

الجمهورية الجزائرية الديمقراطية الشعبية
REPUBLICUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
جامعة أبي بكر بلقايد - تلمسان
Université Aboubakr Belkaïd – Tlemcen –
Faculté de TECHNOLOGIE



THESE

Présentée pour l'obtention du grade de DOCTORAT 3^{ème} Cycle

En : Génie biomédical

Spécialité : Imagerie médicale

Par : ELAOUABER Zineb Aziza

Sujet

**Systeme d'aide au diagnostic pour la détection automatique
du Glaucome et de la Rétinopathie diabétique**

Soutenue publiquement, le 30 / 09 /2023, devant le jury composé de :

Mr Hadj Slimane Zinedine	Professeur	Univ. Tlemcen	Président
Mr Messadi Mahammed	Professeur	Univ. Tlemcen	Directeur de thèse
Mr Lazouni Mohamed EL Amine	MCA	Univ. Tlemcen	Co- Directeur de thèse
Mr Maliki Fouad	MCA	ESSA, Tlemcen	Examinateur
Mme Benchaib Yasmine	MCA	Univ. Tlemcen	Examinatrice
Dr Zahar Sofiane	Ophtalmologue		Invité

Remerciements

Avant toute personne, je remercie "Allah" le tout puissant et miséricordieux qui m'a donné le courage, la patience et la volonté pour accomplir ce travail.

Avec tout terme de gratitude, j'adresse mes sincères remerciements à mon directeur de thèse **Mr. Messadi Mohamed** et mon co-directeur **Mr. Lazouni Mohamed El Amine** pour m'avoir appris à être plus autonome et persistante tout au long de la réalisation de cette thèse, pour m'avoir très justement guidé pendant la période de leurs encadrements, pour leurs temps qu'ils m'ont consacré et pour leurs aides à avoir terminé cet humble travail.

C'est avec reconnaissance que j'exprime mes respectueux remerciements aux membres des jurés : **Pr Hadj Slimane Zinedine, Dr Maliki Fouad, Dr Benchaib Yasmine** et **DR Zahar Sofiane** pour avoir bien accepté d'évaluer et juger cette thèse, que je souhaiterais qu'elle sera à la hauteur de leurs attentes.

Je tiens à remercier également les membres de la clinique d'ophtalmologie **Lazouni** pour m'avoir ouvert leurs portes, pour m'avoir aidé à collecter les informations nécessaires dans ma recherche sans faille.

Mes gratitudes s'adressent aussi au staff médical de **l'hôpital militaire de Ain Naadja** dans le service d'ophtalmologie et de DEMA spécialement Mme Tlemceni Feriel Sakina et Mr Tedjini fayçal pour leur accueil chaleureux, leur gentillesse et pour m'avoir procuré les éléments dont j'avais besoin dans mon travail.

Mes remerciements vont aussi à mes amis et collègues Hadjer, Khadidja, Brahim, Wissem, Ahmed, Mohamed, Asma, Nadia, Sara et Amine Brixi pour leurs nombreux avis et conseils, pour leurs encouragements, pour m'avoir offert la bonne atmosphère de travail et pour les beaux moments qu'on a passé ensemble.

Au terme de cette thèse, je remercie tout l'ensemble des enseignants et doctorants du laboratoire de recherche de Génie Biomédical.

Enfin, je remercie spécialement et personnellement mes chers parents, ma famille, mes amis et toute personne contribuant, de près ou de loin, à l'achèvement de ce travail.

Dédicace

Après des années d'efforts continus et au cours d'un cursus plein de défis et de difficultés, le jour est venu pour présenter le fruit de ces persistances.

Aujourd'hui, ma thèse voit le jour et avec fierté je la dédie tout d'abord à mes chers parents : ma chère mère et mon cher père, qu'autant de termes aussi expressifs soient-ils ne sauraient leur exprimer mes sincères gratitude pour leur éducation digne, leur soutien continu et leur présence à mes côtés.

C'est avec joie que je dédie cette thèse également à mes chers frères pour leur témoignage, à ma belle-sœur et mes adorables neveux et à tout membre de ma famille.

Je tiens aussi, avec reconnaissance à dédier cet humble travail à mes proches, mes amies, et à toute bonne personne que j'ai rencontrée dans ma vie.

Résumé

Le glaucome et la rétinopathie diabétique sont deux affections oculaires courantes qui peuvent entraîner des problèmes de vision sévères, voire la cécité, si elles ne sont pas détectées et traitées à temps. Il est important de souligner que ces deux pathologies peuvent être asymptomatiques aux premiers stades, ce qui rend le dépistage précoce essentiel pour prévenir des graves complications.

Pour remédier à ce problème, nous avons développé un système autonome basé sur les techniques de traitement d'images et les algorithmes de l'intelligence artificielle pour dépister ces deux pathologies afin de réduire le risque de la cécité.

Notre système développé dans cette thèse est basé sur trois étapes principales : La segmentation des différentes régions de l'œil telles que le réseau rétinien, le disque optique, et le cup optique à partir des images rétiniennes en employant les modèles de deep learning.

Ensuite, un ensemble de paramètres sont calculés à partir des images segmentées pour les utilisés dans l'étape de classification afin de distinguer entre un sujet sain et un sujet pathologique (glaucome ou rétinopathie diabétique). Cette étape a été effectuée à l'aide de plusieurs classifieurs d'apprentissage supervisé.

Les méthodes proposées ont été testées sur différentes bases d'images publiques et une base collectée localement. Pour évaluer quantitativement les performances de nos méthodes diverses métriques d'évaluation sont calculées.

D'après les résultats obtenus nous constatons que les modèles proposés ont donné des résultats remarquables, similaires ou même meilleurs que ceux de la littérature.

Mots clés : Glaucome, Rétinopathie diabétique, Image rétinienne, Traitement d'images, Apprentissage automatique, Apprentissage profond.

Abstract

Glaucoma and diabetic retinopathy are two common eye diseases that may lead to severe vision problems and even blindness if undetected and untreated early. It is important to emphasize that both conditions might be asymptomatic in their early stages, making early detection essential to prevent serious complications.

To solve this problem, we developed an autonomous system based on image processing techniques and artificial intelligence algorithms to detect these two pathologies in order to reduce the blindness risk.

Our developed system in this thesis is based on two main steps: The segmentation of different regions of the eye such as the retinal blood vessels, the optic disc, and the optic cup from color retinal images using deep learning models.

Then, a set of parameters are calculated from the segmented images, which are then used in the classification step to distinguish between a healthy and a pathological subject (glaucomatous or diabetic retinopathy). This step was carried out using several supervised learning classifiers.

The proposed methods are tested on different public image databases and a locally collected database. To quantitatively evaluate the performance of our methods, various evaluation metrics are computed.

According to the obtained results, we conclude that the proposed models gave remarkable results, similar or even better than those in the literature.

Key words: Glaucoma, Diabetic retinopathy, Retinal image, Image processing, Machine learning, Deep learning.

ملخص

يعتبر الجلوكوما واعتلال الشبكية السكري من أمراض العين الشائعة التي يمكن أن تؤدي إلى مشاكل شديدة في الرؤية، أو حتى العمى، إذا لم يتم اكتشافها وعلاجها في الوقت المناسب. من المهم ملاحظة أن هاتين الحالتين يمكن أن تكون بدون أعراض في المراحل المبكرة، مما يجعل الاكتشاف المبكر ضرورياً لمنع المضاعفات الخطيرة.

لعلاج هذه المشكلة، قمنا بتطوير نظام مستقل يعتمد على تقنيات معالجة الصور وخوارزميات الذكاء الاصطناعي لاكتشاف هذين المرضين من أجل تقليل خطر الإصابة بالعمى.

يعتمد نظامنا الذي تم تطويره في هذه الأطروحة على ثلاث خطوات رئيسية: تجزئة مناطق مختلفة من العين مثل شبكة الشبكية والقرص البصري والكأس البصري من صور الشبكية باستخدام نماذج التعلم العميق.

بعد ذلك، يتم حساب مجموعة من المعلمات من الصور المجزأة للصورة المستخدمة في خطوة التصنيف للتمييز بين الموضوع الصحي والموضوع المرضي (الجلوكوما أو اعتلال الشبكية السكري). تم تنفيذ هذه الخطوة باستخدام العديد من مصنفات التعلم الخاضعة للإشراف.

وجرى اختبار الأساليب المقترحة على قواعد بيانات مختلفة للصور العامة وقاعدة بيانات تم جمعها محلياً. للتقييم الكمي لأداء أساليبنا يتم حساب مقاييس التقييم المختلفة.

بناءً على النتائج التي تم الحصول عليها، نجد أن النماذج المقترحة أعطت نتائج ملحوظة، مماثلة أو حتى أفضل من تلك الموجودة في الأدبيات.

الكلمات المفتاحية: الجلوكوما، اعتلال الشبكية السكري، صورة الشبكية، معالجة الصور، التعلم الآلي، التعلم العميق

Table de matière

Résumé.....	I
Abstract.....	II
Table de matière.....	III
Liste des figures.....	VIII
Liste des tableaux.....	XII
Liste des acronymes.....	XIII
Introduction générale.....	1

Chapitre I : Contexte médical

1. Introduction	8
2. Anatomie de l'œil	8
2.1. La cornée.....	8
2.2. La rétine	9
2.3. Le nerf optique.....	9
2.4. La papille optique	10
3. Les pathologies oculaires :	10
3.1. Glaucome	10
3.1.1. Définition du glaucome.....	10
3.1.2. Types du glaucome.....	12
3.2. Rétinopathie diabétique	12
3.2.1. Définition du diabète.....	13
3.2.2. Définition de la rétinopathie diabétique	14
3.2.3. Les stades de la rétinopathie diabétique.....	14
3.2.4. Lésions correspondantes à l'apparition de la RD.....	16
4. Techniques d'exploration des pathologies oculaires :.....	17
4.1. Tonométrie :.....	18
4.1.1. Tonomètre à aplanation.....	18
4.1.2. Tonomètre à jet d'air	19
4.2. Pachymétrie	19
4.3. Périmétrie ou Champ Visuel.....	21
4.3.1. Périmétrie automatisée	21
4.3.2. La périmétrie à doublement de fréquence FDT (Frequency Doubling Technology)	22

4.4. Rétinographie.....	22
4.5. Tomographie par Cohérence Optique (OCT)	23
4.5.1. OCT du nerf optique	23
4.5.2. OCT Maculaire.....	24
4.6. Angiographie à la fluorescéine	24
5. Conclusion.....	25

Chapitre II : Etat de l’art et base de données

1. Introduction	27
2. Etat de l’art	27
2.1. Glaucome	27
2.2. Rétinopathie diabétique (RD)	33
3. Bases de données (BDD).....	38
3.1. DRIVE (Digital Retinal Images for Vessel Extraction)	38
3.2. HRF (High Resolution Fundus).....	39
3.3. CHASE_DB1 (Child Heart and Health Study in England)	39
3.4. STARE (STructured Analysis of the Retina)	40
3.5. MESSIDOR (Méthodes d'Evaluation de Systèmes de Segmentation et d'Indexation Dédiées à l'Ophtalmologie Rétinienne)	40
3.6. RIM-ONE (An open retinal image database for optic nerve evaluation).....	41
3.7. DRISHTI-GS1	41
3.8. Base locale collectée	42
3.9. DRIONS-DB (Digital Retinal Image for Optic Nerve Segmentation Database)	43
3.10. ORIGA (Online Retinal Images for Glaucoma Analysis)	43
3.11. ACRIMA	43
4. Conclusion	45

Chapitre III : Techniques de traitement des images rétiniennes et principe d’apprentissage profond

1. Introduction	47
2. Techniques de traitement d’images médicales	47
2.1. Prétraitement	47
2.1.1. Filtre médian.....	48
2.1.2. Filtre gaussien.....	48
2.1.3. Filtre morphologique	48
2.1.4. Egalisation d’histogramme adaptative (AHE).....	49

2.1.5. Egalisation d’histogramme adaptative limité en contraste	49
2.1.6. Matrice de hessienne	49
2.2. Segmentation d’images	49
2.2.1. Segmentation par la méthode ISODATA.....	50
2.2.2. K-Means	50
2.2.3. Fuzzy C-Means (FCM).....	50
2.2.4. Contour actif.....	51
2.3. Post-traitement	51
3. Apprentissage automatique.....	52
3.1. Algorithmes de classification supervisée.....	53
3.1.1. K-plus-proches-voisins (k-Nearest Neighbor, KNN).....	53
3.1.2. Arbre de décision	54
3.1.3. Machines à vecteurs de supports (Support Vector Machine SVM).....	54
3.1.4. Analyse discriminante linéaire (Linear Discriminant Analysis LDA).....	55
3.1.5. Réseau de neurones artificiel (Artificial Neural Network ANN).....	56
4. Apprentissage profond ou Deep learning	58
4.1. Réseaux de neurones convolutifs (CNN).....	59
4.2. Couches des réseaux neuronaux convolutifs	60
4.2.1. Couche de convolution (CONV).....	60
4.2.2. Fonctions d’activation	60
4.2.3. Couche de pooling (POOL).....	64
4.2.4. Couche entièrement connectée (FC)	64
4.2.5. Couche de déconvolution (convolution transposée)	65
4.2.6. Couche de normalisation	65
4.2.7. Couche de Dropout.....	65
4.2.8. Fonction de perte :.....	66
4.3. Algorithmes d’optimisation	66
4.4. Les hyperparamètres en apprentissage profond.....	67
4.5. Architectures d’apprentissage profond populaires pour la segmentation sémantique... 68	
4.5.1. SegNet	68
4.5.2. U-Net.....	69
4.6. Les architectures les plus utilisées pour la classification d’images	70
4.6.1. VGGNet	70
5. Les métriques d’évaluation.....	71

6. Conclusion	73
---------------------	----

Chapitre IV : Détection automatique du glaucome : Méthodes et Résultats

1. Introduction	75
2. Méthodes proposées	75
2.1. Prétraitement : Extraction de la région d'intérêt	76
2.2. Segmentation du disque et cup optique	76
2.2.1. Techniques du traitement d'images pour détecter le disque/ Cup optique.	77
2.2.1.1. Segmentation du disque optique.....	77
2.2.1.2. Segmentation du cup optique	78
2.2.1.3. Lissage des contours du disque et cup.....	79
2.2.1.4. Résultats et discussion des méthodes classiques	79
2.2.2. Algorithmes d'apprentissage profond pour détecter CO et DO	80
2.2.2.1. Préparation et augmentation des données.....	80
2.2.2.2. Segmentation du CO et DO	81
A. Architecture SegNet modifiée	81
B. U-Net modifiée	83
2.2.2.3. Résultats et discussion	84
2.3. Extraction de caractéristiques	89
2.4. Classification	91
2.4.1. Résultats et discussions de l'étape de classification.....	91
4. Conclusion.....	94

Chapitre V : Détection automatique de la rétinopathie diabétique : Méthodes et Résultats

1. Introduction	96
2. Méthodes proposées	96
2.1 Prétraitement et augmentation des données	96
2.2. Segmentation du réseau vasculaire rétinien.....	97
2.2.1. Techniques de traitement d'images classiques pour segmenter le réseau rétinien .	97
2.2.1.1. Prétraitement.....	97
2.2.1.2. Segmentation des vaisseaux sanguins	98
2.2.1.3. Résultats et discussion	98
2.2.2. Méthodes de deep learning pour l'extraction du réseau rétinien	99
2.2.2.1. Augmentation des données.....	99
2.2.2.2. Segmentation du réseau rétinien.....	100

A. SegNet originale	100
B. SegNet modifié	101
C. U-Net originale	102
D. U-Net modifié.....	102
E. CNN 1.....	103
F. CNN 2.....	103
2.2.2.3. Résultats et discussion	105
2.3. Extraction de caractéristiques	109
2.4. Classification	111
2.4.1. Résultats et discussion de la classification.....	111
3. Conclusion	115
Conclusion générale.....	116
Références.....	119

Liste des figures

Figure I.1 : Anatomie du globe oculaire.....	8
Figure I.2 : Schéma de la rétine.....	9
Figure I.3 : Progression de la vision chez un glaucomateux.....	11
Figure I.4 : La différence entre une vision normale et une vision avec RD.....	14
Figure I.5 : Les différentes lésions de la RD.....	17
Figure I.6 : Les examens cliniques pour le diagnostic du glaucome et de la RD.....	18
Figure I.7 : Tonométrie à aplanation. (a) Appareil ; (b) Image observée ; (c) Principe de fonctionnement.....	19
Figure I.8 : Tonométrie à jet d'air. (a) Appareil ; (b) Principe de fonctionnement.....	19
Figure I.9 : Pachymétrie. (a) OCT de segment antérieur ; (b) Image topographique.....	20
Figure I.10 : Périmétrie. (a) Appareil OPTOPOL PTS 1000 ; (b) Image saine ; (c) Image glaucomateuse.....	21
Figure I.11 : Rétinographie. (a) Rétinographe ; (b) Image fond d'œil de la tête du nerf optique ; (c) Image fond d'œil rétinienne.....	23
Figure I.12 : Examen OCT. (a) Appareil OCT Heidelberg ; (b) Image de l'OCT papillaire ; (c) Image de l'OCT maculaire.....	24
Figure I.13 : Angiographie à la fluorescéine. (a) Angiographe ; (b) Image angiographique....	25
Figure II.1 : Exemple de la base DRIVE.....	39
Figure II.2 : Exemple de la base HRF.....	39
Figure II.3 : Exemple de la base CHASE_DB1.....	40
Figure II.4 : Exemple de la base STARE.....	40
Figure II.5 : Exemples des images de la base MESSIDOR.....	41
Figure II.6 : Exemple de la base RIM-ONE.....	41
Figure II.7 : Exemple de la base DRISHTI-GS1.....	41
Figure II.8 : Répartition de la base collectée selon le sexe.....	42
Figure II.9 : Exemple de notre base de données collectée.....	42
Figure II.10 : Exemples de la base DRIONS-DB avec contours du disque optique fournis par les experts.....	43

Figure II.11. Exemple de la base ORIGA.....	43
Figure II.12 : Exemples des images de la base de donnée ACRIMA.....	44
Figure II.13 : Résumé du nombre d'images normales, glaucomateuses et RD.....	45
Figure III.1 : Exemple de la méthode enveloppe convexe ; (a) ensemble de points X ; (b) l'enveloppe convexe de X.....	52
Figure III.2 : Représentation d'un réseau de neurone.....	57
Figure III.3 : Exemple d'un réseau de neurones MLP.....	57
Figure III.4 : Représentation de la liaison entre l'intelligence artificielle, machine learning et le deep learning.....	58
Figure III.5 : Exemple d'un CNN pour la classification des images rétiniennes.....	59
Figure III.6 : Principe de convolution pour une entrée de taille 4x4 avec un filtre de taille 3x3 et un pas de 1.....	61
Figure III.7 : Le principe de fonctionnement du ReLU.....	62
Figure III.8 : Les courbes des quatre fonctions d'activation.....	63
Figure III.9 : Processus de max et average pooling avec fenêtre de taille 2x2 et pas 2.....	64
Figure III.10 : L'architecture SegNet.....	69
Figure III.11 : L'architecture U-Net.....	70
Figure III.12 : Architectures VGG16 et VGG19.....	71
Figure IV.1 : Organigramme global de nos méthodes pour la détection du glaucome.....	75
Figure IV.2 : Etape de prétraitement. (a) Image originale ; (b) Image niveau de gris avec le point d'intensité maximale ; (c) ROI détectée.....	76
Figure IV.3 : Nos méthodes utilisées pour la segmentation du disque et cup.....	77
Figure IV.4 : Segmentation du disque optique. (a) Canal V de l'espace HSV ; (b) Image filtrée ; (c) Réseau rétinien éliminé par fermeture morphologique ; (d) Disque segmenté.....	78
Figure IV.5 : Segmentation du CO. (a) Canal vert ; (b) Fermeture morphologique ; (c) Résultat du FCM ; (d) Cup segmenté.....	78
Figure IV.6 : Amélioration des résultats de la segmentation. (a) DO final ; (b) Contour du disque ; (c) CO final ; (d) Contour du cup.....	79
Figure IV.7 : Exemples d'images préparées pour l'apprentissage.....	81
Figure IV.8 : L'architecture proposée SegNet modifié combiné avec VGG19.....	82
Figure IV.9 : Architecture U-Net modifiée.....	83

Figure IV.10 : Exemples de segmentation du DO et du CO sur la base RIM-ONE en utilisant SegNet modifié. (a) : Images originales ; (b) : Cup segmenté ; (c) : Disque segmenté ; (d) : Images originales avec contours de cup et de disque, le contour rouge correspondant aux résultats des experts et le contour bleu à nos résultats.....	86
Figure IV.11 : Exemples de segmentation du DO et du CO sur la base Locale en utilisant SegNet modifié. (a) : Images originales ; (b) : Cup segmenté ; (c) : Disque segmenté ; (d) : Images originales avec contours de cup et de disque, le contour rouge correspondant aux résultats des experts et le contour bleu à nos résultats.....	87
Figure IV.12 : Exemples de segmentation du DO et du CO sur la base DRISHTI-GS1 en utilisant SegNet modifié. (a) : Images originales ; (b) : Cup segmenté ; (c) : Disque segmenté ; (d) : Images originales avec contours de cup et de disque, le contour rouge correspondant aux résultats des experts et le contour bleu à nos résultats.....	87
Figure IV.13 : Exemples de segmentation du DO et du CO sur la base ORIGA en utilisant SegNet modifié. (a) : Images originales ; (b) : Cup segmenté ; (c) : Disque segmenté ; (d) : Images originales avec contours de cup et de disque, le contour rouge correspondant aux résultats des experts et le contour bleu à nos résultats.....	88
Figure IV.14 : Résultat d'extraction de NRR. (a) disque optique segmenté ; (b) cup optique segmenté ; (c) complément du cup ; (d) NRR détecté.....	90
Figure IV.15 : Vérification de NRR dans la règle ISNT pour un œil droit. (a-d) : Les différents masques : Inférieur, Supérieur, Nasal et temporal. (e-h) : les régions du NRR correspondantes.....	90
Figure IV.15 : Résultats de l'exactitude sur les différentes bases de données en utilisant les cinq classifieurs.....	92
Figure IV.16 : Résultats de la sensibilité sur les différentes bases de données en utilisant les cinq classifieurs.....	92
Figure IV.17 : Résultats de la sensibilité sur les différentes bases de données en utilisant les cinq classifieurs.....	92
Figure V.1 : Organigramme du système proposé pour la classification de la rétinopathie diabétique.....	95
Figure V.2 : Nos méthodes utilisées pour la segmentation de l'arbre vasculaire rétinienne.....	96
Figure V.3 : Etape de prétraitement. (a) Image originale ; (b) Image filtrée ; (c) Image des courbures principales ; (d) Image améliorée.....	97

Figure V.4 : Segmentation des vaisseaux sanguins. (a) seuillage ISODATA ; (b) contour Actif (vaisseaux sanguins fins) ; (c) segmentation manuelle.....	97
Figure V.5 : Exemples de blocs utilisés pour l'apprentissage.....	99
Figure V.6 : Architecture SegNet originale.....	101
Figure V.7 : Architecture SegNet modifié proposée.....	101
Figure V.8 : Architecture U-Net originale.....	102
Figure V.9 : Notre réseau U-Net modifié proposé pour la segmentation des vaisseaux sanguins.....	103
Figure V.10 : l'architecture de notre CNN1 construit.....	103
Figure V.11 : Le deuxième CNN profond proposé pour la segmentation des vaisseaux rétiniens.....	104
Figure V.12 : Description détaillée de notre deuxième CNN.....	104
Figure V.13 : Comparaison entre les résultats d'utilisation des deux bases d'apprentissage en testant la base DRIVE	105
Figure V.14 : Comparaison entre les résultats d'utilisation des deux bases d'apprentissage en testant la base HRF	106
Figure V.15 : Exemple de résultats des vaisseaux sanguins de l'ensemble de données DRIVE . (a) Image d'entrée ; (b) Images labélisées ; (c) Notre CNN2 ; (d) U-Net modifié ; (e) SegNet modifié ; (f) SegNet ; (g) U-Net ; (h) CNN1.....	107
Figure V.16 : Exemple de résultats des vaisseaux sanguins de l'ensemble de données HRF . (a) Image d'entrée ; (b) Images labélisées ; (c) Notre CNN2 ; (d) U-Net modifié ; (e) SegNet modifié ; (f) SegNet ; (g) U-Net ; (h) CNN1.....	107
Figure V.17 : Résultats de performance en utilisant différents classifieurs pour la base de données HRF	112
Figure V.18 : Résultats de performance en utilisant différents classifieurs pour la base de données Messidor	112

Liste des tableaux

Tableau I.1 : Les stades de la RD.....	15
Tableau I.2 : La relation entre la pachymétrie et le tonus oculaire	20
Tableau II.1 : Résumé du nombre d'images dans chaque base de données.....	44
Tableau III.1 : Matrice de confusion.....	72
Tableau IV.1 : Comparaison des performances de détection du disque et cup avec les méthodes de l'état de l'art.....	79
Tableau IV.2 : Performance d'extraction du disque sur les différentes bases de données.....	85
Tableau IV.3 : Performance d'extraction du cup sur les différentes bases de données.....	86
Tableau IV.4 : Résultats de la segmentation du DO et CO sur la base d'images DRISHTI-GS1 comparés avec les travaux existants.....	88
Tableau IV.5 : Résultats de la segmentation du DO et CO sur la base d'images ORIGA comparés avec les travaux existants.....	88
Tableau IV.6 : Résultats de la segmentation du DO et CO sur la base d'images RIM ONE comparés avec les travaux existants.....	89
Tableau IV.7. Performance de la classification du glaucome à partir de la base de données DRISHTI-GS1 comparée aux méthodes existantes.....	93
Tableau IV.8. Performance de la classification du glaucome à partir de la base de données RIM-ONE comparée aux méthodes existantes.....	93
Tableau IV.9 : Performance de la classification du glaucome à partir de la base de données ORIGA comparée aux méthodes existantes.....	93
Tableau V.1 : Comparaison des performances des méthodes classiques de segmentation des vaisseaux rétiniens.....	98
Tableau V.2 : Performance d'extraction du réseau vasculaire rétinien sur les différentes bases de données.....	108
Tableau V.3 : Résultats de la segmentation des vaisseaux sanguins dans la base de données DRIVE par rapport aux méthodes existantes dans la littérature.....	108
Tableau V.4 : Résultats de la segmentation des vaisseaux sanguins dans la base de données HRF comparativement aux méthodes existantes dans la littérature.....	109

Tableau V.5 : Résultats de la classification des RD dans la base de données du HRF comparativement aux méthodes existantes dans la littérature.....	113
Tableau V.6 : Résultats de la classification des RD dans la base de données de Messidor comparativement aux méthodes existantes dans la littérature.....	114

Liste des acronymes

RD: Rétinopathie Diabétique
POI: Pression Intra-Oculaire
CV : Champ de Vision
OMS : Organisation Mondiale de la Santé
GCAO : Glaucome Chronique A Angle Ouvert
GAF : Glaucome Aigu A Angle Fermé
GS : Glaucome Secondaire
GC : Glaucome Congénital
ONH : Optic Nerve Head (tête du nerf optique)
MA : micro-anévrismes
Hs : Hémorragies
RDNP : Rétinopathie Diabétique Non Proliférante
RDP : Rétinopathie Diabétique Proliférante
AMIR : Anomalies Microvasculaires Intra-Rétiniennes
FDT : Technologie de Doublement De Fréquence
RNFL : Couche de Fibres Nerveuses Rétiniennes
OCT: Tomographie par Cohérence Optique
OMD : Œdèmes Maculaires Diabétiques
SWFCM : Spatially Weighted Fuzzy C-Means
CNN : Convolutional Neural Network ou Réseaux de Neurones Convolutifs
FCN : Fully Connected Network (réseau entièrement connecté)
PCA : Analyse en Composante Principale
CDED-Net : Cup Disc Encoder Decoder Network
CHT: Circular Hough Transform
ROI: Region Of Interest
RF: Random Forest
LPE : Ligne des Partages des Eaux
NB: Naive Bayes
k-NN: k-Nearest Neighbor
SVM: Support Vector Machine
FFBPNN: Feed Forward Back Propagation Neural Networks
DTDNN: Distributed Time Delay Neural Network,

RBFEF: Radial Basis Function Exact Fit
RBFFN: Radial Basis Function Few Neurons.
MPS-Net: Multi-Path Scale Network
LCMs : Lightweight Convolution Modules
BSE: Before-activation Squeeze-and-Excitation
BSEResu-Net: Before-activation Squeeze-and-Excitation ResU-Net
ADTCWT Anisotropic Dual-Tree Complex Wavelet Transform
RBFNN: Radial Basis Function Neural Network
SSGAN: Semi-Supervised Generative Adversarial Network
DO: Disque Optique
CO: Cup Optique
FCM: Fuzzy C-Means
RCD : Rapport Cup/Disc
RRD : Rapport Rim/Disc
NRR : Anneau Neuro-Rétinien
ISNT : Inferieur, Supérieur, Nasal, Temporel
DCNN: Deep Convolutional Neural Network
ELM: Extreme Learning Machine
LSBF: Line Set Based Feature
DNN : Deep Neural Network
RCF : Random Crop and Fill
BFCN: Butterfly-FCN
D-MNet: Deformable convolutional M-shaped Network
PCNN: Pulse-Coupled Neural Network
DLA : Deep Learning Algorithm (Algorithme d'apprentissage profond)
BDD : Bases de données
DRIVE : Digital Retinal Images for Vessel Extraction
HRF : High Resolution Fundus
CHASE_DB1: Child Heart and Health Study in England
STARE: STructured Analysis of the Retina
MESSIDOR : Méthodes d'Evaluation de Systèmes de Segmentation et d'Indexation Dédiées à l'Ophtalmologie Rétinienne
RIM-ONE: An open retinal image database for optic nerve evaluation
DRIONS-DB: Digital Retinal Image for Optic Nerve Segmentation Database
ORIGA: Online Retinal Images for Glaucoma Analysis

AHE: Adaptive Histogram Equalization (égalisation d'histogramme adaptative)
CLAHE : Contraste Limited Adaptive Histogram Equalization (égalisation d'histogramme adaptative limité en contraste)
FOV: Field Of View
ISODATA: Iterative Self-Organizing Data Analysis Technique
CART : Classification And Regression Tree
LDA : Linear Discriminant Analysis (Analyse discriminante linéaire)
PLDA : Pseudo-inverse Linear Discriminant Analysis (Analyse discriminante linéaire à pseudo-inverse)
ANN : Artificial Neural Network (Réseau de neurones artificiel)
MLP : Multi Layer Perceptron (perceptrons multicouches)
CONV : Couche de convolution
Tanh : tangente hyperbolique
ReLU : Rectified Linear Unit
Leaky ReLU: Leaky Rectified Linear Unit
POOL : couche de pooling
FC: couche entièrement connectée
BN: Batch Normalization (normalization par lot)
MSE: Mean Squared Error
GD : Gradient Descent
SGD : Stochastic Gradient Descent
SGDM: Stochastic Gradient Descent with Momentum
ADAM : Adaptive Moment Estimation
CAD : Computer-Aided Diagnostic
Acc : Accuracy (Exactitude)
Se : Sensibilité
Sp : Spécificité
IoU : Intersection over Union
ROC : Receiver Operating Characteristic curve
AUC : Area Under the Curve

Introduction générale

1. Contexte générale

La vision est l'une des sens les plus précieux de l'être humain permettant de percevoir et d'interagir avec l'environnement externe. Ce processus est réalisé à l'aide de nombreux éléments dont l'œil est l'organe principale. Ce dernier est une structure complexe et fragile composée de différentes régions.

Cependant, diverses affections oculaires peuvent impacter les différentes structures anatomiques de l'œil, telles que la rétine et le nerf optique. Ils peuvent avoir diverses origines, qu'elles soient infectieuses, inflammatoires, métaboliques, tumorales, traumatiques ou dégénératives. Dans cette thèse, nous nous concentrons particulièrement sur deux pathologies oculaires les plus courantes à travers le monde et qui constituent des problèmes majeurs de santé publique : le glaucome et la rétinopathie diabétique (RD).

Le glaucome est une neuropathie chronique qui se caractérise par une détérioration progressive de la tête du nerf optique et une altération du champ visuel. Dans la plupart des cas, ces dommages sont dus à une montée de la pression intraoculaire (PIO). Dans un stade précoce, le glaucome est asymptomatique ce qui rend son diagnostic précoce et son traitement d'autant plus importants.

La rétinopathie diabétique est une complication du diabète déséquilibré qui affecte la rétine, entraînant une altération des petits vaisseaux sanguins et pouvant conduire à une perte de vision irréversible. Au début, elle est asymptomatique caractérisée par des saignements ou des fuites de liquide, ce qui entraîne l'apparition des lésions sur la surface de la rétine. Par conséquent, l'exploration des vaisseaux sanguins est très importante pour aider les ophtalmologues à reconnaître cette maladie au premier stade afin d'éviter une éventuelle perte de vision.

L'imagerie rétinienne est l'une des examens essentiels de dépistage en ophtalmologie. Elle regroupe un ensemble de techniques permettant d'obtenir des images détaillées de la rétine et de la tête du nerf optique telles que la rétinographie, l'OCT, l'angiographie et l'examen champ visuel. Ces techniques d'imagerie sont largement utilisées pour dépister et surveiller la progression de ces deux maladies.

Par conséquent, les informations présentes sur l'image de la région de l'œil explorée jouent un rôle vital dans le diagnostic précoce et le traitement efficace afin d'éviter la perte de vision irréversible.

Récemment avec les avancées en informatique surtout dans le domaine de l'imagerie médicale, plusieurs systèmes d'aide à la détection médicale (Computer Aided Detection CAD) sont développés. Ces systèmes assistent les médecins dans leurs décisions en analysant et interprétant les images médicales acquises des examens médicaux.

En général, un système CAD comprend plusieurs procédures : le prétraitement de l'image, la segmentation, la sélection des caractéristiques et la classification. Parmi ces procédures, la segmentation de l'image est l'étape clé consistant à classer chaque pixel comme appartenant à un label préalablement défini.

2. Problématique

Le glaucome est une neuropathie optique qui évolue lentement et de manière asymptomatique et se caractérise par une perte du champ visuel pouvant conduire à une cécité totale et irréversible. Il est estimé qu'en 2013, 64,3 millions de personnes âgées de 40 à 80 ans ont été atteints du glaucome, et ce nombre pourrait augmenter jusqu'à 111,8 millions en 2040 [1]. La maladie s'aggrave avec l'absence du traitement approprié. Il est donc nécessaire de la dépister autant que possible. Le diagnostic et le traitement précoces peuvent retarder la progression de la maladie.

La rétinopathie diabétique est la conséquence d'une hyperglycémie. De plus, il est prévu que 415 millions de personnes dans le monde sont touchées par le diabète. Cependant, environ un tiers des patients diabétiques souffrent de rétinopathie diabétique [2]. La progression de cette pathologie provoque des tortuosités et des changements de diamètre dans les vaisseaux rétiniens et, par la suite, la croissance des néovaisseaux, qui peut conduire à la cécité sans traitement approprié. Par conséquent, la segmentation automatique du réseau vasculaire est une tâche importante pour la détection précoce de la DR et la prévention de la perte de vision.

