par une conclusion générale reprenant les principaux points abordés et, en exposant certaines perspectives pour l'amélioration du travail présenté.

Chapitre I

Contexte Médical

Contexte Médical

1.1 Introduction

Ce chapitre présente les aspects médicaux, pour comprendre l'importance de l'analyse des images du fond d'œil. Tout d'abord, l'anatomie de l'œil et ses principaux composants sont décrits ; ensuite, les différentes anomalies de l'œil sont présentées. Deux lésions liées à des maladies rétiniennes ont tiré notre attention ; il s'agit de la rétinopathie diabétique (RD) et la dégénérescence maculaire liée à l'âge (DMLA). Une description des symptômes de ces lésions, l'évolution ainsi que les traitements éventuels sont donnés. Nous terminons ce chapitre par une présentation de différentes techniques d'acquisitions des images rétiniennes ainsi que le dépistage de la RD et la DMLA.

1.2 Description Générale de l'Œil

L'œil est un organe sensoriel du corps humain qui reçoit 80% des informations extérieures. Sa fonction est de transformer l'information lumineuse en influx nerveux transmis au cerveau. Il est de faible volume (6.5 cm³) et il pèse 7 grammes. Il présente une forme d'une sphère d'environ 24 mm de diamètre, complétée vers l'avant par une autre sphère de 8 mm de rayon (la cornée). L'anatomie de l'œil se divise en deux : Le globe oculaire et les annexes (les muscles extra-oculaires, les nerfs, la paupière). L'œil est constitué de trois membranes : la rétine, la choroïde et la sclérotique, et de trois milieux transparents : l'humeur aqueuse, le cristallin et l'humeur vitrée [1]. La Figure. I.1 illustre les composants de l'œil.

1.2.1 Anatomie du globe oculaire

Le globe oculaire présente une structure grossièrement sphérique (cf. Figure. I.1). Il est composé de quatre parties principales :

- **La couche protectrice** : cornée et sclère.
- **La couche vasculaire (nommée uvée)** : iris, corps ciliaire et choroïde.
- **La couche visuelle** : rétine et nerf optique.

Le contenu de la cavité interne : humeur aqueuse, cristallin et corps vitré.

A l'avant de l'œil, on délimite deux zones principales :

- 1) **La chambre antérieure** : qui se situe entre la cornée et l'iris ; elle est remplie par l'humeur aqueuse.
- 2) **La chambre postérieure** : elle se situe entre l'iris et le cristallin.




Figure. I. 1 : le fond d'œil [19]

1.2.1.1 La couche protectrice (couche externe)

Cette couche comprend deux parties dont la cornée et la sclère. Elles sont résistantes, épaisses et faites de fibres collagènes. La cornée est transparente et sert de fenêtre pour l'œil tandis que la sclère est opaque [20].

a) *La cornée*

La cornée est une membrane solide et transparente de 11 mm de diamètre au travers de laquelle la lumière entre à l'intérieur de l'œil. La cornée est privée de vaisseaux sanguins (sinon notre vision serait troublée) ; elle est donc nourrie par un liquide fluide comme l'eau : l'humeur aqueuse. La cornée contient 78% d'eau ; pour maintenir ce degré d'hydrophile elle est constamment recouverte de larmes alimentées en continu par les glandes lacrymales et répartis par le battement des paupières. La cornée est la principale lentille de l'œil, elle assure environ 80% de la réfraction. Elle est composée de 5 couches différentes (cf. Figure. I.2)

- **Épithélium cornéen** : est la couche la plus externe et représente environ 10 % de l'épaisseur totale de la cornée. Elle est constituée de cinq à six couches de cellule régénérable.
- **Membrane de Bowman** : est la couche de transition de 12 micromètres, qui sépare l'épithélium du stroma cornéen.
- **Stroma** : est un tissu conjonctif très spécifique. Très épais (environ 400 microns), il représente 90% de l'épaisseur de la cornée. Il contient de l'eau, des substances organiques et du collagène.
- **Membrane de Descemet** : est une membrane basale transparente de l'endothélium cornéen. Elle se situe entre le stroma postérieur et la monocouche endothéliale.
- **Endothélium** : est une membrane interne, fragile et fine de 6 micromètres. La qualité et la quantité de ces cellules varient avec l'âge et des altérations y surviennent à partir de 65ans.




Figure. I. 2 : Structure de la cornée [20]

b) La sclère

La sclérotique ou sclère est une membrane rigide qui donne sa forme à l'œil. Cette membrane est fibreuse, résistante. Elle entoure et protège l'œil à l'extérieur tout en maintenant sa forme. La sclérotique forme le blanc de l'œil. Elle est traversée par un grand nombre de petits canaux (artères, nerfs, veines) et, à l'arrière, par une ouverture où passent les fibres du nerf optique.

1.2.1.2 La couche vascularisée (couche moyenne)

Elle est aussi appelée « l'uvée ». Elle comprend trois parties : l'iris, le corps ciliaire et la choroïde [1] C'est la partie la plus vascularisée du globe oculaire.

a) L'iris

Cette membrane, située dans l'humeur aqueuse entre la cornée et le cristallin, sépare ainsi la chambre antérieure de la chambre postérieure de l'œil. Il est constitué par des

épithéliums pigmentés donnant sa couleur à l'œil et percé d'un trou correspondant à la pupille. Il est innervé par des fibres du système nerveux autonome qui activent les muscles dilatateurs et sphincters responsables de la dilatation et de la constriction pupillaires (cf. Figure. I.1).

b) *Le corps ciliaire*

Il correspond à la partie intermédiaire de l'uvée, sous forme d'un anneau saillant à l'intérieur de l'œil. Il joue un rôle fondamental dans l'accommodation et la sécrétion de l'humeur aqueuse (cf. Figure. I.1).

c) *La Choroïde*

La choroïde est la membrane intermédiaire de l'œil située entre la rétine et la membrane externe. Elle a pour rôle d'apporter le sang à l'œil. Située entre la sclérotique et la rétine et en continuité avec le corps ciliaire et l'iris, la choroïde est une couche très vascularisée contenant de nombreux pigments colorés.

- Elle forme la chambre noire.
- Elle absorbe les rayons lumineux inutiles pour la vision.
- Elle est richement vascularisée et assure la nutrition de l'iris et de la rétine.

1.2.1.3 La couche visuelle (couche interne)

C'est la couche la plus interne des couches qui constituent le globe oculaire. Elle comprend la rétine et le nerf optique [2].

a) *La rétine*

La rétine est la couche sensible à la lumière grâce aux photorécepteurs (les cônes et les bâtonnets).

Elle a comme épaisseur 0,25 mm [2]. La rétine possède 2 types de photorécepteurs :

- ***Les bâtonnets*** : De forme allongée, ils doivent leur nom à leur forme. Ils sont environ 130 millions. Ils sont absents de la fovéa et se logent à la périphérie. Ils ont une très grande sensibilité à la lumière, d'où leur capacité à percevoir de très faibles lueurs la nuit : vision de nuit. Ainsi ils ont une très faible perception des détails et des couleurs car plusieurs dizaines de bâtonnets ne sont liés qu'à une seule fibre du nerf optique. Ils contiennent une substance chimique appelée rhodopsine ou pourpre rétinien. Quand la lumière frappe une molécule de rhodopsine, celle-ci génère un faible courant électrique. Les signaux ainsi recueillis forment un message qui est transmis aux cellules nerveuses de la rétine (cf. Figure. I.3).
- ***Les cônes*** : Ils sont environ 5 à 7 millions à se loger dans la fovéa. Leur sensibilité à la lumière est très faible mais leur perception des détails est très grande pour deux raisons : il y a une densité très élevée de cônes dans la fovéa et surtout chaque cône de la fovéa

transmet son information à plusieurs fibres du nerf optique ; la vision est donc de jour. Ainsi, ils ont une très bonne sensibilité aux couleurs. Ils sont de trois types selon le pigment qu'ils contiennent et ont donc une sensibilité à des ondes lumineuses de longueurs différentes : cône contenant de l'érythrosine (sensibles au rouge), de la chloropsine (vert), et de la cyanopsine (bleu) (cf. Figure. I.3).




Figure. I. 3 : la rétine [21]

- **La macula** : Dans la zone elliptique centrale se trouve le maximum de cônes. Cette zone permet donc une vision très précise. Elle mesure 3 mm dans le grand axe et 2 mm dans le petit axe. Cette région se nomme la macula. Elle apparaît comme une tâche jaune, située au centre du pôle postérieur comme une fine excavation [3].
- **La fovéa** : est la région de la rétine située dans la macula, près de l'axe optique de l'œil, dans la partie centrale de cette dernière.
 Cette région est de la plus haute importance pour la vision. Elle mesure 300 à 400 microns de diamètre et contient 25 000 cônes.
- **Le nerf Optique** : La transmission des informations vers le cerveau est opérée par le nerf optique. Toutes les fibres optiques issues des cellules visuelles convergent vers un point précis de la rétine : la papille.
- **La papille** : est le point de l'œil qui ne voit pas. On l'appelle aussi la tache aveugle. En ce point débouche aussi le réseau veineux et artériel de la rétine. Les fibres optiques se rejoignent toutes là pour former un câble appelé le nerf optique. Il mesure 4 mm de diamètre et 5 cm de long (cf. Figure. I.4.).

- **Arbre Vasculaire** : il correspond à la structure vasculaire arborescente connectée. Elle est chargée de nourrir les parties internes de la rétine. Cette structure vasculaire provient dans le disque optique avec l'artère centrale de la rétine et de la veine (cf. Figure. I.4).




Figure. I. 4 : Image rétinienne [22]

1.2.1.4 Le contenu de la cavité interne

Il est constitué par l'humeur aqueuse, le cristallin, et le corps vitré. Ce sont des milieux transparents.

a) L'humeur aqueuse

L'humeur aqueuse est un liquide transparent qui remplit l'espace entre la cornée et le cristallin. Constamment renouvelé, il est responsable du maintien de la pression intraoculaire (cf. Figure I.1)

b) Le cristallin

Le cristallin est une lentille biconvexe de l'œil, transparente, a vasculaire. Il est situé à l'intérieur du globe oculaire. Sa partie antérieure est en contact avec l'humeur aqueuse et sa partie postérieure avec le corps vitré (cf. Figure. I.1).

c) Le corps vitré

Le corps vitré est une masse gélatineuse claire et transparente. Il maintient la rétine contre les parois de l'œil, contenant 99% d'eau et représentant 60% du volume oculaire (cf. Figure. I.1).

1.3 Les pathologies rétiniennes

Les anomalies associées à l'œil peuvent être divisées en deux classes principales. La première englobe les maladies de l'œil, telles que la cataracte et le glaucome. Le deuxième groupe est classé comme une maladie liée à un style de vie, telles que l'hypertension, l'artériosclérose et le diabète [4]. Ces pathologies peuvent entraîner une réduction de l'acuité visuelle, une déficience visuelle et la cécité. La discussion dans cette section se concentre sur les maladies oculaires les plus fréquentes, telles que la rétinopathie diabétique, la dégénérescence maculaire liée à l'âge, la cataracte et le glaucome. La section explique comment les symptômes des maladies oculaires émergent et affectent la vision, les traitements envisagés ainsi que le diagnostic de ces anomalies.

1.3.1 La Rétinopathie Diabétique (RD)

La rétinopathie diabétique (RD) est l'expression clinique d'une micro-angiopathie rétinienne. Avec le rein et le système nerveux central, l'œil est l'un des sites majeurs de la micro-angiopathie diabétique [4].

Le diabète peut résulter de facteurs génétiques et environnementaux et se caractérise par un excès permanent de sucre dans le sang. Face à une incroyable augmentation du nombre de malades, les experts parlent aujourd'hui d'épidémie. Le diabète attaque les vaisseaux sanguins et notamment ceux de la rétine, qui est très vascularisée.

La rétinopathie diabétique (RD) est une des principales causes de cécité et de malvoyance. Les études épidémiologiques réalisées dans les pays industrialisés la citent comme une des 4 principales causes de malvoyance dans l'ensemble de la population et la première cause de cécité chez les sujets de moins de 50 ans [5-6].

Cette affection ne se remarque pas pendant de nombreuses années, elle ne devient symptomatique qu'au stade de complications. Le retard du traitement est la cause essentielle de la perte de vision et est évitable avec un dépistage et un traitement approprié [7]. Seul un examen effectué régulièrement peut permettre de la diagnostiquer précocement et de la traiter. La cécité et la malvoyance liées à la rétinopathie diabétique sont en effet en grande partie évitables grâce au traitement par laser, dont l'efficacité a été depuis longtemps démontrée [8-1].

Dans ce qui suit, nous décrivons certains signes de la RD qui peuvent être détectés avec l'analyse des images du fond d'œil, le traitement, ainsi que la classification de la maladie.

1.3.2 Signes cliniques de la RD

Les différents types de lésions qui peuvent apparaître au cours du développement de la RD sont au nombre de 9, certains d'entre eux se déclinant en sous-catégories. Ils sont listés dans le tableau. I.1 [1].

1	Micro-anévrismes
2	Hémorragies rétiniennes
4	AMIRs (Anomalies Microvasculaires Intra Rétiniennes)
5	Anomalies veineuses
6	Ischémie rétinienne
7	Exsudats
8	Nodules cotonneux
9	Néo-vaisseaux

Tab. I. 1 : Lésions de la RD [1]

1.3.2.1 Les Micro-anévrismes

Les micro-anévrismes sont les premiers signes non équivoques de la RD. Ils sont produits par un affaiblissement local des parois capillaires. Ils apparaissent sous forme de points rouges. Leur taille varie de 10 à 100 microns de diamètre. La figure. I.5 (a) montre un exemple de telles lésions [10].

1.3.2.2 Les hémorragies

La progression de la maladie peut produire une rupture d'une paroi d'un capillaire ou d'un micro-anévrisme ce qui provoque des hémorragies rétiniennes. Elles apparaissent soit comme des petits points rouges indiscernables à partir de micro-anévrismes, ou grandes taches de forme ronde avec contour irrégulier. La figure. I. 5(b) montre certains d'entre eux.




Figure. I. 5: Présence des micro-anévrismes et des hémorragies dans les images couleur de la rétine (a) micro-anévrismes montrés par une flèche (b) hémorragies [23].

1.3.2.3 Les Anomalies Micro-vasculaires Intra Rétiniennes (AMIR)

Les AMIR sont des anomalies vasculaires comme des dilatations, des ectasies ou des bourgeonnements. Elles témoignent d'une occlusion vasculaire et par conséquent d'une ischémie locale. Elles représentent une réponse néovasculaire à cette occlusion.

Leur forme est plutôt irrégulière, mais parfois, elles peuvent être facilement confondues avec des micro-anévrysmes (cf. figure. I.6 (a)).




Figure. I. 6 : Présence des AMIR et une occlusion veineuse rétinienne ;(a) : les AMIR ;(b) occlusion veineuse rétinienne [4].


1.3.2.4 Occlusions veineuses rétinienne

Les occlusions veineuses sont la conséquence d'un ralentissement brutal de la circulation veineuse dans la rétine. L'occlusion veineuse peut durer plusieurs mois, et même dans certains cas devenir chronique, selon le siège de l'obstruction (cf. Figure. I.6.b). On distingue deux formes cliniques [1] :

- **Dans le nerf optique** : occlusion de la veine centrale de la rétine (OVCR), ou occlusion hémisphérique en cas de veine centrale dupliquée ;
- **Dans la rétine** : Au niveau d'un croisement artério-veineux : occlusion d'une branche veineuse rétinienne (OBVR).
- **Ischémie rétinienne** : On désigne par ischémie la baisse du débit sanguin local qui devient insuffisant pour assurer les besoins métaboliques d'un tissu dans la rétinopathie diabétique. Elle est secondaire à l'occlusion plus au moins étendue des capillaires rétinien (cf. Figure. I.7.a).

1.3.2.5 Les Exsudats durs

Il s'agit de l'une des principales caractéristiques de la rétinopathie diabétique. En plus de la fuite de sang, des vaisseaux également fuient les lipides et les protéines qui causent l'apparition des exsudats. Ils apparaissent comme des points lumineux, jaunâtres avec contours bien définis. La figure. I.7(b) montre un exemple de telles lésions.



(a)

(b)


Figure. I. 7 : Présence d'une ischémie rétinienne et des exsudats durs ;(a) Ischémie Rétinienne ;(b) Exsudats durs [25].

1.3.2.6 Nodules Cotonneux

Les nodules cotonneux sont plus souvent observés dans la rétinopathie avancée. Ils se présentent comme des lésions de petite taille, blanches, superficielles, d'aspect duveteux et à contours flous. La figure. I. 8 (a) illustre certains d'entre eux.

1.3.2.7 Œdème maculaire

Il correspond à une accumulation de liquide dans la zone maculaire de la rétine. Il se traduit par un épaissement rétinien. L'œdème maculaire est directement accompagné par une dégradation visuelle lente mais progressive [1]. La Figure. I. 8(b) montre un exemple de telles lésions.



(a)

(b)

Figure. I. 8 : Présence des nodules cotonneux et d'œdème maculaire
(a) nodules cotonneux rétinienne ; (b) œdème maculaire [26]

1.3.2.8 La néo-vascularisation

La néo-vascularisation correspond à de nouveaux vaisseaux qui se développent à cause d'une ischémie. Ils apparaissent sous forme d'un lacis vasculaire à la surface de la rétine ou de la papille [27]. Ces néo vaisseaux ont un grand risque de se rompre et provoquent des hémorragies. La figure I. 9 illustre certains d'entre eux.

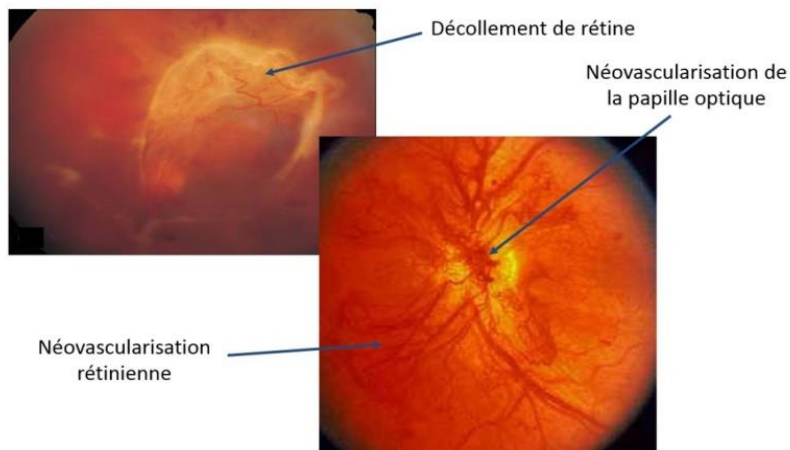


Figure. I. 9 : Néo-vascularisation [27]

1.4 Glaucome

Le glaucome est une maladie de l'œil qui provoque une diminution irrémédiable du champ de vision. Il est la conséquence de dommages du nerf optique. Le glaucome est associé à la suite de l'élévation de la pression à l'intérieur de l'œil (pression intraoculaire). Le glaucome est la deuxième cause de cécité dans le monde [12]. La Figure. I.10.a illustre la présence du glaucome.




Figure. I. 10 : présence du glaucome et cataracte ;(a) : le glaucome ; (b) cataracte [28]

1.5 Cataracte

La cataracte est l'opacification partielle ou totale du cristallin, lentille convergente située à l'intérieur de l'œil [4]. Cette opacification est responsable d'une baisse progressive de la vue, au début accompagné de gêne à la lumière (photophobie). Cette baisse de la vision peut être rapide (quelques semaines) à cause d'un traumatisme (cf. Figure. I.10.b).