Cependant, la segmentation manuelle est une tâche fastidieuse et intensive en temps et en main-d'œuvre, nécessitant l'intervention d'une expertise humaine pour délimiter avec précision les contours des régions d'intérêt. De plus, elle peut être sujette à des erreurs humaines, en particulier dans le cas de données complexes, de mauvaise qualité ou de contours mal définis.

Ces facteurs ont conduit au développement de méthodes de segmentation automatique, utilisant des algorithmes de vision par ordinateur et de traitement d'images pour effectuer la segmentation de manière plus efficace.

La qualité d'images est un autre facteur crucial qui influence sur l'efficacité de prédiction des pathologies. Les images rétiniennes sont souvent affectées par des bruits et des artefacts d'acquisition et elles sont de mauvaise qualité ou de résolution limitée, ce qui peut réduire la

performance des algorithmes de détection. Des approches robustes doivent traiter efficacement les données et garantir des résultats précis même dans le cas des d'image difficiles à interpréter visuellement par les experts.

Le manque ou l'insuffisance des données annotées peut aussi influencer sur la performance des systèmes développés. Donc, il est important d'implémenter des techniques automatique efficaces pouvant s'adaptées avec de petites base de données, tout en garantit l'obtention des résultats fiables en testant de nouvelles bases d'images non annotées.

3. Objectifs et motivations

Au cours des dernières années, les algorithmes d'intelligence artificielle ont donné naissance à une nouvelle génération de modèles de segmentation et de classification d'images. Ces modèles sont des versions améliorées des réseaux de neurones artificiels qui introduits la notion de convolution pour l'extraction des caractéristiques de l'image. Ces algorithmes sont regroupés dans un domaine appelé apprentissage profond (Deep Learning).

L'avantage principale de ces techniques par rapport aux méthodes classiques est l'utilisation des données brutes (images 2D ou 3D) comme entrée et l'extraction automatique des informations pertinentes de l'image sans aucune intervention humaine.

Avec l'émergence des matériaux puissant et des larges bases de données annotées, les architecture de deep learning surpassent les performances des méthodes classiques, obtenant généralement des taux de précision plus élevés sur de grandes bases de données.

L'objectif principal de ce travail est le développement d'un système automatique pour la détection précoce du glaucome et de la rétinopathie diabétique à partir des images du fond d'œil en utilisant les techniques de traitement d'images et d'intelligence artificielle (machine learning et deep learning).

Le glaucome implique des changements dans la tête du nerf optique. Le diagnostic de cette maladie repose généralement sur l'analyse de la région de la papille optique. Dans cette thèse, nous avons proposé un système automatique de détection du glaucome en segmentant le disque et le cup optique et en extrayant les caractéristiques les plus importantes à partir des images de la tête du nerf optique couleur afin de classer le patient comme normal ou pathologique. Ce système passe par trois étapes principales : la segmentation du disque et du cup par les méthodes de deep learning, l'extraction des paramètres clés comme le rapport cup-disque et la règle ISNT et enfin la classification des images en appliquant différents classifieurs d'apprentissage automatique supervisé. Ce système est testé sur plusieurs bases de données publiques et locale.

Le diagnostic précoce de la rétinopathie diabétique peut être fait en analysant les changements géométriques dans les vaisseaux sanguins rétiniens tels que la surface, le diamètre, la largeur et la tortuosité. Néanmoins, la segmentation automatique et précise des vaisseaux rétiniens est essentielle pour le dépistage de cette maladie. Dans ce travail, nous avons introduit un système autonome de détection de la RD en utilisant les techniques d'intelligence artificielle. Ce système se compose de trois étapes : l'extraction de l'arbre vasculaire à l'aide des modèles de deep learning, le calcul d'un ensemble de caractéristiques morphologiques à partir des vaisseaux segmentés. Enfin, cinq classifieurs supervisés différents sont appliqués pour différencier entre les images normales et les images avec un signe de la RD.

4. Contribution

Dans cette thèse, plusieurs contributions sont mises en place pour améliorer les résultats des travaux existant dans l'état de l'art.

- Création des systèmes automatiques pour la détection du glaucome et de la RD qui permet d'obtenir des résultats précis sur des images de bonne et de mauvaise qualité ainsi que dans un temps de calcul plus court.
- Collecte d'une nouvelle base de données locale pour la détection du glaucome. Cette base contient 230 images de la tête du nerf optique avec des cas normaux et des cas glaucomateux.
- Comparaison entre les méthodes classiques et les algorithmes de deep learning pour la segmentation des régions d'intérêt (disque optique, cup optique et réseau rétinien).
- Construction des nouveaux modèles d'apprentissage profond plus efficaces et précis pour la segmentation sémantique des images médicales.
- Calcul des paramètres utilisés cliniquement par les ophtalmologues pour évaluer l'état du patient : sain, glaucomateux ou RD.
- Utilisation de plusieurs classifieurs à savoir : l'arbre de décision CART, machine à vecteur de support (SVM), K plus proches voisins (KNN), analyse discriminante linéaire (LDA) et réseau de neurones artificiel (ANN) pour la classification du glaucome et de la RD
- Test de plusieurs bases de données publiques acquises avec différents dispositifs ainsi que notre base locale.

Toutes ces contributions ont amélioré considérablement les résultats de la littérature surtout pour la segmentation du disque optique, cup optique et des vaisseaux sanguins rétiniens épais et minces.

5. Plan de la thèse :

Cette thèse de doctorat est divisée en cinq chapitres :

Chapitre 1 : Contexte médicale

Ce chapitre est consacré à la présentation de l'anatomie de l'œil en s'appuyant sur les structures affectées par le glaucome et la RD comme : la rétine et le nerf optique. Ces deux maladies sont par la suite définies en citant les stades et les types de chacune. Enfin, les différents examens cliniques employés pour l'exploration de l'œil afin de diagnostiquer et suivre la progression de ces maladies sont mises en œuvre.

Chapitre 2 : Etat de l'art et base de données

Dans ce chapitre nous avons mis en place les travaux récents qui existent dans la littérature pour la détection du glaucome et la rétinopathie diabétique. Ces travaux sont divisés en deux sections : la segmentation des régions d'intérêt et la classification des pathologies. Dans la deuxième partie du chapitre, nous avons décrit les différentes bases de données publiques utilisées pour implémenter et évaluer nos systèmes proposés en mettant l'action sur notre base de données locale collectée.

Chapitre 3 : Techniques de traitement d'images et principe d'apprentissage profond

Ce chapitre décrit l'ensemble des techniques testées au cours de cette thèse. Il est organisé comme suit : Premièrement les méthodes de traitement d'images utilisées dans nos algorithmes sont définies. Ensuite nous avons présenté brièvement l'apprentissage automatique en se basant sur l'apprentissage supervisé et ses algorithmes les plus populaires. La partie qui suit mise en place les notions fondamentales de deep learning. Dans cette partie, nous avons défini les réseaux de neurones convolutifs (CNN), ses différentes couches ainsi que les architectures les plus populaires pour la segmentation et la classification des images. Nous terminerons par la description des métriques d'évaluations utilisées pour valider les résultats obtenus.

Chapitre 4 : Détection automatique du glaucome : Méthodes et Résultats

Dans ce chapitre, nous présentons notre système proposé pour la détection du glaucome. Ce système est basé sur deux étapes : la segmentation du disque et du cup qui est effectuée en appliquant les méthodes de traitement d'images et de deep learning, et l'étape de classification pour classer les images en employant les algorithmes d'apprentissage supervisé. Par la suite nous discutons les résultats obtenus.

Chapitre 5 : Détection automatique de la rétinopathie diabétique : Méthodes et Résultats

Le système de détection de la RD est décrit dans ce chapitre. A ce niveau, nous comparons entre différents algorithmes de segmentation du réseau rétinien pour sélectionner le meilleur algorithme offrant les meilleurs résultats. Les images segmentées obtenues sont ensuite utilisées pour l'extraction d'un ensemble de paramètres géométriques afin d'effectuer la classification binaire de la RD. Cette dernière est réalisée en utilisant les mêmes classifieurs appliqués dans le système de la détection du glaucome. Les résultats obtenus sont présentés et discutés.

Et nous terminerons par une conclusion générale et quelques perspectives qui visent à enrichir ce sujet dans les futurs travaux.

Chapitre I :

Contexte médical

1. Introduction

La vision humaine est un système complexe qui comprend divers processus et structures dans lesquels l'œil est l'objet d'intérêt. Ce dernier est l'un des organes les plus perfectionnés du corps. Directement relié au cerveau, l'œil capte et analyse la lumière pour interagir avec notre environnement. L'œil est vulnérable à diverses maladies, parmi lesquelles nous nous intéressons dans ce travail aux deux maladies les plus courantes : le glaucome et la Rétinopathie Diabétique (RD). Ces deux dernières sont parmi les pathologies oculaires les plus graves, les plus fréquentes et celles qui causent le plus de cécité dans le monde.

Ce premier chapitre décrit l'anatomie de l'œil en général toute en précisant les parties les plus touchées par ces deux maladies. Ensuite nous allons donner un bref aperçu sur le glaucome et la RD. Nous terminerons par une description des différents examens cliniques utilisés par les ophtalmologues pour la détection de ces pathologies.

2. Anatomie de l'œil

Le globe oculaire est l'organe essentiel du système visuel. Son rôle est de percevoir la lumière et la transformer en messages nerveux à destination du cerveau via le nerf optique, qui en assure le traitement afin d'interagir avec le monde externe. L'œil est une sphère constituée de plusieurs composants structurels parmi eux nous nous intéressons par : la cornée, la rétine, la macula, le nerf optique et la papille optique, qui sont les régions affectées par la RD et le glaucome. La figure I.1 illustre un schéma général de l'anatomie du globe oculaire.

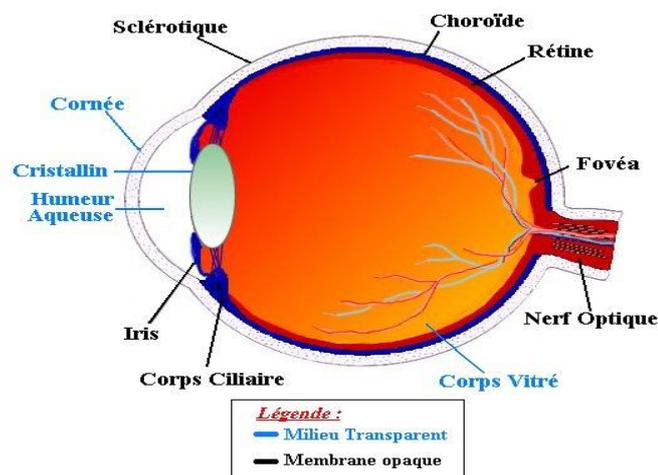


Figure I.1 : Anatomie du globe oculaire.

2.1. La cornée

C'est un tissu asphérique mince, transparent et avasculaire formant la partie la plus antérieure de l'œil. La cornée permet à la lumière de focaliser et d'entrer à l'intérieur de l'œil.

Elle joue un rôle majeur dans la convergence des rayons lumineux vers la rétine. Ce dioptre oculaire assure la réfraction et la transmission de la lumière et la protection de l'œil contre les infections et les dommages structurels des parties les plus profondes [3].

L'épaisseur de la cornée centrale (pachymétrie) est un paramètre pertinent pour apprécier la valeur réelle de la pression intraoculaire. Leur exploration est donc essentielle pour dépister le glaucome.

2.2. La rétine

La rétine est la membrane la plus interne du globe oculaire, elle est complexe transparente et hypersensible à la lumière. C'est un tissu neurosensoriel qui capte et convertit le signal lumineux en signal électrique. Cette action est réalisée en utilisant les photorécepteurs (cônes et bâtonnets). La zone centrale de la rétine (macula) contient des photorécepteurs sensibles aux couleurs appelés cônes. Ils produisent des images très nettes et sont responsables de la vision centrale et diurne. La zone périphérique de la rétine contient des photorécepteurs appelés bâtonnets, qui sont sensibles et stimulés à des intensités lumineuses réduites. Ces bâtonnets sont responsables de la vision périphérique et nocturne [3, 4]. La figure I.2 ci-dessous montre un schéma général de la rétine ainsi que ses différentes couches.

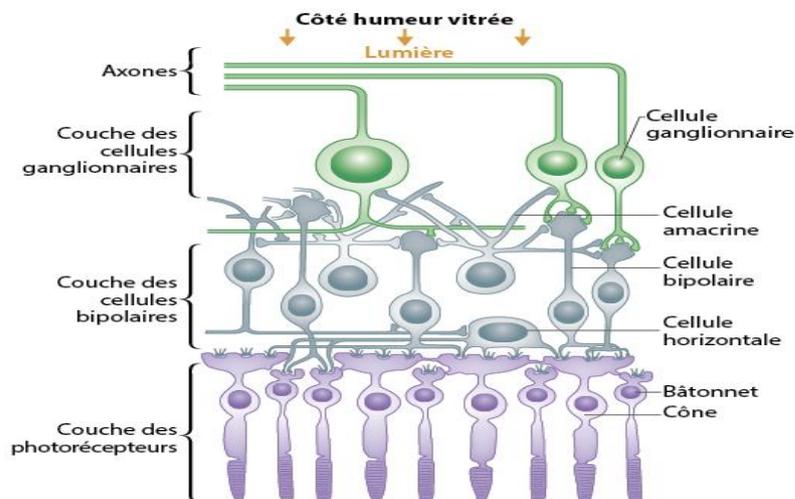


Figure I.2 : Schéma de la rétine.

La macula ou tache jaune est la partie centrale de la rétine de forme ovale où l'intensité visuelle est maximale. Elle est centrée par la fovéa, qui ne contient que les cônes ce qui rend la vision vive et détaillée.

2.3. Le nerf optique

Le nerf optique assure la transmission des impulsions électriques émises par la rétine au cerveau. Ce nerf sensoriel est construit à partir des axones des cellules ganglionnaires de la rétine et contient environ 1,2 million de fibres nerveuses [4]. Le nerf optique joue un rôle

prépondérant dans la création des images visuelles et l'interprétation de l'environnement extérieur. La partie clé du nerf optique est sa tête nommée « papille optique » où se réunissent plus d'un million de fibres optiques pour former le nerf optique.

L'endommagement du nerf optique empêche la transmission de l'information complète vers le cerveau ce qui conduit à une diminution du champ visuel, cela peut définir la présence d'un glaucome.

2.4. La papille optique

C'est la partie circulaire la plus lumineuse du fond d'œil. Elle est dépourvue des cellules visuelles (photoréceptrices), c'est-à-dire le point de l'œil qui ne voit pas. La papille ou disque optique est le point d'émergence (l'origine) des vaisseaux rétiniens [5] et de regroupement de fibres nerveuses. Cette région se constitue d'une partie interne appelée cup optique ou excavation qui est concave et plus lumineuse que le reste du disque. La surface entre le disque et le cup est nommée l'anneau neuro-rétinien (NRR).

Les changements au niveau de la taille, la couleur et la forme de la papille optique sont des signes de présence des problèmes oculaires provoquant une altération du champ de vision. Donc, il est nécessaire d'examiner systématiquement cette partie pour détecter les neuropathies oculaires comme le glaucome.

3. Les pathologies oculaires :

Plusieurs pathologies oculaires peuvent affecter les structures anatomiques de l'œil telles que la cornée, l'iris, la rétine, le nerf optique ...etc. Elles peuvent résulter de diverses causes comme les infections, les inflammations, les traumatismes, les troubles métaboliques, ou les conditions dégénératives.

Dans cette thèse nous nous focalisons sur deux maladies ophtalmiques les plus fréquentes dans le monde qui sont : le glaucome et la rétinopathie diabétique.

3.1. Glaucome

3.1.1. Définition du glaucome

Le glaucome est une neuropathie oculaire asymptomatique grave provoquant une altération de la tête du nerf optique, causée généralement par une élévation de la Pression IntraOculaire (PIO). L'augmentation de ce paramètre est due au mauvais écoulement de l'humeur aqueuse qui est un liquide transparent responsable du maintien de la pression et de la forme de l'œil. Dans le cas sain, il y a un équilibre entre la production et l'écoulement de ce liquide, alors que chez les cas glaucomateux, le canal de drainage du liquide « trabéculum » est partiellement ou

totalemment bloqué ce qui engendre un déséquilibre dans la quantité du fluide et par conséquent une augmentation de la pression à l'intérieur de l'œil. Cette dernière provoque une détérioration des fibres nerveuses et une diminution du champ de vision (CV) périphérique puis s'étend vers le centre et donc une cécité en absence d'un traitement approprié.

Le glaucome n'est généralement ressenti qu'à un stade avancé, d'où son nom de "voleur silencieux de la vue".

En outre, la perte de vision est lente, progressive et irréversible. Ainsi, seul un suivi systématique après les quarantaines permet une détection précoce et, par conséquent, entrave la cécité totale. Cette maladie sévère est considérée comme la deuxième cause de cécité dans le monde [6].

L'Organisation Mondiale de la Santé (OMS) a reportée en 1994 que le glaucome touchait environ 5,2 millions de personnes dans le monde [6]. Il y avait environ 60,5 millions de personnes en 2010 et 80 millions de personnes en 2020 [7]. Les prévisions indiquent que ce chiffre pourrait atteindre 95 millions d'ici 2030 [8]. En Algérie, il est la première cause de cécité, affectant près de 4,6 % de la population, soit environ 500 000 patients [9]. Ces statistiques mettent en évidence la gravité et la prévalence du glaucome, tant au niveau mondial qu'au niveau national.

Comme mentionné précédemment, en absence d'un diagnostic précoce et d'un traitement adéquat, le glaucome peut entraîner une perte de la vision centrale totale. C'est pourquoi il est très important de le détecter dans les stades asymptomatiques pour éviter la cécité. Ce diagnostic peut être établi par la surveillance et l'évaluation de la PIO et l'analyse des images rétiniennes.

Plusieurs facteurs de risques semblent néanmoins favoriser cette maladie tels que : une pression supérieure à 21 mm Hg, l'âge (après 40 ans), les antécédents familiaux (maladie héréditaire), la myopie, le stress... etc. La figure I.3 qui suit illustre un exemple sur l'évolution du glaucome et la perte du champ de vision.



Figure I.3 : Progression de la vision chez un glaucomateux.

3.1.2. Types du glaucome

Comme vu précédemment, le glaucome est généralement associé avec une hypertension intraoculaire, mais ce paramètre est insuffisant pour confirmer la présence de cette maladie car dans certains cas la PIO est normale alors que le patient est diagnostiqué comme glaucomeux c'est le cas d'un glaucome à pression normale.

Il existe plusieurs types du glaucome classés selon la valeur de la PIO et la taille de l'angle irido-cornéen (angle de drainage de l'humeur aqueuse situé entre l'iris et la cornée). Dans la partie ci-dessous, nous allons définir les types du glaucome les plus connus.

Glaucome chronique à angle ouvert (GCAO) : C'est le type le plus courant et le plus grave, représentant environ 70 % à 90 % des cas glaucomeux à l'échelle mondiale [10]. Il est caractérisé par la fermeture progressive et lente de l'angle irido-cornéen ce qui empêche le drainage efficace de l'humeur aqueuse. Cela entraîne une montée progressive de la PIO qui endommage le nerf optique au fil du temps, conduisant à une diminution progressive de la vision périphérique. A un stade précoce, le GCAO est asymptomatique et la majorité des patients ne ressentent pas des troubles visuelles jusqu'à ce qu'ils atteignent un stade avancé [11]. Une détection précoce à l'aide des examens réguliers de la PIO et de la papille optique est essentielle pour prévenir la progression de la maladie et préserver la vision.

Glaucome aigu à angle fermé (GAF) : C'est une forme rare provoquée par le blocage brutal de l'humeur aqueuse due à la fermeture soudaine et totale de l'angle iridocornéen. Le GAF est une urgence oculaire car son évolution est rapide à cause de l'élévation brusque de la pression de l'œil. Les symptômes associés à ce type sont une douleur sévère, vision floue, maux de tête, des nausées et des vomissements [12]. Donc, il faut agir en urgence pour éviter la cécité complète.

Une étude statistique a démontré que le GCAO est courant chez les mélanodermes, alors que le GAF est fréquent chez les asiatiques.

Glaucome à pression normale (GPN) ou à tension normale : Ce type survient lorsque le nerf optique est endommagé et le CV est altéré alors que la PIO est dans la plage normale. La cause exacte du glaucome à tension normale reste inconnue, mais elle pourrait être relative à une mauvaise circulation sanguine du nerf optique [11]. Cela rend le diagnostic et la prise en charge de ce type un défi. Le diagnostic repose sur une évaluation complète de la structure du nerf optique, du champ visuel et d'autres tests spécialisés.

Glaucome secondaire (GS) : Ce type de glaucome survient à la suite d'une autre affection ou lésion oculaire telle qu'une tumeur, un traumatisme, une maladie inflammatoire ou infectieuse, une néo-vascularisation ou un médicament [13].

Glaucome congénital (GC) : Ce type est présent à la naissance ou chez les nouveau-nés et il est causé par une anomalie ou déformation structurelle au niveau du canal d'évacuation de l'humeur aqueuse. Cette déformation augmente la PIO et par conséquent une détérioration de la tête du nerf optique. Le GC est rare mais peut entraîner une perte de vision grave s'il n'est pas traité rapidement [12].

3.2. Rétinopathie diabétique

Dans cette partie, nous allons décrire le diabète et la rétinopathie diabétique. Une description des lésions liées à cette pathologie ainsi que les différents stades sera ensuite mise en place.

3.2.1. Définition du diabète

Le diabète est une pathologie chronique causée par une élévation du taux de sucre dans le sang. Cela est dû à une mauvaise production d'insuline, une hormone produite par le pancréas qui sert à réguler la glycémie. Il existe deux types principaux de diabète : le diabète de type 1 et le diabète de type 2 [2, 14].

Le diabète de type 1 est une maladie auto-immune qui survient lorsque le système immunitaire attaque et détruit les cellules bêta du pancréas qui produisent l'insuline, ce qui entraîne une carence totale en insuline. Les patients diabétiques de ce type doivent prendre de l'insuline pour maintenir le taux du glucose à un niveau normal.

Le diabète de type 2 est le plus courant. Il est caractérisé par une résistance à l'insuline c'est-à-dire que les cellules ne répondent pas efficacement à la quantité produite ou une production insuffisante.

À long terme, le diabète peut causer des complications micro-vasculaires graves engendrant des anomalies oculaires qui affectent la rétine, entraînant une rétinopathie diabétique (RD), qui est la principale cause de la perte de vision chez la population active [15].

3.2.2. Définition de la rétinopathie diabétique

La rétinopathie diabétique (RD) est une complication grave du diabète et la cause majeure de malvoyance diabétique à travers le monde. Selon la fédération internationale du diabète, environ 415 millions de personnes dans le monde sont touchés par le diabète et ce chiffre pourrait atteindre 642 millions d'ici 2040. Cependant, environ un tiers des diabétiques souffrent de la rétinopathie diabétique [2, 14].

La RD est une pathologie rétinienne asymptomatique, lente et principalement le résultat d'une hyperglycémie à long terme. Cette dernière endommage et change la morphologie des vaisseaux sanguins qui nourrissent la rétine entraînant des fuites de liquides ou de sang pouvant au fil du temps provoquer une déficience visuelle irréversible partielle ou totale.

À un stade précoce (RD non proliférante), le système vasculaire rétinien est affecté, provoquant des changements morphologiques et des gonflements dans l'arbre vasculaire et l'apparition de lésions rétiniennes telles que les micro-anévrismes (MA), les hémorragies (Hs), les exsudats, etc.

La progression de la RD provoque des tortuosités et des changements de diamètre dans les vaisseaux rétiniens et, par la suite, la croissance anormale des néo-vaisseaux (RD proliférante), qui peut conduire à la cécité sans traitement approprié [16].

Les symptômes de la RD comprennent une vision floue, une vision nocturne réduite, des taches dans le champ de vision et une perte de vision progressive. Les personnes atteintes de diabète doivent subir un examen annuel des yeux pour détecter cette pathologie à un stade précoce. La figure I.4 ci-dessous montre la différence entre une vision d'un sujet sain et une vision chez un sujet avec RD.



Figure I.4 : La différence entre une vision normale et une vision avec RD.

3.2.3. Les stades de la rétinopathie diabétique

Selon les ophtalmologues la RD est classée en deux grands types : non proliférante et proliférante [17].

La rétinopathie diabétique non proliférante (RDNP)

Elle correspond au stade précoce de la maladie et se caractérise par des petits vaisseaux sanguins qui fuient dans la rétine, formant des lésions comme : microanévrismes, hémorragies et exsudats. La RDNP à son tour est classée en trois types selon les lésions observées sur la rétine : minime, modéré et sévère. Elle peut entraîner une perte de vision légère à modérée.

La rétinopathie diabétique non proliférante minime : Est le premier stade de la RD généralement sans symptômes. Elle est caractérisée par des légers dommages aux vaisseaux sanguins et l'apparition des petits points (MA) ainsi qu'une légère fuite de liquide dans la rétine.

La rétinopathie diabétique non proliférante modérée : Est caractérisée par des dommages plus importants aux vaisseaux rétiniens tels que des gonflements, des hémorragies et des exsudats. A ce stade l'arbre vasculaire commence à se dilater et à s'obstruer ce qui peut réduire l'apport en oxygène à la rétine.

La rétinopathie diabétique non proliférante sévère : A ce stade, la rétine est plus endommagée, les vaisseaux sont obstrués ce qui réduit considérablement la vision. La rétine peut également commencer à former de nouveaux vaisseaux sanguins anormaux.

La rétinopathie diabétique proliférante (RDP)

C'est le stade avancé de la maladie qui survient lorsque la rétine ne reçoit pas suffisamment d'oxygène en raison de vaisseaux sanguins endommagés. En réponse, de nouveaux vaisseaux sanguins commencent à se former pour compenser la diminution d'apport en oxygène. Cependant, ces néo-vaisseaux sont anormaux et fragiles, ce qui peut entraîner des hémorragies dans la rétine et causer une perte de vision sévère.

Pour cette raison, il est crucial de dépister cette pathologie dès que possible pour ralentir sa progression et prévenir la perte de vision.

Le tableau I.1 ci-dessous résume les différents stades de la RD allons d'un cas normal jusqu'à une rétinopathie diabétique proliférante.

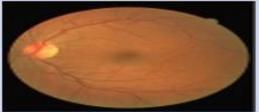
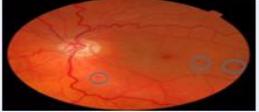
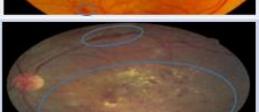
Stade	Description	Diagnostic	Exemples
0 : Cas Normal	<ul style="list-style-type: none"> Absences des lésions 		
1 : RDNP minime	<ul style="list-style-type: none"> Microanévrismes seulement 	Fond d'œil + angiographie annuels	
2 : RDNP modérée	<ul style="list-style-type: none"> Microanévrismes, Exsudats secs, Nodules cotonneux, Hémorragies rétiniennes punctiformes. 	Fond d'œil + Angiographie tous les 6 mois à un an	
3 : RDNP sévère	<ul style="list-style-type: none"> Microanévrismes, exsudats mous, Nodules cotonneux, Anomalies veineuses, Hémorragies rétiniennes punctiformes, AMIR, Hémorragies intra-rétiniennes étendues. 	Fond d'œil + Angiographie tous les 6 mois	
4 : Rétinopathie diabétique proliférante	<ul style="list-style-type: none"> Néo-vaisseaux, Hémorragies vitrée/ pré-rétinienne. 	Fond d'œil + Angiographie 2 à 4 mois	

Tableau I.1 : Les stades de la RD.

3.2.4. Lésions correspondantes à l'apparition de la RD

Avec la progression de la RD, plusieurs types de lésions peuvent apparaître sur la surface de la rétine [18]. Dans ce qui suit nous allons citer les différentes lésions associées à une RD.

Microanévrismes : sont des dilatations anormales et des petits renflements des parois capillaires du réseau vasculaire. Ils sont l'un des premiers signes à apparaître dans une RD. Les MAs sont observés comme des points rouges de petites tailles.

Hémorragies : sont des saignements dans la rétine à cause des vaisseaux sanguins endommagés entraînant une fuite de sang et par conséquent une vision floue. Elles sont des signes de progression de la maladie et peuvent apparaître en trois formes variantes en taille et sévérité :

Les hémorragies ponctuelles : Ce sont de petites taches de sang dispersées dans la rétine. Elles sont souvent le résultat de la rupture de petits vaisseaux sanguins, tels que des capillaires.

Les hémorragies en flamme : Elles se caractérisent par des traînées plus larges de sang dans la rétine. Elles sont généralement causées par la rupture de vaisseaux sanguins plus importants.

Les hémorragies pré-rétiniennes ou intra-vitréennes : Ce type d'hémorragie se produit lorsque le sang s'accumule entre la rétine et le vitré. Elles peuvent être plus importantes et entraîner une vision floue ou une perte de vision partielle.

Nodules cotonneux : apparaissent dans la rétine comme des petites taches blanchâtres ou grises de forme irrégulière légèrement surélevées. Ils sont dus à une ischémie locale c'est-à-dire un manque d'approvisionnement en sang dans la rétine. Ils se forment lorsque les vaisseaux sanguins de la rétine sont endommagés par les effets du diabète.

Exsudats mous : apparaissent comme de petites taches jaunâtres ou blanchâtres, souvent de forme ronde. Ils ont une apparence plus plate par rapport aux nodules cotonneux. Ils sont le résultat de la fuite de liquides, de lipides et de protéines des vaisseaux sanguins endommagés dans la rétine.

Exsudats durs : sont des dépôts de matière grasse plus solides et plus anciens. Ils se présentent comme des petites lésions blanchâtres situées en périphérie de la rétine. Les exsudats durs sont la conséquence d'accumulation prolongée des lipides dans la rétine

Anomalies veineuses : sont des altérations structurelles et fonctionnelles des veines de l'arbre vasculaire. Elles comprennent diverses anomalies telles que des dilatations, occlusions et des hémorragies veineuses.

Anomalies Microvasculaires Intra-Rétiniennes (AMIR) : sont des changements pathologiques affectant les petits vaisseaux sanguins de la rétine qui peuvent provoquer des saignements, des

gonflements, des tortuosités et des fuites de liquide. Les AMIR sont considérés comme un stade précoce de la RD, pouvant progresser vers un stade avancé avec des complications telles que les œdèmes maculaires et la néovascularisation.

Néovaisseaux : un stade sévère de la RD provoque la croissance de nouveaux vaisseaux sanguins anormaux. Ces vaisseaux servent à compenser le manque de l'oxygène dans la rétine dû à l'endommagement des vaisseaux. Les Néovaisseaux sont fragiles provoquant des hémorragies ce qui entraîne une perte de vision sévère et permanente.

La figure I.5 ci-dessous, illustre les différentes lésions qui apparaissent dans la rétine dans le cas de la RD.

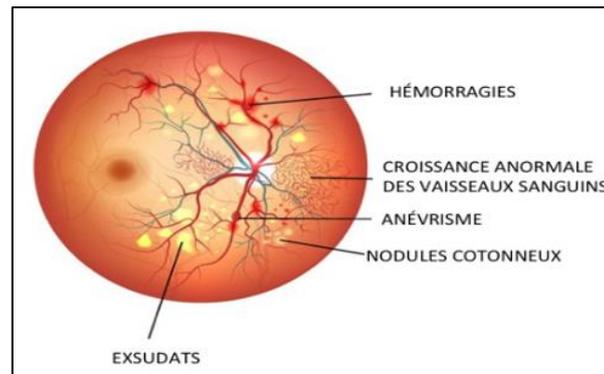


Figure I.5 : Les différentes lésions de la RD.

4. Techniques d'exploration des pathologies oculaires :

Le glaucome et la rétinopathie diabétique sont deux pathologies oculaires graves, les plus fréquentes et les majeures causes de cécité dans le monde. Ils sont asymptomatiques provoquant une perte visuelle irréversible, alors le diagnostic précoce de ces maladies est très important.

Pour cela, plusieurs examens cliniques sont utilisés par les ophtalmologues pour obtenir des informations quantitatives (PIO, pachymétrie ...) et qualitatives (images OCT, fond d'œil, champ visuel ...) sur la santé des régions du globe oculaire. Ces informations jouent un rôle important dans la découverte précoce d'une maladie. De plus, L'imagerie rétinienne est un outil essentiel pour le diagnostic et le suivi de plusieurs maladies oculaires et même cérébrales.

Dans ce qui suit nous allons explorer les différents examens cliniques ophtalmologiques utilisés pour le diagnostic du glaucome et de la rétinopathie diabétique (figure I.6).

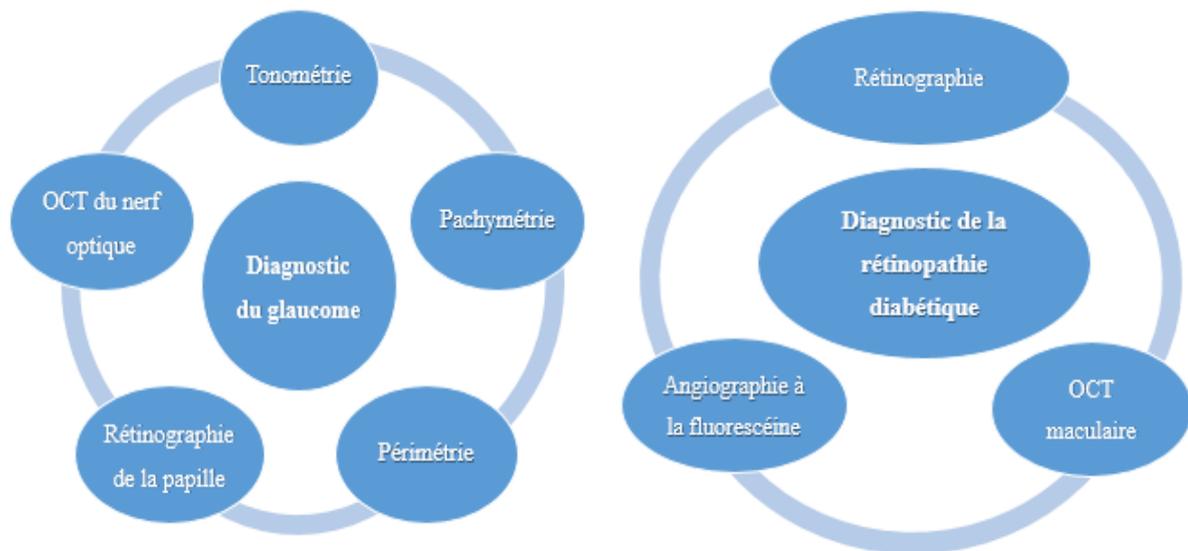


Figure I.6 : Les examens cliniques pour le diagnostic du glaucome et de la RD.