1.6 Classification des stades de la RD

Les stades de la RD sont déterminés en fonction du type, du nombre et de la localisation des lésions présentes (la rétine est divisée en quatre quadrants). L'évolution de la pathologie peut être classifiée en un certain nombre de stades. L'échelle que nous utilisons est l'International

Clinical Diabetic Retinopathy Disease Severity Scale (ICDRS) [11] qui comporte cinq stades, auxquels nous rajoutons un stade 0 correspondant à une absence de pathologie. Les stades de la RD sont décrits dans le tableau. I 2.

Stade	Description
0: Pas de RD apparente	-----
1: Rétinopathie non proliférante minime	Présence de micro-anévrismes uniquement
2: Rétinopathie non proliférante modérée	Présence de lésions autres que des micro-anévrismes mais ne correspond pas au stade 3
3: Rétinopathie non proliférante sévère	Une des 3 conditions suivantes est satisfaite : <ul style="list-style-type: none"> ▪ Plus de 20 hémorragies intra rétinienne dans chacun des 4 quadrants ▪ Anomalies veineuses certaines dans au moins 2quadrants ▪ AMIR proéminent dans au moins un quadrant mais ne correspond pas au stade 4
4: Rétinopathie proliférante	Une des 2 conditions suivantes est satisfaite <ul style="list-style-type: none"> ▪ Présence des néovaisseaux ▪ Hémorragies vitrées/ prérétinienne
5: Rétinopathie traitée non active	La rétine a été traitée au laser et la Rétinopathie n'est plus active

Tab. I. 2 : Classification des stades de la RD [1]

1.7 Dégénérescence maculaire liée à l'âge (DMLA)

Une autre maladie de la rétine qui a un effet similaire à la rétinopathie diabétique, mais d'autres causes est la dégénérescence maculaire liée à l'âge (DMLA). Elle apparait après l'âge de cinquante ans et entraîne une altération de la fonction rétinienne maculaire donc de la vision centrale. La prévalence globale de la maladie est de 8% après 50 ans. Cette prévalence globale augmente progressivement avec l'âge : ainsi, elle est d'environ 1 à 2% entre 50 et 65 ans, 10% entre 65 et 75 ans, et 25% entre 75 et 85 ans [10].

1.7.1 Signes cliniques de la DMLA

Cliniquement, on distingue deux formes de la dégénérescence maculaire liée à l'âge [13] : une forme atrophique (80% des cas), et une forme exsudative (20% des cas).

1.7.2 Maculopathie liée à l'âge (MLA)

La MLA représente le stade précoce de la maladie. Elle n'est pas ou peu symptomatique sur le plan visuel. Elle est caractérisée par la présence, dans la macula (zone centrale de la rétine) d'altérations au niveau de l'épithélium pigmentaire ou de dépôts au niveau de la rétine appelés drusen. Au fond d'œil, les drusens apparaissent comme des amas ronds blanchâtres, de forme et de taille variables (cf. Figure. I.11.a). La présence d'une MLA à un ou deux yeux entraîne un risque de développer une DMLA à 5 ans pouvant aller jusqu'à 50 %. Selon l'importance de la MLA, des traitements préventifs par antioxydants peuvent être prescrits [10].

1.7.3 Forme atrophique

La forme atrophique (forme sèche), résulte de l'atrophie progressive des couches de l'épithélium pigmentaire et des photorécepteurs. Le retentissement visuel est important mais ce processus est lentement évolutif (cf. Figure. I.11.b).

1.7.4 Forme exsudative

La forme exsudative (forme humide) est deux fois plus fréquente que la forme atrophique, elle se caractérise par l'apparition de néo-vaisseaux choroïdiens dans la macula, qui sont responsables d'œdème et d'exsudation intra ou sous rétiniennes, ou d'hémorragies rétiniennes. Son évolution est le plus souvent rapide ou rapidement progressive (cf. Figure. I.11.c).




Figure. I. 91 : Formes cliniques de la dégénérescence maculaire liée à l'âge
(a) Maculopathie liée à l'âge (forme précoce de DMLA) : drusens et altérations de l'épithélium pigmentaire ; (b) DMLA de forme atrophique ; (c) DMLA de forme exsudative : forme avancée avec fibrose au niveau de la macula. [29]

1.8 Techniques d'Acquisition des Images Rétiniennes

Dans cette section du chapitre, nous présentons les différents appareils permettant l'acquisition des différents types d'images couleur du fond d'œil.

1.8.1 Rétinographie mydriatique (RM) et non mydriatique (RNM)

Le rétinographe est utilisé pour surveiller d'éventuelles modifications du fond d'œil ; il permet la réalisation de photographies couleurs du fond d'œil. L'examen est totalement indolore. Il peut être réalisé sans dilatation pupillaire (d'où le nom de RNM, Rétinographe Non Mydriatique). Mais si une analyse fine des 9 champs du fond d'œil est souhaitée, une dilatation pupillaire est souhaitable pour l'obtention de clichés de bonne qualité [8]. L'archivage des photos permettra un examen comparatif de l'état du fond d'œil d'une visite à l'autre afin de juger d'une éventuelle évolution (cf. Figure. I.12.a).

1.8.2 Angiographie a la fluorescence

Cet examen consiste en la prise de photographies du fond d'œil après injection intraveineuse d'un colorant fluorescent (fluorescéine, vert d'indocyanine). Il permet une étude détaillée des vaisseaux sanguins pour établir le diagnostic de certaines maladies ou guider un traitement ; par exemple lorsqu'une photo-coagulation au laser est envisagée [30]. Les indications essentielles sont la rétinopathie diabétique et les dégénérescences maculaires (cf. Figure.12. b).



Figure. I. 102 : Rétinographie et angiographie à la fluorescence
(a) Rétinographie ; (b) Angiographie à la fluorescence [25]

1.8.3 Tomographie a Cohérence Optique (OCT)

La tomographie à Cohérence Optique (OCT), est un appareil ultramoderne qui permet de visualiser au niveau microscopique la rétine [14] et d'individualiser ses différentes couches (cf. Figure 13). Il utilise un laser infrarouge qui balaie la rétine. L'appareil analyse les rayons renvoyés et reconstruit toute l'épaisseur de la rétine grâce à des procédés informatiques. Cet appareil est indispensable au suivi des maladies de la rétine. L'appareil donne des images de l'aspect microscopique des différentes couches de la rétine. Ces images permettent ainsi de mieux connaître l'état de la rétine, la présence de lésions et aigüillent dans le choix de la technique la plus adaptée au traitement de l'anomalie.




Figure. I. 13 : images de l'OCT [31]

1.9 Dépistage de la RD et DMLA

La prévention de la RD et la DMLA se concentre sur un contrôle continu et un traitement précoce. Ces actions préventives peuvent retarder ou arrêter la progression de ces maladies, prévenir la cécité et améliorer la qualité de la vie. Comme il n'y a pas de symptômes saillants dans les premiers stades de la RD et la DMLA ; le nombre de symptômes et la gravité augmentent essentiellement avec le temps. Un dépistage rentable sur de grandes populations est alors nécessaire [15-16]. Le dépistage est une action préventive secondaire qui vise à trouver et traiter des conditions qui ont déjà eu lieu, mais qui n'ont pas atteint un stade qui nécessitent des soins médicaux. Des études ont révélé que les personnes âgées et les personnes qui souffrent davantage de diabète doivent effectuer régulièrement une séance de dépistage [17-18]. Par ailleurs, la progression de ces maladies est révisée au moins une fois en 1-3 an, ce qui en résulte une quantité croissante d'informations pour l'examen. C'est pourquoi le développement d'un système d'analyse d'images est nécessaire pour le dépistage de la RD et la DMLA.

1.10 Conclusion

Dans ce chapitre, l'anatomie du fond d'œil, les maladies oculaires liées au diabète et la dégénérescence maculaire liée à l'âge ainsi que leurs symptômes ont été décrits. Les techniques d'acquisition des images couleur et angiographique ont été discutés par la suite. Finalement, le dépistage de la RD et DMLA a été présenté en montrant la nécessité du suivi, la détection précoce de la RD et la DMLA pour éviter la cécité et la malvoyance. Les appareils d'acquisition jouent un rôle très important pour le dépistage de masse qui permet d'étudier l'évolution des maladies sur un groupe de population.

Dans le chapitre suivant, nous allons nous consacrer à l'étude des techniques de l'apprentissage automatique. Nous allons, en particulier nous intéresser à l'apprentissage profond, ses différentes architectures dont les réseaux de neurones convolutionnels (CNN) qui ont fait l'objet de ce travail.

Chapitre II

Revue de Connaissances en Apprentissage Profond

Revue de Connaissances en Apprentissage Profond

2.1 Introduction

De nos jours, le suivi et la détection automatique des maladies rétinienne a attiré une grande attention dans le champ de la vision par ordinateur. De plus, les bases d'images médicales deviennent de plus en plus volumineuses, nécessitant de nouvelles méthodes de traitement. La variation et la complexité des données d'imagerie médicale, nécessitent un apprentissage à partir d'exemples, et cela constitue un des intérêts clés du domaine de l'apprentissage machine pour décrire et représenter des objets tels que des lésions et des anatomies dans des données.

Les techniques d'apprentissage automatique permettent de proposer des solutions pour développer des outils permettant d'aider les médecins à diagnostiquer, à prédire le risque d'atteinte de maladies et à les prévenir.

L'apprentissage profond (ou Deep Learning) est un axe actif de recherche dans le domaine de l'apprentissage automatique qui englobe un large éventail d'architectures de réseaux élaborés pour exécuter plusieurs tâches. Il s'intéresse aux algorithmes inspirés par la structure et la fonction du cerveau, à savoir les réseaux de neurones artificiels. Les modèles d'apprentissage en profondeur sont formés en utilisant une grande masse de données étiquetées et des architectures de réseau neuronal qui contiennent de nombreuses couches.

Nous commençons donc ce chapitre, en premier lieu, par une présentation de quelques notions concernant les réseaux de neurones en passant en revue leurs différentes topologies. Puis, nous procédons à la description du Deep Learning et ses différentes architectures existantes. Nous expliquons, en particulier ce qu'est un réseau de neurones basé convolution, qui s'est avéré très efficace dans des domaines tels que l'imagerie médicale. Nous terminerons le chapitre par la présentation de quelques méthodes d'optimisation telles que la méthode du gradient conjugué.

2.2 Réseaux de neurones

2.2.1 Définition

Un neurone biologique (cf. Figure. II.1) est constitué d'un corps cellulaire doté d'un noyau et de prolongements appelés dendrites, d'une fibre nerveuse appelée axone et d'une zone synaptique constituée de synapses [73].




Figure. II.1. : Neurone biologique. Inspirée de Chevalier (2017) [73].

Un neurone génère un signal électrique et le transmet à un autre neurone via les synapses. Si le signal est assez stimulant, les dendrites du noyau récepteur vont s'activer à le recevoir et le retransmettre de la même manière à un autre neurone en lui faisant parcourir son axone [32]. Un réseau de neurones artificiels (cf. Figure. I.2) est un système dont la conception est à l'origine inspirée du fonctionnement des neurones biologiques, et qui par la suite s'est rapproché des méthodes statistiques [19]. Les réseaux de neurones artificiels sont des réseaux fortement connectés par des processeurs élémentaires fonctionnant en parallèle.

Chaque processeur élémentaire (neurone artificiel) calcule une sortie unique sur la base des informations qu'il reçoit.




Figure. II.2. : Neurone artificiel [74].

2.2.2 Historique

Les réseaux neuronaux ont vu le jour en 1943 par W.MCCulloch et W. Pitts [97]. Le neurone formel est une abstraction du neurone physiologique. Par cette présentation, ces chercheurs ont démontré que le cerveau est équivalent à une machine de Turing ; la pensée devient alors purement des mécanismes matériels et logiques. Ils déclarèrent en 1955 "Plus nous apprenons de choses au sujet des organismes, plus nous sommes amenés à conclure qu'ils ne sont pas simplement analogues aux machines, mais qu'en est-il de cette machine ?". La démonstration de McCulloch et Pitts a été l'un des acteurs importants de la création de la cybernétique.

En 1949, D. Hebb présenta dans son ouvrage "The Organization of Behavior" une règle d'apprentissage. De nombreux modèles de réseaux aujourd'hui s'inspirent encore de la règle de Hebb [97].

En 1958, F. Rosenblatt développe le modèle du Perceptron [98]. C'est un réseau de neurones inspiré du système visuel. Il possède deux couches de neurones : une couche de perception et une couche liée à la prise de décision. C'est le premier système artificiel capable d'apprendre par expérience. Dans la même période, le modèle de L'Adaline (ADaptiveLINearElement) a été présenté par B. Widrow, chercheur américain à Stanford. Ce modèle sera par la suite le modèle de base des réseaux multicouches.

En 1969, M. Minsky et S. Papert publient une critique des propriétés du Perceptron [99]. Cela va avoir une grande incidence sur la recherche dans ce domaine. Elle va fortement diminuer jusqu'en 1972, où T. Kohonen présente ses travaux sur les mémoires associatives et propose des applications à la reconnaissance de formes.

C'est en 1982 que J. Hopfield présente son étude d'un réseau complètement rebouclé, dont il analyse la dynamique [20].

Aujourd'hui, les réseaux neuronaux sont utilisés dans de nombreux domaines (Médecine, Transport, voiture autonome, Sécurité routier, production automatique...) à cause de leur propriété en particulier, leur capacité d'apprentissage, et qu'ils soient des systèmes dynamiques [20].

2.2.3 Topologie

Chaque réseau de neurones est connecté entre eux de diverses manières. Nous pouvons distinguer deux familles de réseaux de neurones : non bouclés ou statiques et bouclés (dynamiques).

2.2.3.1 Les réseaux de neurones non bouclés

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonctions algébriques de ses entrées, par composition des fonctions réalisées par chacun de ses neurones [33].

Un réseau de neurones non bouclé est représenté graphiquement par un ensemble de neurones "connectés" entre eux ; l'information circulant des entrées vers les sorties sans "retour en arrière". Si l'on représente le réseau comme un graphe dont les nœuds sont les neurones et les arêtes les "connexions" entre ceux-ci, le graphe d'un réseau non bouclé est acyclique. Le terme de "connexions" est une métaphore : dans la très grande majorité des applications, les réseaux de neurones sont des formules algébriques dont les valeurs numériques sont calculées par des programmes d'ordinateurs, non des objets physiques (circuits électroniques spécialisés) ; néanmoins, le terme de connexion, issu des origines biologiques des réseaux de neurones, est passé dans l'usage, car il est commode quoique trompeur. Il a même donné naissance au terme de connexionnisme.

La Figure. II.3 représente un réseau de neurones non bouclé qui a une structure particulière, très fréquemment utilisée : il comprend des entrées, une couche de neurones "cachés" et des neurones de sortie. Les neurones de la couche cachée ne sont pas connectés entre eux. Cette structure est appelée Perceptron multicouche.




Figure. II.3. : Un Perceptron multicouche [75].

Les réseaux de neurones non bouclés sont des objets statiques : si les entrées sont indépendantes du temps, les sorties le sont également. Ils sont utilisés principalement pour effectuer des tâches d'approximation de fonction non linéaire, de classification ou de modélisation de processus statiques non linéaires.

2.2.3.2 Les réseaux de neurones bouclés

Contrairement aux réseaux de neurones non bouclés dont le graphe de connexions est acyclique (cf. Figure. II.4). Les réseaux de neurones bouclés peuvent avoir une topologie de connexions quelconque, comprenant notamment des boucles qui ramènent aux entrées la valeur d'une ou

plusieurs sorties [34]. Pour qu'un tel système soit causal, il faut évidemment qu'à toute boucle soit associé un retard : un réseau de neurones bouclé est donc un système dynamique, régi par des équations différentielles. Comme l'immense majorité des applications sont réalisées par des programmes d'ordinateurs, on se place dans le cadre des systèmes à temps discret, où les équations différentielles sont remplacées par des équations aux différences.

Un réseau de neurones bouclé à temps discret est donc régi par une (ou plusieurs) équations aux différences non linéaires, résultant de la composition des fonctions réalisées par chacun des neurones et des retards associés à chacune des connexions.

Les réseaux de neurones bouclés sont utilisés pour effectuer des tâches de modélisation de systèmes dynamiques, de commande de processus, ou de filtrage.




Figure. II.4. : Un réseau de neurones bouclé [76-77].

2.3 L'apprentissage en profondeur (Deep Learning)

Le Deep Learning est un nouveau domaine de recherche de l'apprentissage machine ou machine Learning (ML), qui a été introduit dans le but de rapprocher le ML de son objectif principal à savoir : l'intelligence artificielle [100]. En effet, il concerne les algorithmes inspirés par la structure et le fonctionnement du cerveau. Ils peuvent apprendre plusieurs niveaux de représentation dans le but de modéliser des relations complexes entre les données. La figure ci-dessous illustre la relation entre l'apprentissage profond, le ML et l'IA.




Figure. II.5. : La relation entre l'intelligence artificielle, le ML et le Deep Learning [78].

2.3.1 Définition

L'apprentissage en profondeur est un ensemble d'algorithmes d'apprentissage automatique qui tentent d'apprendre à plusieurs niveaux, correspondant à différents niveaux d'abstraction. Il a la capacité i) d'extraire des caractéristiques à partir des données brutes grâce aux multiples couches de traitement composé de multiples transformations linéaires et non linéaires et ii) d'apprendre sur ces caractéristiques à travers chaque couche avec une intervention humaine minimale [35-41].




Figure. II.6. : Schéma illustratif de DL avec plusieurs couches [79].

2.3.2 Historique

L'idée du Deep Learning n'est pas une idée récente, mais elle date en réalité des années 1980, plus particulièrement suite aux travaux sur les réseaux de neurones multicouches et aux travaux de certains pionniers du machine Learning et du Deep Learning comme le français Yann Le Cun [101]. En collaboration avec deux autres informaticiens, Kunihiko Fukushima et Geoffrey Hinton, ont mis au point un type d'algorithme particulier appelé Convolutional Neural Network (CNN) [102].

Bien que cette approche donne des résultats, ses progrès et son évolution sont limités par les progrès technologiques en matière de micro-processeurs, de puissance de calculs, et du manque d'accessibilités à des données afin de pouvoir entraîner les neurones. Cependant certains chercheurs ont continué à travailler sur ce modèle pendant environ deux décennies et, avec l'aide des évolutions en matière de technologies, mais surtout avec la disponibilité toujours plus grande de données, ont pu améliorer cette technique.

Afin de développer un système d'apprentissage performant, il faut pouvoir l'exercer et cela requiert un nombre important de données à tester.

C'est dans ce contexte qu'en 2007, le STANFORD VISION LAB, avec Fei-Fei Li à sa tête, développèrent un agrégateur d'images où sont consignées et étiquetées quelques millions de photos : Image Net. En 2010, Image Net a regroupé 15000000 d'images toutes catégorisées en fonction de leurs caractéristiques propres (véhicules, animaux, ...) [21].

En 2012, le Deep Learning est remis au goût du jour avec un succès retentissant à l'Image Net Large Scale Visual Recognition Challenge (ILSVRC) qui est un concours annuel de reconnaissance d'image fondé par l'université de Stanford, dans le cadre de son laboratoire STANFORD VISION LAB [99].

Plusieurs équipes de chercheurs en informatique s'affrontent dans ce concours tous les ans afin de décerner la victoire au programme ayant eu le plus faible taux d'échec.

Alors que les algorithmes d'apprentissage profond étaient absents de la compétition, c'est bel et bien un algorithme de Deep Learning qui va remporter l'édition 2012 à la surprise générale [22].

2.3.3 Pourquoi le choix du Deep Learning ?

Tout d'abord les différents algorithmes du Deep (DL) ne sont apparus qu'à l'échec de l'apprentissage automatique tentant de résoudre une grande variété de problèmes de l'intelligence artificielle [102]. Les principales raisons du DL consistent à :

- améliorer le développement des algorithmes traditionnels dans les tâches de l'IA ;
- traiter une grande quantité de données telle que les big data ;
- s'adapter à n'importe quel type de problème ;
- extraire les caractéristiques de façon automatique [42].