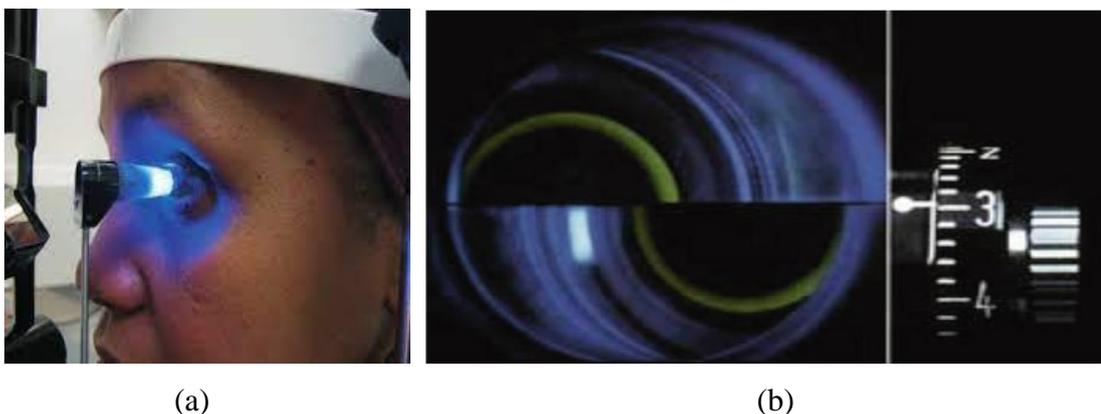
4.1. Tonométrie :

La tonométrie est un examen de mesure de la pression interne de l'œil. Elle est essentielle pour le diagnostic et le suivi du glaucome. La pression oculaire normale est comprise entre 12 et 21 mm Hg. Une valeur en dehors de cette plage peut entraîner la destruction de la tête du nerf optique (ONH), accompagnée d'une altération du champ visuel périphérique puis s'étendant progressivement vers le centre. Dans ces conditions, le risque de perte de vision augmente [19].

Cet examen peut être réalisé à l'aide de deux types d'appareils : tonomètre à aplanation et tonomètre à jet d'air [20].

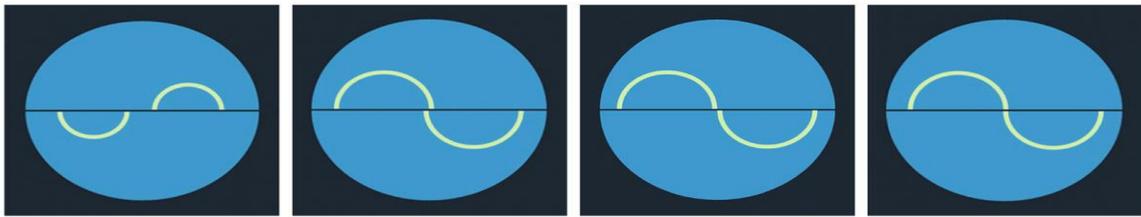
4.1.1. Tonomètre à aplanation

Un examen avec contact ou la tonométrie est mesurée en exerçant une pression sur la surface de la cornée. La valeur de la PIO est obtenue lorsque les deux demi-cercles s'accordent. Au début, ces demi-cercles sont éloignés l'un des autres. La molette est ensuite tournée afin de coïncider le bord interne des demi-cercles. Cela indique la bonne position de la molette et la PIO est lue sur le tonomètre (figure I.7).



(a)

(b)



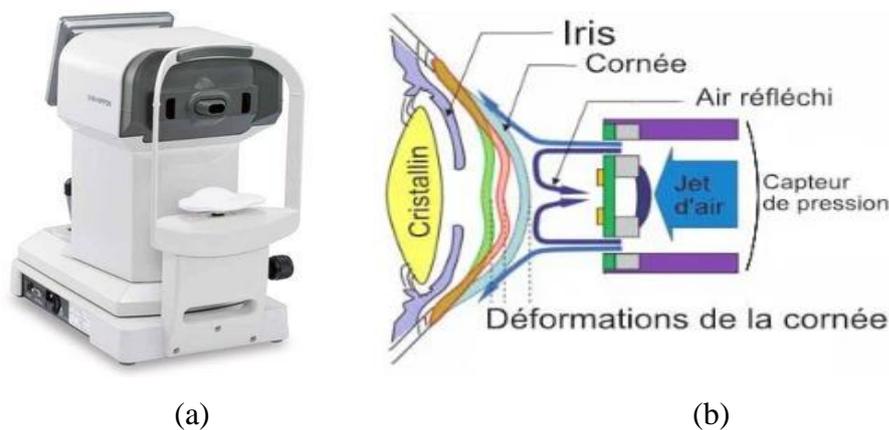
(c)

Figure I.7 : Tonométrie à aplanation. (a) Appareil ; (b) Image observée ; (c) Principe de fonctionnement.

4.1.2. Tonomètre à jet d'air

Le tonus oculaire est mesuré sans contact. Elle consiste à projeter de l'air chaud sur la cornée pour la déformer et l'aplanir. La force d'air rend la cornée concave, un capteur ensuite détecte le maximum de déformation possible et la quantité de l'air réfléchi. Ces informations sont converties pour calculer la PIO.

La figure I.8 ci-dessous présente l'appareil de mesure de la tonométrie sans contact ainsi que son principe de fonctionnement.



(a)

(b)

Figure I.8 : Tonométrie à jet d'air. (a) Appareil ; (b) Principe de fonctionnement.

4.2. Pachymétrie

C'est un examen indolore qui mesure l'épaisseur cornéenne en micromètre (μm). Elle est obtenue en calculant la distance entre la face antérieure et la face postérieure de la cornée. La pachymétrie est facteur primordial pour évaluer et apprécier la valeur de la pression intraoculaire. Elle varie d'une personne à autre et diminue de la périphérie vers le centre dont la pachymétrie centrale est la plus importante pour le diagnostic des maladies [21].

Chez un sujet normal, la pachymétrie centrale moyenne varie entre 500 et 550 μm [22].

Cet examen peut être effectué à l'aide de trois appareils : pachymètre à ultrasons, OCT ou topographe cornéen. La figure I.9 ci-dessous présente une image topographique indiquant les valeurs de la pachymétrie.

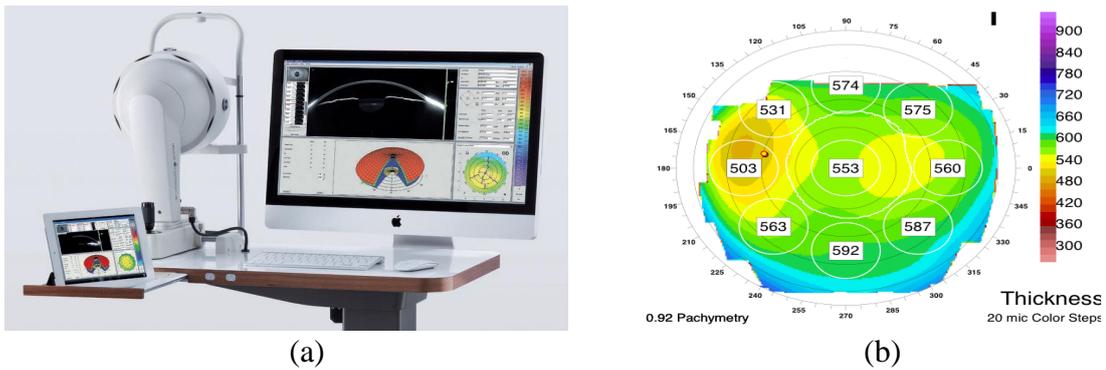


Figure I.9 : Pachymétrie. (a) OCT de segment antérieur ; (b) Image topographique.

Pour diagnostiquer ou suivre l'évolution du glaucome, il est important de calculer l'épaisseur cornéenne. Car la valeur du tonus oculaire (PIO) seule ne suffit pas de confirmer la présence ou l'absence de la maladie. Certains patients ont une pression normale alors que les signes du glaucome sont présents (cas du GPN) ou bien le contraire. De plus, dans un cas normale une cornée épaisse correspond à une PIO élevée alors qu'une fine cornée correspond à une PIO basse et cela peut fausser le résultat de la tonométrie.

C'est pour cela il est vital de combiner la tonométrie et la pachymétrie pour obtenir la vraie valeur du tonus oculaire afin de confirmer le diagnostic du glaucome. Cette vraie valeur est obtenue en ajoutant ou soustrayant la valeur de la correction correspondante à l'épaisseur cornéenne (tableau I.1) de la valeur de PIO mesurée par la tonométrie.

Le tableau I.2 qui suit représente la liaison entre la pachymétrie et la tonométrie pour corriger la valeur de la PIO déjà mesurée.

Pachymétrie	Correction de la PIO	Pachymétrie	Correction de la PIO
445	7	555	-1
455	6	565	-1
465	6	575	-2
475	5	585	-3
485	4	595	-4
495	4	605	-4
505	3	615	-5
515	2	625	-6
525	1	635	-6
535	1	645	-7
545	0		

Tableau I.2 : La liaison entre la pachymétrie et la PIO.

4.3. Périmétrie ou Champ Visuel

Le champ de vision est la plage de l'espace perçue par l'œil autour d'un point droit fixe. Il couvre horizontalement entre 120° et 180° et verticalement entre 60° et 150° .

L'exploration de cette plage est généralement effectuée en utilisant un examen de périmétrie aussi appelé examen champ visuel. C'est un test subjectif qui explore les limites du champ de vision et la sensibilité des cellules rétinienne à l'intérieur de ce champ.

Dans le cas du glaucome, la vision périphérique est endommagée et peut s'étendre vers le centre en absence d'un diagnostic précoce et un traitement approprié. Donc la périmétrie est l'outil de référence pour l'évaluation du champ de vision et la prise en charge de cette neuropathie à un stade débutant.

Il existe différents appareils de la mesure de ce champ tels que la périmétrie statique automatisée [23] et la périmétrie par la technologie de doublement de fréquence (FDT) [24].

4.3.1. Périmétrie automatisée

Elle utilise un programme informatique permettant de générer des points lumineux de différentes intensités sur tout l'espace de vision. Lors d'un examen CV, le patient fixe un point central et doit signaler chaque fois qu'il perçoit un stimulus lumineux. L'appareil enregistre les réponses et crée une carte détaillée sur l'état du champ de vision. Cette carte est généralement en échelle de gris et fournit des informations précieuses sur l'acuité et l'étendue du champ visuel en identifiant d'éventuelles anomalies.

Les photographies acquises sont en niveaux de gris ou bien des chiffres en décibel. Dont les niveaux de gris clair (tend vers le blanc) indiquent des cellules saines et les niveaux de gris sombres (tend vers le noir) indiquent que les cellules sont malades à un stade avancé ou bien détériorées (figure I.10).

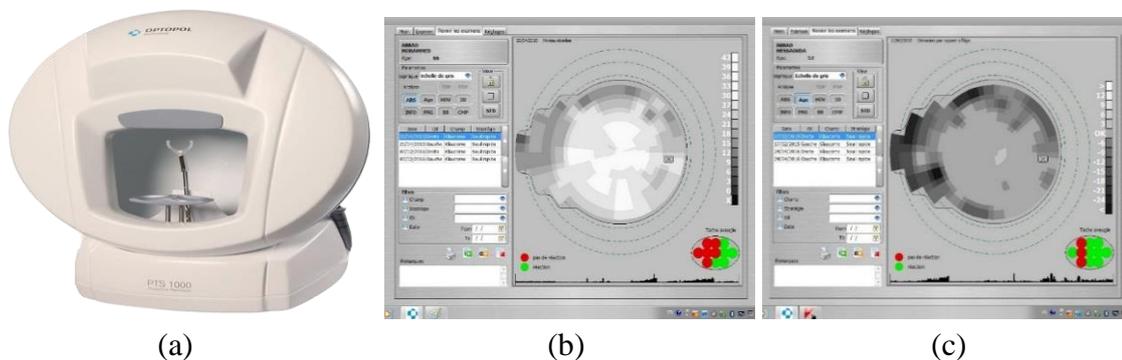


Figure I.10 : Périmétrie. (a) Appareil OPTOPOL PTS 1000 ; (b) Image saine ; (c) Image glaucomateuse.

4.3.2. La périmétrie à doublement de fréquence FDT (Frequency Doubling Technology)

C'est une méthode spécifique généralement employée pour le dépistage des premiers stades du glaucome. Elle utilise des stimuli visuels constitués de bandes de fréquence spatiale élevée. Ces stimuli induisent une illusion optique de doubles fréquences. Le patient signale chaque fois qu'il perçoit une illusion.

Le FDT évalue la sensibilité des cellules ganglionnaires de la rétine, qui sont souvent altérées dans le glaucome avant que des changements significatifs ne se produisent dans le champ visuel central. Cela en fait un outil précieux pour détecter et suivre l'évolution du glaucome. Le résultat de cet examen est une cartographie en noir et blanc mettant en évidence les zones où le patient a pu détecter avec succès les stimuli visuels. Cela indique l'état du champ visuel.

4.4. Rétinographie

La rétinographie ou examen fond d'œil est une technique de visualisation de la rétine, le nerf optique et l'arbre vasculaire rétinienne. Elle peut être réalisée sans une dilatation pupillaire (rétinographie non mydriatique) ou avec une dilatation pupillaire (rétinographie mydriatique) pour une meilleure visualisation de la rétine. Cet examen est essentiel pour le diagnostic et le suivi de la progression de diverses pathologies oculaires, y compris le glaucome et la RD [25].

Dans le cas du glaucome, la rétinographie est employée pour analyser la tête du nerf optique en examinant le disque optique, le cup optique (l'excavation) et l'anneau neuro-rétinien (NRR) à partir des images papillaires en couleur (figure I.11.b). A ce niveau, deux paramètres clés sont utilisés pour évaluer quantitativement les images le rapport cup-disque et la règle ISNT et confirmer la présence de la maladie.

En effet, le rapport entre la taille du disque optique et le cup optique appelé « Rapport Cup-Disque (RCD) ». Ce rapport permet de définir la présence d'une excavation. Dans l'œil normal, la valeur du RCD est inférieure à 0,3 [26]. La taille du cup optique augmente dans le cas glaucomateux, ce qui provoque une augmentation du RCD et un amincissement de NRR. Dans la majorité des cas, une papille normale a tendance d'être elliptique le long de l'axe vertical, alors que la zone centrale (cup) est elliptique le long de l'axe horizontal.

La règle ISNT est utilisée pour évaluer la distribution des fibres nerveuses dans le nerf optique. Selon cette règle, dans un cas sain, les fibres nerveuses sont réparties de manière caractéristique : la région inférieure (I) contient le plus de fibres, suivie de la région supérieure (S), puis la région nasale (N), et enfin la région temporale (T) qui contient le moins de fibres.

Pour diagnostiquer la RD, la rétinographie est l'examen principal utilisé pour évaluer les vaisseaux sanguins rétiniens et identifier les différents signes de lésions, tels que les

microanévrismes, les hémorragies et les néovaisseaux. La rétinographie est également utilisée pour surveiller l'évolution de la RD au fil du temps et pour déterminer l'efficacité du traitement (figure I.11.c).

Deux instruments peuvent être utilisés pour visualiser la rétine : le rétinographe qui repose sur l'utilisation d'une source lumineuse et une caméra spécialisée pour l'obtention des images. La lampe à fente est un microscope doté d'une lumière vive associé avec des lentilles pour grossir et focaliser sur l'intérieur de l'œil en mettant l'accent sur l'avant de la rétine.

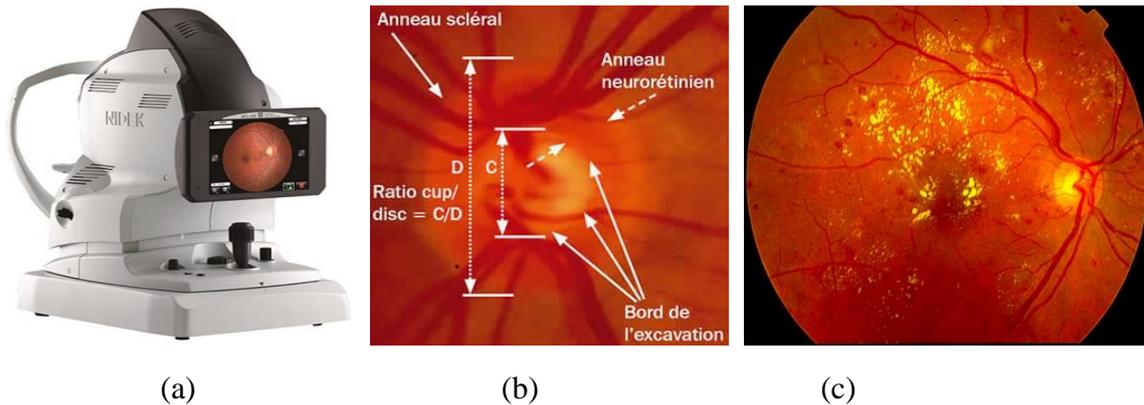


Figure I.11 : Rétinographie. (a) Rétinographe ; (b) Image fond d'œil de la tête du nerf optique ; (c) Image fond d'œil rétinienne.

4.5. Tomographie par Cohérence Optique (OCT)

L'OCT est un outil d'imagerie oculaire utilisé pour le diagnostic et la surveillance de diverses affections oculaires, y compris le glaucome et la rétinopathie diabétique. Cette technique fournit des images en coupe de la rétine et le nerf optique, offrant des informations détaillées sur la structure les changements pathologiques dans ces régions et qui ne sont pas détectées par l'examen fond d'œil.

L'OCT applique des ondes lumineuses pour générer des images de haute résolution en coupe transversales des régions de l'œil. Le faisceau de lumière est dirigé vers la région à examiner et l'appareil capture la lumière réfléchi par les tissus et la transforme en images numériques [25].

Deux types d'images peuvent être obtenues à l'aide de cet appareil : l'OCT du nerf optique et l'OCT maculaire.

4.5.1. OCT du nerf optique

C'est un examen très utilisé pour le diagnostic et le suivi du glaucome en évaluant l'état du nerf optique. L'OCT papillaire permet de visualiser cette région en profondeur afin de détecter les dommages structurels tels que les modifications morphologiques du disque optique et la perte des fibres nerveuses et des cellules ganglionnaires rétiniennes. Il fournit aussi précisément l'épaisseur de la couche de fibres nerveuses rétiniennes (RNFL) (figure I.12.b). Cette dernière

est souvent amincie chez un cas glaucomateux. Cela peut aider à détecter précocement cette grave neuropathie et même avant la manifestation des symptômes.

4.5.2. OCT Maculaire

Cet examen permet de visualiser les différentes couches de la rétine dans la région maculaire. Il joue un rôle crucial pour détecter et quantifier les dommages au niveau de cette région.

Dans la RD, des changements tels que l'œdème maculaire (accumulation de liquide dans la rétine), l'épaississement des couches rétinienne, la formation de membranes épiréiniennes (adhérences sur la surface de la rétine), les exsudats et d'autres lésions peuvent être observés dans les images rétinienne en coupe acquises à l'aide de l'OCT maculaire (figure I.12.c). Ces changements structuraux sont importants pour évaluer la gravité de la RD, planifier le traitement et surveiller la progression de la maladie.

Cette technique permet également de mesurer l'épaisseur des différentes couches et même la macula ce qui aide les spécialistes à prendre des décisions éclairées sur le stade de la maladie et le traitement adapté à la situation surtout dans le cas des œdèmes maculaires diabétiques (OMD).

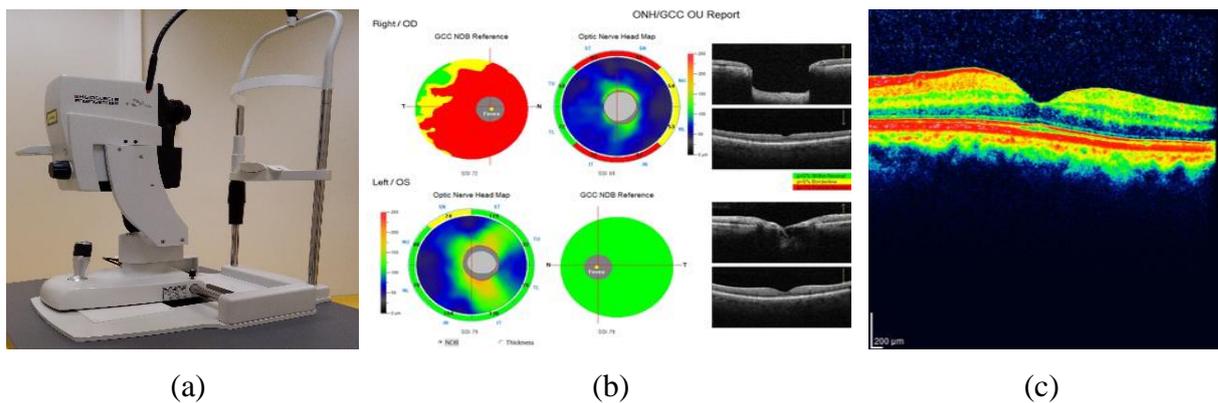


Figure I.12 : Examen OCT. (a) Appareil OCT Heidelberg ; (b) Image de l'OCT papillaire ; (c) Image de l'OCT maculaire.

4.6. Angiographie à la fluorescéine

Les modifications de la structure vasculaire rétinienne sont l'un des indicateurs les plus importants pour le diagnostic de nombreuses maladies oculaires notamment la RD. L'exploration de cette région est donc importante et peut être effectuée en utilisant l'angiographie à la fluorescéine. Cet examen consiste en la prise des images rétinienne avant et pendant l'injection intraveineuse d'un produit fluorescent appelé « fluorescéine ». Les images sont capturées par une caméra spéciale équipée d'un filtre à lumière bleue à mesure que le colorant circule dans l'arbre vasculaire rétinienne. L'angiographie à la fluorescéine fournit une vision détaillée sur l'état du réseau vasculaire et la circulation sanguine. Elle permet de détecter

les anomalies rétiniennes comme les microanévrismes, les fuites de liquide, les obstructions ou la présence des néovaisseaux. Cette technique est utile pour évaluer la sévérité de la RD guider le traitement et surveiller la progression de la maladie au fil du temps [25].

La figure I.13 suivante illustre un exemple d'image angiographique.

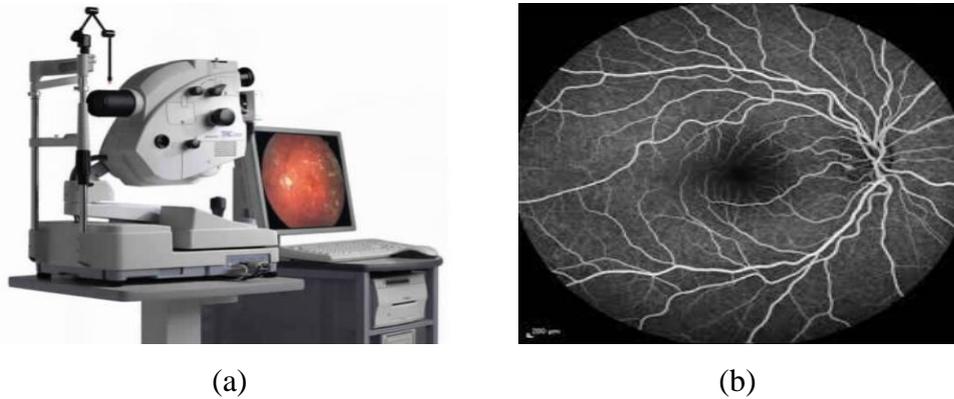


Figure I.13 : Angiographie à la fluorescéine. (a) Angiographe ; (b) Image angiographique.

5. Conclusion

Anatomiquement, l'œil est un organe extrêmement complexe et le responsable de perception et d'interprétation de notre environnement externe. L'endommagement de ce dernier peut conduire à une perte de vision irréversible et même une cécité totale en absence d'un traitement approprié.

Dans ce chapitre nous avons présenté brièvement l'anatomie de l'œil. Ensuite, nous avons défini le glaucome, la rétinopathie diabétique qui sont les maladies les plus graves et les plus fréquentes dans le monde. A la fin de ce chapitre, nous avons décrit les différents examens cliniques utilisés pour le diagnostic de ces deux pathologies.

Vu l'importance de la détection précoce du glaucome et de la RD pour éviter une baisse de l'acuité visuelle, dans le chapitre ci-dessous nous allons citer quelques travaux récents relatifs existant dans la littérature. Une définition des bases de données publiques et locales utilisées dans notre recherche sera ensuite mise en place.

Chapitre II :

Etat de l'art et bases de données

1. Introduction

Le développement des systèmes d'aide au diagnostic en ophtalmologie a reconnu un grand progrès ces dernières années. Ces systèmes exploitent différents éléments de l'œil en utilisant l'intelligence artificielle afin de distinguer entre les cas sains et les cas pathologiques.

Par conséquent, l'analyse des images médicales joue un rôle primordial dans la détection précoce d'une maladie, le suivi de son évolution et la validation de l'efficacité de l'action thérapeutique mise en œuvre. Ce chapitre est divisé en deux parties : la première est dédiée à la présentation d'un ensemble de travaux existant dans la littérature pour la détection du glaucome et de la rétinopathie diabétique. La deuxième partie concerne la description des différentes bases d'images rétiniennes locale et publiques disponibles pour évaluer nos algorithmes développés.

2. Etat de l'art

Comme vu précédemment, le glaucome et la rétinopathie diabétique sont deux maladies fréquentes qui font l'objet de nombreux sujets de recherche. Ces travaux sont généralement divisés en deux grandes parties : la segmentation des régions rétiniennes affectées ainsi que la classification. Dans les sections suivantes, un ensemble des travaux existants relatifs à la détection du glaucome et la RD sera mentionné.

2.1. Glaucome

Le glaucome est une pathologie oculaire. Plusieurs chercheurs se sont intéressés à cette maladie dans le but de faire une détection précoce ainsi qu'un bon suivi. Diverses approches ont été proposées dans la littérature pour la détection du glaucome à partir des images rétiniennes en se basant sur la segmentation du disque optique et du cup optique, la détermination et le calcul du Rapport Cup/Disc (RCD) et Rapport Rim/Disc (RRD) ainsi que la vérification de l'anneau neuro-rétinien (NRR) dans la règle ISNT (Inferieur, Supérieur, Nasal, Temporel). La plupart des algorithmes développés contiennent deux étapes communes qui sont : la segmentation et la classification.

2.1.1. Segmentation du disque optique et cup optique

La segmentation automatisée du disque et du cup optique à partir des images rétiniennes couleur du fond d'œil a fait l'objet de plusieurs recherches ces dernières années. Ces méthodes varient des techniques de traitement d'images classiques [27-33] aux nouvelles approches basées sur l'apprentissage profond [34-45]. Dans cette partie, nous allons citer quelques travaux.

Dnyaneshwari et al. (2016) [27], ont proposé un système de détection du glaucome basé sur l'extraction du disque et cup en appliquant l'égalisation d'histogramme, la morphologie mathématique et le seuillage. Les rapports RCD et RRD ont été calculé pour identifier le glaucome. La méthode a été testée sur 300 images prises des bases Messidor et RIM-ONE.

Mittapalli et Kande (2016) [28], ont utilisé la méthode Spatially Weighted Fuzzy C-Means (SWFCM) pour détecter le cup et le contour actif basé sur la région implicite pour segmenter le disque. Le système a été évalué sur 59 images prises des bases locales et publiques.

Salam et al. (2016) [29], ont développé un algorithme de détection du glaucome en combinant la valeur du RCD avec les caractéristiques d'intensité et de la texture. Pour extraire le cup, ils ont appliqué l'ouverture morphologique en niveau de gris ainsi que la méthode de croissance de région. Le disque a été segmenté en employant la segmentation par seuillage. L'ellipse fitting a été utilisé pour lisser les bordures du cup et disque. La méthodologie a été évaluée sur deux ensembles de données locales contiennent respectivement 50 et 100 images.

Nugroho et al. (2017) [30], ont présenté deux schémas pour segmenter le disque et le cup optique. La combinaison de la reconstruction morphologique et le contour actif est menée pour segmenter le disque, tandis que la combinaison de la reconstruction morphologique, le seuillage et l'enveloppe convexe est employée pour détecter le cup. Les schémas proposés ont été évalués sur la base d'images DRISHTI-GS.

Priyadharsini et al. (2018) [31], ont implémenté un algorithme pour extraire le disque et le cup. L'égalisation de l'histogramme a été appliqué pour prétraiter les images. La transformée de Hough circulaire a été employé pour segmenter le disque. Le cup a été localisé en utilisant une fermeture morphologique sur le disque segmenté, ensuite il est détecté en appliquant la méthode Otsu. L'algorithme a été évalué sur la base de données DRISHTI-GS.

Zhou et al. (2019) [32], ont introduit un nouveau modèle de contour actif statistique local avec l'approche de structure préalable (LSACM-SP) pour segmenter le disque optique et le cup. Le modèle LSACM a été appliqué pour détecter le disque et le cup tandis que le structure préalable a été proposé pour guider le modèle afin de générer des résultats précis. La méthode a été évaluée sur deux bases de données : DRISHTI-GS et RIM-ONE r2.

Pour la binarisation du disque optique Khan et al. (2020) [33], ont utilisé le seuillage adaptatif local et la croissance par région. De plus, l'excentricité et la surface sont utilisées pour détecter la vraie région du disque. Enfin, l'ajustement d'ellipse est appliqué pour remplir cette région. Six bases d'images ont été introduits pour tester la méthode : DRIONS, MESSIDOR, ONHSD, DIARETDB1, DRISHTI and RIM-ONE.

L'inconvénient majeur des méthodes classiques de traitement d'images est de trouver les bonnes valeurs des seuils, l'adaptation des algorithmes sur plusieurs bases de données ainsi que

l'automatisation du processus c'est-à-dire, utiliser les mêmes valeurs pour toutes les bases d'images.

Pour remédier à ce problème, de nouvelles techniques basées sur d'apprentissage profond et les réseaux de neurones convolutifs (CNN) ont été employés pour l'extraction automatique du disque et du cup optique.

Zilly et al. (2017) [34], ont développé une architecture de réseau neuronal convolutif basée sur l'apprentissage d'ensemble pour segmenter le disque optique et le cup. Une méthode d'échantillonnage par entropie a été introduite pour sélectionner les points informatifs, réduisant ainsi la complexité des calculs tout en effectuant un échantillonnage supérieur à uniforme. Pour améliorer le résultat de la segmentation, l'algorithme coupe de graphe et l'enveloppe convexe ont été appliqués. Ce système a été validé sur la base DRISHTI-GS.

De plus, une architecture U-Net modifiée a été appliquée par Sevastopolsky (2017) [35] pour la segmentation du disque et cup. Le modèle segmente d'abord le disque puis extrait une région d'intérêt, sur la base de laquelle segmente le cup. Ce travail a été testé sur les bases de données DRIONS-DB, RIM-ONE et DRISHTI-GS.

Al-Bander et al. (2018) [36] ont proposé un réseau DenseNet combiné à un réseau entièrement convolutif (FC-DenseNet) pour segmenter le disque et le cup. Les contours des images segmentées sont ensuite utilisés pour estimer le RCD sur les deux axes vertical et horizontal pour le diagnostic du glaucome. Le modèle a été entraîné sur la base d'images ORIGA et évalué sur quatre bases publiques sans entraînement : DRISHTI-GS, RIM-ONE, DRIONS-DB et ONHSD.

Dans le même contexte, Yu et al. (2019) [37] ont utilisé une architecture U-Net modifiée, qui combine les couches d'encodeur du modèle ResNet-34 pré-entraîné largement adopté avec des couches de décodeur U-Net classique pour la segmentation du disque et du cup. Le modèle a été entraîné sur la base RIGA et testé sur DRISHTI-GS et RIM-ONE.

En 2019, Afolabi et al. [38] ont appliqué une architecture U-Net améliorée pour extraire le disque optique et le cup optique. La méthode a été validée sur les deux bases de données DRISHTI-GS et RIM-ONE.

Qin et al. (2019) [39] ont proposé une approche pour la segmentation du disque et du cup à l'aide d'un réseau convolutionnel entièrement connecté (FCN) modifié et des éléments de base initiaux du modèle GoogleNet. L'algorithme a été entraîné et testé sur la base REFUGE et une base locale contenant 697 images.

De plus, pour l'extraction du disque et du cup, Božić-Štulić et al. (2020) [40] ont proposé un modèle de réseau de neurones profond entièrement convolutif basé sur SegNet pour la partie décodage et un modèle VGG16 affiné pour la partie encodage. Enfin, le RCD a été calculé pour

la détection du glaucome. La méthode a été formée sur les ensembles de données DRIVE et DIARETDB1 et évaluée sur Messidor.

Tabassum et al. (2020) [41] ont appliqué un nouveau modèle encodeur-décodeur nommé CDED-Net inspiré de SegNet et U-Net pour la segmentation sémantique du disque et du cup. Pour préserver les caractéristiques d'information possibles, des connexions denses ont été introduits entre les couches convolutionnelles de l'encodeur, tandis que la section du décodeur suit la structure originale de SegNet. CDED-Net a été validé avec les bases d'images RIM-ONE, DRISHTI-GS et REFUGE.

D'autre part, Liu et al. (2021) [42] ont suggéré un algorithme constitué de deux étapes pour la segmentation des images rétinienne. Dans la première étape, le disque optique a été localisé à l'aide d'un simple CNN, puis le ROI a été extrait en appliquant la transformée de Hough Circulaire (THC). Dans la deuxième étape, l'architecture DDSC-Net a été implémentée et entraînée afin d'obtenir le disque et le cup segmentés. Ce modèle utilise une connexion dense de réseau de convolution séparable profond et une entrée de pyramides d'images multi-échelles. Enfin, la fermeture morphologique de l'image a été utilisée pour obtenir le résultat final. DRISHTI-GS et REFUGE sont utilisés pour tester cette méthode.

Une nouvelle architecture basée sur le CNN et l'apprentissage résiduel profond appelée GlaucoNet a été construite par Panda et al. (2021) [43]. Ce modèle introduit les sauts des connexions supplémentaires qui reformulent explicitement les couches de sorte que la fonction d'apprentissage dépend d'une fonction résiduelle de la couche d'entrée. Ensuite, la transformation d'enveloppe convexe a été appliquée pour améliorer la segmentation. La méthode a été testée sur les bases d'images DRISHTI-GS, RIM-ONE et ORIGALight.

Shyamalee et al. (2022) [44] ont présenté un modèle U-Net attentif avec trois architectures de réseaux de neurones convolutifs (CNN) : Inception-v3, VGG19 et ResNet50 pour segmenter le cup et le disque. Plusieurs techniques d'augmentation des données ont été employées pour éviter le sur-apprentissage. L'U-Net attentif avec ResNet50 comme encodeur a montré la plus grande précision en utilisant l'ensemble de données RIM-ONE.

Veena et al. (2022) [45] ont proposé une approche de détection du glaucome en utilisant l'apprentissage profond. Le système est composé de deux architectures CNN séparées pour segmenter le cup et le disque dont chacune contient 39 couches (19 convolution, 4 max-pooling, 4 déconvolution, 11 dropout et une couche de fusion). Enfin, le RCD a été calculé pour différencier entre les images normales et glaucomateuses. Ce modèle a été formé et testé sur la base DRISHTI – GS.

2.1.2. Classification du Glaucome

La détection précoce du glaucome est une tâche importante pour prévenir la perte de vision irréversible. Plusieurs algorithmes sont développés pour distinguer entre les images saines et les images glaucomateuses en utilisant l'apprentissage automatique supervisé [46-55] et même l'apprentissage profond [56-62]. Singh et al. (2016) [46] ont présenté une méthode de traitement d'images pour le diagnostic du glaucome. Tout d'abord, la transformation des ondelettes a été utilisée pour extraire les caractéristiques, suivie de l'analyse en composante principale (PCA) pour la sélection des caractéristiques. Enfin, la classification a été effectuée à l'aide de cinq classifieurs supervisés : machines à vecteurs de supports (SVM), k plus proche voisin (KNN), réseau de neurones artificiels (ANN), forêt aléatoire (RF) et Naïve bayes (NB).