La Figure. II.7. illustre la comparaison entre le Machine Learning et le Deep Learning.

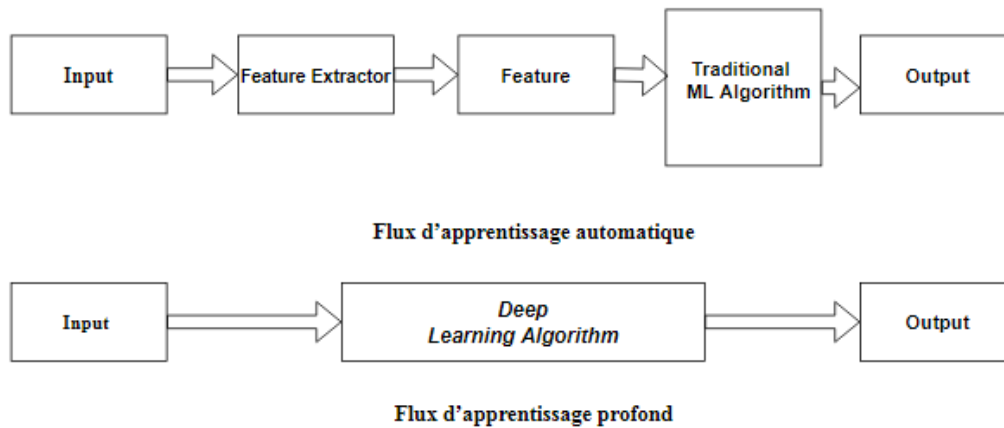


Figure. II.7. : Comparaison entre le machine Learning et le Deep Learning.

2.4 Les différentes Architectures du Deep Learning

Bien qu'il existe un grand nombre de variantes d'architectures profondes, il n'est pas toujours possible de comparer les performances de toutes les architectures, car elles ne sont pas toutes évaluées sur les mêmes ensembles de données. Le Deep Learning est un domaine à croissance rapide, et de nouvelles architectures, variantes ou algorithmes apparaissent.

2.4.1 Les réseaux de neurones convolutifs

Les réseaux de neurones convolutifs ou Convolutional Neural Network (CNN) sont un type de réseau de neurones spécialisés pour le traitement de données ayant une topologie semblable à une grille. Ils se sont avérés très efficaces dans des domaines tels que la reconnaissance et la classification d'images et vidéos. Les CNN ont réussi à identifier les visages, les objets, panneaux de circulation, auto-conduite des voitures et autres [43]. Les CNN ont aussi été efficaces dans plusieurs tâches de traitement du langage naturel (telles que la classification des phrases) [44-46].

Dans le ML, un réseau convolutif est un type de réseau de neurones feed-forward, il a été inspiré par des processus biologiques [47]. Il existe quatre (4) principales opérations illustrées dans le CNN à savoir :

- La couche de convolution.
- La couche Rectified Linear Unit.
- La couche Pooling.
- La couche entièrement connectée.

2.4.2 Réseau de neurones récurrents

L'idée derrière les RNN est d'utiliser des informations séquentielles. Dans un réseau neuronal traditionnel, nous supposons que toutes les entrées (et les sorties) sont indépendantes les unes des autres. Mais pour de nombreuses tâches, c'est une très mauvaise idée. Par exemple, si on veut prédire le prochain mot dans une phrase, il faut connaître les mots qui sont venus avant. Les RNN sont appelés récurrents, car ils exécutent la même tâche pour chaque élément d'une séquence ; la sortie étant dépendante des calculs précédents. Une autre façon de penser les RNN est qu'ils ont une «mémoire» qui capture l'information sur ce qui a été calculé jusqu'ici. En théorie, les RNN peuvent utiliser des informations dans des séquences arbitrairement longues ; mais dans la pratique, on les limite à regarder seulement quelques étapes en arrière. [48-51]. Ils sont utilisés pour :

- la modélisation du langage et génération de texte ;
- la traduction automatique ;
- la reconnaissance vocale ;
- et la description des images.

2.4.3 Modèle génératif

Les modèles discriminatifs, comme les CNN ou RNN sont utilisés pour prédire les données du label et de l'entrée. Le modèle génératif, quant à lui décrit comment générer les données ; il apprend et fait des prédictions en utilisant la loi de Bayes [52]. Les modèles génératifs sont capables de réaliser beaucoup plus qu'une simple classification ; un exemple serait de générer de nouvelles observations.

Voici quelques exemples de modèles génératifs :

- Boltzmann Machines [53].
- Restricted Boltzmann Machines [54, 55].
- DeepBelief Networks [56].
- Deep Boltzmann Machines [57, 58].
- Generative Adversarial Networks Generative Stochastic Networks [59].
- Adversarial auto encoders [60].

2.5 Réseaux de neurones convolutifs et apprentissage en profondeur

Les réseaux de neurones à convolution (Convolutional Neural Networks, CNN) sont une catégorie de réseaux de neurones qui se sont avérés très efficaces dans des domaines tels que

la détection automatique des pathologies, la reconnaissance et la classification d'images.

2.5.1 Les différentes couches de CNN

Il existe quatre principales opérations dans le CNN (cf. Figure. II.8), tout en ayant un rôle bien défini [30].

2.5.1.1 Etape de convolution

- i) **La convolution** : est le cœur du réseau de neurones convolutif. À l'origine, une convolution est un outil mathématique (on parle de produit de convolution) très utilisé en traitement d'image, car il permet d'en faire ressortir l'extraction des caractéristiques à partir des images d'entrées, afin d'appliquer un bon filtre. En fait, une convolution prend simplement en entrée une image et un filtre (qui est une autre image), effectue un calcul, puis renvoie une nouvelle image [61].




Figure. II.8. : Une architecture exemplaire du réseau neuronal convolutif [80].

Les différentes convolutions

Il existe plusieurs types de convolutions, même si en général on utilise celle de base, il peut s'avérer utile de connaître les outils à notre disposition [9].

- **La convolution classique**, qui représente le décalage du noyau entre chaque calcul, et le padding qui est la manière dont on peut « dépasser » l'image pour appliquer la convolution.
- **La dilated convolution**, identique à la convolution à ceci près que le kernel est éclaté (on prend, par exemple, un pixel sur deux pour calculer la convolution). Il y a un paramètre supplémentaire : la dilation rate, qui est le nombre de pixels à ignorer.

- **La transposed convolution**, qui construit la sortie comme si on inversait une convolution sur l'image.
- **La séparable convolution**, qui est une convolution décomposable en convolutions plus simples : une convolution de kernel, une dilated convolution et une transpose de convolution




Figure. II.9. : Différents types de convolutions ;(a) : une convolution de kernel ;(b) : une dilated convolution ;(c) : une transposed convolution [81].

ii) Fonctions d'activation

Une fonction d'activation est une fonction mathématique appliquée à un signal en sortie d'un neurone artificiel. Il dérive de l'équivalent biologique qui signifie "potentiel d'activation, lorsque le seuil de stimulation aura été atteint entraînant ainsi une réponse du neurone. Son but principal est de pouvoir permettre aux réseaux de neurones d'apprendre des fonctions plus complexes qu'une simple régression linéaire.

iii) Rectified Linear Unit (ReLU)

Elle est utilisée après chaque opération de convolution ; toutes les valeurs de pixels négatifs sont mises à zéro. Le but de ReLU est d'introduire la non-linéarité dans le CNN, puisque l'ensemble de caractéristiques appliquées à l'une des cartes d'entrée donne une carte de sortie qui est également appelée carte de caractéristiques rectifiées [62]. La figure II.10 illustre la fonction d'activation ReLU.

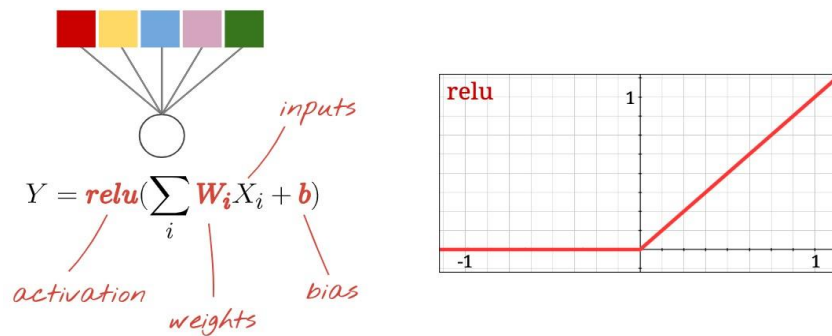


Figure. II.10. : La fonction d'activation (ReLU) [82].

2.5.1.2 Etape de pooling

Elle permet de réduire la dimension de chaque carte de caractéristiques, mais conserve l'information la plus importante. Cette étape peut être réalisée selon différents types : max, moyenne, somme, etc.

En cas de Pooling max, on définit un voisinage spatial (par exemple, une fenêtre 2×2) et on prendra le plus grand élément dans cette fenêtre.

La fonction de Pooling consiste à réduire progressivement la taille de la carte de caractéristiques rectifiée. En particulier, le pooling :

- rend les représentations d'entrée plus petites et plus faciles à gérer ;
- réduit le nombre de paramètres et les calculs dans le réseau [63] ;
- rend le réseau invariant aux petites transformations, les distorsions et les translations dans l'image d'entrée (cf. Figure. II.11) [64, 65].




Figure. II.11. : Exemple de description de la couche pooling [83].

Il existe plusieurs types de pooling dont [9] :

- Le « max pooling », qui revient à prendre la valeur maximale de la sélection. C’est le type le plus utilisé, car il est rapide à calculer (immédiat), et permet de simplifier efficacement l’image.
- Le « mean-pooling » (ou average-pooling), 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.
- Le « sum-pooling », c’est la moyenne sans avoir à diviser par le nombre de valeurs (on ne calcule que leur somme).

Un exemple illustratif de ces trois types est représenté dans la Figure. II.12.

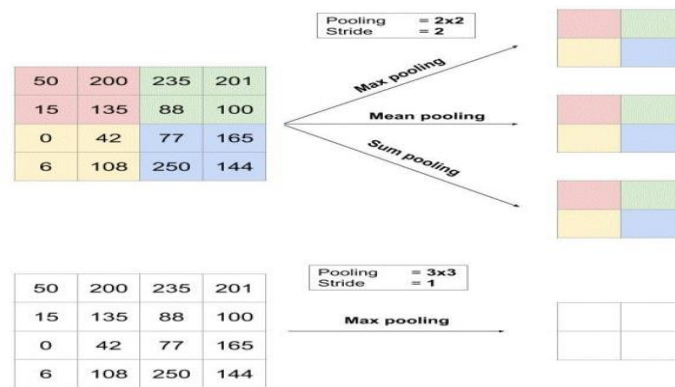


Figure. II.12. : Calcul du pooling sur une image 4x4 [84].

2.5.1.3 Etape de mise à plat

Il consiste simplement à mettre à bout toutes les images (matrices) que nous avons pour en faire un (long) vecteur. Les pixels (en réalité ce ne sont plus des images ou des pixels, mais des matrices de nombres, donc les pixels sont ces nombres) sont récupérés ligne par ligne et ajoutés au vecteur final (cf. Figure. II.13).




Figure. II.13. : Mise à plat d’une image [85].

2.5.1.4 Couche totalement connectée

La couche entièrement connectée est un traditionnel perceptron multicouche (Multi Layer Perceptron) utilisant une fonction d'activation notamment appelée « softmax » dans la couche de sortie (d'autres classificateurs comme SVM peuvent également être utilisés).

Le terme « entièrement connecté » implique que chaque neurone dans la couche précédente est connecté à chaque neurone sur la couche suivante.

La sortie des couches de convolution et de Pooling représente les fonctions de haut niveau de l'image d'entrée. Le but de la couche entièrement connectée est de pouvoir utiliser ces fonctions pour classer l'image d'entrée dans différentes classes en fonction de l'ensemble des données d'apprentissage [45].

2.6 Optimisation pour l'apprentissage en Deep Learning

L'apprentissage peut être défini comme une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré [67].

L'une des premières méthodes d'apprentissage a été formulée par Donald Hebb en 1949 pour l'apprentissage des corrélations [68-69].

On peut distinguer trois types d'apprentissage :

- **Apprentissage supervisé** : un professeur fournit au réseau des couples de données (entrée, sortie désirée correspondante). Les paramètres du réseau sont ajustés de manière à minimiser une certaine norme de l'erreur de sortie constituée par la différence entre la sortie réelle du réseau et la valeur désirée correspondante (fournie par le professeur). [69]
- **Apprentissage par renforcement** : est une approche utilisée dans les problèmes de planification à travers le temps. Elle utilise deux réseaux : un réseau d'action et un réseau d'évaluation qui joue le rôle d'un superviseur et qui génère un signal d'avertissement à chaque fois que les actions prises sont mauvaises. Ce signal sert à entraîner le réseau d'action. Les poids du réseau d'évaluation sont altérés dans le sens de renforcer les bonnes actions et de sanctionner les mauvaises [69].
- **Apprentissage non supervisé** : en absence de tout professeur, le réseau organise lui-même les formes d'entrée en classes de façon à minimiser un critère de

performances. Ceci peut être fait, par exemple, en désignant un certain nombre de neurones gagnants dans une compétition d'activation ou en désignant un certain nombre de bassins d'attraction dans l'espace d'état [70].

2.6.1 Méthodes d'optimisation

L'optimisation est l'une des branches les plus importantes des mathématiques appliquées modernes ; de nombreuses recherches, à la fois pratiques et théoriques, lui sont consacrées.

Si on met de côté les problèmes d'optimisation discrète ou multicritère, alors la théorie de l'optimisation peut être séparée en deux grandes branches : l'optimisation locale et l'optimisation globale [71].

La tâche principale de l'optimisation globale est la recherche de la solution qui minimisera un critère de coût donné, appelée « optimum global ». L'optimisation globale vise donc à rechercher non seulement un minimum local, mais surtout le plus petit de ces minima locaux. Il existe deux grandes approches pour atteindre l'optimum global. L'une est dite déterministe ; les algorithmes de recherche utilisent toujours le même cheminement pour arriver à la solution et on peut donc déterminer à l'avance les étapes de la recherche. L'autre est aléatoire ; pour des conditions initiales données, l'algorithme ne suivra pas le même cheminement pour aller vers la solution trouvée et peut même proposer différentes solutions.

2.6.1.1 Algorithme de la rétro-propagation

Plusieurs variantes de cet algorithme ont été développées par des chercheurs travaillant dans des domaines différents. La première formulation de la version actuelle a été faite par Werbos en 1974. Il a été appliqué pour les réseaux multicouches par Rumlethart en 1986 [67].

L'algorithme de la rétro-propagation altère les coefficients synaptiques (w_i) du réseau dans le sens inverse du gradient du critère d'erreur, en utilisant seulement les données d'entrée/sortie.

A chaque itération, on retire un exemple d'apprentissage (x_i, y_i) et on calcule une nouvelle estimation du poids synaptique w_i .

Cette itération consiste en deux phases :

- **Propagation** : à chaque itération, un élément de l'ensemble d'apprentissage est introduit à travers la couche d'entrée. L'évaluation des sorties du réseau se fait couche par couche, de l'entrée vers la sortie [67].

- **Rétro-propagation** : cette étape est similaire à la précédente. Cependant, les calculs s'effectuent dans le sens inverse (de la sortie vers l'entrée). A la sortie du réseau, on forme le critère de performance E en fonction de la sortie réelle de système et sa valeur désirée. Puis, on évalue le gradient de E par rapport aux différents poids en commençant par la couche de sortie et en remontant vers la couche d'entrée.

2.6.1.2 Méthode de recherche aléatoire (méthode de Monte-Carlo) [71]

C'est la plus simple des méthodes stochastiques. Cette méthode consiste à tirer à chaque itération une solution au hasard.

La fonction objectif f est évaluée en ce point. La nouvelle valeur est comparée à la précédente. Si elle est meilleure que la précédente, cette valeur est enregistrée, ainsi que la solution correspondante et le processus continu. Sinon, on repart du point précédent et on recommence le procédé, jusqu'à ce que les conditions d'arrêt soient atteintes.

2.6.1.3 Méthode de gradient conjugué

La méthode du gradient conjugué est plus souvent utilisée comme méthode itérative pour résoudre de manière approchée les grands systèmes non linéaires. Sa force vient du fait que le nombre d'itérations nécessaires pour obtenir une bonne approximation de x est petit devant la taille N du système [72]. Elle repose sur la recherche de directions successives permettant d'atteindre la solution exacte du système étudié.

2.7 Conclusion

Dans cette partie, nous avons exposé tout d'abord, l'un des puissants outils de l'IA, à savoir les réseaux de neurones. Nous avons aussi présenté des notions sur le Deep Learning ainsi que les trois familles majeures de ce modèle : les réseaux convolutifs, les réseaux récurrents ainsi que les modèles génératifs. Ces derniers font encore l'objet de recherches intensives.

Ensuite, nous avons essayé d'expliquer les concepts principaux des réseaux de neurones à convolution (CNN). La mise en œuvre des CNN se fait généralement en quatre opérations : convolution, la fonction d'activation (à travers la fonction de non-linéarité ReLU très souvent), Pooling et la couche entièrement connectée. La première opération est la convolution pour l'extraction des caractéristiques de l'image d'entrée. La deuxième opération correspond à la fonction non-linéarité (ReLU) pour remplacer toutes les valeurs négatives des pixels par zéro. La troisième opération est le Pooling pour réduire progressivement la taille de la carte de

caractéristiques rectifiée. Enfin, une couche entièrement connectée permet d'effectuer la classification.

Le prochain chapitre, traite les détails de la conception, ainsi que la méthode et les outils utilisés pour la réalisation de notre application.

Chapitre III

Conception d'un système de classification des stades de la rétinopathie diabétique

Conception d'un système de classification des stades de la rétinopathie diabétique

3.1 Introduction

La rétinopathie diabétique (RD) est une complication du diabète qui affecte les yeux. Les lésions des vaisseaux sanguins du tissu photosensible de la rétine sont à l'origine de la RD. La rétinopathie diabétique est l'une des causes de la cécité chez les adultes en âge de travailler. Environ 420 millions de personnes dans le monde ont été diagnostiquées avec un diabète sucré. L'universalité de cette maladie a doublé au cours des 20 dernières années [66].

On s'attend à ce qu'environ un tiers des personnes atteintes soient diagnostiquées avec la RD, une maladie oculaire chronique qui peut entraîner une perte de la vision. Pour un traitement correct et pour prévenir la perte de la vision, la classification des stades de la RD est une phase très importante. La RD peut être classé en cinq stades : le premier stade est le stade normal ; le deuxième correspond au stade léger ou NPDR (qui signifie None-Proliférative Diabetic Retinopathy) ; le troisième est le stade modéré, le quatrième est le stade grave et enfin le cinquième correspond au stade PDR (Proliférative Diabetic Retinopathy).

Dans la première section du chapitre, nous avons survolé quelques types de classificateurs de la RD, puis nous proposons notre système d'aide au diagnostic de la rétinopathie diabétique. Après avoir décrit la base d'images utilisées dans ce mémoire, la section qui suit se focalise sur la présentation des différentes approches permettant la détection de la RD par application du Deep Learning. Nous avons conçu deux architectures : la première est basée sur les réseaux de neurones convolutifs ; tandis que la deuxième repose sur l'exploitation des réseaux VGG16. Ces modèles permettront par la suite de réaliser la classification sur la base d'images rétinienne choisie.

Finalement, les méthodes de détection du RD proposées sont évaluées et comparées par des segmentations manuelles effectuées par des ophtalmologues.