Das et al. (2016) [47] ont utilisé la ligne des partages des eaux (LPE) pour extraire le cup et le disque, puis les images ont été classées en vérifiant la NRR dans les quadrants de la règle ISNT. La technique a été appliquée sur quatre bases publiques HRF, Messidor, DRIONS-DB, RIM-ONE et une base d'images hospitalière locale.

Chakravarty et al. (2016) [48], ont appliqué la transformation de Hough pour segmenter le disque, puis ils ont extrait les caractéristiques de la texture des projections et de la couleur. Enfin, un classifieur SVM a été formé pour distinguer entre le disque sain et le disque glaucomateux. La base de données DRISTI-GS1 a été testée pour valider la performance du système.

Karkuzhali et al. (2017) [49] ont segmenté le disque et le cup à l'aide de la méthode super-pixel pour mesurer le RCD, extraire les quadrants ISNT, calculer la distance entre le centre du disque et la papille optique et la partie des vaisseaux à l'intérieur de la papille. Afin de classer les images sept différents classifieurs ont été testés qui sont : NB, k-NN, SVM, FFBPNN (Feed Forward Back Propagation Neural Networks), DTDNN (Distributed Time Delay Neural Network), RBFEF (radial basis function exact fit) et RBFFN (Radial Basis Function Few Neurons). Ces méthodes ont été évalué sur DRIVE, DIARETDB0, DIARETDB1 et DRISHTI-GS1.

Un système de diagnostic précoce du glaucome a été suggéré par Soltani et al. (2018) [50]. Ce système utilise le détecteur de CANNY et la transformée de Hough pour la segmentation du disque optique et du cup. Ensuite, un classifieur logique flou a été employé pour déterminer l'état du patient. Cette approche a été testée sur un jeu de données local qui contient 104 images.

De plus, Guo et al. (2018) [51] ont d'abord segmenté les régions de disque et de cup à l'aide du réseau U-net. Huit différentes caractéristiques morphologiques ont été extraites pour être

introduites dans un classifieur basé sur les forêts aléatoires. Cette méthode a été validée en utilisant la base ORIGA.

Raja et al. (2020) [52] ont développé un CNN pour extraire le disque et la croissance de région modifiée pour segmenter la cup. Ensuite, les caractéristiques de texture (surface, périmètre, entropie, intensité maximale et minimale et RCD) ont été extraites. Enfin, un réseau de neurones a été utilisé pour le diagnostic du glaucome. Les résultats expérimentaux ont été obtenus en utilisant la base de données DRIVE.

Sreng et al. (2020) [53] ont présenté un système automatique de dépistage du glaucome en deux étapes qui sont la segmentation et la classification. La segmentation du disque optique a été faite en utilisant une architecture DeepLabv3 combinée avec MobileNet. L'étape de la classification a été réalisée par les CNN pré-entraînés en testant trois stratégies différentes : (1) l'apprentissage par transfert, (2) l'apprentissage des descripteurs à l'aide de SVM et (3) construction d'un ensemble de méthodes à partir de (1) et (2). Les méthodes ont été évaluées avec cinq bases de données RIM-ONE, DRISHTI-GS1, ORIGA, ACRIMA et REFUGE.

Shinde (2021) [54] a utilisé l'architecture Le-Net pour valider les images d'entrée et la méthode du point le plus lumineux pour l'extraction de la région d'intérêt. Ensuite, le cup et disque ont été segmentés avec U-Net. Enfin, la classification du glaucome a été effectuée à l'aide des classifieurs SVM, ANN et Adaboost en utilisant le RCD, NRR et le rapport des vaisseaux rétinien. Le vote majoritaire a été utilisé pour obtenir les résultats finals. Six différentes bases de données publiques ont été testées.

Pathan et al. (2021) [55] ont segmenté le disque et le cup en utilisant l'arbre de décision et le seuillage. Ensuite, le RCD, la surface de NRR, et les caractéristiques de couleur et de texture ont été calculés. Enfin, les algorithmes ANN, SVM, AdaBoost ont été employés pour détecter les cas glaucomateux. Ces méthodes ont été testées sur la base DRISHTI_GS et une base locale.

Récemment, plusieurs travaux ont été présentés pour la détection du glaucome basée sur l'apprentissage profond sans passer par les étapes de segmentation et de caractérisation. Diaz-Pinto et al. (2019) [56] ont utilisé cinq modèles CNN différents : InceptionV3, XceptionNet, VGG16, VGG19 et ResNet50 pour classer les images normales et glaucomateuses. Le modèle XceptionNet a fourni la meilleure performance pour RIM-ONE, DRISTI-GS1 et ACRIMA.

De même, Gómez-Valverde et al. (2019) [57] ont employé cinq modèles fondés sur le CNN standard, VGG19, ResNet50, DENet et GoogleNet. Les meilleurs résultats ont été obtenus avec le VGG19 en utilisant la base de données RIM-ONE.

Elangovan P. et Nath M. K. (2020) [58] ont élaboré un CNN à 18 couches pour l'extraction des caractéristiques et la discrimination entre les cas glaucomateux et les cas sains. Ce modèle se compose de quatre couches de convolution chacune est suivie par la normalisation et ReLU,

deux max pooling, une couche entièrement connectée et couche de Softmax. Une augmentation des données a été faite en utilisant la rotation sur les 05 base de données testées (DRISHTI-GS1, ORIGA, RIM-ONE2, ACRIMA et LAG).

Pour la détection du glaucome, Juneja M. et al. (2020) [59] ont construit une architecture GC-NET. Les auteurs ont appliqué le filtre médian adaptatif pour améliorer les images et des méthodes d'augmentation des données pour agrandir l'ensemble des données d'apprentissage. Les images obtenues ont été envoyées en entrée à GC-NET, qui se compose de 76 couches (convolution, normalisation, ReLU, max pooling, dropout et couches denses). GC-NET a été validé sur les bases RIM-ONE et DRISHTI-GS1.

Ovriu S. et al. (2021) [60] ont appliqué le modèle pré-entraîné DenseNet-201 pour le dépistage du glaucome à partir de la base de données ACRIMA. Pour agrandir les images de formation, ils ont utilisé la rotation et le retournement (effet miroir).

Sudhan M. B. et al. (2022) [61] ont mis au point un système d'apprentissage profond pour détecter le glaucome. Ce système utilisait l'architecture U-Net pour la segmentation du cup, le réseau Dense-Net201 pour l'extraction des fonctionnalités et le CNN profond (DCNN) pour la classification du glaucome. Cette méthode a été évaluée sur l'ensemble d'images ORIGA.

Latif J. et al. (2022) [62] ont implémenté le réseau ODGNet pour la localisation du disque et la détection du glaucome. Au départ, le disque était localisé à l'aide d'une carte visuelle des zones saillantes incorporées à CNN peu profond. Ensuite, trois modèles pré-entraînés : VGGNet-16, AlexNet et ResNet-34 ont été appliqués pour diagnostiquer le glaucome. Cinq bases ont été exploitées pour évaluer l'efficacité d'ODGNet : RIM-ONE, ORIGA, DRIONS-DB, HRF et DR-HAGIS.

2.2. Rétinopathie diabétique (RD)

La RD est une pathologie rétinienne et la conséquence d'un diabète non équilibré. Dans un stade précoce, elle affecte les petits vaisseaux rétiens, produisant des changements de diamètre, de largeur et de tortuosité et par le temps l'apparition des lésions rétiennes (microanévrismes (Mas), hémorragies (Hs)...etc).

Dans cette partie, nous allons citer quelques travaux existant pour la segmentation du réseau rétinien et la classification de la RD à partir des images rétiennes.

2.2.1. Segmentation du réseau vasculaire rétinien

La progression de la RD engendre des altérations morphologiques dans l'arbre vasculaire rétinien, donnant naissance à des néo vaisseaux. Par conséquent, une bonne segmentation des vaisseaux sanguins est décisive pour la détection précoce de cette maladie. Plusieurs systèmes

utilisant le traitement d'images [63-67] et l'apprentissage profond [68-80] ont été développés pour la détection précoce du réseau rétinien.

La technique Extreme Learning Machine (ELM) et les opérations morphologiques ont été utilisés par Zhu et al. (2016) [63] pour segmenter les vaisseaux. 39 caractéristiques (locales, morphologiques, hessien...) ont été calculées pour chaque pixel et appliquées comme entrée de ELM. Les tests expérimentaux ont été effectués sur les 02 BDD DRIVE et RIS.

Un autre algorithme a été proposé par Jyotiprava Dash et al. (2017) [64] pour l'extraction des vaisseaux sanguins. Au début le canal vert a été amélioré par CLAHE et le filtre médian. Ensuite la méthode de seuillage C-moyen et le nettoyage morphologique ont été appliqués pour obtenir le résultat final. L'algorithme a été évalué sur les deux bases de données DRIVE et CHASE_DB1.

Dans le travail [65], Luiz Carlos Rodrigues et al. (2017) ont appliqué le chapeau haut de forme blanc, la transformée en ondelettes et le seuillage pour détecter le disque optique. Pour segmenter les gros vaisseaux le filtrage multi-échelle basé sur la matrice de Hessien et l'algorithme génétique ont été utilisés. L'extraction des petits vaisseaux a été effectuée en combinant un détecteur de ligne avec un seuillage d'hystérésis. Les résultats des deux méthodes ont été fusionnés avec l'algorithme de plus court chemin afin d'avoir le résultat final. La méthode a été testée sur les bases DRIVE et HRF.

Les auteurs de [66] ont utilisé la méthode LSBF (Line Set Based Feature) pour obtenir les descriptions locales, le gradient morphologique pour améliorer le contour local des petits vaisseaux. La méthode SVM a été entraînée pour segmenter des vaisseaux sanguins en utilisant les 02 bases DRIVE et STARE.

La technique proposée par Qu et al. (2017) [67] utilise l'opérateur de ligne multi-échelle et les opérations morphologiques pour segmenter les vaisseaux sanguins rétiens à partir d'une base locale.

L'inconvénient des méthodes citées précédemment est la nécessité d'un bon prétraitement afin d'améliorer la qualité d'images, ainsi qu'une étape de post-traitement. Cependant, les petits vaisseaux restent mal détectés à cause de leurs tailles minimales. Afin d'augmenter la précision de la segmentation des techniques basées sur l'apprentissage profond ont été développées.

Pour la segmentation des vaisseaux rétiens, Jin et al. (2019) [68] ont proposé un modèle U-Net déformable (DUNet) en inspirant de U-Net et ConvNet déformable. DUNet remplace certaines couches de convolution par un bloc convolutif déformable dans l'encodeur et le décodeur. Ce modèle a été évalué en utilisant les bases de données DRIVE, STARE, CHASE DB1 et HRF.

Dans le même contexte, Samuel et Veeramalai (2019) [69] ont proposé un réseau de neurones profond (DNN) initialisé avec les quatre premières couches du modèle VGG16 et incorporé avec les couches de supervision profonde multiniveaux/multi-échelles en utilisant des convolutions gaussiennes pour segmenter les vaisseaux rétiniens. Ils ont validé le modèle sur les 03 BDD : DRIVE, STARE et HRF.

Un système d'extraction des vaisseaux rétiniens a été proposé par Jiang et al. (2019) [70] à l'aide d'un réseau de neurones entièrement convolutionnel (M3FCN) à fusion multi-échelles, multi-voies et multi-sorties. Une augmentation des données a été faite en utilisant la méthode RCF (Random Crop et Fill). L'algorithme M3FCN a été testé sur les BDD : DRIVE, STARE et CHASE-DB1.

De plus, Ozgunalp et al. (2020) [71] ont utilisé SegNet initialisé avec le réseau VGG16 pour l'extraction des vaisseaux sanguins. Ils ont testé la méthode sur la base de données HRF.

Ma et al. (2020) [72] ont développé un réseau d'activation étendu (WA-Net) utilisant un bloc d'apprentissage résiduel pour détecter les vaisseaux sanguins. La technique WA-Net a été testée sur les bases de données DRIVE et STARE.

Un U-Net avec convolution dilatée guidé par l'attention (AA-U-Net) a été proposé par Lv et al. (2020) [73] pour classer les pixels comme vaisseaux ou fond à partir des bases DRIVE, STARE et CHASE-DB1. Ils ont ajouté un module d'attention et deux raccourcis dans la couche caractéristique et remplacé deux couches de convolution par la convolution dilatée.

Jiang et al. (2020) [74] ont appliqué l'architecture Butterfly-FCN efficace (BFCN) pour la segmentation des vaisseaux en utilisant plusieurs entrées multi-échelles, la convolution dilatée avec différents taux d'expansion et la couche de transfert. Ensuite, le post-traitement a été effectué en employant le Laplacian pour améliorer les résultats. L'algorithme proposé a été testé sur les bases de données DRIVE, STARE et CHASE-DB1.

Sathamantavathi et Indumathi (2021) [75] ont appliqué un réseau U-Net d'encodeur amélioré atrous (EEA) pour segmenter les vaisseaux rétiniens en remplaçant toutes les couches de convolution par des convolutions dilatées et en introduisant des couches d'addition pour améliorer la partie d'encodeur. Le modèle a été validé sur DRIVE, STARE, CHASE_DB1 et HRF.

De même, Lin et al. (2021) [76] ont proposé un réseau avec une échelle à trajets multiples MPS-Net pour l'extraction des vaisseaux rétiniens. En outre, la fonction de perte cross-entropie forte orientée modifiée a été utilisée pour améliorer les résultats. MPS-Net a été vérifié sur DRIVE, STARE, CHASE-DB1.

Un nouveau réseau appelé RV-Net a été présenté par Boudegga et al. (2021) [77] pour la détection de l'arbre vasculaire. Cette architecture utilise des modules de convolution légers (LCM) à la place des couches de convolution. Le modèle a été testé sur DRIVE et STARE.

Li et Rahadja (2021) [78] ont implémenté un modèle U-Net résiduel modifié construit avec un bloc résiduel BSE (BSEResu-Net). Aussi, une fonction de perte articulaire basée sur la perte d'entropie croisée et le dice a été utilisée pour détecter les vaisseaux rétiniens. L'algorithme BSEResU-Net a été testé sur les bases de données DRIVE, STARE et HRF.

L'architecture SegNet a été employée par Xu et al. (2022) [79] pour augmenter la précision de la segmentation de l'arbre vasculaire rétinienne. La performance du modèle a été évaluée sur les trois bases publiques DRIVE, STARE et HRF.

Deng et Ye (2022) [80] ont développé un nouvel algorithme de segmentation basé sur une attention multi-échelle avec un mécanisme résiduel D-MNet (Deformable convolutional M-shaped Network), combiné avec un modèle amélioré PCNN (Pulse-Coupled Neural Network). Les bases DRIVE, STARE, CHASE_DB1 et HRF ont été utilisées pour tester l'algorithme D-MNet.

2.2.2. Classification de la rétinopathie diabétique

Les changements dans la largeur et la tortuosité des vaisseaux rétiniens sont des indicateurs clés de la présence de la RD. Habituellement, les ophtalmologistes identifient cette pathologie à l'aide des caractéristiques géométriques de l'arbre vasculaire comme la surface, le périmètre, la largeur, le diamètre, les points de bifurcation et la tortuosité ainsi que la présence des différentes lésions. Les algorithmes de classification supervisée [81-89] et de deep learning [90-96] ont largement appliqués pour différencier entre les cas normaux et les cas affectés par la RD.

Nair et Muthuvel (2019) [81] ont segmenté des gros vaisseaux en prenant des pixels similaires sur deux images obtenues par le filtrage passe-haut et top-hat par reconstruction, puis le classifieur GMM a été utilisé pour détecter des petits vaisseaux à partir des pixels résiduels dans les deux images. Par la suite, GLCM et GLRM ont été employés pour l'extraction des caractéristiques, suivi du classifieur de réseau neuronal modifié (ANN) pour reconnaître la RD. La méthode MCS-NS a été appliquée pour optimiser les poids. Ils ont vérifié l'algorithme sur les ensembles de données HRF, DRIVE et STARE.

Sultana et Rajasekhar (2019) [82] ont appliqué la méthode Haralick en combinant haar-DWT et GLCM pour l'extraction des paramètres à partir des bases Diaretdb0 et HRF. Ensuite, SVM avec différents noyaux a été effectué pour la classification, où le noyau linéaire.

Qomariah et al. (2019) [83] ont utilisé les modèles de l'apprentissage par transfert (Alexnet, VGGnet, InceptionNet, GoogleNet et Densenet) pour l'extraction des caractéristiques et SVM pour la classification des images. Ils ont testé sur la base Messidor.

Pour la classification binaire et multi-classe de la RD, Gayathri et al. (2020) [84] ont combiné la fonction Haralick de deuxième ordre et ADTCWT pour l'extraction des caractéristiques. Ensuite, SVM, Random Forest, Random Tree, J48 ont été utilisés pour la classification. Random Forest a donné les meilleurs résultats sur MESSIDOR, KAGGLE et DIARETDB0.

De plus, Kumar et al. (2020) [85] ont élaboré des méthodes de détection des MA et des Hs à l'aide d'opérations morphologiques. Ensuite, sept caractéristiques géométriques ont été calculées. Enfin, le réseau neuronal à fonction de base radiale (RBFNN) est utilisé pour distinguer les images normales des images RD. Ils ont été testées sur Diaretdb0 et Diaretdb1.

Bilal et al. (2021) [86] ont segmenté les Hs et les exsudats à l'aide d'un seuillage adaptatif et d'opérations morphologiques et extrait quatre caractéristiques. Pour la classification des stades de la RD, SVM, KNN et les arbres binaires (BT) sont utilisés, suivis de l'approche du vote majoritaire pour améliorer les résultats. La méthode a été validée sur IDRiD.

En outre, Wang et al. (2021) [87] ont proposé l'approche SSGAN (semi-supervised generative adversarial network) à multicanal pour la classification des RD en employant les données étiquetées et non étiquetées de la base Messidor. Le générateur multicanal a été utilisé pour générer une série de sous-images. Ces dernières ont été fusionnées pour extraire les caractéristiques les plus significatives.

Abdelmaksoud et al. (2021) [88] ont présenté une technique pour le diagnostic de la RD à l'aide de huit bases de données publiques. Premièrement, onze caractéristiques ont été calculées en appliquant la méthode GLRLM. Par la suite, l'architecture U-Net a été utilisée pour segmenter les MAs, Hs, Exsudats et vaisseaux sanguins à partir d'images RD. Après, ils ont extrait six caractéristiques en utilisant GLGM et ils ont calculé les surfaces des images segmentées et les points de bifurcation des vaisseaux rétinien. Enfin, la classification a été faite par SVM avec noyau RBF.

Bilal et al. (2022) [89] ont appliqués deux architectures U-Net indépendantes pour extraire le disque et l'arbre vasculaire. La classification de la RD a été réalisée en utilisant le modèle inception-v3 basé sur le transfert learning. L'algorithme a été testé sur Messidor-2, EyePACS-1 et DIARETDB0.

Récemment, l'apprentissage profond est largement utilisé pour la détection de la RD sans extraire les régions pertinentes. Aujih et al. (2018) [90] ont employé U-Net avec couche de dropout et normalisation pour la segmentation du réseau rétinien, et le modèle InceptionV1 pour la classification. Cette technique a été validée sur DRIVE et MESSIDOR.

Pour le dépistage de la RD, Hajabdollahi et al. (2019) [91] ont modifié le réseau VGG16 en utilisant une technique d'élagage hiérarchique pour simplifier le modèle et minimiser le nombre de paramètres. Ils ont vérifié les performances sur l'ensemble d'images Messidor.

Hemanth et al. (2019) [92] ont appliqué HE et CLAHE pour améliorer l'image et un CNN pour détecter la DR. Ils ont évalué en utilisant 400 images de la base Messidor.

En outre, Baget-Bernaldiz et al. (2021) [93] ont mis au point un algorithme d'apprentissage profond (DLA) pour évaluer et différencier entre les images saines, RD ou RD référible. Le DLA est un CNN composé de 7 blocs avec 2 couches. Chaque couche constitue de : convolution + normalisation + ReLU suivie d'une couche de pooling. Dans la couche finale, un classifieur linéaire et une fonction softmax sont appliqués. La fonction de perte kappa pondérée quadratique est utilisée pour l'optimisation. MESSIDOR a été utilisée pour valider les résultats.

Pour la détection de la RD, Das et al. (2022) [94] ont utilisé un CNN pour l'extraction des caractéristiques et SVM pour la classification. Les meilleurs paramètres du CNN comme le nombre et la taille des filtres de convolution sont fixés par l'algorithme génétique. Cette approche a été évalué sur la base MESSIDOR.

Dans [95], Mazumder et al. (2022) ont proposé une stratégie de classification binaire de la DR à l'aide de cinq modèles (InceptionV3, MobileNetV2, ResNet50, VGG16 et VGG19). L'architecture MobileNetV2 a donné les meilleurs résultats avec 3662 images de Kaggle.

Un système de détection des grades de la RD a été proposé par da Rocha et al. (2022) [96] en appliquant le modèle VGG16. Ils ont validé leurs résultats sur les bases DDR, EyePACS et IDRiD.

Vu l'importance du diagnostic précoce du glaucome et de la rétinopathie diabétique pour éviter la perte de vision irréversible, il y a toujours de nouveaux travaux proposés afin d'améliorer les résultats existants [97-100] et même de nouvelles bases d'images collectées.

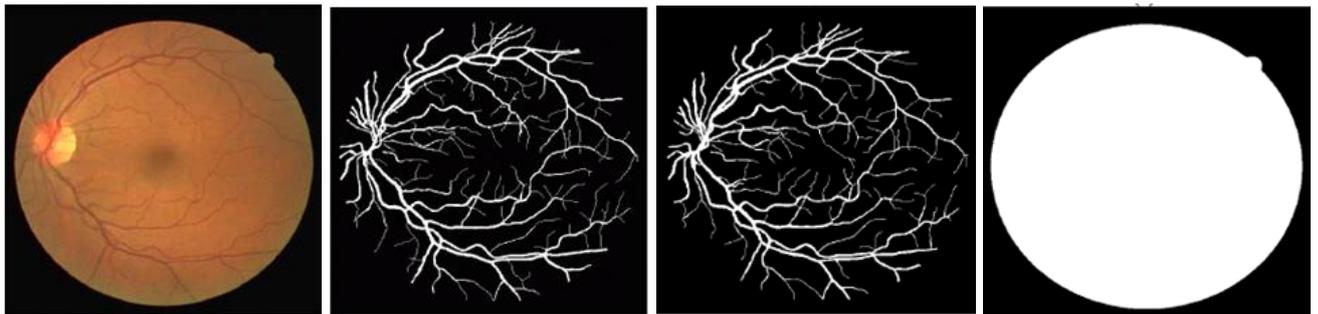
Dans la partie qui suit, nous allons citer les différentes bases de données publiques et locales collectées utilisées dans nos travaux réalisés pour valider et comparer les résultats obtenus.

3. Bases de données (BDD)

Plusieurs bases d'images rétiniennes sont disponibles en ligne pour évaluer et tester les performances des systèmes d'aides à la décision. Ces BDD ont été utilisées par plusieurs chercheurs [27-100] pour cette raison dans notre travail nous allons utiliser les mêmes bases pour évaluer nos algorithmes.

3.1. DRIVE (Digital Retinal Images for Vessel Extraction)

Elle comprend 40 images du fond d'œil, dont 33 normales et 7 pathologiques avec des signes de la RD. Ces images sont acquises par un rétinographe non mydriatique Canon RC5 avec un champ de vision (CV) de 45°. Cette base est divisée en deux groupes : 20 images pour l'apprentissage et 20 pour le test. Deux segmentations manuelles de l'arbre vasculaire et le masque pour délimiter le ROI sont fournies par des ophtalmologues. Un exemple d'image est montré dans la figure II.1 [101].

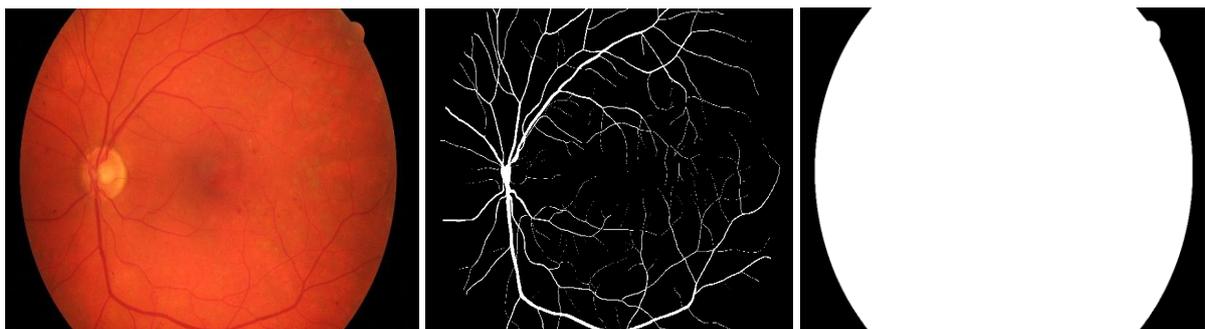


a-Image originale b- Vérité terrain expert1 c-Vérité terrain expert2 d- Masque d'image

Figure II.1 : Exemple de la base DRIVE.

3.2. HRF (High Resolution Fundus)

Elle regroupe 45 images rétiniennes dont 15 normales, 15 glaucomateuses et 15 images avec rétinopathie diabétique. Ces images sont capturées avec un rétinographe non mydriatique avec un CV de 45°. Chaque image possède une segmentation vérité terrain de l'arbre vasculaire, ainsi qu'un masque du ROI. Un exemple est illustré dans la figure II.2 [102].



a- Image originale b- Image vérité terrain c- Masque de l'image

Figure. II.2 : Exemple de la base HRF.

3.3. CHASE_DB1 (Child Heart and Health Study in England)

Elle contient 28 images recueillies auprès des deux yeux de 14 enfants. Elles sont de bonne qualité et sans aucun symptôme de pathologies. Toutes les images sont capturées en utilisant une cible de fixation et focalisée sur le disque optique. Pour chaque image deux images labellisées des vaisseaux rétiniens sont réalisées par 2 experts (figure II.3) [103].

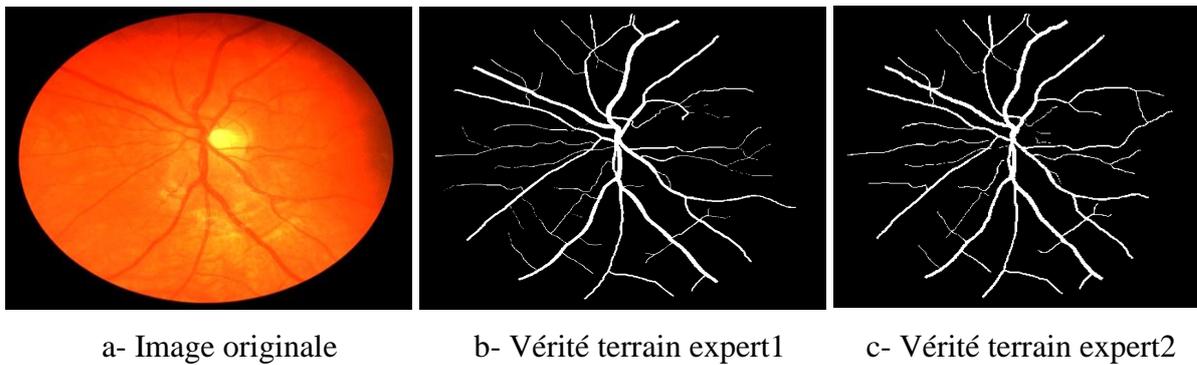


Figure II.3 : Exemple de la base CHASE_DB1.

3.4. STARE (STructured Analysis of the Retina)

Elle se compose de 20 images dont 10 images normales et 10 images affectées par la RD. Ces images sont acquises par le rétinographe Topcon TRV-50 avec un CV de 35°. La segmentation manuelle de l'arbre vasculaire est effectuée par deux ophtalmologues. Un exemple est présenté dans la figure ci-dessous [104].

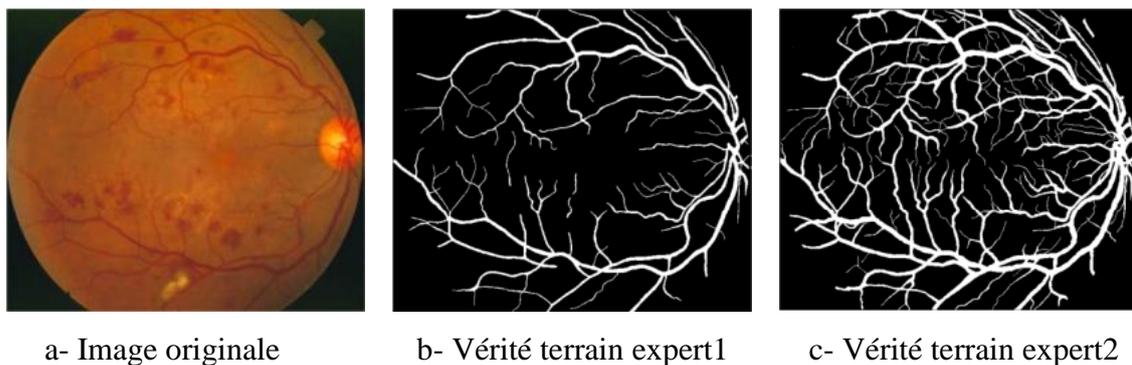


Figure II.4 : Exemple de la base STARE.

3.5. MESSIDOR (Méthodes d'Evaluation de Systèmes de Segmentation et d'Indexation Dédiées à l'Ophtalmologie Rétinienne)

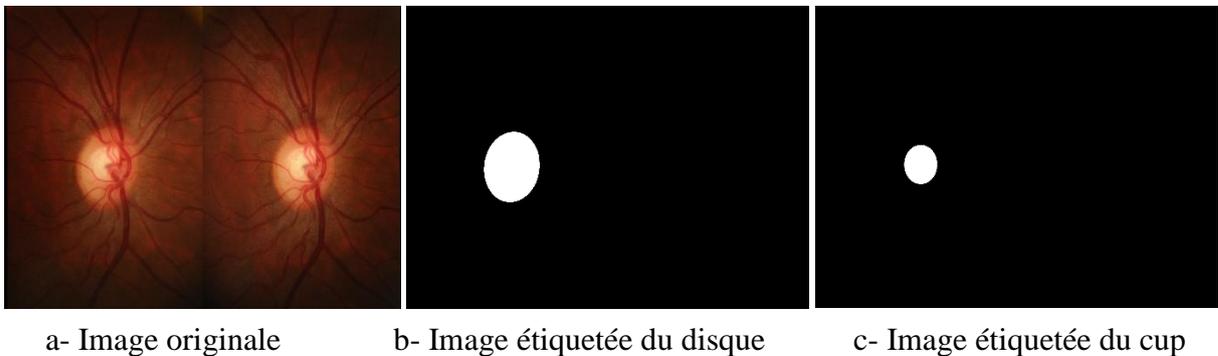
Elle englobe 1200 images rétiniennes couleurs acquises en utilisant une caméra 3CCD intégrée à un rétinographe non mydriatique de type Topcon TRC NW6 avec un CV de 45°. 800 photographies sont collectées avec dilatation pupillaire et 400 photographies sans dilatation. Pour chaque image, le grade de la RD et le risque d'œdème maculaire sont indiqués par des spécialistes [105]. La figure II.5 montre quelques exemples d'images de cette base.



Figure II.5 : Exemples des images de la base MESSIDOR.

3.6. RIM-ONE (An open retinal image database for optic nerve evaluation)

Elle possède 159 stéréo-images couleur de la papille optique de haute résolution, dont 74 images glaucomateuses ou suspectes et 85 images saines. Les images sont capturées en utilisant l'appareil Nidek AFC210 avec un corps de Canon EOS 5D Mark II de 21,1 mégapixels. La segmentation manuelle du disque et du cup optique est fournie par les experts (figure II.6) [106].



a- Image originale

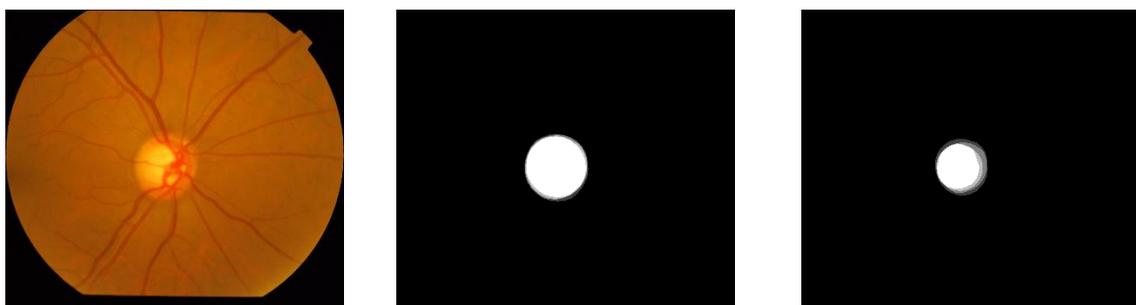
b- Image étiquetée du disque

c- Image étiquetée du cup

Figure II.6 : Exemple de la base RIM-ONE.

3.7. DRISHTI-GS1

Elle comprend 101 images rétinienne couleurs centrées sur le disque optique, dont 31 images normales et 70 images glaucomateuses. Elle est divisée en deux groupes : 50 images d'entraînement avec des segmentations manuelles de disque et de cup, et 51 images de test non annotées. Les images sont prises avec un CV de 30 degrés [107]. La figure suivante illustre un exemple de cette base.



a- Image originale

b- Image étiquetée du disque

c- Image étiquetée du cup

Figure II.7 : Exemple de la base DRISHTI-GS1.

3.8. Base locale collectée

Une nouvelle base de données locale est collectée en 2019 au niveau du service d'ophtalmologie dans un hôpital Algérien pour la détection et le suivi du glaucome. Elle regroupe 230 images OCT papillaire (tête du nerf optique) couleur, dont 118 images normales et 112 images glaucomateuses. Ces images sont prises de l'un ou des deux yeux de 110 patients (41 femmes et 69 hommes). L'ensemble des patients ont un intervalle d'âge entre 12 et 83 ans. La figure ci-dessous représente la répartition de notre base de donnée selon le sexe.