3.2 Travaux connexes

Il existe de nombreux classificateurs conçus pour classer la RD. La plupart d'entre eux, sont des classificateurs binaires, c'est-à-dire qu'ils ne classent les données que dans deux classes : normale (pas de RD) et présence de RD (rétine affectée) [66] [88, 89]. Récemment, des travaux ont traité l'utilisation du traitement d'images et des méthodes d'apprentissage approfondi pour diagnostiquer la rétinopathie diabétique à partir d'images du fond d'œil [89] [88].

En 2018, Deperlioglu et al. [89] ont tout d'abord amélioré les images du fond de la rétine en utilisant les techniques d'égalisation d'histogrammes ainsi qu'un filtre passe-bas gaussien. La classification a été effectuée à l'aide du réseau neuronal convolutif. Une précision de 96,67 % a été obtenue.

Suriyal et al. [66] se sont concentrés sur le développement d'une application mobile pour le dépistage en temps réel de la rétinopathie diabétique. Elle a été créée à l'aide d'une architecture Tensorflow. Le modèle de réseau neuronal convolutif utilisé est MobileNets, conçu pour les appareils mobiles. Il est constitué de 28 couches convolutionnelles. Le résultat de la classification correspond à l'absence ou présence de la rétinopathie diabétique. Le modèle a obtenu une précision de 73,3 %.

Alban et al. [87] ont conçu un classificateur pour prédire le stade de la RD à partir d'images d'angiographie à la fluorescéine en utilisant des réseaux neuronaux convolutifs (CNN). Les images d'angiographie à la fluorescéine, images en noir et blanc, représentent le flux sanguin dans la rétine. Les images sont capables de montrer des vaisseaux sanguins anormaux ou des dommages dans la rétine.

Un classificateur utilisant trois réseaux neuronaux convolutifs (CNN) séparément a été développé par Wang et al. [87]. Il en ressort qu'InceptionNet a atteint la plus haute précision, soit 63,23 %.

3.3 Notre système

Dans le cadre de ce projet de fin d'études, nous sommes appelées à concevoir et développer un système qui classifie les différents stades de la RD à partir des images fundoscopiques en couleur. La classification est effectuée en cinq stades en fonction de la gravité de la maladie. Pour cette classification, des réseaux CNN basés sur Deep Learning sont déployés. Par le passé, de nombreuses études médicales ont été menées dans le domaine de la conception d'un algorithme de classification de la rétine à partir d'une image du fond d'œil [86] [89]. Mais il ne

s'agissait que de classificateurs binaires qui ne différencient que deux stades de la RD. Certains travaux précédents, ont également tenté de construire un classificateur de la RD en utilisant un CNN. Les résultats obtenus ont généré une précision de prédiction inférieure, lorsqu'ils sont appliqués aux données considérées dans ce travail [86, 87].

Dans ce travail, nous vérifions la précision des prédictions de différentes architectures des réseaux neuronaux convolutifs lorsqu'ils sont déployés comme classificateur de stade de la RD.

L'étude a été réalisée sur la base d'images "*Diabetic Retinopathy 224x224 Gaussian Filtered*" qui est public et téléchargeable dans le site Kaggle qui contient 3662 images de rétines. Nous avons testé et implémenté deux architectures avec deux types d'apprentissage différents. La première architecture correspond à VGG16 avec le transfert d'apprentissage (Transfer Learning) et le deuxième est une architecture basée sur un réseau de neurones convolutionnel, afin d'avoir un classificateur offrant la plus grande précision.

3.4 Connaissances Préalables

Les réseaux neuronaux convolutifs (CNN) sont une architecture de réseaux neuronaux artificiels (ANN) principalement utilisée pour la classification des images.

Les CNN ajoutent quelques opérations supplémentaires aux réseaux neuronaux réguliers comme la convolution, la non-linéarité et le sous-échantillonnage. Ils comportent principalement deux parties : la première est la partie d'extraction des caractéristiques et la seconde est la partie de classification. Dans la première partie, une série d'opérations de convolution et de pooling sont effectuées pour la détection des caractéristiques. Pour produire une carte des caractéristiques, à l'aide d'un filtre, l'opération de convolution est appliquée.

Cette carte d'éléments contient des valeurs négatives en pixels et doit être remplacée par zéro. Pour cela, une opération non linéaire est effectuée après avoir effectué chaque convolution. La non-linéarité est introduite en utilisant l'unité linéaire rectifiée (ReLU).

Dans la partie classification, en plus de ces caractéristiques extraites, des couches entièrement connectées (layers) serviront de classificateurs. Elles attribuent une probabilité à l'objet sur l'image. Lorsque ces images sont très grandes, l'opération de pooling réduit continuellement la dimensionnalité. Ceci est fait pour réduire le nombre de calculs et de paramètres dans le réseau. Cela réduit le temps d'entraînement et contrôle le surajustement (overfitting).

Le pooling spatial appelé aussi sub-sampling ou down-sampling permet de conserver les informations les plus importantes. Le pooling spatial est principalement de trois types : Max-

pooling, Average pooling, et Sum-pooling. L'élément le plus important de la carte des caractéristiques rectifiées est pris dans le Max pooling.

Dans le Sum-pooling, la somme de tous les éléments de la carte des caractéristiques est prise. Il est également possible d'ajouter autant de couches convolutives que nécessaire. L'architecture de base de CNN est illustrée dans la Figure III.1.

Dans ce document, nous utilisons des architectures CNN, VGG16, pour la classification précise des étapes de la RD. Avant de passer à la configuration de ces couches, voyons l'architecture de ce réseau.

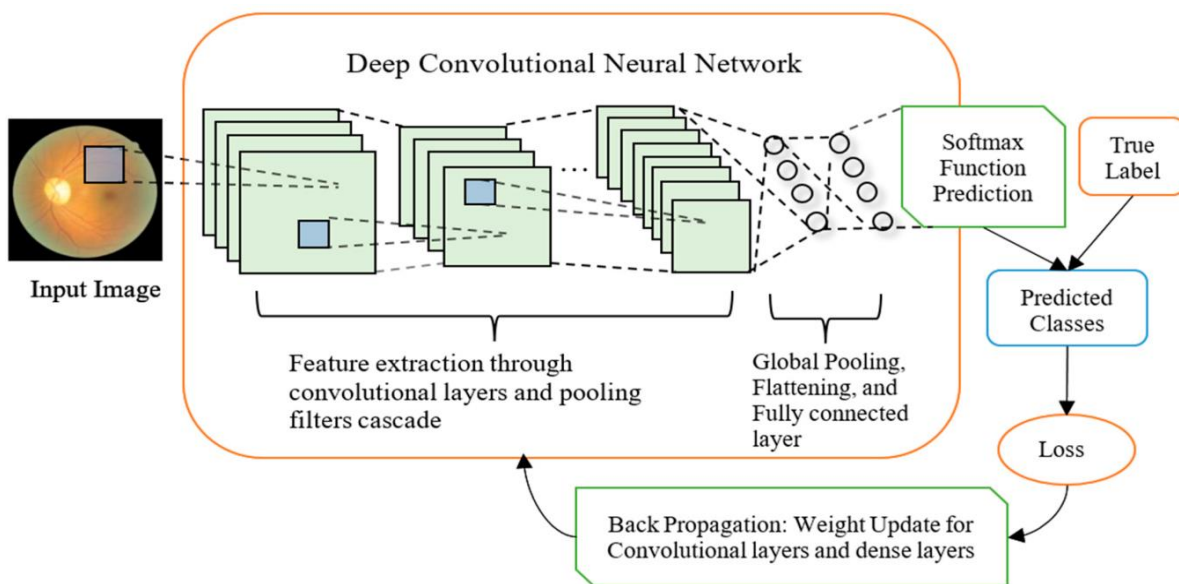


Figure III.1. : Architecture de CNN [91]

3.4.1 Apprentissage sans transfert à l'aide d'un CNN

Un convolutional neural network (CNN) est un type de réseau neuronal artificiel utilisé dans la reconnaissance et le traitement d'images et spécifiquement conçu pour traiter les données de pixels.

Un réseau neuronal convolutif se compose d'une couche d'entrée et d'une couche de sortie, ainsi que de plusieurs couches cachées. Les couches cachées d'un CNN consistent généralement en une série de couches convolutives qui se convoluent avec une multiplication ou un autre produit scalaire. La fonction d'activation, généralement une couche RELU, est ensuite suivie par des convolutions supplémentaires telles que des couches de mise en commun, des couches entièrement connectées et des couches de normalisation, appelées couches cachées car leurs entrées et sorties sont masquées par la fonction d'activation et la convolution finale.

Cette étape consiste à construire un modèle d'apprentissage. Avant de discuter l'apprentissage du CNN, nous devons modéliser son architecture par la spécification d'un certain nombre de paramètres. La construction d'une architecture CNN n'est pas une opération simple ; c'est un processus long et répétitif qui à chaque itération exige un ajustement du réseau CNN. En effet, il faut d'abord se fixer un nombre de couches et bien sélectionner leurs types puis, tester et avoir la performance du modèle. Si les résultats obtenus sont satisfaisants on sauvegarde le modèle sinon on ajuste le modèle en ajoutant, éliminant ou modifiant des couches pour obtenir une architecture qui fournit des résultats acceptables.

Les réseaux neuronaux convolutifs ont de larges applications dans la reconnaissance d'image et vidéo, les systèmes de recommandation.

3.4.2 Apprentissage par transfert à l'aide du VGG16

L'apprentissage par transfert est la réutilisation de modèles d'apprentissage approfondi qui sont préformés sur d'énormes ensembles de données, comme les sous-ensembles du projet ImageNet, pour les adapter à un ensemble de données inédit. Le réseau neuronal convolutif (CNN) est un exemple d'architecture de l'apprentissage approfondi qui convient mieux aux signaux à plusieurs réseaux tels que les images et les vidéos. L'apprentissage profond dépend d'une grande quantité de données d'entraînement pour fonctionner correctement.

L'apprentissage par transfert, sur des réseaux neuronaux convolutionnels, a gagné en popularité en raison de l'insuffisance des données de formation annotées dans les modèles de construction. L'apprentissage par transfert peut être utilisé pour réduire les données de formation requises et minimiser le temps de formation de l'apprentissage profond.

ImageNet [96] est un projet de recherche visant à développer une vaste base de données d'images avec des annotations, par exemple des images et leurs étiquettes. Les modèles préformés comme InceptionV1, Inception V2, VGG-16 et VGG-19 sont déjà entraînés sur ImageNet qui comprend des catégories d'images disparates [96]. Ces modèles sont construits à partir de zéro et formés en utilisant des GPU puissants sur des millions d'images comprenant des milliers de catégories d'images.

Comme le modèle est formé sur un énorme ensemble de données, il apprend une bonne représentation des caractéristiques de bas niveau comme l'espace, les bords, la rotation, l'éclairage, les formes.

Ces caractéristiques peuvent être partagées entre les différentes catégories pour permettre le transfert de connaissances et servir d'extracteur de caractéristiques pour de nouvelles images dans différents problèmes de vision par ordinateur. Ces nouvelles images peuvent être de

catégories complètement différentes de l'ensemble de données source, mais le modèle préformé doit toujours être capable d'extraire les caractéristiques pertinentes de ces images en se basant sur les principes de l'apprentissage par transfert.

Dans ce travail, nous allons réduire la puissance de l'apprentissage (réduire nombre d'époques pour apprentissage) par transfert en utilisant le modèle préformé - VGG-16 comme un extracteur de caractéristiques efficace pour classer les stades de la rétinopathie diabétique.

3.4.2.1 Description du VGG16

Le réseau VGG a été présenté par les chercheurs du Visual Graphics Group à Oxford (d'où le nom VGG). Il a été proposé par K. Simonyan et A. Zisserman de l'Université d'Oxford dans le document *Very Deep Convolutional Networks for Large-Scale Image Recognition* [96].

Ce réseau est spécialement caractérisé par sa forme pyramidale, où les couches inférieures les plus proches de l'image sont larges, tandis que les couches supérieures sont profondes.

Il a été formé sur l'ensemble de données ImageNet, qui est une collection de plus de 14 millions d'images provenant d'environ 22 000 classes. VGG16 a pu atteindre une précision de test d'environ 92,7% dans le top 5 dans ImageNet [96].

L'architecture du VGG16 est illustrée dans la Figure III.2.

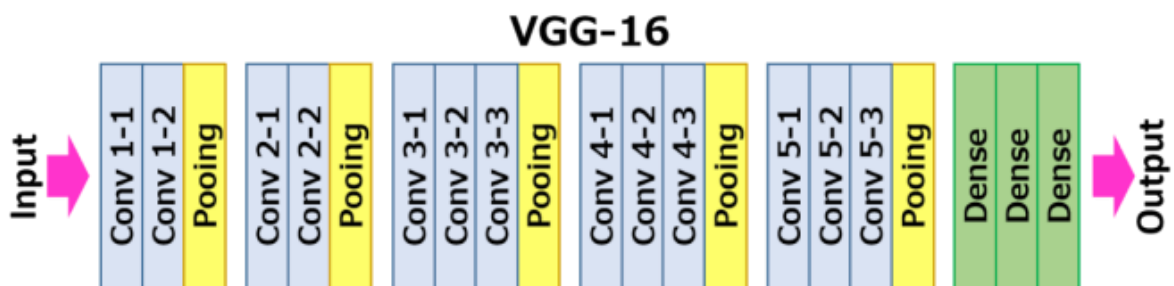


Figure III.2. : Architecture en couches de VGG16 [92]

- À partir du diagramme ci-dessus, nous pouvons voir que VGG16 a 5 blocs de convolution et 1 bloc entièrement connecté.
- Chaque bloc de convolution a des couches de convolution et 1 couche de regroupement. Les couches de convolution utilisent des filtres 3×3 .
- Les couches de mise en commun utilisent la mise en commun maximale 2×2 .
- Le bloc entièrement connecté contient 3 couches FC, la première et la seconde ont 4096 unités tandis que la troisième à 1000 unités en fonction du nombre de classes.

3.5 Méthodologie Proposée

La méthodologie que nous avons proposée est fortement inspirée des aspects clés de la classification de la gravité des stades de la rétinopathie diabétique à partir des images du fond d'œil. Notre système prend une image de fond de l'œil par le médecin ophtalmologiste et l'envoie dans le site web et se dirige vers le serveur qui applique l'algorithme d'augmentation sur l'image avant de passer aux réseaux neuronaux convolutifs pour extraire les caractéristiques dans les images. Ensuite, un FC est utilisé pour classer les données extraites. Puis, les catégories de maladies avec le diagnostic sont envoyées à l'ophtalmologiste sur l'application web.

3.5.1 Architecture de l'approche adoptée

Dans le modèle de classification de la rétinopathie diabétique que nous proposons à la figure III.3, l'architecture est condensée et ses éléments constitutifs sont :

- a. Augmentation des données.
- b. Prétraitement.
- c. Classification des réseaux neuronaux à convolution.

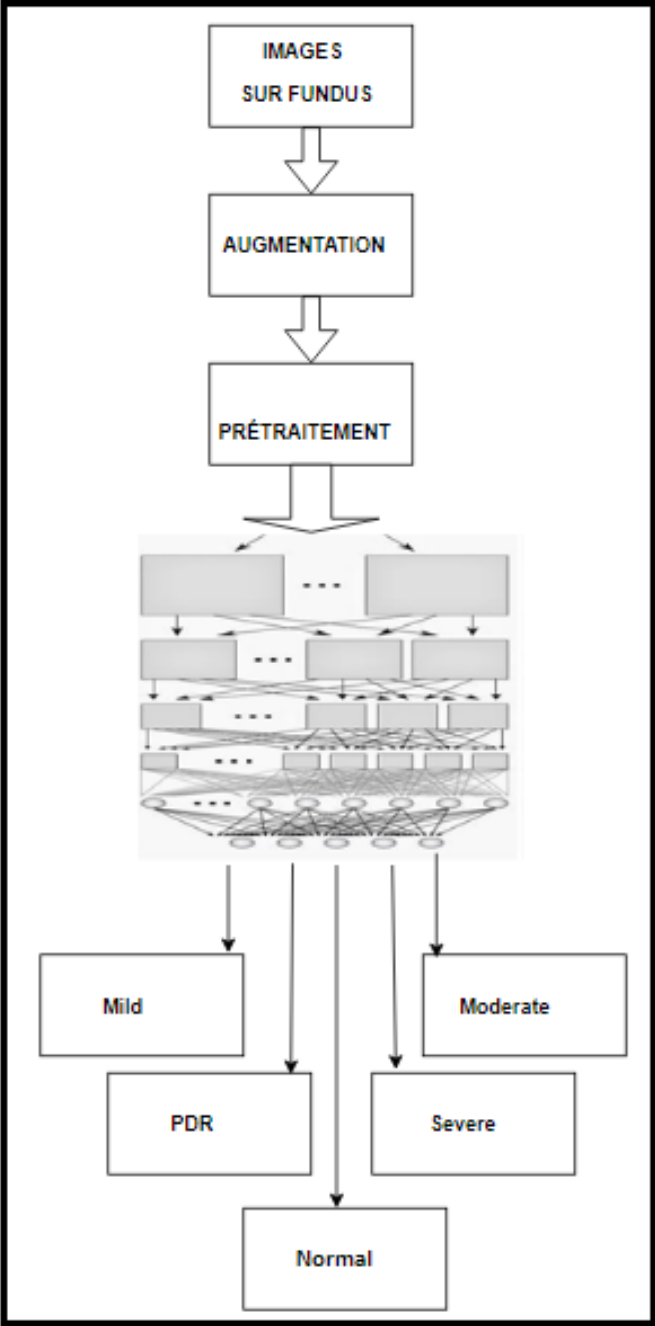


Figure III.3. Schéma global du modèle proposé de classification de la RD

Les étapes de l'approche proposée sont représentées dans l'organigramme ci-dessous (cf. figure III.4) :

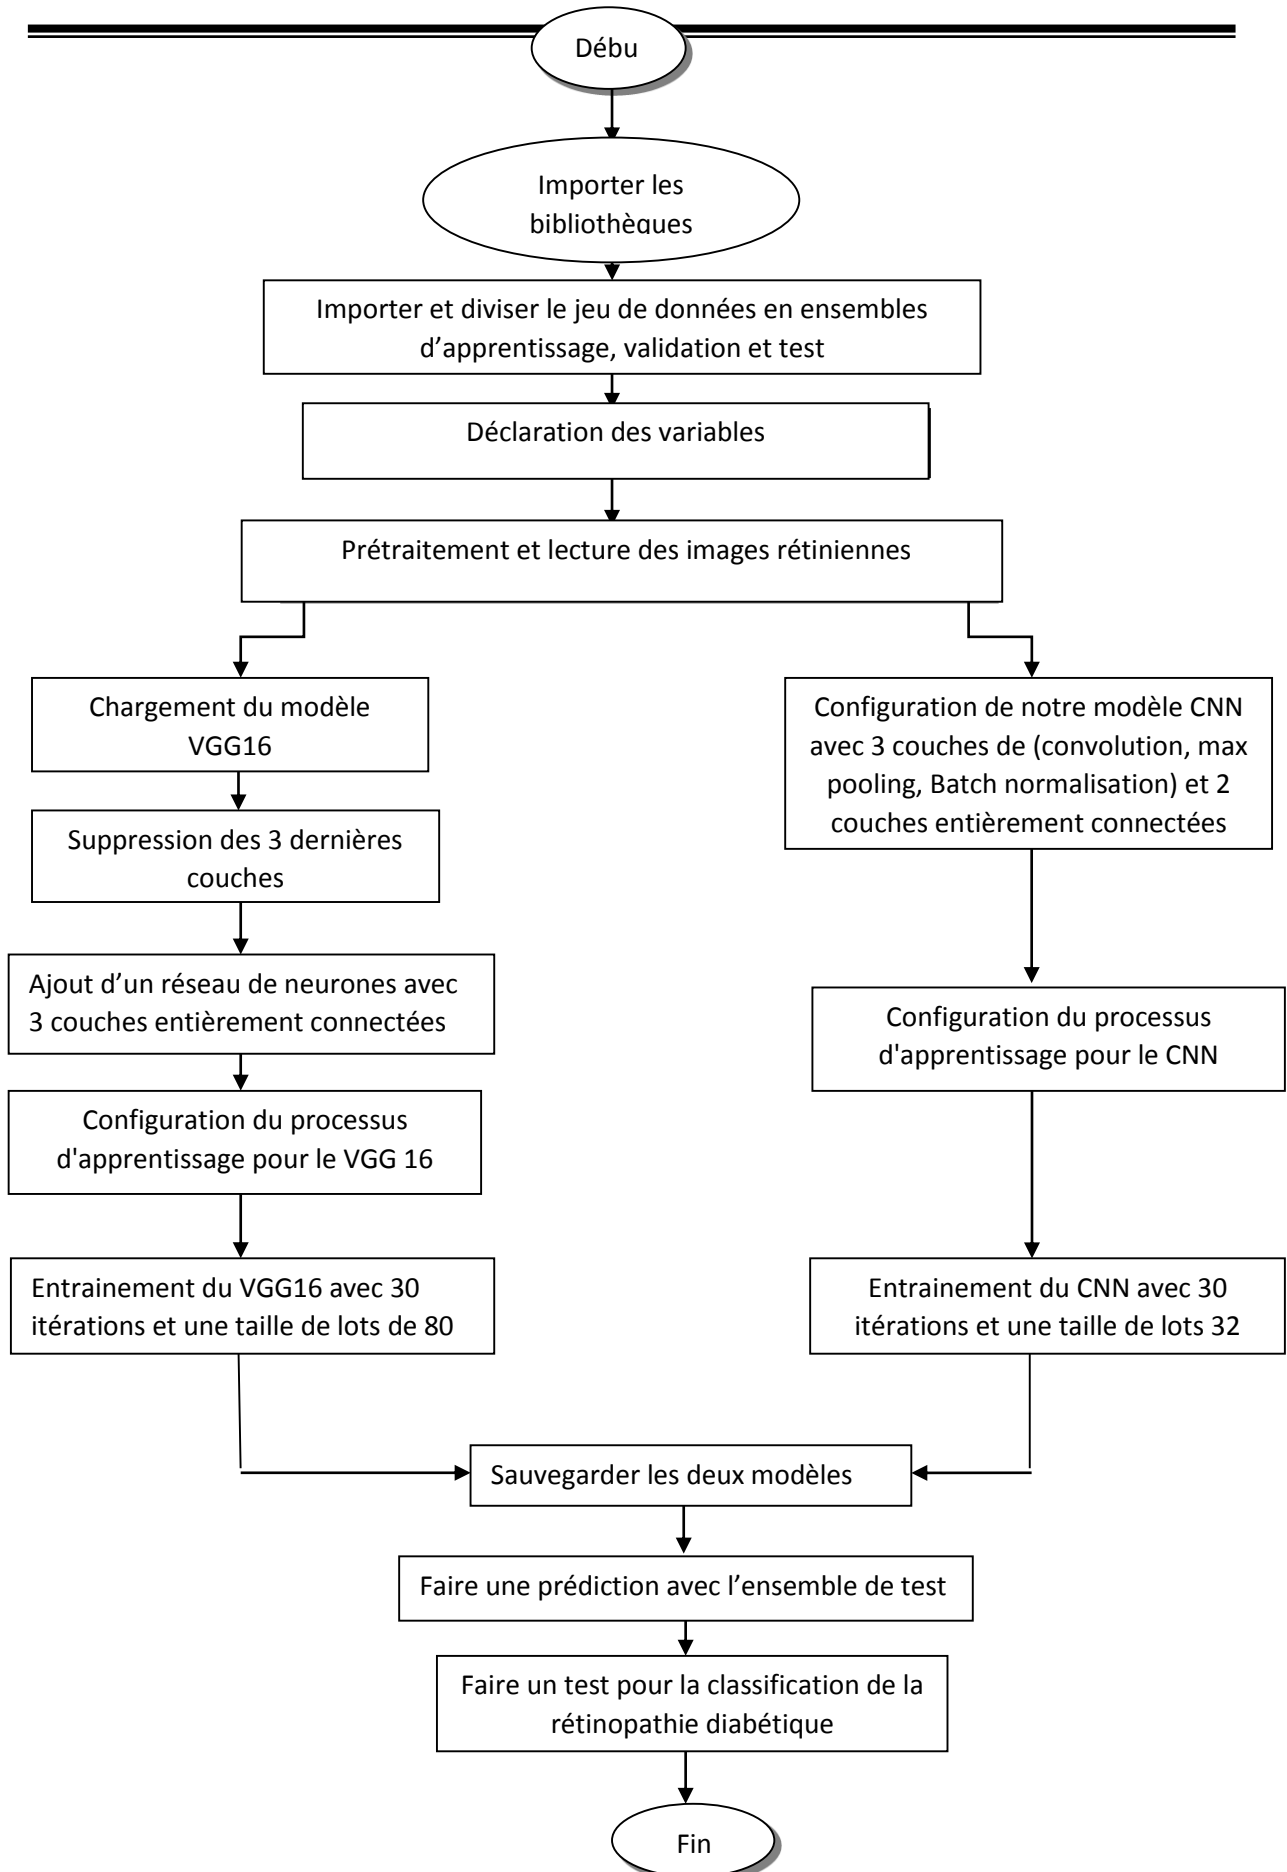


Figure III.4. : Organigramme global proposé

3.5.2 Description des étapes de l'organigramme

Nous décrivons dans cette partie, les différentes étapes de l'approche proposée dans l'organigramme de la figure III.4

- 1) **Préparation du Dataset**
 - Déclarer la localisation de la base de données
 - Diviser la base en 3 ensembles : apprentissage, validation, test
 - Déclarer la localisation du nouveau dataset

- 2) **Déclaration des variables**
 - La dimension et la taille des images
 - Le Learning rate.
 - Les fichiers h5 pour le stockage des poids et le modèle après L'entraînement.

- 3) **Préparation des entrées**
 - Prétraitement des images de training set et validation set et testing set.
 - Lecture des images training set et validation set

4) Environnement de travail avec un CNN

Nous avons choisi les caractéristiques suivantes pour configurer l'environnement de travail avec un CNN :

- Créer le réseau de neurones
 - Filtre=3, pour la 1^{ère} et la 2^{ème} couches de convolution
 - Filtre =4, pour la 3^{ème} couche de convolution
 - Convolution 1=8, nombre de filtres (featuresmaps 8)
 - Convolution 2=16, nombre de filtres (featuresmaps 16)
 - Convolution 3=32, nombre de filtres (featuresmaps 32)
 - Pool size=2, taille de pool
 - Dropout=0.15, appliquer un dropout avec probabilité de 15%
 - Couche 1=32, créer une 1^{ère} couche avec 32 neurones
 - Couche 2=5, créer une 2^{ème} couche avec 5 neurones

- Avant l'entraînement du CNN
 - configurer le processus d'apprentissage

- Compiler de modèle
 - entraîné le modèle avec 30 époques et une taille de lot de 32 images

5) Environnement de travail avec un VGG16

Dans le cas du VGG16, nous avons choisi les caractéristiques suivantes pour configurer l'environnement de travail :

- Importer le VGG16
 - Sans les couches de fully_connected
 - avec les poids d'imagenet

Spécifier les couches à entraîner	{ - On entraîne seulement le nouveau classifieur sans ré-entraîner les autres couches - Le modèle VGG16
Créer un nouveau classifieur	{ - Couche1=256, créer la 1 ^{ère} couche avec 256 neurones - Dropout=0.2, appliquer un dropout de 20% - Couche2=128, crée la 2 ^{ème} couche avec 128 neurones - Dropout =0.5, appliquer un dropout de 50% - Couche3=5, créer la 3 ^{ème} couche avec 5 neurones
Avant d'entraîner le VGG16	{ - Configurer le processus d'apprentissage
Compiler de modèle	{ - Entraîner le modèle avec 30 époques et une taille de lot de 80 Images.
Après l'entraînement	{ - Sauvegarder les poids et le modèle
Préparation des images de test	{ - Lecture des images de l'ensemble, de test
Evaluer le modèle	{ - Tester le modèle avec des nouvelles images la prédiction et la précision.

La méthodologie du système proposé est illustrée pour VGG16 sur la Figure III.5.

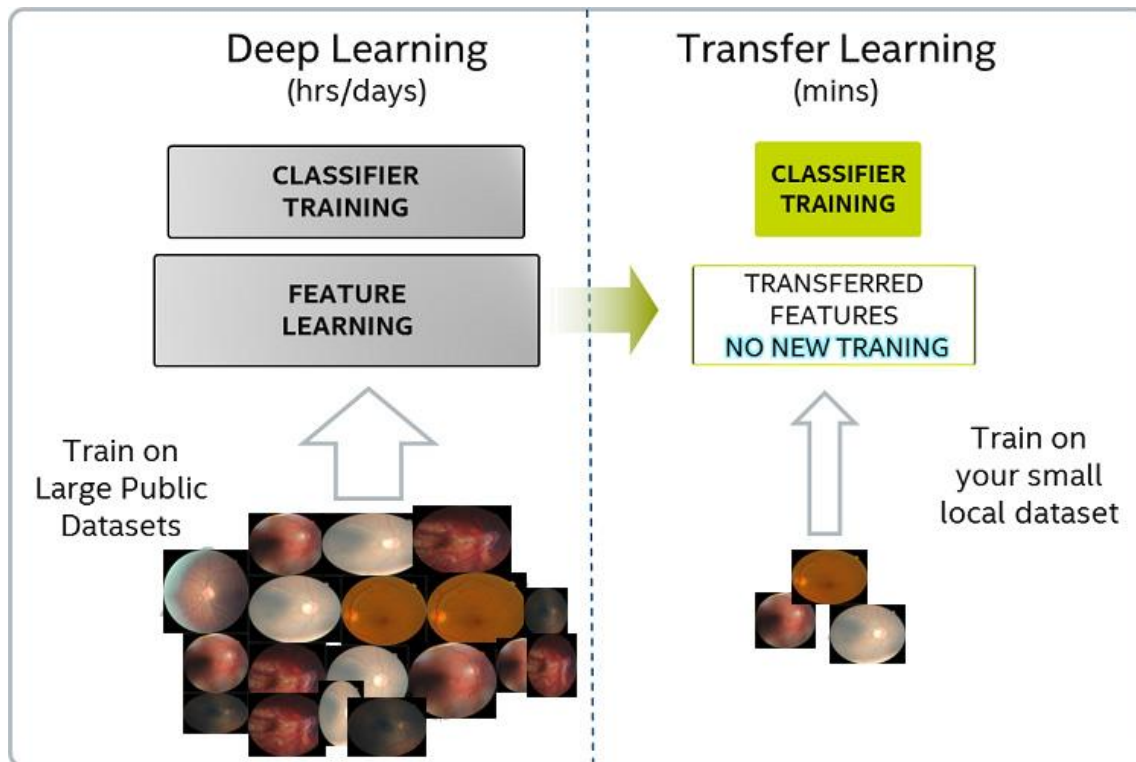


Figure III.5. : Méthodologie proposée (Transfer Learning par VGG16)

3.5.3 Augmentation des données

L'ensemble des données fournies par Kaggle est déséquilibré. Pour l'équilibrer, nous avons donc besoin d'une augmentation des données. Nous n'augmentons que les classes qui ont moins d'images. Ainsi, après l'augmentation, toutes les classes ont plus ou moins le même nombre d'images.

Nous avons utilisé les techniques suivantes pour l'augmentation des données :

1. Renversement horizontal
2. Renversement vertical
3. Rotation

En utilisant ces techniques, notre modèle est plus robuste pour différentes orientations (cf. Figures III.6, III.7 et III.8).



Figure III.6 : Image originale



(a) Renversement horizontal (b) Retournement vertical

Figure III.7 : Images après retournement horizontal et vertical



(a) Rotation de 90 degrés (b) Rotation de 180 degrés

Figure III.8 : Images après rotation

Nous avons utilisé le jeu de données "*Diabetic Retinopathy 224x224 Gaussian Filtered*", qui contient 3662 images, pour la rétinopathie diabétique. A partir des 3662 images, 70% sont

utilisées à des fins d'apprentissage et le reste est utilisé 15% pour tester le système et 15% pour la validation du système.

3.5.4 Prétraitement

Pour entraîner nos modèles d'apprentissage en profondeur pré-entraînés, nous avons donc choisi une base de données avec des images rétiniennes filtrées gaussiennes publiées sur le web. L'ensemble de données fourni contient des images de différentes dimensions, alors nous avons redimensionné toutes les images en 224x224 pixels, pour faciliter l'entraînement et résoudre le problème de mauvaise précision qui est provoqué par la descente de gradient.




Figure III.9. : Échantillon d'une image du dataset

3.5.5 Classification

Une fois les modèles générés durant la phase d'apprentissage (le modèle CNN, le modèle VGG16), le système est alors capable de diagnostiquer n'importe quelle image inconnue en entrée.

3.5.5.1 Discussion de l'architecture de notre modèle VGG16

VGG-16 est constitué de plusieurs couches, dont 13 couches de convolution et 3 couches entièrement connectées. Il doit donc apprendre les poids de 16 couches.

L'image en entrée est de taille (224x224), l'image passe d'abord à la première couche de convolution, cette couche est composée de 64 filtres de taille (3x3), chaque couche est suivie d'une couche de correction ReLU. Après cette convolution 64 cartes de caractéristiques (features maps) de taille (224x224) sont créées.

Les features maps obtenues à l'étape précédente, sont ensuite transmises en entrée à la deuxième couche de convolution qui est composée de 64 filtres. Ensuite on applique un Maxpooling pour réduire la taille de l'image et compresser les données. À la sortie de cette couche, nous obtenons 64 features maps de taille (112x112).

On répète le même processus avec les couches de convolutions trois et quatre ; ces couches sont composées de 128 filtres, la fonction ReLU est toujours appliquée sur chaque convolution. Une couche de Maxpooling est appliquée après la quatrième couche de convolution. À la sortie nous aurons 128 features maps de taille (56x56). En répétant le processus, nous obtenons :

- A la sortie de la septième couche nous aurons 256 features maps de taille (28x28).
- A la sortie de la dixième couche nous aurons 512 featuresmaps de taille (14x14).
- A la sortie de la treizième couche nous aurons 512 features maps de taille (7x7).

Le vecteur caractéristique issu des convolutions a une dimension de 25088.

On remplace les dernières couches par notre propre réseau de neurones composé de 3 couches entièrement connectées. La première couche a 256 neurones et la fonction d'activation ReLU ; la deuxième couche a 128 neurones avec une fonction d'activation ReLU. La troisième couche est obtenue en appliquant un softmax qui permet de calculer la distribution de probabilité des 5 classes.

La figure ci-dessous montre la configuration de notre modèle VGG16

```

Model: "sequential_1"

```

Layer (type)	Output Shape	Param #
vgg16 (Model)	(None, 7, 7, 512)	14714688
flatten_1 (Flatten)	(None, 25088)	0
dense_1 (Dense)	(None, 256)	6422784
dropout_1 (Dropout)	(None, 256)	0
dense_2 (Dense)	(None, 128)	32896
dropout_2 (Dropout)	(None, 128)	0
dense_3 (Dense)	(None, 5)	645

```

Total params: 21,171,013
Trainable params: 13,535,749
Non-trainable params: 7,635,264

```

Figure III.10 : Configuration de notre modèle VGG16

3.5.5.2 Discussion de l'architecture de notre modèle CNN

L'architecture de notre CNN est composée de 3 couches de convolution, 3 couches de maxpooling, 3 couches de batch Normalisation et 2 couches entièrement connectées.

Nos images en entrée sont de tailles (224x224). L'image passe par la première couche de convolution qui est composée de 8 filtres de taille (3 x3) ; chacune de ces couches de

convolution est suivie d'une fonction ReLU. Cette dernière force les neurones à retourner des valeurs positives ; après cette convolution 8 features maps de taille (222 x222) seront créées. Les 8 features maps qui sont obtenues sont considérées en entrée de la deuxième couche de maxpooling pour réduire la taille spatiale de la sortie de cette couche ; on obtient alors 8 features maps de taille (111 x111). Afin de stabiliser le processus d'apprentissage et réduire le nombre d'époques mais aussi normaliser les entrées du réseau, on ajoute une couche de batch normalisation.

On répète le même processus pour la deuxième couche de convolution qui est composée de 16 filtres de taille (3 x3), suivie d'une couche ReLU. A la sortie, on obtient 16 features maps de taille (109 x109). L'application du maxpooling génère par la suite 16 features maps de taille (54 x54) suivie de la couche de batch normalisation à la fin.

Une troisième couche de convolution, composée de 32 filtres de taille (4 x4) et suivie d'une couche ReLU, après le maxpooling et la couche de batch normalisation génère 32 features maps de taille (25 x25).

Le vecteur caractéristique issu des convolutions a une dimension de 20000.

Nous utilisons un réseau de neurones composé de 2 couches entièrement connectées. La première couche est composée de 32 neurones avec une fonction d'activation ReLU, et la deuxième est une couche de softmax permettant de calculer la distribution de la probabilité des 5 classes (nombre de classes dans la base d'image).

La figure ci-dessous indique la configuration de notre modèle CNN

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 222, 222, 8)	224
max_pooling2d (MaxPooling2D)	(None, 111, 111, 8)	0
batch_normalization (BatchNo	(None, 111, 111, 8)	32
conv2d_1 (Conv2D)	(None, 109, 109, 16)	1168
max_pooling2d_1 (MaxPooling2	(None, 54, 54, 16)	0
batch_normalization_1 (Batch	(None, 54, 54, 16)	64
conv2d_2 (Conv2D)	(None, 51, 51, 32)	8224
max_pooling2d_2 (MaxPooling2	(None, 25, 25, 32)	0
batch_normalization_2 (Batch	(None, 25, 25, 32)	128
flatten (Flatten)	(None, 20000)	0
dense (Dense)	(None, 32)	640032
dropout (Dropout)	(None, 32)	0
dense_1 (Dense)	(None, 5)	165
Total params: 650,037		
Trainable params: 649,925		
Non-trainable params: 112		

Figure III.11 : Configuration du modèle CNN élaboré

3.6 Conclusion

Parmi les autres algorithmes de classification supervisée existants, la plupart nécessitent davantage d'étapes de près ou de post-traitement pour identifier les différents stades de la rétinopathie diabétique. D'autres algorithmes requièrent également des étapes d'extraction manuelle des caractéristiques pour classer les images du fond d'œil.

Dans la solution que nous proposons, le réseau neuronal convolutif (CNN) est une approche globale englobant tous les niveaux de détection des différents stades de la rétinopathie diabétique.

Dans ce chapitre, nous avons présenté les différentes parties de notre système d'aide au diagnostic de la rétinopathie diabétique à ses différents niveaux.

Nous avons commencé par schématiser le processus général de notre système ainsi que l'illustration du processus général de la phase d'apprentissage et de classification, ensuite nous avons détaillé chacune des phases citées, ainsi que l'explication de l'architecture et des paramètres choisis.

Dans le prochain chapitre, nous allons présenter les outils utilisés pour l'implémentation de l'application et discuter les différents résultats expérimentaux obtenus par notre système.

Chapitre IV

Réalisation et Expérimentation

Réalisation et expérimentation

4.1 Introduction

Dans ce chapitre nous allons discuter la démarche adoptée pour la réalisation de notre application en utilisant les algorithmes de réseaux de neurones convolutifs. Nous allons tout d'abord présenter, l'environnement matériel ainsi que le langage utilisé pour implémenter notre système. Nous décrirons également, l'environnement de développement, ainsi que la bibliothèque utilisée pour réaliser ce travail.

Ensuite, nous illustrons l'application développée par quelques aperçus d'écrans montrant le déroulement et les différentes fonctionnalités. Nous clôturons ce chapitre par la présentation des différents résultats expérimentaux obtenus par les différentes modalités.