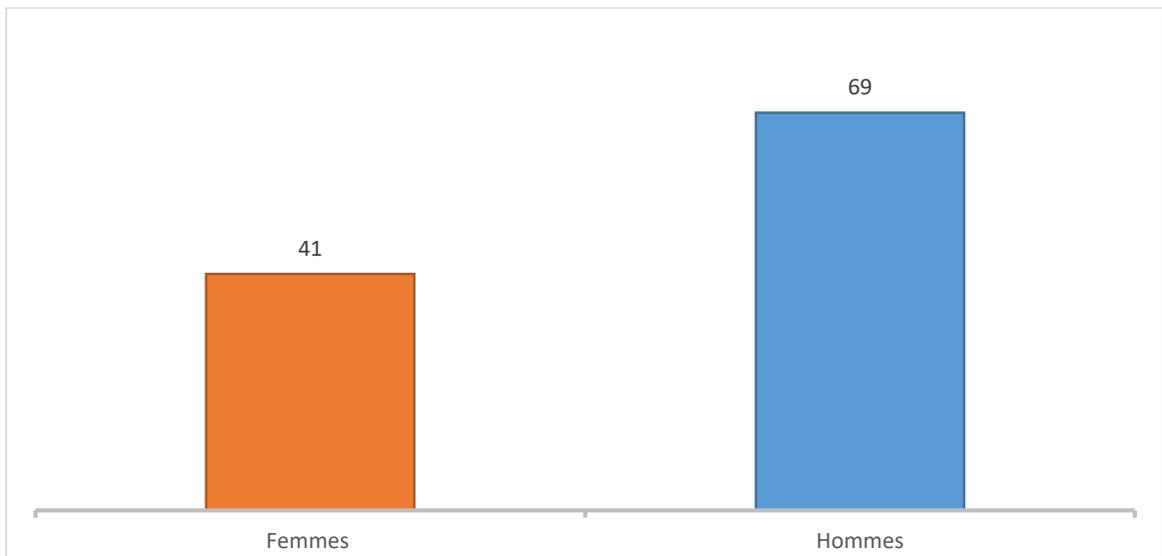
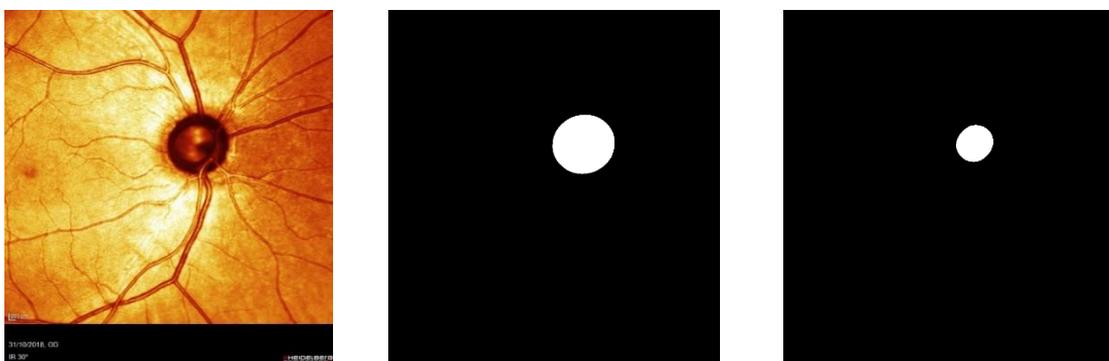


Figure II.8 : Répartition de la base collectée selon le sexe.

Les images sont acquises à l'aide de l'appareil OCT Spectralis Heidelberg Engineering avec un champ de vision de 30° et avec ou sans une dilatation papillaire. Elles sont capturées et enregistrées au format JPG, avec une taille de 768 * 868 pixels. Des images vérité terrain sont fournies pour le disque optique et le cup optique par des experts en ophtalmologie. La figure II.9 suivante montre un exemple de notre base locale collectée.



a- Image originale

b- Image étiquetée du disque

c- Image étiquetée du cup

Figure II.9 : Exemple de notre base de données collectée.

3.9. DRIONS-DB (Digital Retinal Image for Optic Nerve Segmentation Database)

Elle englobe 110 images rétinienne couleurs avec les images étiquetées du disque optique. Ces photographies sont acquises en utilisant une caméra analogique couleur et numérisées à l'aide d'un scanner haute résolution HP-PhotoSmart (figure II.10) [108].

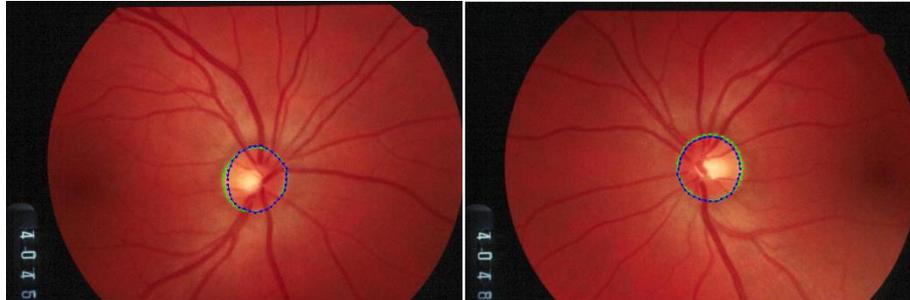
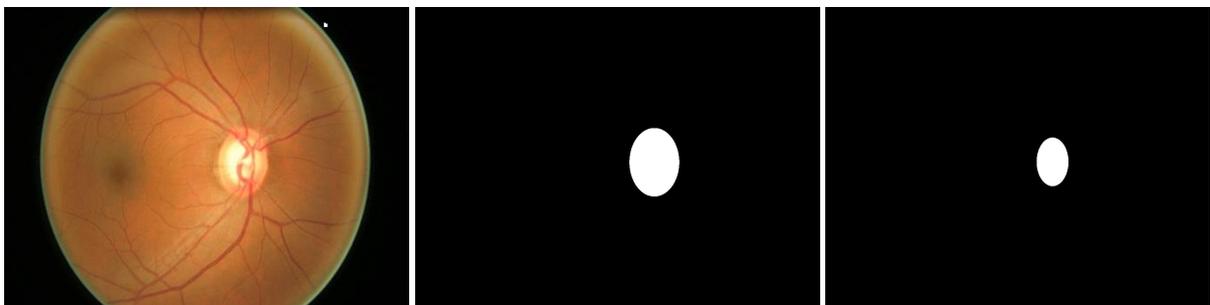


Figure II.10 : Exemples de la base DRIONS-DB avec contours du disque optique fournis par les experts.

3.10. ORIGA (Online Retinal Images for Glaucoma Analysis)

Elle constitue de 650 images fond d'œil couleur dont 482 images normales et 168 images glaucomateuses. Chaque image possède la segmentation du disque et cup effectuée par des experts et le RCD [109]. Un exemple d'image est présenté dans la figure II.11.



a- Image originale

b- Image étiquetée du disque

c- Image étiquetée du cup

Figure II.11. Exemple de la base ORIGA.

3.11. ACRIMA

Elle contient 705 images fond d'œil divisées en 309 cas sains et 396 cas glaucomateux. Les images sont capturées en utilisant la caméra Topcon TRC avec un CV de 35° sur des yeux dilatés. Les images sont centrées autour du disque optique (figure II.12). Deux experts ont catégorisé les images en deux classes : normales et pathologiques [56].

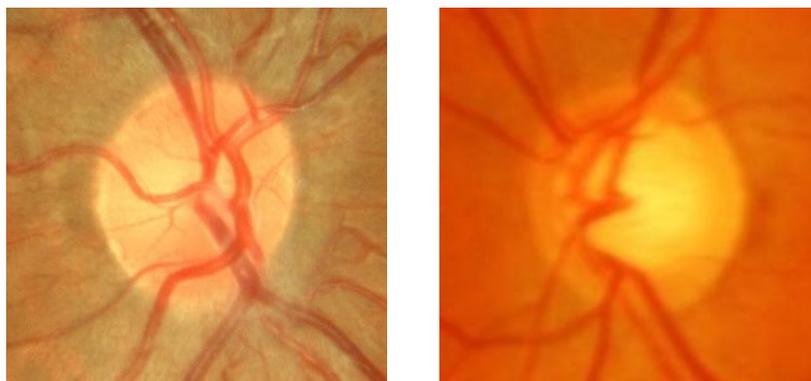


Figure II.12 : Exemples des images de la base de donnée ACRIMA.

Le tableau II.1 ci-dessous résume pour chaque base de données le nombre d'images disponible dans les trois cas : normal, glaucome et RD, ainsi que l'accessibilité en ligne. Il indique le nombre total d'images normales et pathologiques utilisées dans cette thèse pour valider les différents algorithmes développés.

BDD	Accessibilité	Nombre total	Normale	Glaucome	RD
DRIVE	Publique	40	33	0	7
HRF	Publique	45	15	15	15
CHASE_DB1	Publique	28	28	0	0
STARE	Publique	20	10	0	10
MESSIDOR	Publique	1200	547	0	653
RIM ONE	Publique	159	85	74	0
DRISHTI_GS1	Publique	101	31	70	0
LOCALE	Privée	230	118	112	0
DRIONS_DB	Publique	110	55	55	0
ORIGA	Publique	650	482	168	0
ACRIMA	Publique	705	309	396	0
Nombre total		3288	1713	890	685
				1575	

Tableau II.1 : Résumé du nombre d'images dans chaque base de données.

Cependant, la majorité des bases d'images publiques sont petites et insuffisantes pour valider la robustesse des systèmes d'aide au diagnostic. De même elles ont des inconvénients en termes de la résolution et d'annotation d'images. L'intérêt de tester et combiner plusieurs bases de données est l'adaptation de nos algorithmes sur des images de différentes qualités et résolutions pour augmenter les performances et avoir une large base de donnée équilibrée en terme de cas normaux et de cas pathologiques afin d'éviter des problèmes de classification.

La figure II.12 illustre le nombre globale d'images dans chaque cas. Selon cette représentation nous observons que le nombre d'images est équilibré : 52% cas normaux et 48% cas pathologiques (27% glaucome et 21% RD).

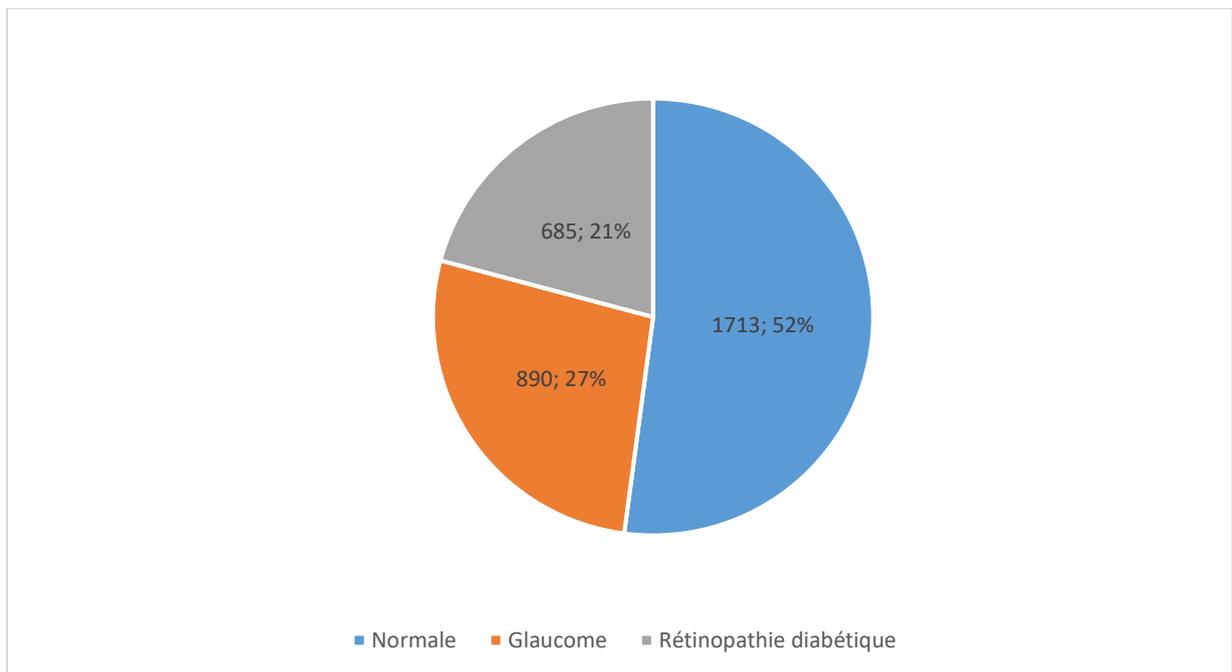


Figure II.13 : Résumé du nombre d'images normales, glaucomateuses et RD.

4. Conclusion

Ce chapitre a passé en revue certaines des recherches les plus récentes disponibles dans la littérature pour la détection du glaucome et de la RD. Un ensemble de base de données publiques ainsi que la base de donnée locale collectée au cours de cette thèse sont décrites.

Dans le chapitre suivant, nous définirons les techniques de traitement d'images et de l'apprentissage profond pour la segmentation des régions de l'œil et la classification du glaucome et de la rétinopathie diabétique.

Chapitre III :

**Techniques de traitement des images rétiniennes et
principe d'apprentissage profond**

1. Introduction

L'application des algorithmes de traitement d'images et de l'intelligence artificielle a vécu un grand progrès ces dernières années dans divers domaines. Ces techniques visent à gérer des problèmes complexes en temps minime et avec une grande performance. Dans le domaine médical, l'objectif principal des logiciels informatisés est la détection précoce et le diagnostic automatique des troubles médicaux. Ces systèmes aident les spécialistes dans leurs pratiques clinique en interprétant des images acquises à l'aide de différents examens cliniques. En ophtalmologie, l'intégration des applications intelligentes est essentielle pour prévenir la défiance visuelle et la cécité totale.

Ce chapitre est consacré à la description des algorithmes de traitement d'images et d'apprentissage automatique employés dans cette thèse pour la détection des maladies oculaires. Dans la partie qui suit, nous présenterons le principe du deep learning et les réseaux de neurones convolutifs avec ces différentes couches, ainsi que les méthodes d'optimisation et les hyperparamètres d'apprentissage d'un CNN. Par la suite, les modèles de segmentation et de classification les plus populaires seront décrits. Enfin, nous introduirons les différentes métriques d'évaluation les plus utilisées en traitement d'images.

2. Techniques de traitement d'images médicales

Le traitement et l'analyse des images médicales est une tâche très importante consistant à extraire automatiquement les informations significatives à l'aide des outils computationnels. Il englobe trois sous-parties principales : le prétraitement, la segmentation et le post-traitement. Chacune d'elles à un rôle majeur dans l'amélioration et la détection des objets avec une grande précision. Dans ce qui suit, nous allons définir brièvement l'intérêt de chaque partie.

2.1. Prétraitement

Les images rétinienne couleur prises lors d'un examen ophtalmologique sont souvent faiblement contrastées et menées des artéfacts, ce qui rend la segmentation des régions d'intérêt difficile et compliquée surtout dans le cas des images pathologiques. Pour remédier ce problème, différentes méthodes peuvent être introduites. Le prétraitement est l'une des étapes primordiales dans un outil d'aide au diagnostic médical. Il sert à améliorer la qualité d'une image en préservant le maximum d'informations pertinentes. Dans les parties suivantes, nous allons décrire les différentes techniques de filtrage et d'amélioration de contraste employées au cours de cette thèse pour prétraiter les images rétinienne.

2.1.1. Filtre médian

Filtre médian est l'un des filtres les plus simples, il sert à éliminer les pics isolés correspondant au bruit impulsionnel, préserver les discontinuités et améliorer la qualité d'image. Il fonctionne en remplaçant chaque pixel par la valeur médiane des pixels dans son voisinage [110]. L'algorithme du filtre médian est implémenté en parcourant tous les pixels de l'image comme suit :

1. Définir la taille de la fenêtre du voisinage (généralement impaire).
2. Ordonner les valeurs des pixels de cette fenêtre de manière croissante.
3. Déterminer la valeur médiane de cette séquence ordonnée.
4. Remplacer le pixel central par la valeur médiane trouvée dans l'étape précédente.

2.1.2. Filtre gaussien

Filtre gaussien est un filtre linéaire utilisé pour atténuer les bruits aléatoires. Il est basé sur la distribution gaussienne qui est définie comme suit [111] :

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (\text{III.1})$$

Où σ est la variance de la fonction de moyenne nulle. Si σ est petite, ce filtre est employé pour réduire le bruit, sinon (σ grande) il ajoute un flou à l'image et adoucit les détails importants.

L'image filtrée I_f est obtenue en effectuant un produit de convolution entre la fonction gaussienne G et chaque pixel de l'image originale I :

$$I_f(x, y) = G(x, y) * A(x, y) \quad (\text{III.2})$$

2.1.3. Filtre morphologique

Ce type de filtrage repose sur la simplification de l'image en éliminant des objets géométriques selon un élément structurant. Quatre opérateurs de base sont décrits dans cette partie qui sont l'érosion, la dilatation, l'ouverture et la fermeture [112].

- ✓ L'érosion a pour résultat de diminuer des objets de l'image en supprimant les petits détails.
- ✓ La dilatation sert à élargir les objets, elle a pour but d'éliminer les trous et dilater les contours.
- ✓ L'ouverture a comme effet d'éliminer toutes les parties connexes les plus étroites que l'élément structurant.
- ✓ La fermeture rebouche toutes les parties du fond les plus étroites que l'élément structurant.

2.1.4. Egalisation d'histogramme adaptative (AHE)

L'égalisation d'histogramme adaptative (Adaptive Histogram Equalization AHE) est l'une des méthodes d'amélioration de contraste. Elle consiste à redistribuer les valeurs des intensités de l'image initiale sur tout l'intervalle des niveaux de gris de manière uniforme. Son principe est de calculer plusieurs histogrammes chacun correspond à une partie distincte de l'image. Puis les utilisés pour distribuer les valeurs d'intensité. Elle est donc adaptée pour améliorer le contraste local et les contours de chaque région de l'image [113].

2.1.5. Egalisation d'histogramme adaptative limité en contraste

L'égalisation d'histogramme adaptative limité en contraste (Contraste Limited Adaptive Histogram Equalization CLAHE) est la technique la plus utilisée pour l'amélioration du contraste locale des images médicales. Elle diffère de l'AHE par sa limitation de contraste. CLAHE applique une méthode de limitation de contraste à chaque voisinage à partir duquel une fonction de transformation est dérivée. Elle a été développée pour éviter la suramplification du bruit des régions homogènes que l'AHE produit [113].

2.1.6. Matrice de hessienne

La matrice d'Hessienne est une matrice carrée obtenue en calculant la dérivée partielle de second ordre de l'image [114, 115]. Elle est employée pour déterminer les points extrêmes (les maximas et les minimax locaux) existants dans une image en utilisant les valeurs propres. Elle est présentée comme suit (eq.3) :

$$H = \begin{bmatrix} G_{xx} & G_{xy} \\ G_{yx} & G_{yy} \end{bmatrix} \quad (\text{III.3})$$

Où, G_{xx} est la dérivée seconde suivant la direction x , G_{yy} est la dérivée seconde suivant la direction y et G_{xy} est la dérivée seconde selon les directions x et y . La matrice de hessienne est symétrique par rapport aux valeurs propres réelles, alors $G_{xy} = G_{yx}$.

2.2. Segmentation d'images

La segmentation d'images est la principale étape dans un système d'aide au diagnostic. Elle consiste à partitionner l'image en régions homogènes selon des critères d'homogénéité. La segmentation des images médicales joue un rôle important dans la délimitation des régions anatomiques et la détection des lésions pathologiques. Il existe une diversité de méthodes de segmentation dans la littérature, variées des techniques classiques comme le seuillage, croissance de région, fuzzy-C-Means et le contour actif, jusqu'aux algorithmes avancés et complexes basés

sur l'apprentissage profond. Les sections ci-dessous présentes quelques méthodes de segmentation utilisées dans cette recherche pour l'extraction des différentes régions rétinienne.

2.2.1. Segmentation par la méthode ISODATA

L'algorithme ISODATA (Iterative Self-Organizing Data Analysis Technique) est une technique itérative et l'une des méthodes basées sur la classification non-supervisée pour la segmentation d'images [116]. C'est une version modifiée de K-means. ISODATA est utilisé pour estimer la valeur du seuil, puis cette valeur est utilisée pour segmenter l'image. L'objectif de cet algorithme est de diviser une région hétérogène (histogramme) en deux sous-régions homogènes. Les étapes de cette méthode sont données comme suit [117] :

1. Définir une valeur initiale de seuil S comme moyenne de l'image ;
2. Segmenter l'image en utilisant S . Cela produira deux classes de pixels : C_1 regroupe tous les pixels avec des valeurs de niveau de gris $< S$ et C_2 les pixels avec des intensités $\geq S$;
3. Calculer les valeurs moyennes de niveaux de gris μ_1 et μ_2 pour chacune des régions C_1 et C_2 ;
4. Calculer un nouveau seuil $S = (\mu_1 + \mu_2)/2$;
5. Répéter les étapes 2 à 4 jusqu'à ce que la différence de S dans les itérations successives soit faible par rapport à un paramètre prédéfini.

2.2.2. K-Means

C'est une méthode simple de l'apprentissage non-supervisé utilisée lorsque les données ne sont pas étiquetées. Elle est largement appliquée pour la segmentation d'images. K-Means est une technique itérative qui divise l'ensemble de données en k clusters distincts qui ne chevauchent pas, où chaque point de données appartient à un seul groupe [118, 119]. Le principe de K-means est le suivant :

1. Initialiser les K objets formant ainsi K clusters ;
2. Attribuer chaque point O au cluster C_i de centre M_i tel que la distance (O, M_i) est minimale ;
3. Mise à jour des centres M_i de clusters en calculant la moyenne de tous les pixels dans un cluster ;
4. Répéter le processus (étapes 2 et 3) jusqu'à convergence du critère (les centres ne se changent pas).

2.2.3. Fuzzy C-Means (FCM)

FCM est une technique de clustering similaire à k-Means. Elle introduit le concept d'ensemble flou dans la construction des classes. Chaque point de l'ensemble de données

appartient à chaque classe avec un certain degré, et toutes les classes sont caractérisées par leur centre de gravité. FCM nécessite la fixation préalable du nombre de clusters. Ces derniers sont générés à l'aide d'un processus itératif en minimisant une fonction objective [119]. L'algorithme Fuzzy C-Means est défini comme suit :

1. Initialisation aléatoire des centres de classes et de la matrice d'appartenance ;
2. Calcul des nouveaux centres des classes après l'attribution d'un point ;
3. Mise à jour de la matrice d'appartenance en fonction des nouveaux centres ;
4. Calcul du critère de minimisation et répéter les étapes 2 et 3 jusqu'à convergence de critère.

Cette méthode offre une souplesse supplémentaire par rapport à K-means, en permettant aux points d'appartenir à plusieurs classes avec un degré d'appartenance (probabilité).

2.2.4. Contour actif

Contour actif ou Snake est un modèle déformable basé sur la détection des contours. Il est appliqué pour séparer les objets du fond d'image avec une certaine énergie et des forces. Cette segmentation des objets est basée sur la minimisation de l'énergie du snake [117]. L'énergie totale du snake (E_s) est donnée par l'équation suivante (eq III.4) [120] :

$$E_s^* = \int_0^1 E_s(v(q))dq = \int_0^1 (E_i(v(q)) + E_{im}(v'(q)) + E_{cons}(v(q)))dq \quad (\text{III.4})$$

Où, E_i : l'énergie interne, E_{im} : l'énergie de l'image, E_{cons} : la force de contrainte sur un point v_q , avec $q=0, \dots, n-1$.

2.3. Post-traitement

Le post-traitement d'images est généralement introduit pour améliorer le résultat de la segmentation afin d'éliminer les objets non candidatures, connecter les discontinuités ou bien lisser les contours des régions segmentées. Cette étape assure une bonne extraction de caractéristiques et par la suite une bonne classification. Différents algorithmes peuvent être employés pour effectuer ces tâches tels que la morphologie mathématique (élimination des régions selon certains critères), la transformée de hough circulaire et la méthode d'enveloppe convexe. Dans cette thèse nous avons appliqué la méthode enveloppe convexe pour lisser les contours du disque optique et cup optique.

L'enveloppe convexe (convex hull, en anglais) est le plus petit polygone convexe qui regroupe tout l'ensemble des points d'une région. Il est développé pour mieux estimer les bordures des régions. Convexe signifie que le polygone n'a pas de coin plié vers l'intérieur, c'est-à-dire les angles de tous les points du polygone doivent être inférieurs ou égales à 180° . La figure III.1 suivante présente un exemple de l'enveloppe convexe.

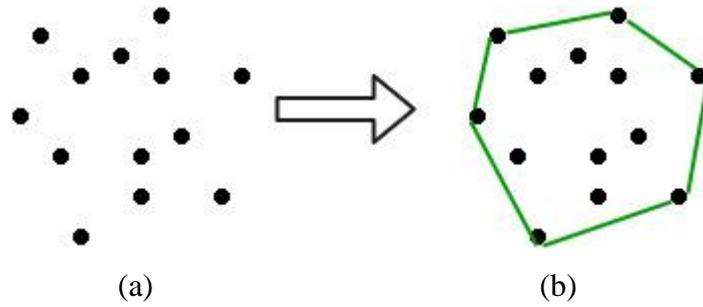


Figure III.1 : Exemple de la méthode enveloppe convexe ; (a) ensemble de points X ; (b) l'enveloppe convexe de X.

L'enveloppe convexe est la région d'un objet telle que tout segment de ligne qui rejoint deux points de l'objet devrait se trouver dans cette région. Elle est constituée comme l'union des enveloppes convexes des sous-ensembles de X. l'enveloppe convexe est déterminée à l'aide de quatre éléments structurants B_i , $i = 1, 2, 3, 4$ (eq. III.5, III.6 et III.7) [121].

$$X_k^i = (X_{k-1} * B^i) \cup A \quad (\text{III.5})$$

$$(X_{k-1} * B^i) = (X_{k-1} \ominus B^i) \cap [X_{k-1}^c \ominus (W - B^i)] \quad (\text{III.6})$$

$$D^i = X_k^i, C(A) = \coprod_{i=1}^4 D^i \quad (\text{III.7})$$

Avec, A est l'image segmentée, l'algorithme commence par $X_k^0 = A$, et l'itération continue pour $k = 1, 2, 3, \dots$ jusqu'à ce qu'aucun changement n'apparaisse dans X_k^i . Chaque itération résultante de i est combinée pour obtenir l'enveloppe convexe final.

3. Apprentissage automatique

L'apprentissage automatique (machine learning, en anglais) est une dérivée de l'intelligence artificielle [122]. C'est un ensemble de méthodes mathématiques permettant à une machine d'apprendre et de connaître à partir d'un jeu de données afin d'effectuer automatiquement des tâches spécifiques. La réputation de l'apprentissage automatique a augmenté avec la disponibilité des données et l'augmentation des capacités de calcul. Il intervient dans des situations difficiles ou impossibles à réaliser par des moyens algorithmiques plus classiques ou même par l'être humain. L'apprentissage automatique permet aux ordinateurs d'apprendre et d'améliorer continuellement leur apprentissage et même, dans certains cas, de dépasser les capacités humaines.

Il existe trois types principales de l'apprentissage automatique : l'apprentissage supervisé, non supervisé et semi supervisé [123]. Chacun de ces types traite une catégorie de données et regroupe un ensemble d'algorithmes capable de gérer des problèmes complexes.

L'apprentissage supervisé : Est le type le plus simple et le plus utilisé de l'apprentissage automatique. Il est employé lorsque la classe ou la sortie de l'ensemble des données est prédéfinie par des experts. Les algorithmes d'apprentissage supervisé passent par deux étapes principales : l'apprentissage qui permet à un modèle d'entraîner et d'apprendre en utilisant une sous partie de la base de données étiquetée. Ensuite l'étape de test est entamée pour prédire la classe de nouvelles données à partir du modèle déjà entraîné et évaluer la capacité réelle de la méthode à identifier ces données.

L'apprentissage non-supervisé : Il est employé dans le cas où les données sont non étiquetées. Il consiste de regrouper un ensemble de points en classes selon un critère de similarité fixé à l'avance. Ce type d'apprentissage permet de construire automatiquement des classes sans avoir été explicitement informé des relations existantes dans les données. Une bonne technique de regroupement garantie une grande similarité intra-classe et une faible similarité inter-classe. Il nécessite cependant un bon choix du nombre de classes et du critère de similarité. La classification non-supervisée est largement appliquée dans la segmentation en partitionnant l'image en régions homogènes selon une mesure de proximité.

L'apprentissage semi-supervisé : Ce type est une combinaison de l'apprentissage supervisé et non-supervisé. Il est utilisé lorsque le jeu de données contient une petite partie étiquetée et une grande partie non étiquetée. Les algorithmes d'apprentissage semi-supervisé utilise les données étiquetés pour l'entraînement, puis exploiter les données non-étiquetés à l'aide de l'algorithme déjà entraîné.

Dans cette thèse, nous avons utilisé les algorithmes d'apprentissage supervisé car toutes les bases de données sont labélisées par des experts en ophtalmologies. Parmi ces algorithmes : K-plus-proche-voisins (KNN), l'arbre de décision (DT), machines à vecteurs de supports (SVM), réseaux de neurones artificiels (ANN) et l'analyse discriminante linéaire pseudo-inverse.

3.1. Algorithmes de classification supervisée

3.1.1. K-plus-proches-voisins (k-Nearest Neighbor, KNN)

KNN est l'une des méthodes d'apprentissage supervisé les plus simples dédié à la classification et la régression des données. Cet algorithme n'a pas besoin de produire un modèle prédictif à partir des données d'apprentissage pour le processus de classification mais seulement le stockage des données (il n'y a pas de phase d'apprentissage). Pour trouver la classe d'un nouveau point x , KNN utilise deux paramètres : le nombre K et la fonction de distance. L'idée est de chercher les K plus proches voisins selon une fonction de distance (généralement la

distance euclidienne est la plus utilisée), ensuite, la classe de x correspond à la classe majoritaire parmi les k plus proches voisins. La détermination des k plus proches voisins est basée sur une fonction de distance, parmi ces distances [124, 125] :

Distance euclidienne : calcule la racine carrée de la somme des différences carrées entre les coordonnées de deux points x et y :

$$\text{Distance euclidienne}(x, y) = \sqrt{\sum_{k=1}^n (x_k - y_k)^2} \quad (\text{III.8})$$

Distance Manhattan : calcule la somme des valeurs absolues des différences entre les coordonnées de deux points x et y :

$$\text{Distance de manhattan}(x, y) = \sum_{k=1}^n |x_k - y_k| \quad (\text{III.9})$$

3.1.2. Arbre de décision

La technique des arbres de décisions est une technique d'apprentissage supervisé non paramétrique. Cette technique est utilisée à la fois pour les tâches de classification et régression. Il existe plusieurs modèles d'arbres de décisions parmi eux la méthode CART (Classification And Regression Tree). Cette dernière est une technique alternative de construction d'arbres de décision binaires. Cet algorithme utilise une nouvelle métrique nommée indice de Gini pour créer des points de décision et définir la pureté des nouvelles classes pour les tâches de classification. L'indice de Gini stocke la somme des probabilités au carré de chaque classe comme suit [126].

$$\text{indice de gini} = 1 - \sum_{i=1}^n (P_i)^2 \quad (\text{III.10})$$

Où, n est le nombre de classes et $P(i)$ la probabilité de chaque classe.

3.1.3. Machines à vecteurs de supports (Support Vector Machine SVM)

Machines à Vecteurs de Supports (SVM) est un algorithme d'apprentissage supervisé utilisé pour les tâches de classification et de régression. Elle est l'une des meilleures méthodes pour la classification binaire d'images, elle repose sur l'existence d'un classificateur linéaire dans un espace approprié appelé hyperplan. Cet algorithme cherche un hyperplan pouvant séparer linéairement les classes d'objets. La procédure d'entraînement analyse les données d'apprentissage afin de déterminer la méthode la plus efficace pour catégoriser les images. Dans le cas non linéaire, la SVM utilise une fonction du noyau (kernel) pour mapper les données d'entrée dans un espace différent (changer l'espace des données) et construire l'hyperplan optimal dans un nouvel espace de dimension plus élevée pour séparer linéairement ces points de données. En effet, intuitivement, plus la dimension du nouvel espace est grande, plus la

probabilité de pouvoir trouver un hyperplan séparateur entre les données est élevée. Cet algorithme trouve un classifieur qui va maximiser la distance entre les deux classes des points de données, et cela minimise l'erreur de généralisation du classificateur global. Cette maximisation de la distance marginale entre les points de données augmente la confiance pour la classification des nouveaux points de données [127].

Il existe plusieurs noyaux supportant la SVM tels que Linéaire, Polynomial, gaussien (RBF), etc., et leurs fonctions sont indiquées comme suit [128] :

$$\text{Noyau Linéaire } (X_i, X_j) = (X_i \cdot X_j) \quad (\text{III.11})$$

$$\text{Noyau Polynomial } (X_i, X_j) = (X_i \cdot X_j + C)^d \quad (\text{III.12})$$

$$\text{Noyau Gaussien } (X_i, X_j) = \exp\left(-\frac{\|X_i - X_j\|^2}{2\sigma^2}\right) \quad (\text{III.13})$$

Avec, X_i et X_j sont deux vecteurs, C une constante positive, d l'ordre du noyau polynomial et σ^2 l'écart type défini par l'utilisateur.

3.1.4. Analyse discriminante linéaire (Linear Discriminant Analysis LDA)

L'analyse discriminante linéaire est une méthode d'analyse statistique appliquée pour la classification supervisée. Elle peut être utilisée conjointement avec la réduction de dimensionnalité en passant d'un espace de dimensions supérieures à un espace de dimensions inférieures tout en préservant le maximum d'informations pertinentes [129]. Ces dernières peuvent être utilisées pour construire une fonction discriminante plus efficace. Cette technique réduit le nombre des données explicatives en éliminant les entités redondantes afin d'améliorer la performance de la classification. Le principe de la LDA est de trouver une frontière linéaire optimale entre deux ou plusieurs classes. Cette frontière de séparation des données est appelée fonction discriminante, elle maximise la variance inter-classes V_{inter} (variance entre les différentes classes) et minimise variance intra-classe V_{intra} (variance à l'intérieur de chaque cas). Ces deux paramètres sont calculés en utilisant les équations suivantes :

$$V_{inter} = \sum_{i=1}^k n_i (\bar{x}_i - \bar{x})^2 \quad (\text{III.14})$$

$$V_{intra} = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2 \quad (\text{III.15})$$

Où n est le nombre total d'échantillons, k est le nombre de classes, n_i nombre d'échantillons dans la classe i , x_{ij} la valeur de la variable explicative j pour l'échantillon i , \bar{x}_i est la valeur moyenne de la variable explicative j pour la classe i et \bar{x} est la moyenne globale des données.

Cependant, la LDA peut souffrir des problèmes de singularité lorsque la dimension du vecteur des caractéristiques est plus élevée que le nombre d'échantillons, ce qui peut entraîner une matrice de covariance non inversible. Pour résoudre ce problème, une version améliorée appelée analyse discriminante linéaire à pseudo-inverse a été développée [130].

Analyse discriminante linéaire à pseudo-inverse (Pseudo-inverse Linear Discriminant Analysis PLDA) : La PLDA est une variante de l'analyse discriminante linéaire développée pour résoudre le problème des échantillons de petite taille. Cette méthode utilise pseudo-inverse pour inverser la matrice de covariance intra-classe pour éviter le problème de singularité de la LDA. Cela permet d'estimer les coefficients de la fonction discriminante tout en maximisant la variance entre les classes [131].

3.1.5. Réseau de neurones artificiel (Artificial Neural Network ANN)

Les ANN sont des modèles informatiques non linéaires employés pour résoudre des problèmes de classification. Ils sont développés en inspirant du fonctionnement des neurones biologiques. Un réseau de neurones formel contient une ou plusieurs couches d'entrée, une couche de sortie et une ou plusieurs couches intermédiaires appelées couches cachées, chacune étant responsable d'une partie de traitement pour générer la sortie. L'idée est de construire automatiquement des relations entre les entrées et les sorties d'un jeu de données afin de produire un outil intelligent [132]. Chaque entrée X_i est associée à un poids synaptique W_i qui indique l'importance relative de cette entrée pour la génération de la sortie. Les poids relient l'entrée de la couche L avec la sortie de la couche $L-1$. Un réseau de neurones calcule la somme pondérée des entrées et utilise une fonction d'activation (généralement sigmoïde) pour décider la valeur de la sortie (0 ou 1) (figure III.2).