4.2 Configuration matérielle

4.2.1 Configuration matérielle distante (Google Colab)

Google Collaboratory¹ ou Colab, est un outil Google simple et gratuit pour s'initier aux réseaux profonds ou collaborer avec des collègues sur des projets en science des données. Colab permet d'améliorer ses compétences de codage en langage de programmation Python, de développer des applications en réseaux profonds en utilisant des bibliothèques populaires telles que Keras, TensorFlow, PyTorch et OpenCV sans installation ainsi que d'utiliser un environnement de développement (Jupyter Notebook) qui ne nécessite aucune Configuration. Cependant, chaque 12 heures, la machine virtuelle mise à disposition par Google est réinitialisée nécessitant un mécanisme de sauvegarde des données en cours. De plus, les documents Colab (Jupyter Notebook) sont enregistrés directement le compte Google Drive. L'infrastructure distante mise à disposition par Google Colab et utilisée pour l'entraînement possède la configuration suivante :

- Processeur Intel Core Xeon CPU @2.3Ghz, 45MB Cache.
- Processeur graphique NVIDIA Tesla K80, ayant 2496 coeurs CUDA, Compute 3,7, 12

1. <https://colab.research.google.com>

- Go (11.439 Go utilisable) GDDR5 VRAM.
- Mémoire vive de 12.6 Go.
- Disque dur de capacité 320 Go.
- Jupyter Notebook
- Système d'exploitation Linux x64 bits.

4.2.2 Configuration matérielle locale

Pour la classification, nous avons utilisé deux ordinateurs portables personnels avec les configurations suivantes :

Pour le premier pc portable :

- Processeur Intel Core i5-6200U CPU @2.3Ghz, with Turbo Boost up to 2.8 GHz.
- Mémoire vive de 4 Go.
- Disque dur hybride SSD de capacité 500 GB HDD.
- Système d'exploitation Windows 7 x64 bits.

Pour le deuxième pc portable :

- Processeur Intel(R) Core(TM) i3-6100 CPU @ 3.70GHz
- Mémoire installée (RAM) : 8.00 Go
- Disque dur WDC WD5000LPCX-24C6HT0 de capacité 500GB
- Système d'exploitation Windows 10x64bits

4.3 Environnement de développement logiciel

4.3.1 Python

Python² est un langage de programmation puissant et facile à apprendre. Il dispose de structures de données de haut niveau et permet une approche simple mais efficace de la programmation orientée objet. Parce que sa syntaxe est élégante, que son typage est dynamique et qu'il est interprété, Python est un langage idéal pour l'écriture de scripts et le développement rapide d'applications dans de nombreux domaines et sur la plupart des plateformes. L'interpréteur Python peut être facilement étendu par de nouvelles fonctions et types de données implémentés en C ou C++ (ou tout autre langage appelable depuis le C). Python est également adapté comme langage d'extension pour personnaliser des applications.

4.3.2 Anaconda

Anaconda³ est une distribution libre et open source des langages de programmation Python et R appliquée au développement d'applications dédiées à la fouille de données et à

2. <https://www.python.org/>

3. <https://www.anaconda.com/>

l'apprentissage automatique (traitement de données à grande échelle, analyse prédictive, calcul scientifique), qui vise à simplifier la gestion des paquets et de déploiement.

Les versions de paquetages sont gérées par le système de gestion de paquets conda.

La distribution Anaconda est utilisée par plus de 6 millions d'utilisateurs et comprend plus de 250 paquets populaires fouille de données adaptés pour Windows, Linux et MacOS.

4.3.3 TensorFlow

TensorFlow⁴ est une bibliothèque de logiciels open source publiée en 2015 par Google pour faciliter la conception, la construction et la formation de modèles d'apprentissage en profondeur pour les développeurs.

TensorFlow était prévu à l'origine comme une bibliothèque interne que les développeurs de Google utiliseraient pour construire des modèles en interne.

À un niveau élevé, TensorFlow est une bibliothèque Python qui permet aux utilisateurs d'exprimer un calcul arbitraire sous forme de graphique de flux de données.

Les nœuds de ce graphique représentent des opérations mathématiques, tandis que les arêtes représentent les données communiquées d'un nœud à un autre.

Les données de TensorFlow sont représentées sous la forme de tenseurs, qui sont des tableaux multidimensionnels.

Bien que ce cadre pour la réflexion sur le calcul soit précieux dans de nombreux domaines différents, TensorFlow est principalement utilisé pour l'apprentissage profond dans la pratique et la recherche.

4.3.4 Keras

Keras⁵ est une API de réseaux de neurones de haut niveau, écrite en Python et interfaçable avec TensorFlow, CNTK et Theano. Elle a été développée avec pour objectif de permettre des expérimentations rapides. Être capable d'aller de l'idée au résultat avec le plus faible délai possible étant la clef d'une recherche efficace. Keras a été développé pour rendre la mise en œuvre de modèles d'apprentissage profond aussi rapide et aussi facile que possible pour la recherche et le développement. Il fonctionne sur Python 2,7 ou 3,5 et peut s'exécuter en toute

4. <https://www.tensorflow.org/>

5. <https://keras.io/>

transparence sur les GPU et les CPU ont donné les frameworks sous-jacents. Il est diffusé sous la licence permissive MIT.

Keras a été développé et entretenu par François Chollet, un ingénieur de Google qui utilise quatre principes directeurs :

- **Modularité** : un modèle peut être interprété comme une séquence ou un graphique seul. Toutes les préoccupations d'un modèle d'apprentissage profond sont des composants discrets qui peuvent être combinés de manière arbitraire.
- **Minimalisme** : la bibliothèque fournit juste assez pour obtenir un résultat, sans fioritures et maximisant la lisibilité.
- **Extensibilité** : les nouveaux composants sont intentionnellement faciles à ajouter et à utiliser dans le cadre, destiné aux chercheurs à l'essai et à explorer de nouvelles idées.
- **Python** : aucun fichier de modèle distinct avec des formats de fichiers personnalisés. Tout est natif Python.

4.3.5 Flask

Flask⁶ est un framework open-source de développement web en Python. Son but principal est d'être léger, afin de garder la souplesse de la programmation Python, associé à un système de templates.

4.4 Mesures de performance

L'évaluation des performances⁷ d'un système de classification est une phase très importante car ces performances traduisent la fiabilité du système proposé.

Dans les applications médicales, le taux de bonne classification et d'erreur globale ne suffisent pas pour juger la performance.

Dans ce travail, nous avons analysé le comportement de nos classifieurs CNN en appliquant plusieurs mesures de performances afin de mieux évaluer notre système pour comprendre son comportement. Les mesures adoptées sont définies comme suit.

4.4.1 Matrice de confusion

Elle permet de générer la performance de chaque classe prise individuellement. C'est une matrice de taille égale au nombre de classes (cf. Figure. IV.1).

6. [https://fr.wikipedia.org/wiki/Flask_\(framework\)](https://fr.wikipedia.org/wiki/Flask_(framework))

7. <https://blog.expert.conciliator.ai/mesure-de-performance-et-machine-learning/>

		<u>Actual class</u>	
		Positive	Negative
<u>Predicted class</u>	Positive	True Positive (TP)	False Positive (FP)
	Negative	False Negative (FN)	True Negative (TN)

Figure. IV.1. : Matrice de confusion.

4.4.2 Taux de bonne classification (Accuracy)

Taux de bonne classification (tbc_s) représente l'indicateur le plus naturel et le plus évident permettant d'évaluer les performances d'un système de classification. Cette valeur simple à calculer, correspond au pourcentage d'éléments correctement identifiés par le système.

$$tbc_s = \frac{\text{Nombre d'élément correctement identifiés}}{\text{Nombre d'éléments total}} \quad (4.1)$$

4.4.3 La précision

C'est le nombre de vrais positifs divisé par le nombre de vrais positifs et faux positifs.

$$prec = \frac{TP}{PPos} = \frac{TP}{TP + FP} \quad (4.2)$$

4.4.4 Le rappel (Recall)

Le rappel est le nombre de vrais positifs divisé par le nombre de vrais positifs et le nombre de faux négatifs.

$$rec = tpr = \frac{TP}{Pos} = \frac{TP}{TP + FN} \quad (4.3)$$

4.4.5 F-Mesure (F1 score)

La F-mesure correspond à une moyenne harmonique de la précision et du rappel. Elle est donnée par l'équation ci-dessous :

$$F1 = \frac{((1 + \beta^2) * prec * rec)}{((\beta^2 * prec) + rec)} \quad (4.4)$$

Le paramètre β permet de pondérer la précision ou le rappel ; il est fixé généralement à 1.

L'avantage de ce choix est que lorsque la précision est égale au rappel, on obtient :

$$Précision = Rappel = F1_{mesure} \quad (4.5)$$

Ceci facilite la lecture et on recherche à maximiser la F-mesure en maximisant simultanément la précision et le rappel.

4.4.6 Sensibilité et spécificité

La sensibilité d'un test mesure sa capacité à donner un résultat positif lorsqu'une hypothèse est vérifiée. Elle s'oppose à la spécificité, qui mesure la capacité d'un test à donner un résultat négatif lorsque l'hypothèse n'est pas vérifiée.

La sensibilité, ou la probabilité que le test soit positif si la maladie est présente, se mesure chez les malades seulement. Elle est donnée par :

$$\frac{VP}{VP + FN} \quad (4.6)$$

Une mesure de la sensibilité s'accompagne toujours d'une mesure de spécificité.

Cette dernière se mesure chez les non malades seulement. Ainsi, la spécificité ou la probabilité d'obtenir un test négatif chez les non malades, est donnée par :

$$\frac{VN}{VN + FP} \quad (4.7)$$

4.5 Description de la base de données

Notre tâche consiste à créer un système d'analyse automatisé capable de diagnostiquer la rétinopathie diabétique. Pour cela nous allons utiliser un ensemble des données originales correspond à "Diabetic Retinopathy 224x224 Gaussian Filtered" [93]. Cet ensemble est public et consistent en des images rétiniennes filtrées gaussiennes pour détecter la rétinopathie diabétique. Ces images de la rétine sont prises à l'aide de la photographie du fond d'œil dans diverses conditions d'imagerie.

Un clinicien a évalué chaque image en fonction de la gravité de la rétinopathie diabétique sur une échelle de 0 à 4 [93] :

- 0 - Pas de RD (Normal)
- 1 - Doux (Mild)
- 2 - Modéré (Moderate)

3 - Sévère

4 - RD proliférative




Figure. IV.2. : Les cinq stades de RD [93]

- Les images de l'ensemble de données proviennent de différents modèles et types de caméras, ce qui peut affecter l'apparence visuelle de gauche par rapport à droite. Certaines images sont représentées comme on si on voyait la rétine anatomiquement (macula à gauche, nerf optique à droite pour l'œil droit). D'autres sont représentées comme si on la voyait à travers une lentille de condensation de microscope (c'est-à-dire inversée, comme on la voit dans un examen de la vue en direct typique).
- Comme tout ensemble de données du monde réel, les images et les étiquettes sont entachées de bruit.
- Les images peuvent être floues, sous-exposées ou surexposées.
- Notre objectif majeur est de développer des algorithmes robustes pouvant fonctionner en présence de bruit et de variation.

4.5.1 Dataset utilisé

Nous utilisons un dataset originales correspond à "Diabetic Retinopathy 224x224 Gaussian Filtered " et publier dans le site web kaggle⁸ et contenant un ensemble de 3662 images, divisé a trois ensembles comme suit : Un ensemble d'apprentissage de 2562 images, un ensemble de test de 554 images et un ensemble de validation de 546 images. Cette configuration sera utilisée pour les deux modèles : CNN et VGG16.

La Figure. IV.3 représente le fichier csv qui contient les images id_code et leurs stades (Diagnosis) et la Figure. IV.4 fournit une représentation graphique du total du dataset avant repartit.

⁸ <https://www.kaggle.com/sovitrath/diabetic-retinopathy-224x224-gaussian-filtered/activity>

	id_code	diagnosis
0	000c1434d8d7	2
1	001639a390f0	4
2	0024cdab0c1e	1
3	002c21358ce6	0
4	005b95c28852	0
5	0083ee8054ee	4
6	0097f532ac9f	0
7	00a8624548a9	2
8	00b74780d31d	2
9	00cb6555d108	1

Figure. IV.3. : Visualisation du tableau csv




Figure. IV.4. : Représentation graphique du Dataset.

4.5.2 Ensemble d'apprentissage (Training set)

Nous avons considéré 2562 images pour l'entraînement du modèle au cours du processus d'apprentissage (cf. Figure. IV.5).




Figure. IV.5. : Représentation graphique de l'ensemble d'apprentissage.

4.5.3 Ensemble de validation (Validation set)

Nous avons pris 546 images pour la validation de notre modèle qui permet de mesurer l'erreur de prédiction (cf. Figure. IV.6).




Figure. IV.6. : Représentation graphique de validation set.

4.5.4 Ensemble de test (Testing set)

Nous avons considéré 554 images pour le test de notre modèle. Cette phase permet de mesurer l'erreur du modèle final sur des données non apprises. Nous allons simplement passer ces données comme s'il s'agissait de données que l'on n'a encore jamais rencontrées et mesurer la performance de notre modèle sur ces données (cf. Figure. IV.7).




Figure. IV.7. . : Représentation graphique du Testing set.

4.6 Expérimentation paramétrique

Avant d'expérimenter le modèle final conçu et présenté dans le chapitre 3, nous allons faire plusieurs tests paramétriques sur le modèle CNN et le modèle VGG16. Nous présenterons par la suite les résultats obtenus pour les classificateurs de la RD.

Dans les prochaines sections, nous présentons quelques expérimentations effectuées.

4.6.1 Comparaison des réseaux VGG 16 et CNN

- Après l'entraînement de nos deux modèles nous discuterons les résultats obtenus illustrée dans les figures IV.8 et 9 ci-dessous :

```
Epoch 1/30
81/81 [=====] - 71s 881ms/step - loss: 1.0376 - acc: 0.6187 - val_lo
ss: 1.5383 - val_acc: 0.2802

Epoch 30/30
81/81 [=====] - 72s 889ms/step - loss: 0.2824 - acc: 0.9235 - val_lo
ss: 0.7812 - val_acc: 0.7363
```

Figure. IV.8. : Résultat de l'entraînement du modèle CNN

```

Epoch 1/30
32/32 [=====] - 685s 21s/step - loss: 1.6784 - acc: 0.6136 - val_loss: 2.3890 - val_acc: 0.7279
-
Epoch 30/30
32/32 [=====] - 685s 21s/step - loss: 0.0711 - acc: 0.9785 - val_loss: 1.1027 - val_acc: 0.7704
    
```

Figure. IV.9. : Résultat de l’entrainement du modèle VGG16

a) Les tableaux suivants montrent les résultats de l’entrainement de nos deux modèles pour la première et la dernière itération :

Itération 1

	Acc train	Acc validation	Loss train	Loss validation
CNN	0.618	0.280	1.037	1.538
VGG16	0.613	0.727	1.678	2.389

Itération 30

	Acc train	Acc validation	Loss train	Loss validation
CNN	0.923	0.736	0.282	0.781
VGG16	0.978	0.770	0.071	1.102

(a) Résultats des deux modèles pour l’itération 1

(b) Résultats des deux modèles pour l’itération 30

Tab. IV.1. : Résultats d’entrainement des deux modèles

- Si nous faisons une comparaison entre ces deux itérations nous constatons que le taux d’erreur baisse tandis que la précision augmente ; cela signifie que les deux modèles ont été bien entraînés.

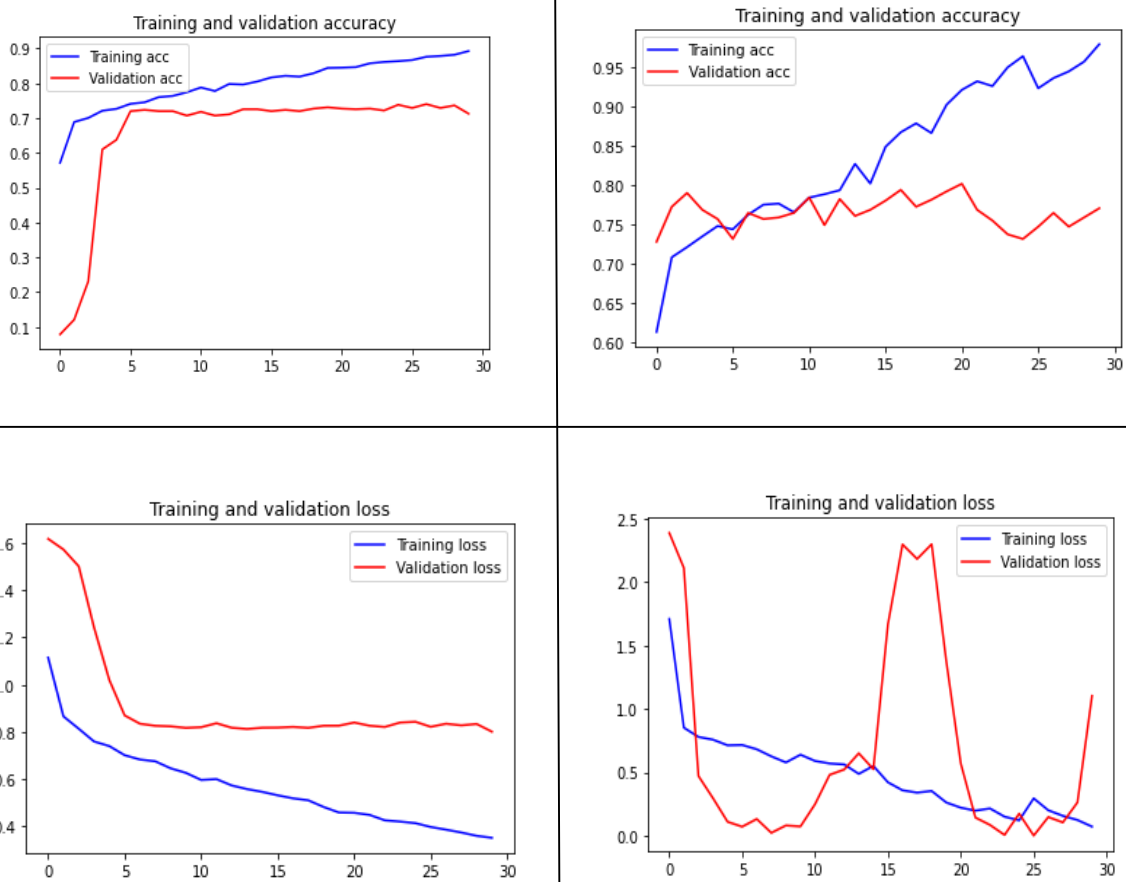
b) Le tableau ci-dessous montre les différents résultats obtenus sur les deux modèles

	Data	Taille du lot	Nombre d’itérations	Learning Rate	Train	Validation	Test
CNN	Notre dataset RD (224x224)	32 images	30	0.00001	0.923	0.736	0.759
VGG16		80 images	30	0.0001	0.978	0.770	0.794

Tab. IV.2. : Comparaison des résultats de VGG16 et de CNN

- Le tableau ci-dessus permet de faire une comparaison des deux modèles, en utilisant le même jeu de données et le même nombre d'itérations ; la taille du lot et le taux d'apprentissage (Learning rate) sont différents. Les résultats obtenus sont exprimés en termes de précision d'apprentissage, de validation, de test. Le modèle VGG16 a présenté les meilleurs résultats.

La figure. IV.10. ci-dessous illustre la précision et la perte des deux modèles.



(a) Taux de précision et d'erreur pour CNN (b) Taux de précision et d'erreur pour VGG16

Figure. IV.10. : Représentation de la précision et la perte des modèle VGG16 et CNN

- La précision d'apprentissage et de validation obtenue est relativement acceptable pour les deux modèles ; elle augmente avec le nombre d'itérations. Ceci reflète qu'à chaque itération, les deux modèles apprennent plus d'informations. De même, l'erreur d'apprentissage diminue avec le nombre d'itérations.

Nous constatons que le modèle VGG16 apprend plus d'information que le modèle CNN pour 30 itérations ; les performances sont meilleures que celles de CNN.

- Bien que le modèle VGG16 donne de meilleurs résultats que CNN, le modèle CNN est plus stable.

4.7 Précisions

Dans les deux prochaines sections, nous présenterons quelques-uns des résultats obtenus par les classificateurs proposés pour les deux modèles CNN et VGG16.

4.7.1 Matrice de confusion

Pour savoir quelles sont les erreurs commises par le modèle de classification, on utilisera la matrice de confusion qui donne un résumé sur les résultats de prédiction.

Les figures. IV.11 et 12 illustrent les matrices de confusion de nos deux modèles.




Figure. IV.11. : Matrice de Confusion pour le modèle CNN


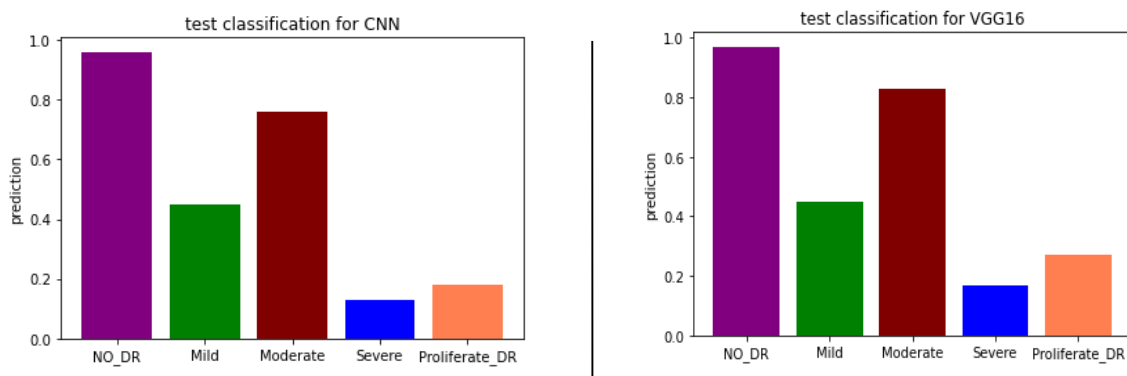


Figure. IV.12. : Matrice de confusion pour le modèle VGG16

- La matrice de confusion permet d'évaluer la performance des deux modèles, puisqu'elles reflètent les métriques du vrai positif, vrai négatif, faux positif et faux négatif. Les deux modèles ont bien classé les images rétinienne. La Figure. IV.13 illustre la représentation graphique du taux de classification pour CNN et VGG16.



(a) Taux de classification pour CNN (b) Taux de classification pour VGG16

Figure. IV.13. : Représentation graphique du taux de classification des images

Le tableau. IV.3 ci-dessous montre le taux de classification des deux modèles :

	<i>No_DR</i>	<i>Mild</i>	<i>Moderate</i>	<i>Severe</i>	<i>Prolifere_DR</i>
CNN	0.96	0.45	0.76	0.13	0.18
VGG16	0.98	0.45	0.83	0.17	0.27

Tab. IV.3. : Comparaison du taux de classification des deux modèles

- Nous remarquons que le modèle VGG16 a une bonne prédiction des classes rétinienne par rapport au CNN ; par conséquent les erreurs de classification seront réduites.

4.7.2 Rapport de classification

Le tableau ci-dessous montre les différents résultats de rapport de classification :

		<i>No_DR</i>	<i>Mild</i>	<i>Moderate</i>	<i>Severe</i>	<i>Prolifere_DR</i>
CNN	<i>Précision</i>	0.90	0.44	0.63	0.44	0.62
	<i>Rappel</i>	0.96	0.45	0.76	0.13	0.18
VGG16	<i>Précision</i>	0.94	0.57	0.65	0.45	0.55
	<i>Rappel</i>	0.98	0.45	0.83	0.17	0.27

Tab. IV.4. : Comparaison de la précision et du rappel des deux modèles

- Pour évaluer les performances de nos deux modèles, nous allons utiliser le rapport de classification qui indique la proportion de résultats positifs réels identifié correctement (*rappel*) ainsi que la proportion d'identifications positives qui est effectivement correcte (*précision*). Les résultats de rappel et de précision montrent que bien qu'on ait utilisé la même base de données pour l'apprentissage et pour le test, le VGG16 est plus performante que le CNN (cf. Tab. IV.4).
- Le VGG16 est un modèle pré-entraîné, il nous a permis de résoudre le problème de classification d'une manière simple en utilisant la technique de " Transfer Learning " et d'avoir ainsi une meilleure qualité des résultats pour uniquement 30 itérations d'entraînement. La base d'apprentissage est également un élément déterminant dans les réseaux de neurones convolutionnels, alors il faut avoir une base d'apprentissage de grande taille pour aboutir à de meilleurs résultats.

4.8 Discussion

D'après les résultats obtenus dans les Figures IV.9, IV.10 et IV.12, nous remarquons que le modèle VGG16 donne des résultats très satisfaisants, ce qui confirme le choix de ce modèle pour augmenter la performance de la classification de la RD.

A partir des tableaux IV.3 et IV.4, nous observons que les performances des modèles de classification augmentent sur différentes mesures utilisées. En effet, l'effet d'augmenter la base de données permet au classifieur CNN et VGG16 d'enrichir les informations des données à classer. Il permet aussi au modèle de classer les images de manière robuste, même s'il est placé dans différentes orientations. Il est doté de la propriété appelée invariance.

4.9 Présentation du déroulement de l'application

Cette application Site Web peut détecter et classer les cinq stades de la rétinopathie diabétique en utilisant des images rétinienne. Nous avons utilisé un modèle VGG16 pré-entraîné ; le modèle est formé sur l'ensemble de données accessibles au public de Kaggle.

4.9.1 Création de notre d'application Web

Les étapes suivies pour créer notre application Web sont listées ci-dessous :

- Utilisation du modèle entraîné pour faire la prédiction sur les données de test.
- Utilisation du framework python Flask pour créer une application Web simple et interactive.
- Déploiement de l'application Web sur localhost et sur Google colab.
- Utilisation du modèle pré-entraîné VGG16 formé sur des données ImageNet.
- Affichage du résultat sur le navigateur.

4.9.2 Structure de notre projet de l'application Web

La structure de notre projet est illustrée dans la Figure. IV.14, comme suit :



Figure. IV.14. : Illustration de la structure de l'application Web.

- **Dossier statique** : ce support est présent dans notre dossier racine et contiendra tous les fichiers statiques tels que css, fichiers js, fichiers logo.png, poids du modèle, ...
- **Dossier templates** : ce dossier contiendra tous les fichiers HTML que nous utiliserons dans tout le projet. Toutes les redirections et le routage se feront via ce dossier. C'est l'endroit par défaut où Flask recherche les modèles de rendu lorsque nous utiliserons la fonction `render_template ()`.
- **Fichier app.py** : il s'agit du fichier principal back-end. Nous écrivons tous les codes back-end pour la logique Flask et python dans ce fichier.
Nous exécuterons ce fichier pour démarrer le serveur pour héberger notre application. Ce fichier est essentiellement un lien entre les fichiers HTML affichant la sortie sur le navigateur et l'appel de modèle.
- **Fichier index.html** : il s'agit de la page Web par défaut qui s'affiche lors du chargement de l'application. Pour accéder aux images de la Galerie de l'appareil utilisé, on appuiera sur le bouton "Drop image here or click to select". En fonction des choix effectués, on pourra télécharger l'image depuis l'ordinateur ou le Smartphone et l'envoyer ensuite à l'application qui analysera l'image. Le résultat du diagnostic de la rétinopathie diabétique est ensuite généré en un temps très minime (environ en trois secondes).

4.10 Déploiement de l'application sur localhost et Google Colab

Une fois que tous les modèles et fichiers prêts, nous utilisons Flask pour déployer notre application sur localhost. Pour cela, il suffit d'aller dans le répertoire racine et de taper «python app.py» dans le terminal et d'appuyer sur Entrée, Cela démarrera notre serveur au port 5000 ou tout autre port.

- On recevra un message comme indiqué dans Figure. IV.15, une fois qu'on aura réussi à démarrer le serveur.

```
Model loaded. Start serving...  
Model loaded. Check "http://848fdc832757.ngrok.io" -> "http://127.0.0.1:5000/"
```

Figure. IV.15. : illustration du déploiement réussi du serveur principal.

- Après cette étape, ouvrons n'importe quel navigateur Web à partir de notre PC et tapons :
`"http://848fdc832757.ngrok.io" -> "http://127.0.0.1:5000/" / accueil`

- Maintenant, lorsque nous cliquons sur le lien ci-dessus, nous arrivons à la page index.html, de notre application, comme indiqué ci-dessous (cf. Figure. IV.16).

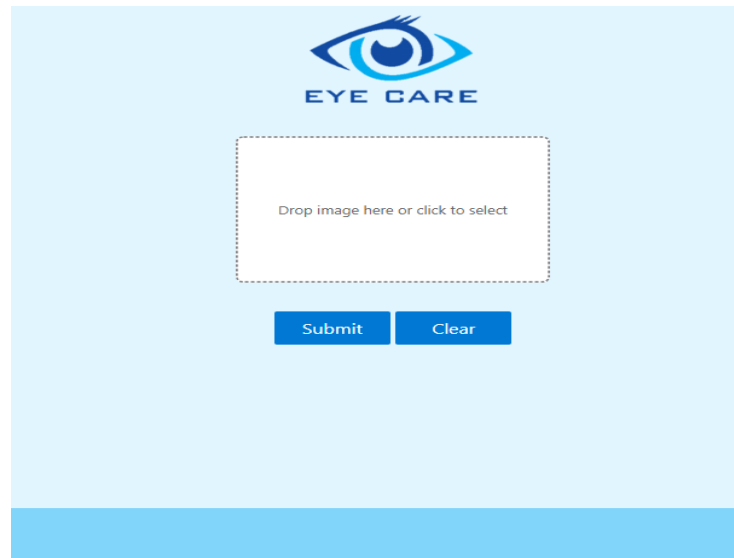


Figure. IV.16. : Page d'accueil de l'application

- En cliquant sur le bouton "*Déposer l'image ici ou Cliquer pour sélectionner*", nous amènera à la page checkup.html où nous allons sélectionner l'image du fond d'œil soit de notre galerie ou à partir d'autres fichiers existants. Après avoir cliqué sur le bouton "*Soumettre*", la page Web illustrée ci-dessous s'affiche (cf. Figure. IV.17).

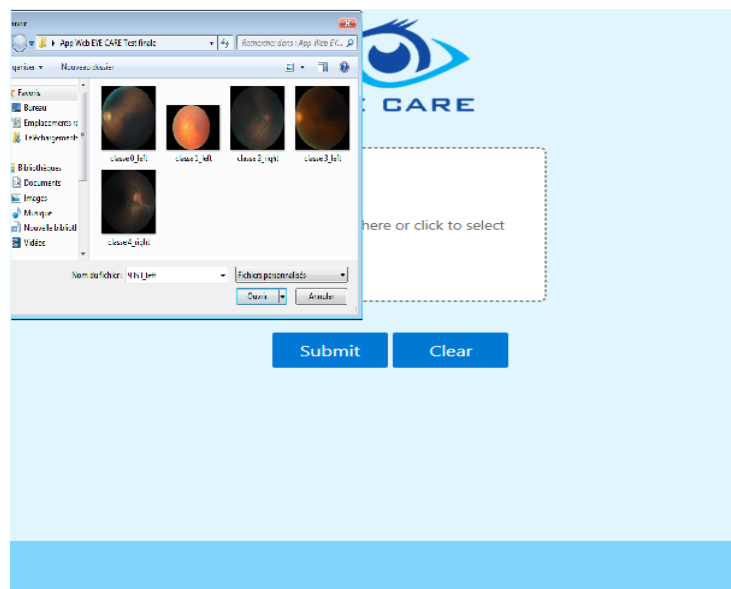


Figure. IV.17. : Chargement des images du fond d'œil

- Pour modifier l'image d'entrée, il suffit d'appuyer sur le bouton «*Clear*» et envoyer une autre image à l'application.

La Figure. IV.18 montre les résultats de classification des stades de la RD de notre application Web qui a pour but d'aider le médecin ophtalmologiste à prendre une décision afin de générer un diagnostic final.

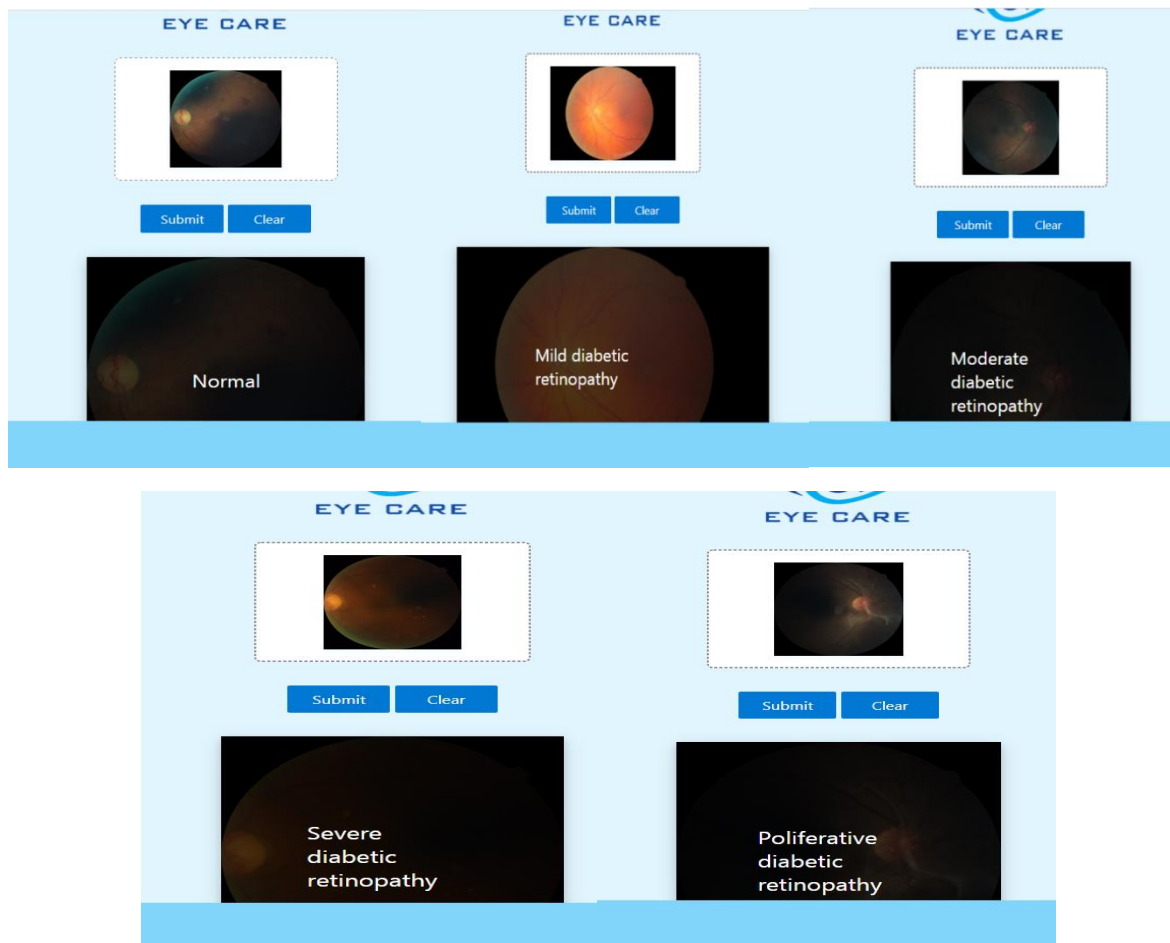


Figure. IV.18. : Résultats de classification des stades de la RD par notre application

4.11 Conclusion

Dans ce chapitre, nous avons présenté et détaillé la mise en œuvre de notre application, la configuration matérielle et logicielle utilisée. Après que les expérimentations aient été faites, nous avons présenté les résultats obtenus et comparé entre notre deux modèles CNN et VGG16.

A la fin, nous avons présenté, l'application Web "*EYE CARE*" développée dans le cadre de ce projet. Le développement ainsi que le déploiement de cette application ont été également décrits. Nous pensons que notre application Web permettra d'apporter une modeste contribution afin d'aider le médecin ophtalmologiste dans sa prise de décision thérapeutique.

Conclusion générale

Nous avons présenté dans ce mémoire, la description d'un système de classification de stades de la rétinopathie diabétique. Dans un premier temps, nous avons mené une étude bibliographique sur cette pathologie pour avoir une idée précise de cette maladie et les différences entre ses cinq types. Nous avons également survolé divers concepts en lien avec notre problématique, concernant l'imagerie médicale et l'apprentissage automatique.

La rétinopathie diabétique (RD), maladie chronique de la rétine, est une des principales causes de cécité et de malvoyance. La photo-coagulation par laser est aujourd'hui le traitement thérapeutique précoce principal utilisé pour ralentir la dégradation de la vision. Les études ont montré que le nombre de patients atteints de cette pathologie augmente chaque année ; par conséquent, le dépistage de la RD est devenu aujourd'hui un problème de santé publique.

Nos travaux entrent dans le cadre du développement d'un système d'aide au diagnostic médical orienté vers la classification des images de la rétine en utilisant les techniques avancées de l'apprentissage automatique, en particulier celles qui reposent sur l'apprentissage profond (ou *Deep Learning*) et les réseaux de neurones convolutionnels.

L'étude a été réalisée sur la base d'images "*Diabetic Retinopathy 224x224 Gaussian Filtered*" de Kaggle. Nous avons testé et implémenté deux architectures avec deux types d'apprentissage différents. La première architecture correspond à VGG16 avec le transfert d'apprentissage (transfer learning) et le deuxième est une architecture basée sur un réseau de neurones convolutionnel,

Pour avoir la meilleure architecture adéquate à notre problématique, nous avons mené une série de tests et de changements soit dans le côté architectural ou bien dans le côté paramétrage de plusieurs facteurs entrant en jeu durant la conception des CNN.

Cette architecture présente quelques inconvénients : une augmentation supplémentaire pour les images prises par différentes caméras avec différents champs de vision. En outre, notre architecture réseau est complexe et exige beaucoup de calculs, ce qui nécessite une unité de

Conclusion générale

traitement graphique de haut niveau pour traiter les images haute résolution lorsque le niveau des couches est plus élevé.

Afin d'avoir un classificateur offrant la plus grande précision, le système développé dans notre projet a été évalué par plusieurs critères. Les résultats obtenus par le système sont encourageants, par rapport aux approches proposées dans la littérature. Comme le système d'analyse de l'image du fond d'œil détecte des anomalies avec une bonne sensibilité et une spécificité raisonnable, il peut être utilisé pour aider les ophtalmologistes dans le diagnostic afin de leur fournir une aide. Notre système peut également fonctionner comme un outil pour le dépistage de masse de la RD.

Ce travail reste ouvert pour des travaux de comparaison et/ou d'hybridation avec d'autres méthodes de classification. Nous prévoyons aussi d'adopter des stratégies d'enrichissement et de sélection des échantillons d'apprentissage.

De plus, nous avons remarqué dans nos expérimentations qu'il existe une différence de précision pour chaque classe étudiée. En effet, certaines classes sont plus difficiles à identifier que d'autres. C'est là aussi une autre piste à étudier.