Un autre terme constant appelé biais peut être ajouté à la somme pondérée des entrées pour décaler la réponse du réseau, ce qui peut être utile pour générer les situations où les entrées sont proches de zéro. Alors, la sortie d'un neurone Y est obtenue par l'équation suivante :

$$Y = f(b + \sum_{i=1}^n X_i * W_i) \quad (\text{III.16})$$

Où y est la sortie du nœud, f la fonction d'activation, b et W_i sont le biais et le poids associés à l'entrée X_i .

Donc les poids et les biais sont utilisés pour contrôler la façon dont les entrées sont combinées pour produire la sortie. Ils sont généralement ajustés lors de l'entraînement pour minimiser l'erreur entre la sortie prévue et la sortie réelle permettant au modèle de s'adapter aux caractéristiques des données d'entraînement.

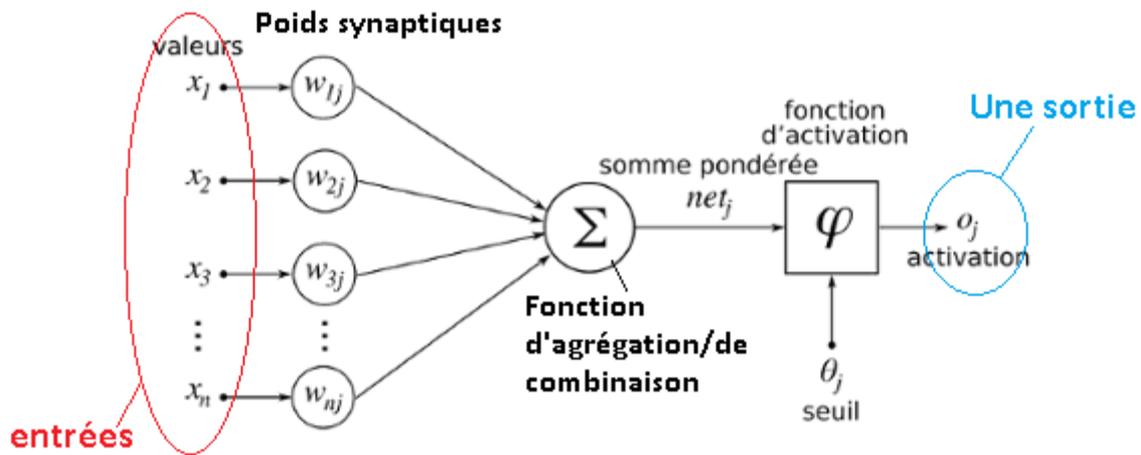


Figure III.2 : Représentation d'un réseau de neurone.

Il existe deux types de réseaux de neurones : les perceptrons multicouches et la rétro-propagation [133].

Les perceptrons multicouches (Multi Layer Perceptron MLP) : ou réseaux non rebouclés sont des réseaux de type feedforward, c'est-à-dire les données se propagent dans un seul sens des entrées vers la sortie en passant par les couches cachées. Les MLP consistent de plus d'une couche cachée de neurones. Ils sont des modèles interconnectés ou chaque sortie du neurone de la couche L est introduite comme entrée de tous les neurones de la couche suivante ($L+1$) à l'exception des couches d'entrée et de sortie. Alors que les neurones de la même couche ne sont pas connectés entre eux. La propagation des données pour obtenir les valeurs en sortie est un calcul simple et itératif, de couche en couche et de neurone en neurone. Par contre, le nombre de calculs nécessaires croît très vite en fonction du nombre de neurones (connexions). La figure III.3 ci-dessous montre le fonctionnement d'un réseau multicouche.

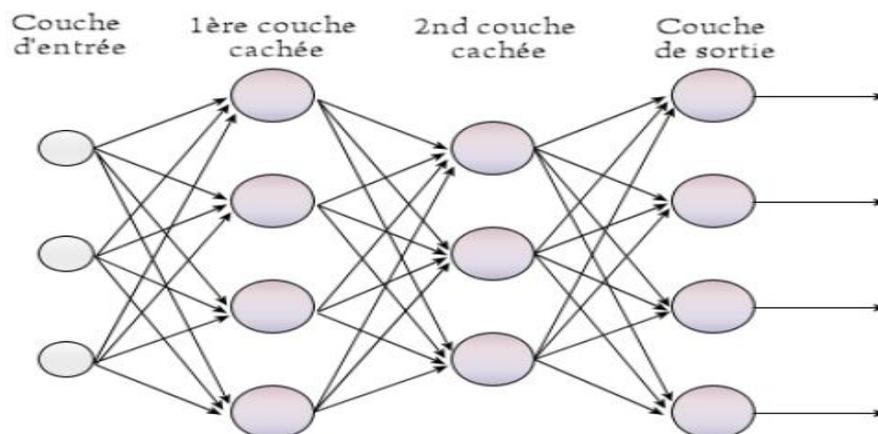


Figure III.3 : Exemple d'un réseau de neurones MLP.

Les réseaux de neurones à plusieurs couches sont souvent formés en utilisant l'algorithme de descente de gradient, qui consiste à minimiser une fonction de coût en ajustant les poids des

connexions entre les neurones. Les poids sont ajustés en fonction des erreurs commises lors de la prédiction, jusqu'à ce que les erreurs soient suffisamment faibles.

Ces modèles résolvent des problèmes complexes qui sont non linéairement séparables, ce qui les rendent très utilisés dans la littérature pour l'analyse des images médicales.

La rétro-propagation : le processus se passe dans les deux sens. Au début, la sortie du réseau est calculée en propageant les données de l'entrée vers la sortie. Ensuite, le calcul de l'erreur E entre la sortie réelle et l'erreur obtenue est effectué. A partir de cette erreur les poids sont corrigés et réajustés en rétro-propageant l'erreur de la sortie vers l'entrée.

Dans la partie ci-dessous, nous allons présenter les principes de base des réseaux de neurones profonds, qui sont les techniques les plus utilisées actuellement pour l'analyse et le traitement des images médicales.

4. Apprentissage profond ou Deep learning

L'apprentissage profond (deep learning en anglais) est une sorte d'intelligence artificielle développée à partir de l'apprentissage automatique pour lequel la machine peut apprendre toute seule à partir des données brutes, contrairement à l'apprentissage automatique, qui nécessite une intervention humaine dans le calcul et la sélection des caractéristiques pertinentes. La figure III.4 suivante présente la liaison entre l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond.

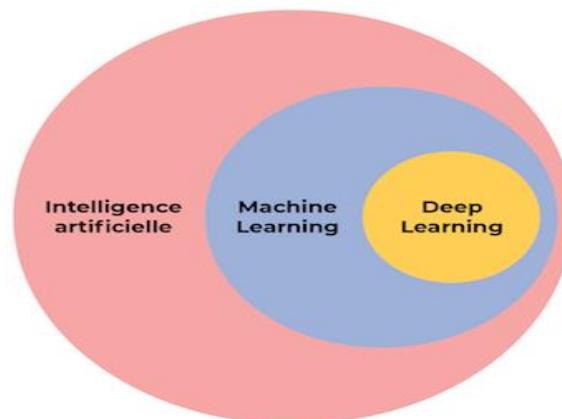


Figure III.4 : Représentation de la liaison entre l'intelligence artificielle, machine learning et le deep learning.

Les algorithmes de l'apprentissage profond utilisent les images comme entrée au lieu d'un ensemble de caractéristiques extraites par les méthodes traditionnelles. Ils reconnaissent et apprennent automatiquement les caractéristiques de complexité variable, des plus élémentaires aux plus sophistiquées de chacune d'elles pour entraîner et former un modèle spécifique [134].

Récemment, les méthodes d'apprentissage profond ont révolutionné la vision par ordinateur dans divers domaines tels que la reconnaissance faciale, la détection des objets et le traitement des images, des textes et de la parole. En particulier dans le domaine médical, elles sont utilisées pour résoudre des problèmes complexes et difficiles à gérer par les médecins.

L'avancement de l'apprentissage profond a été rendu possible grâce à des augmentations de puissance de calcul et à la création de grandes bases de données annotées. Actuellement, les réseaux de neurones convolutifs (CNN) sont les modèles d'apprentissage profond les plus puissants et les plus utilisés pour la segmentation et la classification des images médicales.

4.1. Réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs (Convolutional Neural Network CNN) sont des modèles améliorés des réseaux de neurones artificiels avec plus que cinq couches cachées. Ils sont composés de multiples couches interconnectées de traitement indépendant pour apprendre des représentations de données à plusieurs niveaux d'abstraction. Les neurones des couches inférieures traitent des caractéristiques simples des données d'entrée, tandis que les neurones des couches supérieures combinent ces caractéristiques pour former des représentations plus abstraites et complexes. Ces méthodes ont considérablement amélioré l'état de l'art dans l'analyse des images médicales et la détection des pathologies et bien d'autres tâches plus complexes à effectuer par l'être humain. Les CNN révèlent la structure complexe de grands ensembles de données en utilisant des algorithmes de rétro-propagation pour spécifier comment une machine modifie ses paramètres internes afin de calculer la représentation de chaque couche à partir de la représentation de la couche précédente [135].

Les réseaux de neurones convolutifs sont constitués d'un empilement de couches. Les deux couches les plus couramment utilisées sont la convolution et le pooling. La couche de convolution est l'élément clé d'un CNN d'où vient son nom, elle applique un ensemble de filtres de petite taille afin d'extraire des caractéristiques de l'image d'entrée. Cette couche est généralement suivie par une couche de pooling qui réduit la taille de l'image en agrégeant les informations importantes. Les couches de convolution et de pooling sont souvent alternées dans les CNN pour produire une hiérarchie de caractéristiques de l'image. Les premières couches de convolution extraient des caractéristiques simples comme des bords et des lignes droites, tandis que les couches plus profondes extraient des caractéristiques plus complexes comme des motifs et des formes. Une fois que les caractéristiques de l'image ont été extraites, la sortie de la dernière couche de convolution est aplatie pour produire un vecteur de caractéristiques. Ce vecteur de caractéristiques est ensuite utilisé comme entrée pour une ou plusieurs couches de neurones entièrement connectées, qui peuvent être employées pour la classification ou la

segmentation. La dernière couche du réseau est souvent une couche de classification qui utilise une fonction d'activation pour produire des probabilités de classe pour les différentes catégories d'images que le réseau a été entraîné à reconnaître. Le réseau est entraîné en ajustant les poids des connexions entre les neurones à l'aide d'un algorithme de rétro-propagation du gradient pour minimiser la fonction de perte. La figure III.5 résume les différents couches d'un CNN.

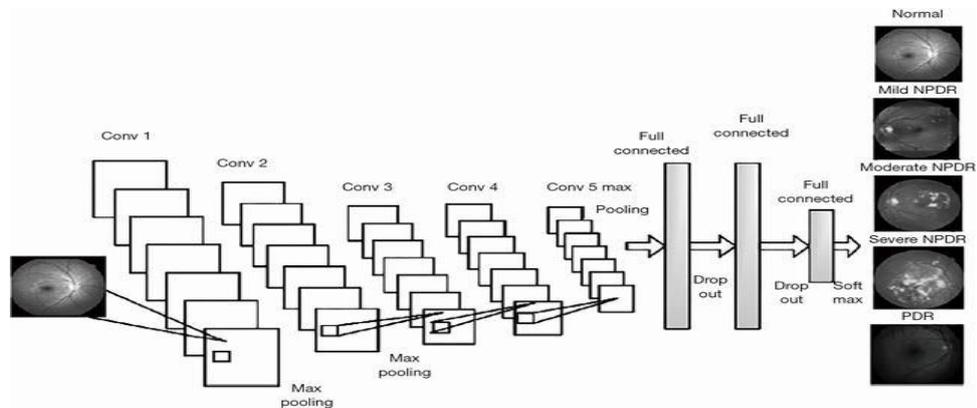


Figure III.5 : Exemple d'un CNN pour la classification des images rétiniennes.

Dans la partie qui suit, nous allons décrire brièvement le rôle de chaque couche dans un réseau de neurones profond.

4.2. Couches des réseaux neuronaux convolutifs

Les couches d'un CNN sont les éléments fondamentaux qui permettent au modèle de réaliser ses tâches complexes et intelligentes sur les images. Chaque couche joue un rôle essentiel dans la chaîne du traitement des données. Ils peuvent être classés en plusieurs catégories en fonction de leur fonction spécifique.

Les CNN se composent généralement de quatre couches principales qui sont : Couche de convolution, Couche de correction (fonction d'activation), couche de pooling et couche entièrement connectée (figure III.5). Ils existent d'autres couches comme la couche de déconvolution (convolution transposée) utilisée dans le cas de segmentation, la couche de normalisation et la couche de régularisation (dropout).

Dans les parties qui suit, nous allons décrire les différentes couches employées pour la construction des CNN.

4.2.1. Couche de convolution (CONV)

C'est l'élément fondamental d'un CNN, il est utilisé pour extraire un ensemble de caractéristiques locales à partir d'images d'entrée en appliquant divers filtres (noyaux) de petite taille (généralement 3x3 ou 5x5). Chaque filtre interagit avec l'image en effectuant une opération de convolution. Pour chaque portion, les coefficients du filtre sont multipliés par les

valeurs de l'image et les produits sont additionnés pour générer une nouvelle valeur. Cette dernière est enregistrée dans une nouvelle image appelée carte de caractéristique (feature map en anglais) (figure III.6). La première couche de convolution capture les caractéristiques de bas niveau, tandis que les couches ultérieures extraient les caractéristiques de haut niveau. Ces cartes sont ensuite introduites à l'entrée de la couche suivante. Le but de cette opération est de détecter des caractéristiques spécifiques dans l'image, telles que des lignes, des courbes, des textures, etc. Les filtres sont des matrices de poids initialisés aléatoirement au départ, puis ils sont mis à jour et appris pendant le processus d'entraînement du modèle pour mieux extraire les caractéristiques des images et s'adapter aux données d'entraînement [134, 136].

Pour chaque couche de convolution, quatre hyperparamètres doivent être fixés au début : la taille et le nombre de filtres, le pas (stride en anglais) et le remplissage à zéros (zero padding en anglais). La taille de filtre doit être inférieure à la taille de l'image d'entrée. Les filtres de petite taille dans plusieurs couches de convolution empilées, ont tendance de mieux fonctionner par opposition à petit nombre de couches avec des grands filtres. De même, en augmentant la taille du filtre le temps d'apprentissage augmente. Le nombre de filtre contrôle le nombre de carte de caractéristiques produites pour une seule image d'entrée. Il est considéré comme la troisième dimension (profondeur) dans le volume de sortie. L'utilisation de plusieurs filtres différents peut permettre d'extraire des caractéristiques différentes pendant l'entraînement. Les cartes générées peuvent être combinées pour donner une représentation encore plus complexe de l'entrée. Le pas de convolution correspond au nombre de pixels à décaler par le filtre après chaque calcul (décalage du filtre). Il évite le chevauchement entre les portions d'images pendant le glissement du filtre, en augmentant le nombre le pas, la taille du volume de sortie diminue. Le dernier hyperparamètre est le remplissage qui consiste à contrôler la taille des remplissages par zéros dans les contours de l'image. Ce paramètre sert à conserver la même taille de l'entrée après la convolution. Donc, tous ces paramètres doivent être choisis et fixés précisément car certaines valeurs fonctionnent mieux et plus vite que d'autres.

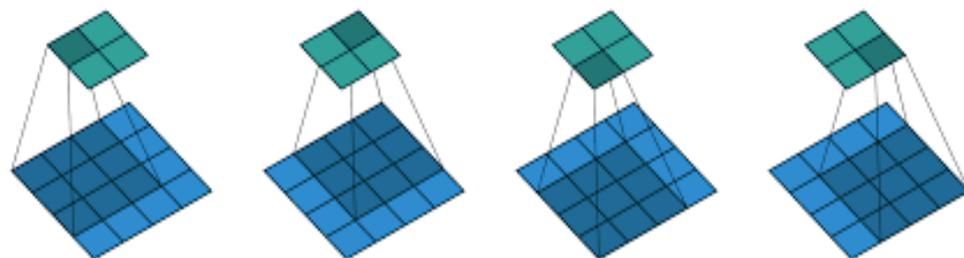


Figure III.6 : Principe de convolution pour une entrée de taille 4x4 avec un filtre de taille 3x3 et un pas de 1.

4.2.2. Fonctions d'activation

Après chaque couche de convolution, une fonction d'activation est appliquée aux valeurs de la carte des caractéristiques. Elle introduit de la non-linéarité dans le modèle et modéliser des relations complexes entre les entrées et les sorties. Les fonctions d'activation les plus couramment employées sont : sigmoïde, tanh, ReLU, Leaky ReLU et Softmax [136].

Fonction sigmoïde : elle transforme une valeur réelle en une valeur entre 0 et 1. Cette fonction en forme de S est souvent utilisée pour normaliser la sortie d'un neurone. L'équation de fonction sigmoïde f est définie comme suit :

$$\text{Sigmoïde}(x) = 1/(1 + \exp^{-x}) \quad (\text{III.17})$$

Où x est la valeur d'entrée. Si x est positif, la fonction f tend vers 1 sinon elle tend vers 0 pour une valeur négative de x .

Fonction tanh (tangente hyperbolique) : est similaire à la fonction sigmoïde, mais avec une plage de sortie plus large. Elle transforme une valeur réelle en une valeur entre -1 et 1. Tanh est définie comme suit :

$$\tanh(x) = (\exp^x - \exp^{-x})/(\exp^x + \exp^{-x}) \quad (\text{III.18})$$

Fonction Unité linéaire rectifiée (Rectified Linear Unit ReLU) : est la fonction d'activation par défaut dans les architectures d'apprentissage profond, car elle est simple, rapide à calculer et efficace pour de nombreuses tâches. ReLU désigne la fonction réelle non linéaire définie par :

$$\text{ReLU}(x) = \max(0, x) \quad (\text{III.19})$$

Cette fonction remplace toutes les valeurs négatives reçues en entrée par un zéro « 0 » (figure III.7) ce qui peut affecter les performances du réseau de neurones, en réduisant le nombre de neurones actifs et en entraînant une perte de précision. Pour résoudre ce problème, des variantes de la fonction ReLU ont été proposées, telles que la fonction Leaky ReLU.

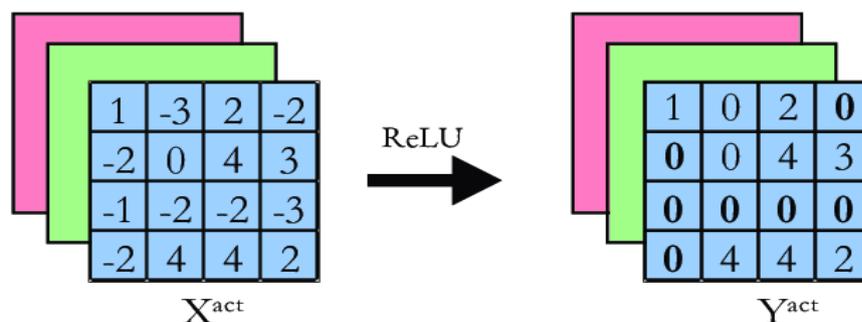


Figure III.7 : Le principe de fonctionnement du ReLU.

Fonction Leaky ReLU (Leaky Rectified Linear Unit) : est une variante (version améliorée) de ReLU développée pour réduire le problème de ReLU. Elle présente une faible pente négative au lieu d'une pente plate. Mathématiquement, elle se définit comme suit :

$$\text{Leaky ReLU}(x) = \begin{cases} 0.01x, & \text{si } x < 0 \\ x, & \text{ailleurs} \end{cases} \quad (\text{III.20})$$

La figure III.8 ci-dessous illustre les tracés des quatre fonction d'activation décrites précédemment : sigmoïde, tanh, ReLU et Leaky ReLU.

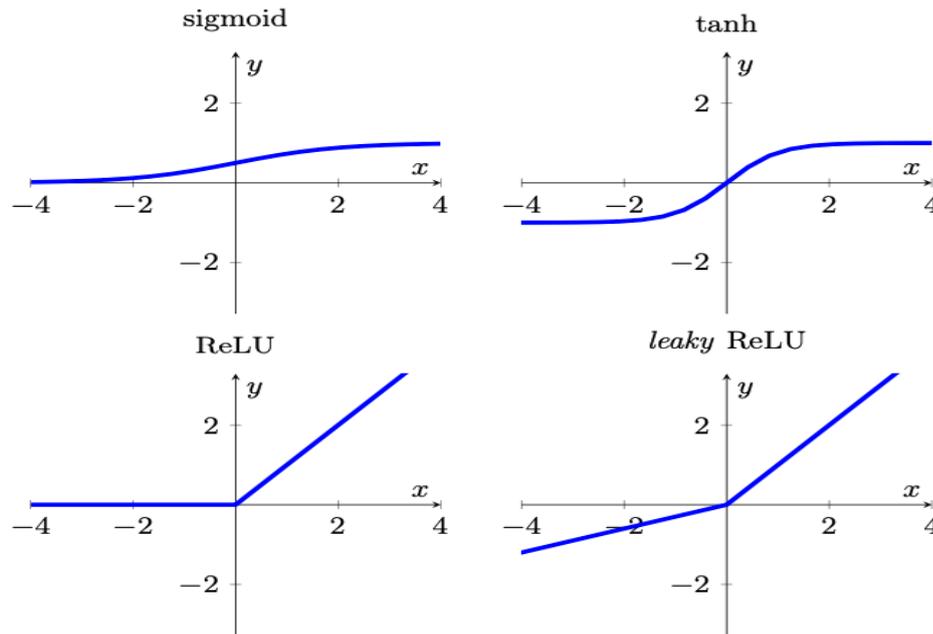


Figure III.8 : Les courbes des quatre fonctions d'activation.

Fonction Softmax : est une fonction d'activation souvent utilisée dans les réseaux de neurones pour transformer les sorties en une distribution de probabilités normalisées sur plusieurs classes. Elle est couramment utilisée comme dernière couche dans les réseaux de neurones convolutifs pour la classification multi-classes.

La fonction Softmax prend un vecteur de valeurs (z) en entrée et produit en sortie un vecteur de probabilités normalisées pour chaque classe. Chaque probabilité est comprise entre 0 et 1 et la somme de toutes les probabilités vaut 1. La classe avec la probabilité la plus élevée est choisie comme prédiction finale. Cette fonction est définie comme l'exponentielle de chaque valeur (z_i) divisée par la somme exponentielle de toutes les valeurs (z_j), où $j=1, 2, \dots, k$ et k est le nombre de classes. Chaque valeur de la sortie de cette fonction est calculée comme suit :

$$\text{Softmax}(z) = e^{z_i} / \sum_{j=1}^k e^{z_j} \quad (\text{III.21})$$

4.2.3. Couche de pooling (POOL)

Le pooling est une forme de sous-échantillonnage de l'image, est un autre élément crucial dans un CNN. Il minimise la taille spatiale (hauteur et largeur) d'une image intermédiaire (carte de caractéristiques) en conservant les informations les plus pertinentes afin de réduire le nombre de paramètres et le temps du calcul dans le réseau. Pour contrôler le sur-apprentissage et augmenter la robustesse, il est recommandé d'insérer une couche de pooling après une couche de convolution. Le principe de pooling consiste à découper l'image d'entrée en petites fenêtres de taille $n*n$ pixels qui ne se chevauchent pas (sous-échantillonnage) et prendre une seule valeur de chaque fenêtre en fonction du type de pooling choisi [136]. Généralement la taille de la fenêtre est $2*2$ ou $3*3$.

Il existe deux types de pooling : le max-pooling est le plus utilisé dans les CNN, qui consiste à conserver la valeur maximale de chaque fenêtre dans la carte des caractéristiques. Le pooling avec la fonction moyenne (average pooling) conserve la valeur moyenne de chaque fenêtre (figure III.9).

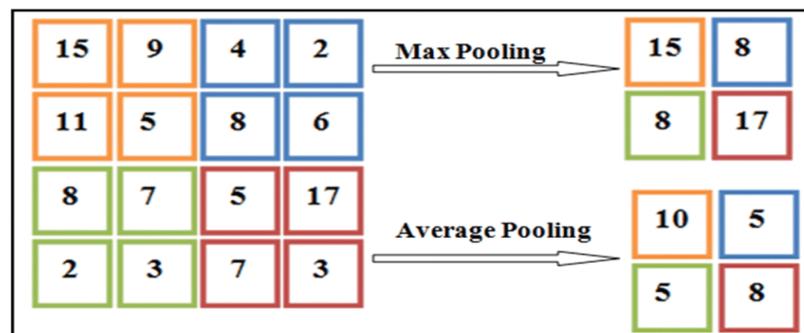


Figure III.9 : Processus de max et average pooling avec fenêtre de taille $2x2$ et pas 2.

4.2.4. Couche entièrement connectée (FC)

Cette couche est placée à la fin d'un CNN, elle prend en entrée les caractéristiques extraites par les couches précédentes et les transforme en un vecteur de sortie pour effectuer des tâches spécifiques comme la classification et la régression. Comme dans un ANN, chaque neurone de la couche FC est connecté à tous les neurones de la couche précédente. Le nombre de neurones dans la couche entièrement connectée est généralement déterminé par la taille de la tâche de classification ou de prédiction à effectuer. Cette couche est souvent suivie par une fonction d'activation telle que Softmax pour normaliser les sorties et produire une distribution de probabilités pour chaque classe possible. La classe ayant la plus haute probabilité est choisie comme prédiction finale du modèle [134, 136].

4.2.5. Couche de déconvolution (convolution transposée)

Dans le cas de la segmentation sémantique d'images, la couche de déconvolution (couche de convolution transposée) est introduite à la fin d'un réseau de neurones convolutif afin de reconstruire la carte de segmentation à partir des cartes de caractéristiques obtenues par les couches précédentes. Elle est appliquée dans l'échantillonnage ascendant (up-sampling) pour augmenter la dimension d'une image. La couche de convolution transposée inverse le processus d'une couche de convolution standard en utilisant des filtres inverses pour remonter l'information dans le réseau et restaurer la taille de l'image d'entrée originale [137].

La sortie de cette couche est souvent soumise à une fonction d'activation, comme la fonction Sigmoidale ou Softmax, pour produire l'image segmentée finale avec des valeurs entre 0 et 1, qui représentent la probabilité qu'un pixel appartienne à une classe d'objet particulière.

4.2.6. Couche de normalisation

La couche de normalisation par lot (batch normalisation, en anglais) [138] est une approche de régularisation très utilisée en apprentissage profond pour accélérer la convergence d'apprentissage et améliorer les performances d'un modèle. Cette couche est généralement introduite entre la couche de convolution et la fonction d'activation et elle normalise les entrées (activations) en calculant la moyenne et l'écart type pour chaque mini-lot plutôt que l'ensemble des données d'entraînement. Cela minimise la sensibilité aux changements de distribution des entrées du modèle, stabilise le processus d'apprentissage et réduit considérablement le nombre d'époques de formation nécessaires pour construire des réseaux profonds. Elle peut être appliquée en combinaison avec d'autres méthodes de régularisation comme dropout pour atteindre un certain niveau de précision, en améliorant la robustesse de l'initialisation des poids et en réduisant le sur-apprentissage.

4.2.7. Couche de Dropout

Dropout [139] est une technique de régularisation qui permet de combattre le sur-apprentissage (over-fitting) et d'optimiser l'apprentissage d'un réseau de neurone profond. Il consiste à désactiver temporairement et aléatoirement à chaque époque un certain nombre de neurones (c'est-à-dire les mettre à zéro) ainsi que toutes ses connexions d'entrées et de sorties lors de l'entraînement d'un modèle. Le nombre de neurones à désactiver est choisi selon une probabilité p fixé préalablement et qui varie entre 0 et 1 (généralement $p=0.5$). A chaque époque, chaque neurone a une probabilité d'être désactivé ce qui permet de créer un nouveau réseau avec un sous-ensemble de neurones actifs à chaque itération et d'entraîner plusieurs

modèles différents simultanément. Cependant, le dropout réduit les interdépendances entre les neurones en obligeant chacun d'eux d'être utile dans la représentation de l'information. Cette technique est désactivée lors de la partie du test c'est-à-dire tous les neurones sont activés et les sorties sont pondérées pour compenser le déséquilibre fourni par le dropout.

4.2.8. Fonction de perte :

La fonction de perte également appelée fonction d'erreur ou de coût, est une mesure de la différence entre la sortie prédite et la sortie réelle (l'étiquette). Puis, elle retourne une valeur scalaire qui représente l'erreur moyenne du modèle sur les données d'entraînement. Cette erreur est utilisée pour évaluer la qualité des prédictions et ajuster les paramètres du modèle via l'algorithme d'optimisation, dans le but de minimiser l'erreur. Il existe différents types de fonction de perte, chacun est adaptés à une tâche spécifique tels que MSE (Mean Squared Error) qui est utilisée dans le cas de la régression et l'entropie croisée qui est employée dans les tâches de classification. La perte d'entropie croisée calcule la somme des erreurs en utilisant le logarithmique et elle est souvent utilisée en combinaison avec la fonction Softmax dans la dernière couche afin de transformer les sorties du réseau en une distribution de probabilités normalisées [134].

4.3. Algorithmes d'optimisation

Comme vu précédemment, les algorithmes d'optimisation sont utilisés pour ajuster les poids et les biais des neurones du réseau afin de minimiser la fonction de de perte. Ils sont important pour l'apprentissage profond afin de trouver les paramètres optimaux qui améliorent les performances du modèle. Il existe de nombreux algorithmes d'optimisation différents, chacun avec ses propriétés tels que la descente de gradient, la descente de gradient stochastique, avec Momentum et Adam.

Ces algorithmes sont basés sur une technique itérative appelée descente de gradient (Gradient Descent GD) [134] qui calcul le gradient de la fonction du cout sur tout l'ensemble de données et met à jour successivement les paramètres en fonction de la direction de la plus forte pente (convergence vers le minimum global). Un hyperparamètre nommé pas d'apprentissage, doit être choisi au départ pour fixer la longueur du pas à effectuer dans la direction du gradient.

La descente de gradient stochastique (Stochastic Gradient Descent SGD) [136] est une variante de GD qui calcule le gradient et met à jour les poids sur chaque échantillon des données d'entraînement, au lieu de l'ensemble de données complet. Cela peut être plus rapide, mais peut également entraîner plusieurs minimax locaux dans la fonction de perte.

La descente de gradient stochastique avec moment (Stochastic Gradient Descent with Momentum SGDM) [140] est une amélioration du SGD proposée pour améliorer l'entraînement et accélérer la convergence. Elle introduit un terme de momentum pour accumuler les gradients précédents à l'aide d'une moyenne mobile des gradients afin de modifier les poids. En utilisant cette mémoire des gradients, les mises à jour des poids sont plus importantes dans le cas d'une forte pente, ce qui permet de converger plus rapidement.

ADAM (Adaptive Moment Estimation) [141] est une méthode adaptative qui reprend l'idée de SGDM en gardant la moyenne mobile des gradients précédents (moment d'ordre 1) et ajoute une autre valeur (moment d'ordre 2) qui calcule la moyenne mobile des gradients précédents au carré afin d'ajuster automatiquement le taux d'apprentissage. Cette opération supplémentaire permet de mettre à jour les poids et le biais de manière efficace, d'accélérer la convergence du modèle et de minimiser le temps d'apprentissage. Tous ces avantages rendent cet optimisateur très robuste et largement utilisé en apprentissage profond.

En conclusion, le choix de l'algorithme d'optimisation approprié dépend de la tâche à accomplir, de la taille de l'ensemble de données et de l'architecture utilisée.

4.4. Les hyperparamètres en apprentissage profond

Ils sont des paramètres clés en apprentissage profond qui doivent être choisis et fixés soigneusement avant le début de l'entraînement d'un modèle afin d'optimiser sa performance et obtenir les meilleurs résultats. Ces hyperparamètres influencent sur la progression de l'apprentissage et la convergence du réseau. Parmi ces paramètres nous citons :

Le taux d'apprentissage (learning rate) : contrôle la taille de pas d'ajustement des poids lors de GD. Un taux d'apprentissage très élevé peut conduire à une convergence plus rapide, mais peut aussi entraîner une instabilité du modèle, alors qu'un taux d'apprentissage très faible peut conduire à une convergence lente.

Le nombre d'époques (epochs) : correspond au nombre de fois que le modèle va passer sur l'ensemble des données d'entraînement. Un nombre trop faible peut conduire à un sous-apprentissage du modèle, tandis qu'un nombre trop élevé peut entraîner un sur-apprentissage.

La taille du mini-lot (mini batch size) : indique le nombre d'échantillons utilisés pour calculer une seule mise à jour des poids. Une taille très petite peut entraîner une instabilité du modèle, tandis qu'une taille très grande peut entraîner une convergence lente.

Le nombre de couches et la taille du réseau : la profondeur et la structure du modèle peuvent grandement influencer sa performance. Une architecture trop simple peut conduire à un sous-apprentissage, tandis qu'une architecture trop complexe peut entraîner un sur-apprentissage.

Le choix de la fonction de coût : le bon choix de cette fonction influence sur la capacité de généralisation du modèle.

Le choix de l'algorithme d'optimisation : spécifie la manière utilisée pour ajuster les poids du modèle.

Dans la partie qui suit nous allons présenter les architectures de segmentation et de classification les plus populaires dans la littérature.

4.5. Architectures d'apprentissage profond populaires pour la segmentation sémantique

CNN est l'algorithme d'apprentissage profond le plus puissant pour la segmentation sémantique des images médicales. Il se compose de deux parties distinctes : La partie de contraction pour l'extraction des caractéristiques d'images, en passant par un ensemble de filtres, la construction de nouvelles images appelées des cartes convolutionnelles. La sortie de cette partie est ensuite attachée à l'entrée de la deuxième partie appelée expansive, composée de couches de convolution transposée (dé-convolutions) pour générer la sortie finale en combinant les caractéristiques pertinentes.

4.5.1. SegNet

SegNet [142] est une architecture de CNN construite pour la segmentation sémantique des pixels. C'est un réseau encodeur-décodeur contenant deux parties essentielles : encodage et décodage. La partie encodage de SegNet utilise une série de convolution et pooling, elle est typologiquement identique aux 13 couches convolutionnelles du modèle VGG16 [143] en supprimant les couches entièrement connectées, ce qui rend l'encodeur considérablement plus petit et plus facile à former que de nombreuses autres architectures récentes. Le réseau de décodeur est une symétrie de l'encodeur et se compose d'une hiérarchie de décodeurs chacun correspondant à encodeur. Les décodeurs appropriés utilisent les indices de mise en commun maximale (max pooling) reçus de l'encodeur correspondant pour effectuer un sur-échantillonnage (up-sampling) non linéaire de leurs cartes de caractéristiques d'entrée pour la classification de chaque pixel et reconstruire une image segmentée de la même taille que l'image d'entrée. La dernière couche de cette architecture est Softmax suivie par la fonction de perte cross-entropy.