Bibliographie

- [1] Feroui, A., Bessaid, A. (2014). Analyse des images couleur du fond d'œil pour l'aide au diagnostic en ophtalmologie : application à la détection des pathologies rétinienne. Thèse de doctorat. Université de Tlemcen.
- [2] Benmessaoud, N., Benaouali, M. (2016) Conception et Réalisation D'une Application Android Dédiée À La Télé-ophtalmologie : Aide Au Dépistage De La Rétinopathie Diabétique (Master dissertation) Université Abou Bakr Belkaid -Tlemcen-.
- [3] Ahmed, M. S., & Indira, B. (2015). A survey on automatic detection of diabetic retinopathy. *International Journal of Computer Engineering and Technology*, 6(11), 36-45.
- [4] Hayashi, J., Kunieda, T., Cole, J., Soga, R., Hatanaka, Y., Lu, M., ... & Fujita, H. (2001, October). A development of computer-aided diagnosis system using fundus images. In *Proceedings Seventh International Conference on Virtual Systems and Multimedia*. pp. 429-438.
- [5] Klein, R., Klein, B. E., & Moss, S. E. (1984). Visual impairment in diabetes. *Ophthalmology*, 91(1), 19.
- [6] Sjølie, A. K., Stephenson, J., Aldington, S., Kohner, E., Janka, H., Stevens, L., ... & Petrou, K. (1997). Retinopathy and vision loss in insulin-dependent diabetes in Europe: the EURODIAB IDDM Complications Study. *Ophthalmology*, 104(2), 252-260.
- [7] Feroui, A. (2009) Traitement automatique d'images du fond d'œil : Application au recalage des images rétinienne (Magister dissertation). Université Abou Bakr Belkaid -Tlemcen-.
- [8] Bensenouci, H., & Ahmed Brahim, (2013) A. Detection Des Lésions Lumineuses Dans Les Images Rétiniennes (Master dissertation). Université Abou Bakr Belkaid -Tlemcen-.
- [9] Lambert R : Le réseau de neurones convolutifs, <https://penseeartificielle.fr/focus-reseau-neurones-convolutifs/>, consultée le 25 mai 2020.
- [10] Feguri, A. (2018). Classification du degré de sévérité de l'hémorragie rétinienne (Master dissertation). Université Abou Bakr Belkaid -Tlemcen-.
- [11] Wilkinson, C. P., Ferris III, F. L., Klein, R. E., Lee, P. P., Agardh, C. D., Davis, M., ... & Group, G. D. R. P. (2003). Proposed international clinical diabetic retinopathy and diabetic macular edema disease severity scales. *Ophthalmology*, 110(9), 1677-1682.
- [12] Resnikoff, S., Pascolini, D., Etya'Ale, D., Kocur, I., Pararajasegaram, R., Pokharel, G. P., & Mariotti, S. P. (2004). Global data on visual impairment in the year 2002. *Bulletin of the world health organization*, 82, 844-851.

Bibliographie

- [13] Parment, S., Lynn, C., & Glass, R. M. (2006). Age-related macular degeneration. *JAMA*, 295(20), 2438-2438.
- [14] Ghorbel, I., Rossant, F., Bloch, I., Paques, M., & Tick, S. (2009). Segmentation des couches rétiniennes dans des images OCT : méthode et évaluation quantitative. In *MajecSTIC-2009*, Avignon, France.
- [15] Kristinsson, J. K., Hauksdottir, H., Stefansson, E., Jónasson, F., & Gíslason, I. (1997). Active prevention in diabetic eye disease: A 4- year follow-up. *Acta Ophthalmologica Scandinavica*, 75(3), 249-254.
- [16] Savolainen, E. A. Et Lee, Q. P. (1982), Diabetic retinopathy—need and demand for photocoagulation and its cost-effectiveness: evaluation based on services in the United Kingdom. *Diabetologia*, vol. 23, no 2, p. 138-140.
- [17] Early Treatment Diabetic Retinopathy Study Research Group. (1991). Early photocoagulation for diabetic retinopathy: ETDRS report number 9. *Ophthalmology*, 98(5), 766-785.
- [18] Bresnick, George H., Mukamel, Dana B., Dickinson, John C., et al. (2000). A screening approach to the surveillance of patients with diabetes for the presence of vision-threatening retinopathy. *Ophthalmology*, vol. 107, no 1, p. 19-24.
- [19] Beth. Baran, L'anatomie de l'œil santé des yeux,
[http : //www.pinterest.ca/pin/570620215272043467/](http://www.pinterest.ca/pin/570620215272043467/). Consultée le : 25 février 2020.
- [20] un membre de Centre de la Cornée et du Kératocone (CCK), La cornée, [https : //www.centre-cornee-keratocone.com/content/la-corn%c3%a9e](https://www.centre-cornee-keratocone.com/content/la-corn%c3%a9e), consultée le : 25 février 2020.
- [21] Giulio O., Ugo T., Louise V., & JAUSSEME, Les mécanismes de la vision, (TPE 2015-2016), Lycée Pierre <http://tpedaltonismepremiere.emonsite.com/pages/dossier/1.html>, consultée le : 25 février 2020.
- [22] Bediang, Georges, Panpom, Valère Abbou, Koki, Godefroy, *et al.* (2020). Utilisation d'un Logiciel d'Aide à la Décision pour le Dépistage de la Rétinopathie Diabétique au Cameroun. *Health Sciences And Disease*, vol. 21, no 3.
- [23] Lazzouni, S. (2014). Contusion oculaire a globe fermé (Doctoral dissertation). Université Abou Bakr Belkaid -Tlemcen-.
- [24] Bodaghi, B., Delyfer, M. N., Creuzot-Garcher, C., Kodjikian, L., Sellam, A., & Zayani, A. Rétine Et Vitré. Elsevier Health Sciences. Section 12 2015–2016, Partie II, chapitre 6.
[https : //www.emconsulte.com/em/sfo/h2018/b9782294756399000061.html](https://www.emconsulte.com/em/sfo/h2018/b9782294756399000061.html), consultée, le : 27 février 2020.
- [25] Adenis J.P. , Robert P.Y. , RÉTINOPATHIE DIABÉTIQUE (Cours), Campus numérique d'ophtalmologie, <http://umvf.omsk-osma.ru/campus-ophtalmologie/poly/0200faq.htm>, consultée le:01mars 2020.
- [26] Creuzot-Garcher C. et al. RAPPORT 2016 Œdèmes maculaires, Partie II chapitre 14, https://www.em-consulte.com/em/sfo/2016/html/file_100027.html, consultée le:27février2020.

Bibliographie

- [27] un membre de Syndicat National des Ophtalmologistes de France (SNOF), Progrès dans la chirurgie maculaire, https://www.snof.org/encyclopedie/r%c3%a9tine_, consultée le :28 février 2020.
- [28] Kyari, F. Gérer l'opération de la cataracte chez les patients présentant un glaucome. *Santé Oculaire*, 17(23), 12.
- [29] Arnoux, B. (2019). Dépistage de la rétinopathie diabétique : notre expérience en Champagne-Ardenne. *Revue Francophone d'Orthoptie*, 12(2), 88-91.
- [30] Monasse P, Nadjahi K : Qu'est-ce qu'un réseau de neurones convolutif (ou CNN) ? , <https://openclassrooms.com/fr/courses/4470531-classez-et-segmentez-des-donnees-visuelles/5082166-quest-ce-quun-reseau-de-neurones-convolutif-ou-cnn>, consultée le 29 mai 2020.
- [31] Hoang-Xuan, T. (2011) La cornéoplastie antérieure dans le kératocône. *Les Cahiers d'Ophtalmologie*, n°148:32-4. (Pagination pdf 1/3). <https://www.cahiers-ophtalmologie.fr/la-corneoplastie-anterieure-dans-le-keratocone>, consultée le 20 mars 2020.
- [32] Harrison, G. A., Weiner, J. S., Tanner, J. M., & Barnicot, N. A. (1964). *Human Biology. An Introduction to Human Evolution, Variation and Growth.* Human Biology. An Introduction to Human Evolution, Variation and Growth.
- [33] Bishop, C. M. (1995). *Neural networks for pattern recognition.* Oxford university press.
- [34] Dreyfus, G., & Idan, Y. (1998). The canonical form of nonlinear discrete-time models. *Neural Computation*, 10(1), 133-164.
- [35] Deng, L., & Yu, D. (2014). Deep learning: methods and applications. *Foundations and trends in signal processing*, 7(3-4), 197-387.
- [36] Bengio, Y. (2009). *Learning deep architectures for AI.* Now Publishers Inc.
- [37] Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.
- [38] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- [39] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- [40] Arel, I., Rose, D. C., & Karnowski, T. P. (2010). Deep machine learning-a new frontier in artificial intelligence research [research frontier]. *IEEE computational intelligence magazine*, 5(4), 13-18.
- [41] Schmidhuber, J. (2015). Deep learning. *Scholarpedia*, 10(11), 32832.
- [42] Moualek, D. Y. (2017). *Deep Learning pour la classification des images* (Master dissertation). Université Abou Bakr Belkaid -Tlemcen-.
- [43] Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.

Bibliographie

- [44] Hubara, I., Courbariaux, M., Soudry, D., El-Yaniv, R., & Bengio, Y. (2017). Quantized neural networks: Training neural networks with low precision weights and activations. *The Journal of Machine Learning Research*, 18(1), 6869-6898.
- [45] Van den Oord, A., Dieleman, S., & Schrauwen, B. (2013). Deep content-based music recommendation. In *Advances in neural information processing systems* (pp. 2643-2651).
- [46] Collobert, R., & Weston, J. (2008, July). A unified architecture for natural language processing: Deep neural networks with multitask learning. In *Proceedings of the 25th international conference on Machine learning* (pp. 160-167).
- [47] Matsugu, M., Mori, K., Mitari, Y., & Kaneda, Y. (2003). Subject independent facial expression recognition with robust face detection using a convolutional neural network. *Neural Networks*, 16(5-6), 555-559.
- [48] Mikolov, T., Karafiát, M., & Burget, L. (2010). Jan Černocký, and Sanjeev Khudanpur. 2010. Recurrent neural network based language model. In *Eleventh annual conference of the international speech communication association* (pp. 1045-1048).
- [49] Liu, S., Yang, N., Li, M., & Zhou, M. (2014). A recursive recurrent neural network for statistical machine translation. In *Association for Computational Linguistics, Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, (pp. 1491-1500).
- [50] Graves, A., & Jaitly, N. (2014, January). Towards end-to-end speech recognition with recurrent neural networks. In *International conference on machine learning* (pp. 1764-1772).
- [51] Karpathy, A., & Fei-Fei, L. (2015). Deep visual-semantic alignments for generating image descriptions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3128-3137).
- [52] Ng, A. Y., & Jordan, M. I. (2002). On discriminative vs. generative classifiers: A comparison of logistic regression and naive bayes. In *Advances in neural information processing systems* (pp. 841-848).
- [53] Ackley, D. H., Hinton, G. E., & Sejnowski, T. J. (1985). A learning algorithm for Boltzmann machines. *Cognitive science*, 9(1), 147-169.
- [54] Salakhutdinov, R., Mnih, A., & Hinton, G. (2007, June). Restricted Boltzmann machines for collaborative filtering. In *Proceedings of the 24th international conference on Machine learning* (pp. 791-798).
- [55] Hinton, G. E. (2012). A practical guide to training restricted Boltzmann machines. In *Neural networks: Tricks of the trade* (pp. 599-619). Springer, Berlin, Heidelberg.
- [56] Hinton, G. E., Osindero, S., & Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural computation*, 18(7), 1527-1554.
- [57] Salakhutdinov, R., & Hinton, G. (2009). Deep boltzmann machines. In *Artificial intelligence and statistics* (pp. 448-455).
- [58] Srivastava, N., & Salakhutdinov, R. R. (2012). Multimodal learning with deep boltzmann machines. In *Advances in neural information processing systems* (pp. 2222-2230).

Bibliographie

- [59] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., & Bengio, Y. (2014). Generative adversarial nets. In *Advances in neural information processing systems* (pp. 2672-2680).
- [60] Denton, E. L., Chintala, S., & Fergus, R. (2015). Deep generative image models using a laplacian pyramid of adversarial networks. In *Advances in neural information processing systems* (pp. 1486-1494).
- [61] Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.
- [62] Bengio, Y., Laufer, E., Alain, G., & Yosinski, J. (2014, January). Deep generative stochastic networks trainable by backprop. In *International Conference on Machine Learning* (pp. 226-234).
- [63] Makhzani, A., Shlens, J., Jaitly, N., Goodfellow, I., & Frey, B. (2015). Adversarial autoencoders. *ArXiv preprint arXiv : 1511.05644*.
- [64] Diallo, N., A., D., Kouahla, M., N. (2019). La reconnaissance des expressions faciales (Master dissertation). Université 8 Mai 1945 -Guelma-.
- [65] Chandrakumar, T., & Kathirvel, R. (2016). Classifying diabetic retinopathy using deep learning architecture. *Int J Eng Res Technol*, 5(6), 19-24.
- [66] Suriyal, S., Druzgalski, C., & Gautam, K. (2018). Mobile assisted diabetic retinopathy detection using deep neural network. In *2018 Global Medical Engineering Physics Exchanges/Pan American Health Care Exchanges (GMEPE/PAHCE)* (pp. 1-4).
- [67] Dreyfus, G. (2005). *Neural networks: methodology and applications*. Springer Science & Business Media.
- [68] Simpson, P.K. (1989). *Artificial neural systems: foundations, paradigms, applications, and implementations*. Elsevier Science Inc.
- [69] Blum, A. (1992). *Neural networks in C++: an object-oriented framework for building connectionist systems*. John Wiley & Sons, Inc.
- [70] Kosko, B. (1990). Unsupervised learning in noise. *IEEE Transactions on Neural Networks*, 1(1), 44-57.
- [71] Zhigljavsky, A. A. (2012). *Theory of global random search* (Vol. 65). Springer Science & Business Media.
- [72] Traynard, A. (1990). D'une méthode de gradient conjugué préconditionné élément par élément. In *Institut National de Recherche en Informatique et en Automatique*, 39 pages.
- [73] Julien Chevallier, Patricia Reynaud-Bouret, Nos Neurones Se Synchronisent-Ils ?, <http://images.math.cnrs.fr/nos-neurones-se-synchronisent-ils.html?lang=es>, consultée le : 05 mars 2020.
- [74] Laqrichi, S., Gourc, D., & Marmier, F. (2015). Toward an effort estimation model for software projects integrating risk. *arXiv preprint arXiv:1509.00602*.

Bibliographie

- [75] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [76] Tian, X., Hérault, R., Gasso, G., Canu, S., & EA4108, L. I. T. I. S. (2010, January). Pré-apprentissage supervisé pour les réseaux profonds. In *Proceedings of Rfia* (Vol. 2010, p. 36).
- [77] Ziane, K. (2017). *Analyse, Évaluation et Réduction des Risques d'un Parc Éolien* (Doctoral dissertation). Université d'Oran 2.
- [78] Admin de hospitalia, IA en imagerie médicale : une technologie de rupture en marche, https://www.hospitalia.fr/ia-en-imagerie-medecale-une-technologie-de-rupture-en-marche_a1538.html, consultée le : 06 mars 2020.
- [79] Sánchez, P. A. S., González, J. R. G., Fajardo-Toro, C. H., & Sánchez, P. M. T. M. (2020). Designing a Neural Network Model for Time Series Forecasting. In *Theoretical and Applied Mathematics in International Business* (pp. 259-284). IGI Global.
- [80] Raveane, W., & Green, C. (2017). U.S. Patent Application No. 15/039,855.
- [81] Pröve, P. (2017). An introduction to different types of convolutions in deep learning. *Towards Data Science*, 22. (Document web), <https://towardsdatascience.com/types-of-convolutions-in-deep-learning-717013397f4d>, consultée le: 06 mars 2020.
- [82] Yannick Serge Obam, Comprendre les Réseaux de Neurones Convolutifs (CNN), <https://medium.com/@yannicksergeobam/comprendre-les-r%c3%a9seaux-de-neurones-convolutifs-cnn-d5f14d963714>, consultée le : 06 mars 2020.
- [83] Mageswaran D., Text Information Extraction (part 2 : tf.keras Convolutional API), <https://blog.imaginea.com/text-information-extraction-2/>, consultée le : 06 mars 2020.
- [84] Villani, C., Bonnet, Y., Berthet, C., Levin, F., Schoenauer, M., Cornut, A. C., & Rondepierre, B. (2018). Donner un sens à l'intelligence artificielle: pour une stratégie nationale et européenne. Conseil national du numérique.
- [85] Panadda K. (2019). CNN : Step 3— Flattening, https://medium.com/@PK_KwanG/cnn-step-2-flattening-50ee0af42e3e, consultée le : 06 mars 2020.
- [86] Wang, X., Lu, Y., Wang, Y., & Chen, W. B. (2018). Diabetic retinopathy stage classification using convolutional neural networks. In *2018 IEEE International Conference on Information Reuse and Integration (IRI)* (pp. 465-471).
- [87] Alban, M., & Gilligan, T. (2016). Automated detection of diabetic retinopathy using fluorescein angiography photographs. Report of standford education.
- [88] Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural networks*, 12(1), 145-151.
- [89] Deperlioğlu, Ö., & Köse, U. (2018). Diagnosis of Diabetic Retinopathy by Using Image Processing and Convolutional Neural Network. In *2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-5).
- [91] Wikipédia, Réseaux neuronal convolutif,

Bibliographie

https://fr.wikipedia.org/wiki/r%c3%a9seau_neuronal_convolutif_, consultée le : 27 mars 2020.

[92] Gülgün, O. D., & Hamza, E. R. O. L. (2020). Classification Performance Comparisons of Deep Learning Models in Pneumonia Diagnosis Using Chest X-Ray Images. *Turkish Journal of Engineering*, 4(3), 129-141.

[93] Wang, Z., & Yang, J. (2017). Diabetic retinopathy detection via deep convolutional networks for discriminative localization and visual explanation. *arXiv preprint arXiv:1703.10757*.

[94] Kerenidis, I., Landman, J., & Prakash, A. (2019). Quantum algorithms for deep convolutional neural networks. *arXiv preprint arXiv:1911.01117*.

[95] Wikipédia, Python(langage), [https://fr.wikipedia.org/wiki/python_\(langage\)](https://fr.wikipedia.org/wiki/python_(langage)), consultée le : 04avril 2020.

[96] Tammina, S. (2019). Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images. *International Journal of Scientific and Research Publications*, 9(10), 143-150.

[97] Damelincourt J : Présentation et historique des réseaux neuronaux. <https://www.futura-sciences.com/tech/dossiers/robotique-presentation-historique-reseaux-neuronaux-31/>, consultée le 8 mai 2020.

[98] Touzet, C. (1992). les réseaux de neurones artificiels, introduction au connexionnisme. <https://hal-amu.archives-ouvertes.fr/hal-01338010>, consultée le 8 mai 2020.

[99] Khellout, S., & Lakhdari, H. (2017). Etude et application du réseau ELM-LRF en classification des images (Master dissertation). Université Mouloud Mammeri.

[100] Habba, A., Ishak, O., & Ouahab, A. (2019). La classification des images satellitaires par l'apprentissage profonde (deep learning) (Master dissertation). Université Ahmed Draïa-Adrar.

[101] Tertre M, Intelligence artificielle : Comprendre le Deep et le Machine Learning, <https://blogs.mediapart.fr/marc-tertre/blog/130318/intelligence-artificielle-comprendre-le-deep-et-le-machine-learning>, consultée le 26 mai 2020.

[102] Meilleur C, Intelligence artificielle : de la programmation manuelle à l'apprentissage profond, <https://knowledgeone.ca/artificial-intelligence-from-manual-programming-to-deep-learning/?lang=fr>, consultée le 26 mai 2020.

[103]Gastard R : La vraie différence entre machine Learning et deep Learning, <https://www.jedha.co/blog/la-vraie-difference-entre-machine-learning-deep-learning>, consultée le 28 mai 2020.