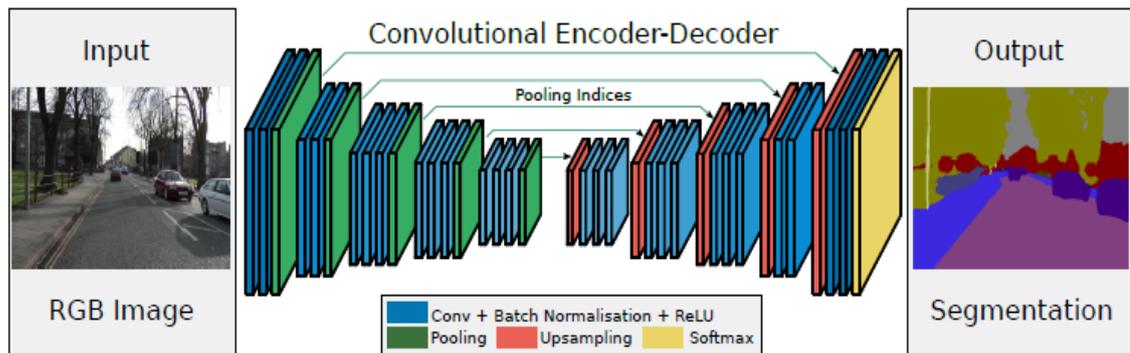


Figure III.10 : L'architecture SegNet.

4.5.2.U-Net

U-Net est une architecture des réseaux de neurones convolutifs symétrique en forme de U [144] conçue spécifiquement pour résoudre le problème de la segmentation des images médicales. Elle consiste à effectuer une classification de chaque pixel de l'image. U-Net contient deux parties principales : partie contractante (encodeur) et partie expansive (décodeur) avec une concaténation entre eux.

La partie contractante qui consiste à extraire le maximum d'informations pertinentes à partir des images d'entrée. Elle est composée d'étages répétés, chacun étant composé de deux couches de convolution de taille 3x3 suivies de la fonction ReLU et d'une couche de max-pooling de taille 2x2. Chaque couche convolutionnelle vise à extraire des caractéristiques locales spécifiques. En passant d'un étage à un étage supérieur, le nombre de filtre de convolution est doublé et par conséquent le nombre de caractéristiques augmente ce qui permet au modèle d'apprendre des structures complexes.

La partie expansive contient un nombre identique d'étages que le chemin de contraction, est composé de couches convolutionnelles transposées 2D au lieu de couches de convolution. Cette partie combine les informations de caractéristiques obtenues par une séquence de convolutions ascendantes et de concaténations avec des caractéristiques de haute résolution du chemin de contraction. A la fin une couche de convolution de taille 1x1 est utilisée pour mapper le vecteur de caractéristique construit par Softmax au nombre de classes souhaité. Le résultat de tout ce processus est une image étiquetée présentant la segmentation sémantique d'un objet. La figure suivante représente l'architecture U-Net.

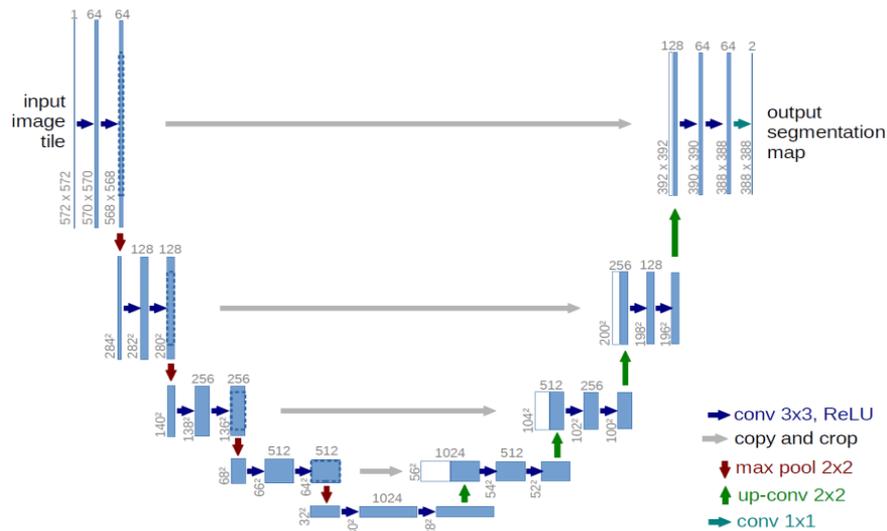


Figure III.11 : L'architecture U-Net.

4.6. Les architectures les plus utilisées pour la classification d'images

La classification des images médicales par les modèles de l'apprentissage profond a reconnu un grand succès ces dernières années et a prouvé sa robustesse par rapport aux méthodes classiques. Dans cette partie, nous allons citer les modèles les plus populaires dans la littérature pour la classification tels que : VGG 16 et VGG19.

4.6.1. VGGNet

VGGNet est une architecture de réseaux de neurones convolutifs développée en 2014 par le Groupe de Géométrie Visuelle (Visual Geometry Group VGG) de l'université d'oxford pour la classification d'images [143]. Il contient cinq blocs de convolution avec des petits filtres de taille 3x3, pas de 1 et une profondeur (nombre des filtres) de 64, 128, 256, 512 et 512 respectivement. Chaque couche convolutive est suivie par la fonction d'activation ReLU. Cinq couches de max pooling de taille 2x2 et un pas de 2 sont aussi introduites entre les blocs pour réduire la dimension spatiale. A la fin, trois couches entièrement connectées avec un nombre de neurones de 4096, 4096 et 1000 respectivement, suivis par Softmax sont utilisées et pour la classification. Le réseau est formé sur plus d'un million d'images de la base de données ImageNet et peut classer les images en 1000 catégories d'objets. L'image d'entrée doit être couleur (RVB) de taille 224*224*3. Les versions les plus connues de ce modèle sont VGG16 et VGG19 qui contient 16 et 19 couches de poids (convolution et FC).

VGG16 se compose de 13 couches de convolution et 3 couches FC. Les deux premiers blocs convolutifs contiennent deux couches de convolution avec des filtres de taille 3x3, chacune est suivie par ReLU et une couche de max pooling de taille 2x2. Les trois autres blocs contiennent

trois couches de convolution est une couche de max pooling dans chacun. La sortie de ces blocs est acheminée vers les trois couches FC pour produire la sortie finale.

VGG19 est similaire à VGG16, mais elle contient trois couches de convolution supplémentaires par rapport que VGG16 c'est-à-dire elle se constitue de 16 convolution et 3 FC. Les deux premiers blocs de convolution sont identiques à ceux dans VGG16, alors que les trois autres blocs contiennent quatre couches de convolution au lieu de trois.

Le modèle VGG19 est plus robuste et performant que VGG16 car il est plus profond ce qui lui permet d'extraire des caractéristiques plus complexes et de mieux s'adapter à des bases de données plus grandes et plus complexes. Mais cela peut rendre l'entraînement plus lent et nécessite plus de ressources de calcul et de grande mémoire.

L'architecture VGGNet est largement utilisée dans la littérature et elle a montré que la profondeur du réseau est un facteur critique en termes de bonnes performances.

La figure III.12 ci-dessous présente la structure des deux architectures VGG16 et VGG19 et illustre bien la différence entre eux en terme de nombre de couche de convolution.

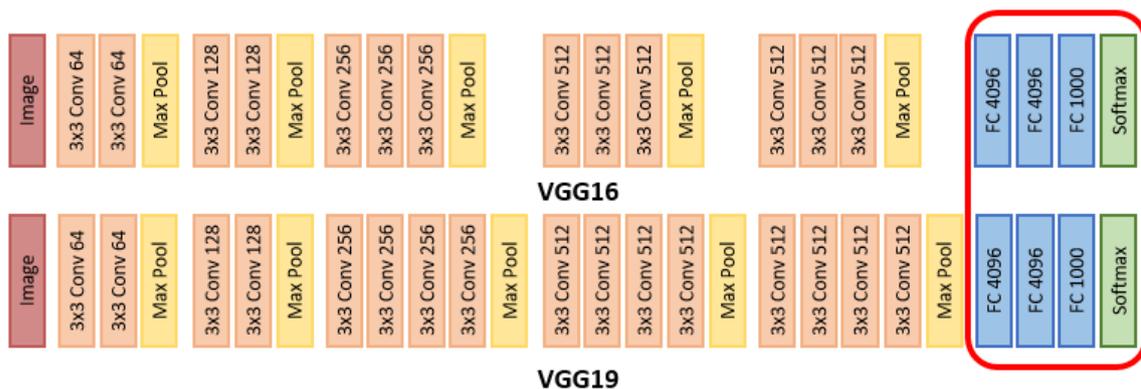


Figure III.12 : Architectures VGG16 et VGG19.

5. Les métriques d'évaluation

Les métriques d'évaluation sont des mesures quantitatives utilisées pour évaluer la performance d'un modèle, d'un algorithme ou d'un système. Elles sont employées pour comparer entre les différentes approches ou les paramètres d'apprentissages d'un CNN. Ces mesures sont calculées en comparant les valeurs prédites par le modèle avec les valeurs réelles fournis par des experts, à partir desquelles différents paramètres sont déduits pour valider la pertinence des résultats et l'efficacité du modèle dans la résolution d'un problème donné tels que les vrai positifs, faux positifs, vrai négatifs et faux négatifs. Ces derniers sont stockés dans une matrice carrées appelée matrice de confusion. Cette matrice présente une vue générale des erreurs du modèle lors de la partie du test.

		Classes prédites	
		positive	négative
Classes Réelles	positive	VP	FN
	négative	FP	VN

Tableau III.1 : Matrice de confusion.

Vrai Positif (VP) : donnée positive classée comme positive

Faux Positif (FP) : donnée négative classée comme positive

Vrai Négatif (VN) : donnée négative classée comme négative

Faux Négatif (FN) : donnée positive classée comme négative

A partir de ces quatre paramètres différents métriques d'évaluation peuvent être calculées notamment : l'exactitude (accuracy), le rappel (Recall), l'AUC (l'aire sous la courbe ROC), l'indice de jaccard (IoU), le coefficient de dice (F1 score), la sensibilité, la spécificité et la précision. Chacun de ces paramètres est plus significatif dans des tâches spécifiques. Donc Il est important de choisir les métriques d'évaluation appropriées selon le problème étudié et le type de modèle utilisé pour obtenir une évaluation fiable et précise de la performance du modèle.

Dans ce qui suit, nous allons décrire les différentes métriques utilisées dans nos travaux proposés tels que :

L'exactitude (Accuracy Acc) : indique le pourcentage des cas correctement classés par rapport au nombre total des cas dans l'ensemble de données.

$$\text{Acc} = \frac{VP + VN}{VP + VN + FP + FN} \quad (\text{III.22})$$

La sensibilité (Se) ou rappel : est le pourcentage des cas positifs classés comme positifs.

$$\text{Se} = \frac{VP}{VP + FN} \quad (\text{III.23})$$

La spécificité (Sp) : est le pourcentage des cas négatifs classés comme négatifs.

$$\text{Sp} = \frac{VN}{VN + FP} \quad (\text{III.24})$$

L'indice de jaccard (Intersection over Union IoU) : mesure la similarité entre l'image segmentée et l'image vérité terrain.

$$\text{IoU} = \frac{VP}{VP + FP + FN} \quad (\text{III.25})$$

Le coefficient de dice ou F1 score : est une métrique très utilisé pour évaluer la robustesse d'un algorithme de segmentation d'images. Il est similaire à l'indice de jaccard mais il est plus favorable car il est plus stable et moins sensible aux variations de la taille des objets segmentés.

$$\text{Dice} = \frac{2VP}{2VP + FP + FN} \quad (\text{III.26})$$

La courbe ROC (Receiver Operating Characteristic) et l'aire sous la courbe (AUC) : sont d'autres paramètres très important pour évaluer la robustesse d'un modèle de classification binaire. La courbe ROC est obtenu en traçant la sensibilité (TPR) en fonction de 1-spécificité (FPR). Plus cette courbe rapproche du coin supérieur gauche, meilleure est la performance du modèle. L'AUC représente la surface sous la courbe ROC, elle fournit une mesure de la qualité globale de la classification. Elle varie entre 0,5 pour un classifieur aléatoire et 1 pour un classifieur parfait. L'avantage de cette mesure par rapport aux autres métriques est qu'elle est insensible au données déséquilibrés c'est-à-dire elle est plus fiable lorsqu'une classe est plus grande que l'autre.

6. Conclusion

Les systèmes d'aide au diagnostic en ophtalmologie qui intègrent le traitement d'images et l'intelligence artificielle jouent un rôle important afin de prévenir la perte de vision irréversible. Dans ce chapitre nous avons présenté l'ensemble des méthodes de traitement d'images : prétraitement et segmentation employées dans cette recherche. Ensuite, nous avons défini l'apprentissage automatique, ces trois types : supervisé, non-supervisé et semi-supervisé en se basant sur les algorithmes de classification supervisé utilisés dans notre étude. Dans la deuxième partie, nous avons décrit le concept de l'apprentissage profond. Nous avons mentionné le rôle et le fonctionnement de chacune des couches d'un réseau de neurones convolutifs. Après cela, Les algorithmes d'optimisation des poids et de la fonction d'erreur ont été introduits. La section suivante, les modèles de la segmentation sémantique et de la classification employés dans les travaux de cette thèse ont été décrits. A la fin, nous avons terminé ce chapitre par la description des métriques d'évaluation des performances des systèmes proposés.

Le chapitre qui suit présente nos algorithmes développés pour la détection automatique du glaucome à partir des images rétiniennes couleurs en utilisant les techniques de traitement d'images, l'apprentissage automatique et l'apprentissage profond. Ainsi qu'une discussion et comparaison des résultats obtenus.

Chapitre IV :
Détection automatique du glaucome : Méthodes et
Résultats

1. Introduction

Le glaucome est une neuropathie oculaire grave, asymptomatique et irréversible affectant la tête du nerf optique. Il est caractérisé par une augmentation de la tension à l'intérieur de l'œil, cette dernière altère le champ de vision latéral et progressivement la vision centrale ce qui peut conduire à une cécité totale. Une détection précoce de cette maladie est très importante pour prévenir la perte de vision.

Ce chapitre est consacré à la présentation d'un ensemble de méthodes développées au cours de cette thèse pour la détection automatique et précoce du glaucome en utilisant les techniques de traitement d'images, d'apprentissage automatique supervisé et l'apprentissage profond. Ces méthodes sont employées pour effectuer deux tâches principales : la segmentation du disque optique et cup optique à partir des images du fond d'œil et la classification des images.

Tous les systèmes proposés sont testés sur des bases de données publiques et une base de données locale collectée au niveau de l'hôpital de Ain Naadja pour évaluer leurs performances.

2. Méthodes proposées

Le développement d'un système d'aide au diagnostic (Computer-Aided Diagnostic CAD) pour la détection automatique du glaucome est important pour le diagnostic précoce, le suivi d'évolution et la vérification de l'efficacité du traitement.

Récemment, ces systèmes ont montré leurs performances suite à la disponibilité des grandes bases d'images d'un côté et l'émergence de nouvelles techniques plus performantes d'un autre côté.

Un système CAD de détection du glaucome passe par quatre étapes principales : le prétraitement afin de détecter la région d'intérêt et le filtrage des images. La segmentation du disque et du cup optique. Les résultats de cette étape sont primordiaux pour calculer les paramètres les plus pertinents qui sont : le RCD et la règle ISNT (Inférieur, Supérieur, Nasal et Temporel). Enfin, la classification est mise en place pour distinguer entre un cas normal et un cas glaucomeux en utilisant les caractéristiques extraites.

L'organigramme ci-dessous (figure IV.1) présente notre système développé pour la détection et la classification du glaucome.

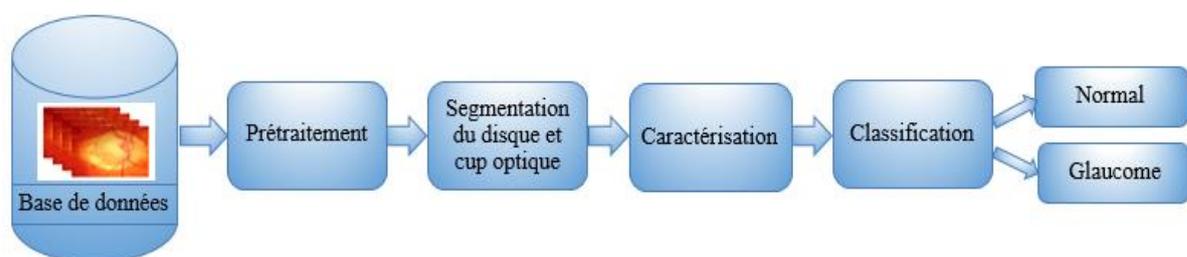


Figure IV.1 : Organigramme global de nos méthodes pour la détection du glaucome.

Dans les sections ci-dessous, nous allons détailler chaque étape de notre système proposé.

2.1. Prétraitement : Extraction de la région d'intérêt

Les images du fond d'œil couleur sont généralement de grande taille présentant toute la région rétinienne ce qui peut prendre un large temps d'exécution nécessitant un matériel puissant.

Dans cette étape, nous avons commencé par l'extraction de la région d'intérêt (ROI) afin de minimiser le temps de calcul. Cette région est délimitée automatiquement autour de la papille optique, la partie affectée par le glaucome. La tête du nerf optique apparaît généralement comme la région la plus brillante par rapport au reste de la rétine (figure IV.2.a) ce qui facilite sa détection.

Pour ce faire, nous avons extrait le point d'intensité maximale à partir de l'image en niveaux de gris (figure IV.2.b). Les coordonnées de ce point sont ensuite utilisées pour fixer une fenêtre de petite taille autour de la papille (figure IV.2.c).

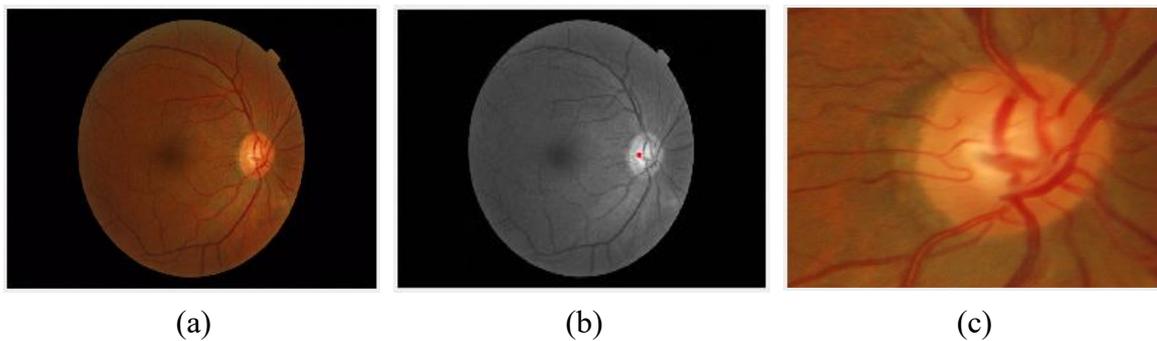


Figure IV.2 : Etape de prétraitement. (a) Image originale ; (b) Image niveau de gris avec le point d'intensité maximale ; (c) ROI détectée.

La sortie de cette étape est utilisée comme entrée dans les étapes ci-dessous.

2.2. Segmentation du disque et cup optique

La segmentation du disque et du cup optique est une étape essentielle pour la détection du glaucome. Dans cette thèse, nous avons testé deux stratégies pour l'extraction de ces régions. La première repose sur l'utilisation des méthodes de traitement d'images, tandis que la deuxième stratégie est fondée sur l'applications des architectures d'apprentissage profond populaires pour la segmentation sémantique du disque et du cup.

L'organigramme ci-dessous (figure IV.3) résume l'ensembles des méthodes proposées pour la segmentation du disque optique et cup optique.

Dans ce qui suit, nous allons détailler chaque méthode séparément.

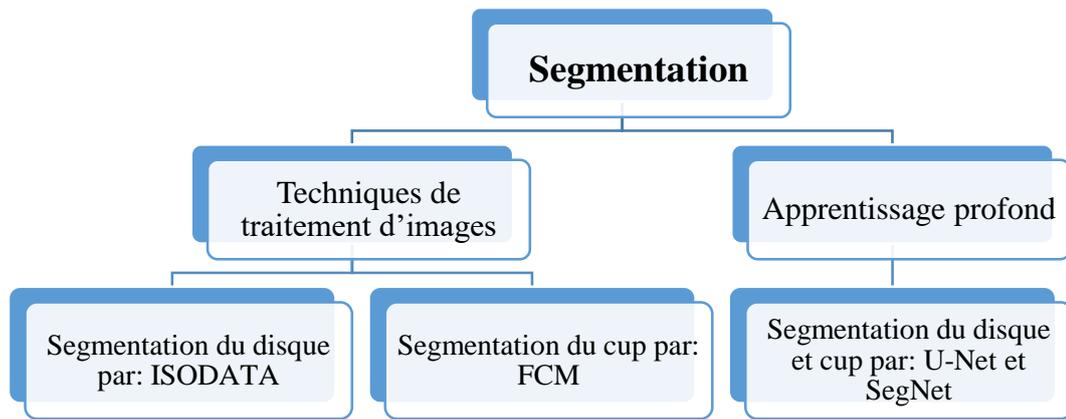


Figure IV.3 : Nos méthodes utilisées pour la segmentation du disque et cup.

2.2.1. Techniques du traitement d'images pour détecter le disque/ Cup optique

Au cours de cette recherche, nous avons testé plusieurs techniques de traitement d'images afin de prétraiter les images, segmenter le Disque Optique (DO) et le Cup Optique (CO) et améliorer les résultats des contours des régions segmentées. Ces régions sont ensuite utilisées pour extraire les paramètres clés qui confirment la présence du glaucome.

Dans ce qui suit, nous allons détailler notre contribution pour l'extraction des régions pertinentes à partir du ROI délimité dans l'étape précédente.

2.2.1.1. Segmentation du disque optique

Dans cette partie, nous avons utilisé le canal V de l'espace HSV où le disque optique apparaît clairement et avec un contraste élevé (figure IV.4.a). Ensuite, nous avons appliqué un filtre médian, afin d'éliminer le bruit et les petits artefacts d'acquisition. Ce filtre conserve les contours du disque optique tout en minimisant les variations des niveaux de gris dans l'image (figure IV.4.b).

La papille est le point de départ des vaisseaux sanguins ce qui peut influencer sur l'efficacité de l'étape de segmentation. Donc pour éliminer l'effet de l'arbre vasculaire et homogénéiser la région du disque optique, nous avons appliqué une fermeture morphologique (figure IV.4.c).

Enfin, une méthode de segmentation ISODATA est employée pour segmenter le disque optique (figure IV.4.d). Cet algorithme est utilisé pour estimer le seuil et segmenter l'image. Le principe de ISODATA est déjà décrit dans la section (2.2.1) du chapitre 3.

Les résultats de chaque partie sont illustrés dans la figure IV.4 suivante.

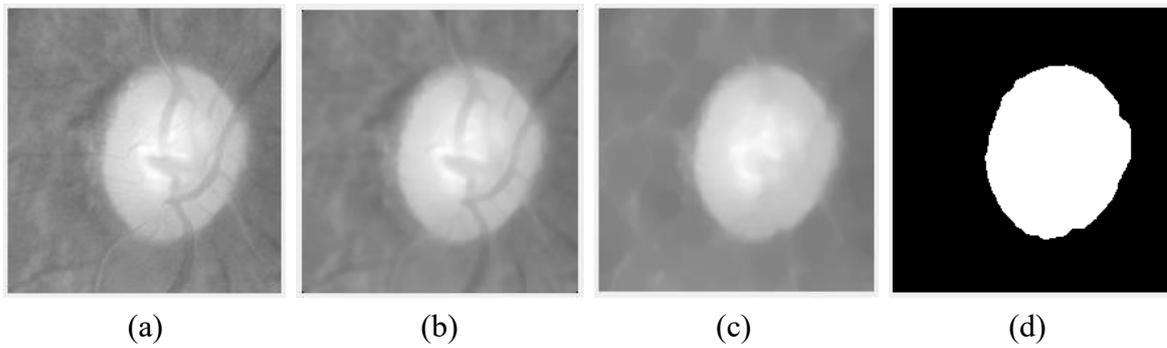


Figure IV.4 : Segmentation du disque optique. (a) Canal V de l'espace HSV ; (b) Image filtrée ; (c) Réseau rétinien éliminé par fermeture morphologique ; (d) Disque segmenté.

2.2.1.2. Segmentation du cup optique

Dans cette partie, nous nous focalisons sur la segmentation du CO à partir du canal vert de l'espace RGB (figure IV.5.a).

Aussi, le réseau vasculaire recouvre presque toute la région du cup optique, cela rendra sa détection difficile. Donc une bonne extraction du CO nécessite une étape d'élimination du réseau rétinien. Pour cela, nous avons appliqué une fermeture morphologique (figure IV.5.b).

Ensuite, une méthode de classification non supervisée Fuzzy C-Means (FCM) est utilisée pour extraire le cup en partitionnant l'image en quatre classes selon le critère d'appartenance (figure IV.5.c). Sachant que la classe qui contient la région du cup n'est pas fixée et se change après chaque exécution. Nous avons ajouté le critère de la classe correspondante à la surface minimale afin de sélectionner automatiquement la classe adéquate qui contient le cup. Ce critère va nous permettre d'automatiser notre algorithme pendant la sélection de la meilleure classe (figure IV.5.d).

La méthode FCM donne des meilleurs résultats par rapport à la méthode K-Means car elle introduit le degré de probabilité dans la répartition des pixels. Ces deux méthodes sont présentées dans les sections (2.2.2 et 2.2.3) du chapitre 3.

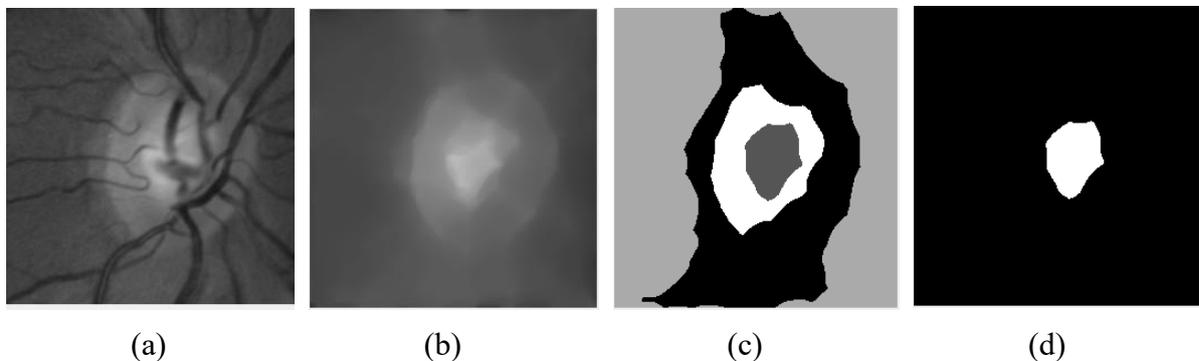


Figure IV.5 : Segmentation du CO. (a) Canal vert ; (b) Fermeture morphologique ; (c) Résultat du FCM ; (d) Cup segmenté.

2.2.1.3. Lissage des contours du disque et cup

Le glaucome engendre une détérioration des fibres nerveuses provoquant un épaissement de la région du cup. Pour cela, une bonne extraction des régions d'intérêts implique une bonne caractérisation et par la suite une classification plus précise.

A ce niveau, nous avons appliqué la méthode enveloppe convexe (voir la section III.2.3). Le rôle de cette méthode est de lisser les contours des régions détectées tout en améliorant les résultats obtenus (figure IV.6).

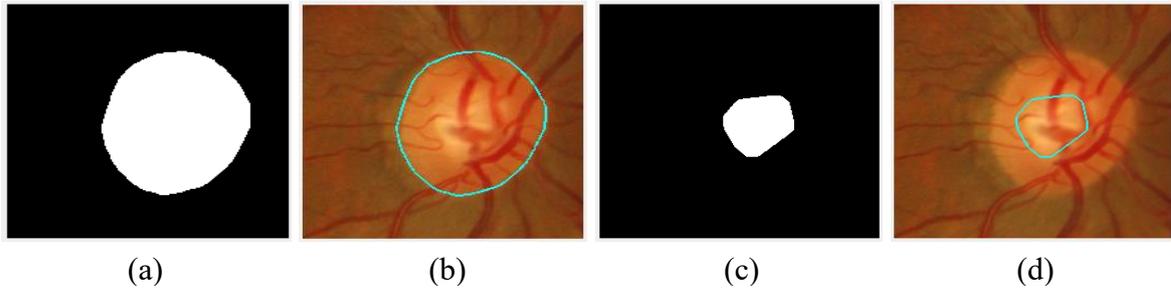


Figure IV.6 : Amélioration des résultats de la segmentation. (a) DO final ; (b) Contour du disque ; (c) CO final ; (d) Contour du cup.

2.2.1.4. Résultats et discussion des méthodes classiques

Afin d'évaluer les performances de l'approche proposée, notre algorithme a été testé sur la base de données Rim-One.

Le tableau IV.1 montre la comparaison de la méthode proposée avec d'autres méthodes disponibles dans la littérature pour l'étape de segmentation en termes d'exactitude moyenne.

Auteurs	Base de données	Exactitude moyenne du DO et CO
Dnyaneshwari D. Patil et al. [27]	Messidor, RIM-ONE	68 % pour Messidor 83 % pour RIM-ONE
Zhou et al. [32]	RIM-ONE	84.69%
Méthode proposée	RIM-ONE	91 %

Tableau IV.1 : Comparaison des performances de détection du disque et cup avec les méthodes de l'état de l'art.

Les résultats présentés indiquent que le système proposé a été capable d'extraire avec une grande précision le disque et le cup par rapport aux autres méthodes [27, 32, 150].

Généralement, les difficultés rencontrées lors d'utilisation de ces techniques sont : le bon choix des valeurs et l'adaptation du système sur une large base de données surtout dans les cas des images pathologiques ou de mauvaise qualité.

Pour résoudre ces problèmes, nous avons basculé vers l'utilisation de nouvelles techniques basées sur l'apprentissage profond pour l'extraction automatique des différentes régions sans une intervention humaine.

2.2.2. Algorithmes d'apprentissage profond pour détecter CO et DO

Actuellement, la segmentation sémantique des images médicales par les modèles de deep learning a reconnu un grand succès avec une amélioration de performances remarquable par rapport aux méthodes classiques.

Dans cette thèse, nous avons testé les architectures les plus populaires : SegNet et U-Net avec des versions améliorées (modifiées). Ces architectures sont des réseaux profonds encodeur-décodeur. La partie encodage extrait les cartes de caractéristiques, alors que la partie décodage génère l'image en combinant ces caractéristiques.

L'entraînement des modèles de deep learning nécessite une grande base d'images annotées pour leur permettre d'apprendre efficacement. Donc, une étape d'augmentation des données est nécessaire.

2.2.2.1. Préparation et augmentation des données

Le manque des données annotées rend un réseau de neurones profond moins précis. Cependant, l'augmentation des données consiste à créer artificiellement de nouvelles données en apportant des modifications subtiles aux données existantes.

Une augmentation de la taille de notre base de données nous permet de renforcer notre apprentissage ce qui peut rendre notre modèle plus robuste aux variations de l'ensemble d'entrée. L'augmentation des données permet aussi d'éviter le problème de sur-ajustement.

Cette étape peut être réalisée à l'aide de transformations géométriques (rotation, translation, zoom), textuelles (filtrage, amélioration de contraste) etc.

Dans notre cas nous avons appliqué trois techniques pour augmenter le nombre d'images qui sont :

- ✓ Rotations avec différents angles.
- ✓ Retournement (flipping) : création d'un reflet de miroir le long des deux axes : horizontal et vertical.
- ✓ Amélioration du contraste à l'aide de l'égalisation d'histogramme.

Dans notre travail, ces techniques sont utilisées pour augmenter les images d'apprentissage des trois bases : RIM-ONE, DRISHTI-GS1 et notre base de données locale qui seront employées pour l'entraînement de nos modèles. Les images de chaque base sont divisées en 80 % pour l'apprentissage et 20 % pour le test.

La figure IV.7 ci-dessous, illustre quelques exemples d'images obtenues après l'augmentation des données avec leur disque et cup correspondants.

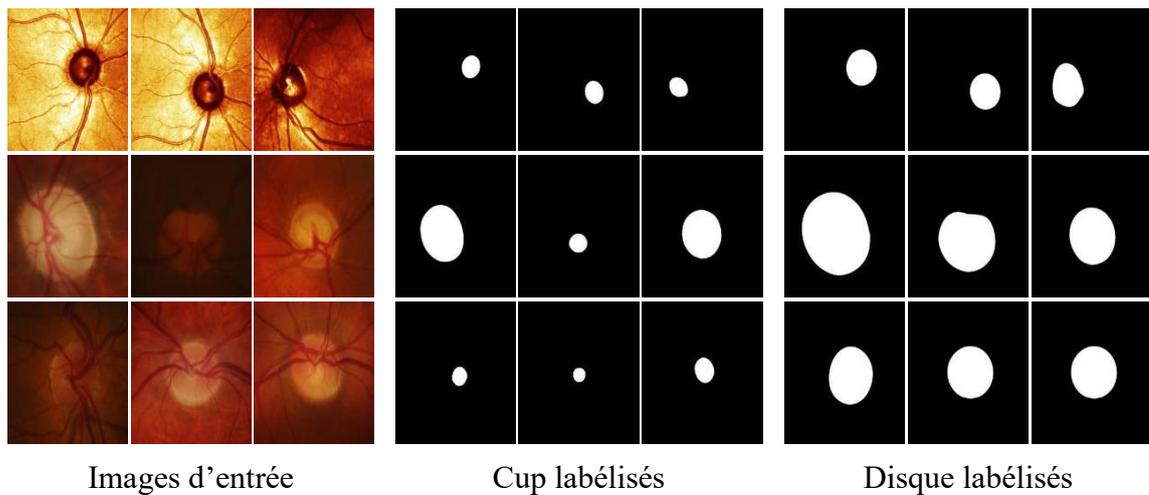


Figure IV.7 : Exemples d'images préparées pour l'apprentissage.

A la sortie de cette étape, nous avons obtenu 2800 images de la tête du nerf optique couleur avec les images labélisées correspondantes appliquées dans la partie d'entraînement.

Pour évaluer la robustesse de nos méthodes sur des images de différentes qualités, nous avons utilisé les images originales sans aucun prétraitement.

2.2.2.2. Segmentation du CO et DO

Pour segmenter automatiquement le DO et le CO, nous avons implémenté plusieurs architectures : SegNet, SegNet modifiée, U-Net et U-Net modifiée. Dans cette étape, nous avons modifié les versions originales des modèles afin d'améliorer les résultats et minimiser le temps de calcul.

A. Architecture SegNet modifiée

SegNet [142] est une architecture entièrement convolutive développée pour la classification pixel par pixel dans les images (voir la session 4.5.1 du chapitre 3). Cette architecture est très populaire pour la segmentation des images médicales offrant des résultats impressionnants. Elle se compose de deux parties principales : L'encodeur qui calcule les caractéristiques et le décodeur qui combine les informations extraites pour construire le résultat final. Pour optimiser ces méthodes nous avons effectué des modifications dans les couches de SegNet.

La nouvelle architecture développée pour la segmentation sémantique du DO et du CO est appelée « *SegNet modifiée* ». Elle est basée sur le réseau de décodage de SegNet et le modèle pré-entraîné VGG19. Ce dernier est utilisé pour initialiser les couches et les poids, construire le réseau d'encodage et générer un ensemble de cartes de caractéristiques (Fig.3). Notre SegNet modifié est composé de cinq blocs d'encodeur et cinq décodeurs.

La partie d'encodage est similaire aux 16 couches convolutives du VGG19 présentées dans la figure III.12. En effet, les deux premiers blocs de l'encodeur contiennent deux couches de convolution, tandis que les trois blocs restants contiennent quatre couches convolutives. À la fin de chaque encodeur, un max pooling avec une fenêtre de taille 2x2 et un pas de 2 est appliqué. La sortie du pooling est sous-échantillonnée par un facteur de 2. Dans notre modèle, les couches entièrement connectées ont été remplacées par un réseau de décodeurs. Ce remplacement rend l'encodeur SegNet plus facile et plus efficace pour la segmentation d'images.

Le réseau décodeur utilise les indices de max pooling calculés dans l'encodeur approprié pour sur-échantillonner sa carte caractéristique d'entrée et obtenir une carte peu dense. Dans le réseau décodeur, nous avons réduit le nombre de couches convolutives à la moitié dans chaque étape du décodeur du SegNet original. Par conséquent, le nombre de couches de convolution est réduit à 8 couches au lieu d'un réseau décodeur à 16 couches (similaire au réseau encodeur). Cette diminution réduit le temps d'apprentissage et résout le problème de la mémoire pendant la phase d'apprentissage. Les trois premiers blocs du décodeur contiennent deux couches de convolution, tandis que les deux derniers contiennent une seule couche CONV. En outre, une convolution transposée est appliquée dans chaque section du décodeur.

Chaque bloc du réseau de décodeur correspond au bloc de l'encodeur avec une classification par pixel. Pour les deux réseaux, chaque couche convolutive de taille 3x3 est suivie d'une couche de normalisation par lots et d'une fonction d'activation LeakyReLU. Cette fonction donne de meilleurs résultats par rapport à la fonction ReLU.

Enfin, notre modèle classe chaque pixel à l'aide d'une fonction Softmax et suivie par la fonction d'entropie croisée pour obtenir les images segmentées finales.

Notre architecture SegNet modifiée est présentée dans la figure IV.8 suivante.

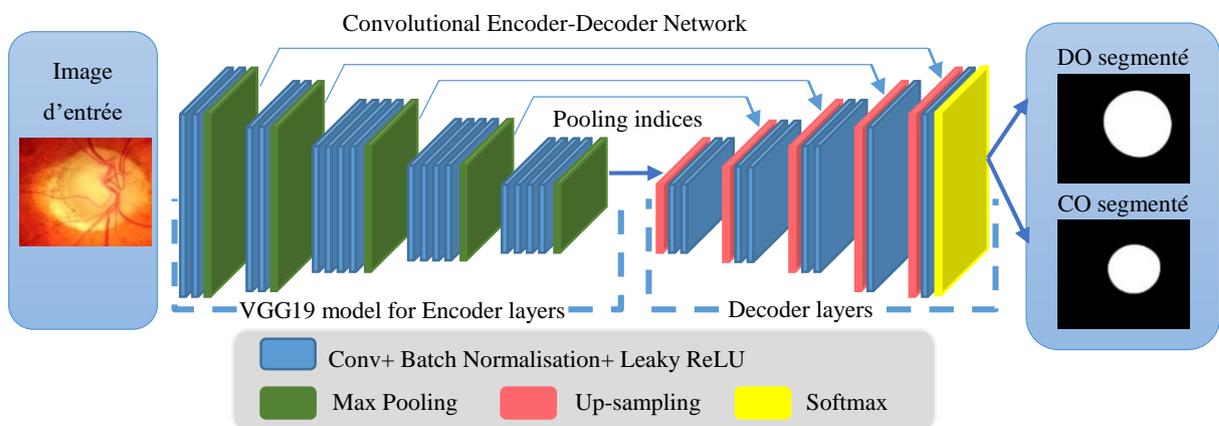


Figure IV.8 : L'architecture proposée SegNet modifiée combinée avec VGG19.

L'architecture proposée utilise le réseau VGG19 pour initialiser les poids d'encodeur, ce qui nécessite relativement moins d'époques d'apprentissage et moins de temps d'apprentissage. La réduction du nombre de couches de convolution dans le réseau de décodage atténue l'utilisation de la mémoire du GPU, comme c'est le cas dans la majorité des architectures d'apprentissage profond au cours de l'étape de formation.

B. Architecture U-Net modifiée

De plus, nous avons utilisé l'architecture U-Net [144] (voir section III.4.5.2) et une version variante.

Dans notre modèle modifié nous avons remplacé la fonction ReLU par la fonction d'activation Leaky ReLU. Cette dernière utilise une petite pente pour les valeurs négatives au lieu de zéro. De même, le max pooling est remplacé par le average pooling.

Notre modèle « *U-Net modifié* » contient deux parties principales : La partie contractante est composée de quatre blocs répétés, chacun étant composé de deux couches de convolution suivies d'une couche de normalisation, la fonction leaky ReLU et d'une couche de average pool 2x2. Chaque couche convolutionnelle vise à extraire le maximum des caractéristiques.

La partie expansive contient un nombre identique de blocs que le chemin de contraction et elle est composée de couches convolutionnelles transposées. Cette partie combine les caractéristiques obtenues par la partie ascendante et des concaténations avec les caractéristiques de haute résolution du chemin de contraction. A la fin, une convolution de 1x1 est utilisée pour mapper le vecteur de caractéristiques au nombre de classes désirées. Le résultat de tout ce processus est une image binaire présentant la segmentation sémantique du DO ou du CO.

Notre modèle U-Net modifié et le nombre de filtres de convolution utilisés dans chaque étape sont détaillés dans la figure IV.9 qui suit.

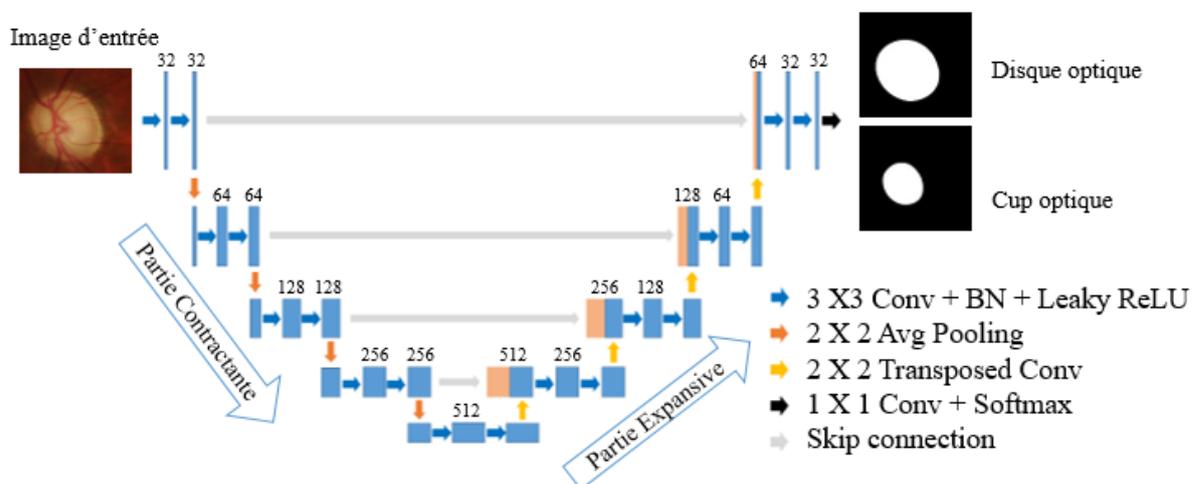


Figure IV.9 : Architecture U-Net modifiée.

L'architecture U-Net modifiée offre de bons résultats en comparaison avec U-Net l'originale.

2.2.2.3. Résultats et discussion

Les algorithmes du deep learning proposés sont implémentés en utilisant l'environnement MATLAB installé sur une machine AMD Ryzen threadripper 1950X 16-Core Processor 3,40 GHz, avec une RAM de 16 Go et la carte graphique (GPU) NVIDIA GeForce GTX 1080. Pour optimiser les poids de ces réseaux et minimiser la quantité de mémoire requise pendant le processus d'apprentissage, nous avons utilisé l'optimiseur Adam avec une taille de mini-lots de 14 et 100 époques.

Nous avons entraîné et testé nos méthodes en utilisant trois bases de données publiques : RIM-ONE, DRISHTI-GS, ORIGA et notre base de données collectée localement. Tous ces ensembles de données sont acquis pour analyser la tête du nerf optique dans les images de glaucome.

L'utilisation de différentes bases de données est très utile pour évaluer les performances de nos modèles sur des images d'intensités variantes.

Rappelons que la base RIM-ONE contient 159 images, la base DRISHTI-GS1 englobe 50 images annotées et 51 images non annotées, la base ORIGA contient 650 images. Notre base de données collectée localement se compose de 230 images de la tête du nerf optique acquises par un OCT Heidelberg Spectralis. Ces bases sont décrites dans la section 3 du chapitre 2.

Pour évaluer quantitativement l'efficacité de nos méthodes proposées, nous avons utilisé cinq métriques d'évaluation : Coefficient de Dice, l'indice de jaccard (IoU), l'exactitude (Acc), la sensibilité (Se) et la spécificité (Sp). Ces mesures sont décrites dans la section 5 du chapitre 3.

Les tableaux IV.2 et IV.3 montrent les résultats de nos modèles proposés : SegNet modifié et U-Net modifié par rapport aux réseaux originaux pour l'extraction du DO et du CO, respectivement. Les valeurs en gras représentent les meilleurs résultats obtenus.

Lors de l'évaluation sur DRISHTI-GS1, RIM ONE, la base locale et ORIGA, respectivement, ces tableaux montrent que notre SegNet modifié est plus performant que les autres modèles ainsi que notre U-Net modifié surpasse l'architecture U-Net originale. Nous observons également que lorsque nous testons notre modèle sur un grand ensemble de données (ensemble de données global), les résultats obtenus par la base de données DRISHTI-GS sont plus fiables.

Les figures IV.10, IV.11, IV.12 et IV.13 présentent quelques exemples des résultats de segmentation du DO et du CO en utilisant notre modèle SegNet modifié qui a donné les meilleurs résultats pour les bases de données RIMONE, locale, DRISHTI-GS1 et ORIGA, respectivement. De gauche à droite, les images originales, le cup segmenté, le disque segmenté

et enfin, la comparaison avec les images labélisées sont illustrées. Ces figures montrent que les résultats de segmentation obtenus sont proches des images labélisées par les experts et ils ont permis d'extraire avec une grande précision et moins d'erreurs de segmentation. Toutefois, ces erreurs sont dues au bruit, aux artéfacts et à la mauvaise qualité de l'image.

Bases de données	Méthodes	Acc (%)	IoU (%)	Dice (%)	Se (%)	Sp (%)
DRISHTI-GS	SegNet originale	99.32	93.67	96.73	99.10	99.34
	SegNet modifiée	99.83	94.68	97.27	99.27	99.45
	U-Net originale	99.15	93.06	95.16	98.94	99.05
	U-Net modifiée	99.37	93.86	96.96	99.08	99.28
RIM ONE	SegNet originale	99.66	97.11	98.53	98.77	99.77
	SegNet modifiée	99.78	97.80	98.97	99.30	99.82
	U-Net originale	99.34	96.31	97.75	98.11	99.22
	U-Net modifiée	99.67	97.30	98.02	99.12	99.56
Base Locale	SegNet originale	99.87	97.45	98.70	98.34	99.95
	SegNet modifiée	99.93	98.60	99.30	99.02	99.97
	U-Net originale	99.53	96.98	98.44	97.95	99.50
	U-Net modifiée	99.76	95.28	98.77	98.80	99.80
ORIGA	SegNet originale	99.41	93.63	95.65	97.56	99.32
	SegNet modifiée	99.70	95.82	97.87	98.19	99.51
	U-Net originale	99.02	91.86	94.92	96.91	99.01
	U-Net modifiée	99.29	94.48	97.21	97.74	99.20
Base Globale	SegNet originale	99.65	96.32	98.12	98.78	99.74
	SegNet modifiée	99.74	97.26	98.61	99.25	99.79
	U-Net originale	98.61	95.79	97.76	98.65	99.52
	U-Net modifiée	99.72	96.87	98.18	99.01	99.80

Tableau IV.2 : Performance d'extraction du disque sur les différentes bases de données.

Le tableau IV.4 indique les résultats obtenus par le modèle proposé en comparaison avec d'autres réseaux existants pour la segmentation sémantique du DO et du CO en utilisant l'ensemble de données DRISHTI-GS1 et différentes métriques. Par rapport à l'état de l'art, notre modèle développé a donné des meilleurs résultats en termes de précision et l'coefficient de Dice.

Le tableau IV.5 et IV.6 présentent la comparaison des résultats obtenus avec d'autres méthodes en utilisant les bases de données ORIGA et RIM-ONE respectivement. SegNet modifiée a surpassé les autres méthodes pour l'extraction du CO. En comparant les résultats du DO, cette architecture est plus performante que les méthodes existantes en termes de Dice, Se et Sp.

Bases de données	Méthodes	Acc (%)	IoU (%)	Dice (%)	Se (%)	Sp (%)
DRISHTI-GS	SegNet originale	99.05	83.23	90.85	96.21	99.62
	<i>SegNet modifiée</i>	99.71	88.95	94.15	96.41	99.79
	U-Net originale	98.97	82.89	90.31	95.98	99.32
	<i>U-Net modifiée</i>	99.30	88.64	93.86	96.09	99.77
RIM ONE	SegNet originale	99.59	93.21	96.48	97.27	99.87
	<i>SegNet modifiée</i>	99.76	95.97	97.94	97.80	99.94
	U-Net originale	99.28	92.98	96.11	96.67	99.43
	<i>U-Net modifiée</i>	99.62	95.74	97.77	97.57	99.91
Base Locale	SegNet originale	99.85	96.78	98.36	98.14	99.97
	<i>SegNet modifiée</i>	99.92	97.34	98.65	97.76	99.99
	U-Net originale	99.47	92.98	96.11	96.67	99.43
	<i>U-Net modifiée</i>	99.66	95.74	97.77	97.57	99.91
ORIGA	SegNet originale	99.10	92.82	95.92	97.15	99.17
	<i>SegNet modifiée</i>	99.55	94.58	96.77	98.00	99.42
	U-Net originale	98.97	90.51	94.24	96.79	98.89
	<i>U-Net modifiée</i>	99.25	93.48	96.01	97.68	99.07
Base Globale	SegNet originale	99.79	91.56	95.59	97.26	99.85
	<i>SegNet modifiée</i>	99.87	95.42	97.22	97.44	99.93
	U-Net originale	99.57	91.23	95.18	96.97	99.76
	<i>U-Net modifiée</i>	99.73	94.98	96.88	97.38	99.89

Tableau IV.3 : Performance d'extraction du cup sur les différentes bases de données.

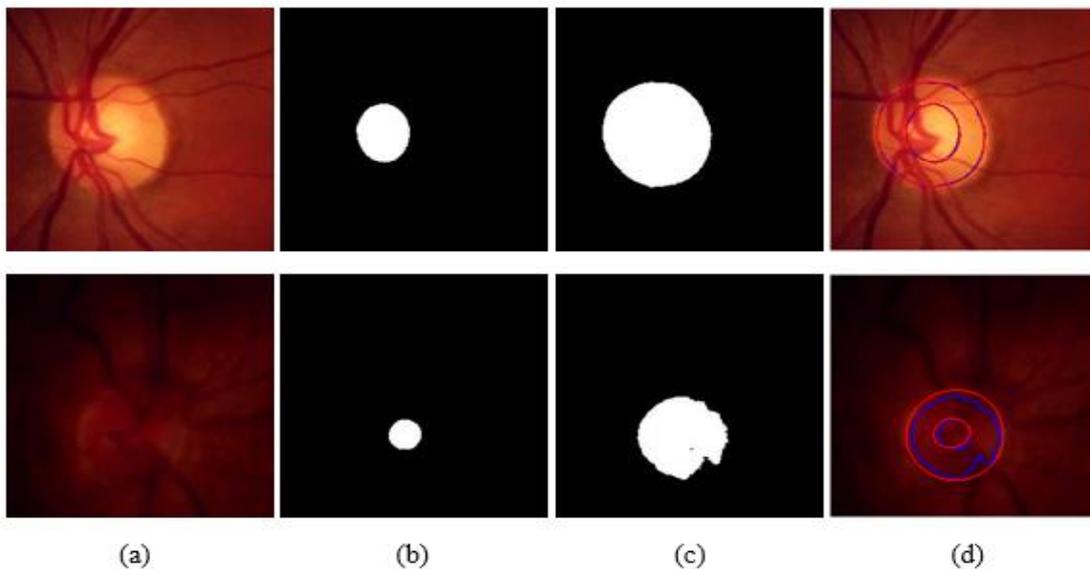


Figure IV.10 : Exemples de segmentation du DO et du CO sur la base **RIM-ONE** en utilisant SegNet modifié. (a) : Images originales ; (b) : Cup segmenté ; (c) : Disque segmenté ; (d) : Images originales avec contours de cup et de disque, le contour rouge correspondant aux résultats des experts et le contour bleu à nos résultats.

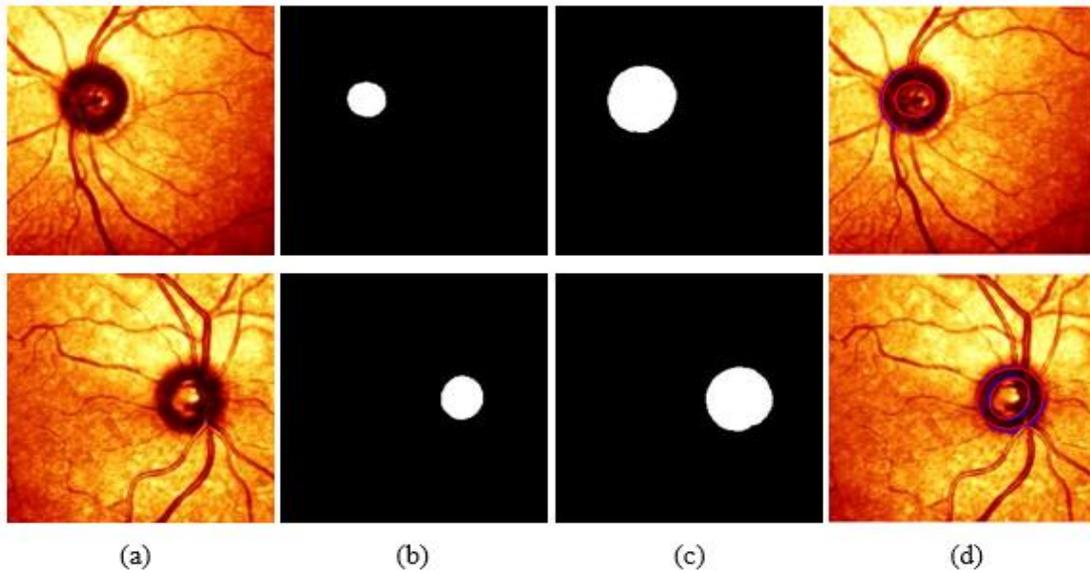


Figure IV.11 : Exemples de segmentation du DO et du CO sur la base **Locale** en utilisant SegNet modifié. (a) : Images originales ; (b) : Cup segmenté ; (c) : Disque segmenté ; (d) : Images originales avec contours de cup et de disque, le contour rouge correspondant aux résultats des experts et le contour bleu à nos résultats.

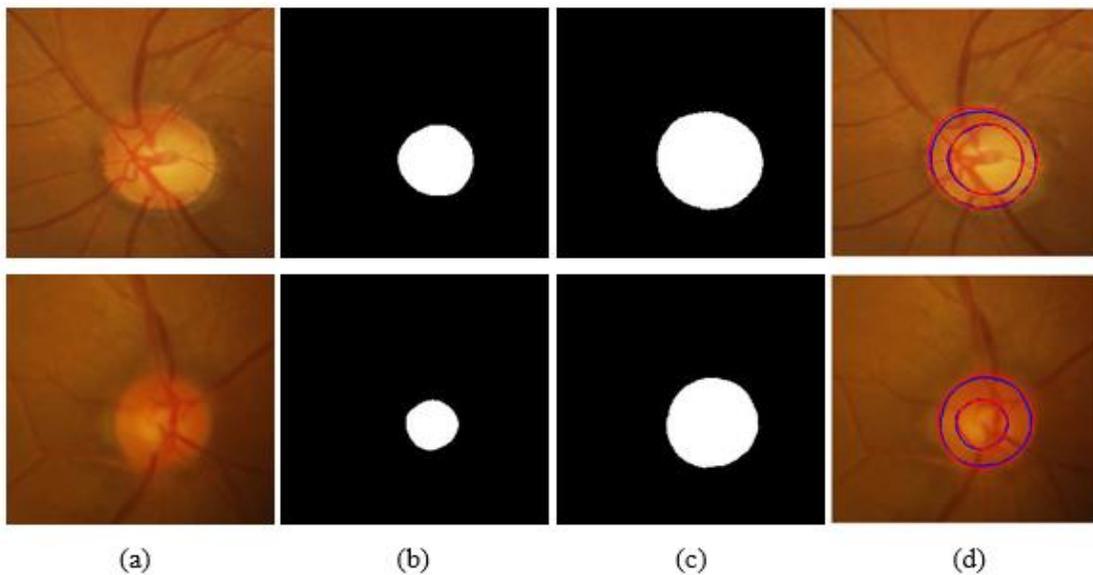


Figure IV.12 : Exemples de segmentation du DO et du CO sur la base **DRISHTI-GS1** en utilisant SegNet modifié. (a) : Images originales ; (b) : Cup segmenté ; (c) : Disque segmenté ; (d) : Images originales avec contours de cup et de disque, le contour rouge correspondant aux résultats des experts et le contour bleu à nos résultats.

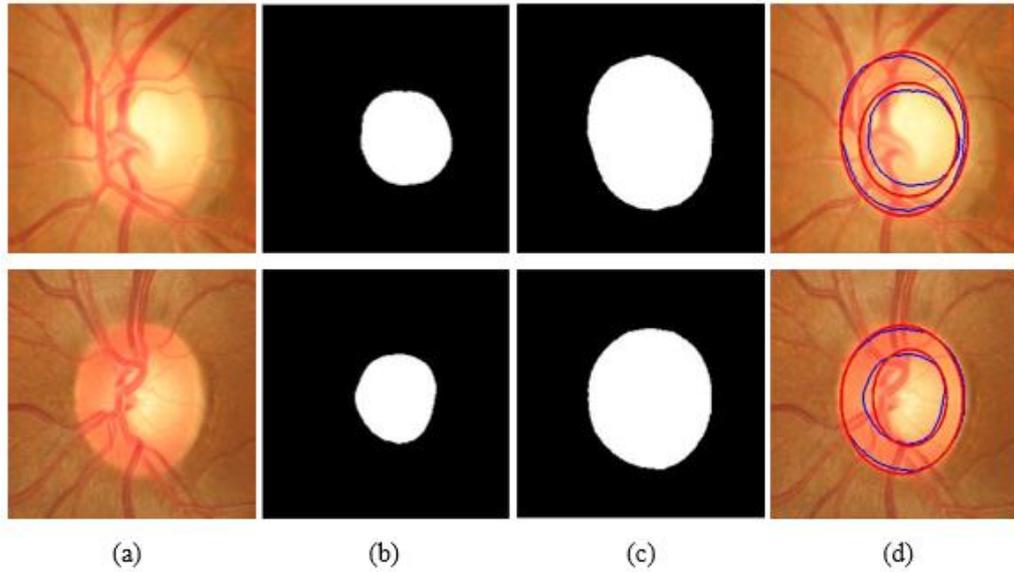


Figure IV.13 : Exemples de segmentation du DO et du CO sur la base **ORIGA** en utilisant SegNet modifié. (a) : Images originales ; (b) : Cup segmenté ; (c) : Disque segmenté ; (d) : Images originales avec contours de cup et de disque, le contour rouge correspondant aux résultats des experts et le contour bleu à nos résultats.

Auteurs	DO (%)					CO (%)				
	Acc	IoU	Dice	Se	Sp	Acc	IoU	Dice	Se	Sp
Zilly et al. [34]	-	91.4	97.3	-	-	-	85	87.1	-	-
Sevastopolsky [35]	-	-	-	-	-	-	75	85	-	-
Al-Bander et al. [36]	99.69	90.42	94.9	92.68	99.92	99.48	71.13	82.82	74.13	99.95
Yu et al. [37]	-	94.92	97.38	-	-	-	80.42	88.77	-	-
Afolabi et al. [38]	-	-	-	-	-	-	79	95	-	-
Tabassum et al. [41]	99.66	91.83	95.97	97.54	99.73	99.71	86.32	92.4	95.67	99.81
Shinde [54]	94	97.6	-	94	94.1	97.7	85.3	-	96.9	97.3
<i>SegNet modifiée</i>	99.83	94.68	97.27	99.27	99.45	99.71	88.95	94.15	96.41	99.79
<i>U-Net modifiée</i>	99.37	93.86	96.96	99.08	99.28	99.30	88.64	93.86	96.09	99.77

Tableau IV.4 : Résultats de la segmentation du DO et CO sur la base d'images **DRISHTI-GS1** comparés avec les travaux existants.

Auteurs	DO (%)					CO (%)				
	Acc	IoU	Dice	Se	Sp	Acc	IoU	Dice	Se	Sp
Al-Bander et al. [36]	99.89	93.34	96.53	96.09	99.95	99.65	76.88	86.59	91.95	99.91
Panda et al. [43]	--	--	93.81	--	--	--	--	88.92	--	--
Guo et al. [51]	98.4	--	--	--	--	94.2	--	--	--	--
<i>SegNet modifiée</i>	99.70	95.82	97.87	98.19	99.51	99.55	94.58	96.77	98.00	99.42
<i>U-Net modifiée</i>	99.29	94.48	97.21	97.74	99.20	99.25	93.48	96.01	97.68	99.07

Tableau IV.5 : Résultats de la segmentation du DO et CO sur la base d'images **ORIGA** comparés avec les travaux existants.

Auteurs	DO (%)					CO (%)				
	Acc	IoU	Dice	Se	Sp	Acc	IoU	Dice	Se	Sp
Zilly et al. [34]	-	89	94.2	-	-	-	80.2	82.4	-	-
Sevastopolsky [35]	-	89	95	-	-	-	69	82		
Al-Bander et al. [36]	99.22	82.89	90.36	87.37	99.76	99.28	55.67	69.03	90.52	99.44
Yu et al. [37]	-	92.56	96.10	-	-	-	74.29	84.45	-	-
Afolabi et al. [38]	-	88	96	-	-	-	76	89	-	-
Tabassum et al. [41]	99.56	91.01	95.82	97.34	99.73	99.61	75.32	86.22	95.17	99.81
Shinde [54]	96.4	98.8	-	97.9	94.4	97	86.8	-	97	97.1
SegNet modifiée	99.78	97.80	98.97	99.30	99.82	99.76	95.97	97.94	97.80	99.94
U-Net modifiée	99.67	97.30	98.02	99.12	99.56	99.62	95.74	97.77	97.57	99.91

Tableau IV.6 : Résultats de la segmentation du DO et CO sur la base d'images **RIM ONE** comparés avec les travaux existants.

Les résultats expérimentaux indiquent que notre réseau SegNet modifié est performant et prouvent qu'il est capable d'extraire avec une grande précision l'OD et l'OC en utilisant différentes bases de données. En outre, il possède le temps de prédiction le plus faible (0,02 seconde par image) par rapport aux autres méthodes existantes.

Donc les résultats de SegNet modifié sont utilisés comme entrée dans l'étape de caractérisation.

2.3. Extraction de caractéristiques

Le glaucome provoque des changements dans la papille optique. Le diagnostic de cette maladie à partir d'images rétiniennes peut être effectué en utilisant trois paramètres clés : le RCD, le RRD et la vérification du NRR dans la règle ISNT, qui sont les changements structurels clés permettant de distinguer entre les images normales et les images glaucomateuses. Dans le cas du glaucome, le RCD est supérieur à 0,3 et la surface du NRR dans les quadrants de la règle ISNT devient déséquilibrée. Dans notre recherche, ces paramètres sont calculés à partir des résultats du modèle SegNet modifié de la manière suivante :

Le Rapport Cup-Disque (RCD) : représente le rapport entre la surface du CO et la surface du DO (eq. IV.1).

$$\text{RCD} = \text{surface du cup} / \text{surface du disque} \quad (\text{IV.1})$$

Le Rapport Rim-Disque (RRD) : l'anneau neuro-rétinien est la région qui indique l'altération des fibres nerveuses rétiniennes. Dans un cas pathologique, cette partie devient plus mince. Le RRD est mesuré comme suit (eq. IV.2) :

$$\text{RRD} = \text{surface du NRR} / \text{surface du disque} \quad (\text{IV.2})$$

Pour effectuer ce calcul, nous avons commencé par l'extraction de la région du NRR en appliquant un ET logique entre le disque segmenté et le complément du cup comme montre la figure suivante.

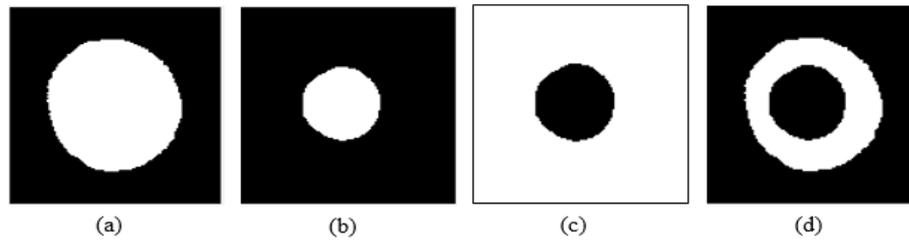


Figure IV.14 : Résultat d'extraction de NRR. (a) disque optique segmenté ; (b) cup optique segmenté ; (c) complément du cup ; (d) NRR détecté.

La vérification de la règle INST dans les quatre quadrants de l'anneau neuro-rétinien :

L'un des points forts de notre méthode est que la règle ISNT, est indépendante de la taille de DO, ce qui donne des résultats de classification supérieurs à ceux de la RCD uniquement. La surface du NRR dans une image rétinienne saine est ordonnée comme suit :

$$\text{NRR Inférieur} \geq \text{NRR Supérieur} \geq \text{NRR Nasal} \geq \text{NRR Temporal}$$

Pour vérifier la région NRR dans la règle ISNT, nous avons appliqué une opération ET entre la région NRR extraite et différents masques pour mesurer le rapport de la région NRR dans les quadrants ISNT (figure IV.15). Une perturbation hors cette règle indique le risque de perte de vision due au glaucome.

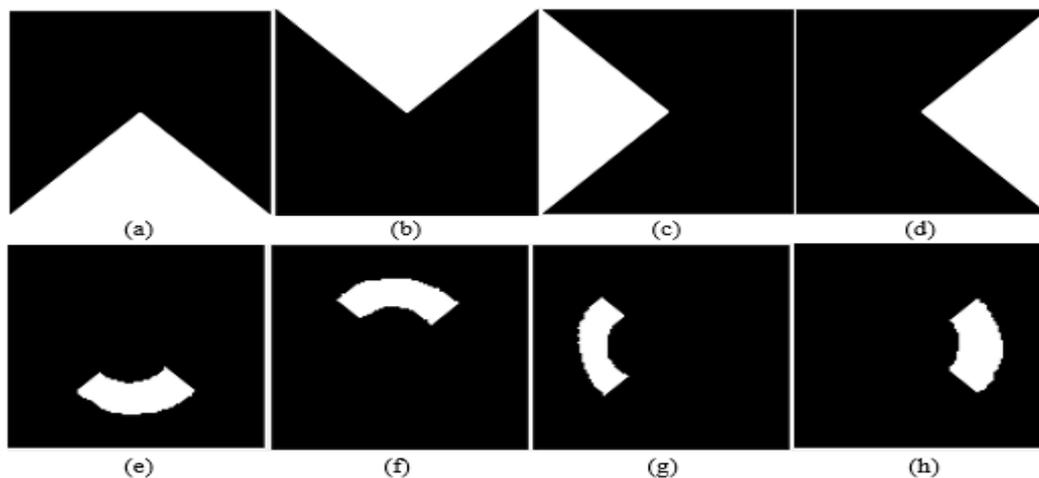


Figure IV.15 : Vérification de NRR dans la règle ISNT pour un œil droit. (a-d) : Les différents masques : Inférieur, Supérieur, Nasal et Temporal. (e-h) : les régions du NRR correspondantes.

2.4. Classification

Après l'extraction des différents paramètres à partir des images segmentées, nous avons utilisé plusieurs classifieurs supervisés pour distinguer entre un patient sain et un patient atteint du glaucome.

Le classifieur qui donne les meilleures performances pour la détection du glaucome sera choisi. Les paramètres utilisés pour chaque classifieur pour obtenir les meilleures performances sont comme suit :

- ✓ Le classifieur SVM avec un noyau non linéaire "Polynôme d'ordre 2" est utilisé pour l'apprentissage et le test.
- ✓ Le classifieur KNN : nombre de voisins égal à 03 avec le choix d'une distance euclidienne.
- ✓ Le classifieur arbre de décision : algorithme CART.
- ✓ L'analyse discriminante pseudo-inverse-linéaire (PLDA) est une approche pionnière, employée pour résoudre le problème des petits ensembles de données.
- ✓ Le classifieur ANN : un réseau de rétropropagation avec 3 couches cachées et 100 époques pour l'entraînement.

Dans ce travail, nous avons utilisé la méthode de la validation croisée (K-cross validation) [144] pour diviser notre ensemble d'apprentissage et de test en choisissant $K=3$.

2.4.1. Résultats et discussions de l'étape de classification

Les figures (IV.16), (IV.17) et (IV.18) illustrent les performances de classification du glaucome à l'aide de cinq classifieurs : KNN, SVM, CART, PLDA et ANN en testant différentes bases de données.

- ✓ Sur la base de données **DRISHTI-GS1**, tous les classifieurs ont atteint une exactitude, une sensibilité et une spécificité de 100 %.
- ✓ Sur la base de données **RIM ONE**, l'exactitude obtenue varie entre 93.94 % et 99.82 %, avec une sensibilité et une spécificité supérieures à 97.44 % et 92 %, respectivement.
- ✓ Sur notre **base de données locale**, les classifieurs ont obtenu une sensibilité de 100 %, avec une exactitude et une spécificité supérieures à 90.2 % et 90 %, respectivement.
- ✓ Sur la base de données **ORIGA**, une exactitude de 98.77 %, 98.82 %, 98.56 %, 94,87 % et 99.75 %, une spécificité de 98.49 %, 98.35 %, 98.12 %, 94 % et 98.95 %, et une sensibilité de 100 % ont été obtenues en appliquant les classifieurs KNN, SVM, CART, PLDA et ANN, respectivement.

Nous avons également comparé les performances des cinq classifieurs supervisés pour la classification du glaucome. D'après les résultats obtenus, le classifieur ANN a obtenu les meilleurs Acc, Se et Sp pour toutes les bases de données. En revanche, le classifieur PLDA donne les faibles résultats car il est robuste dans le cas de petits ensembles de données.

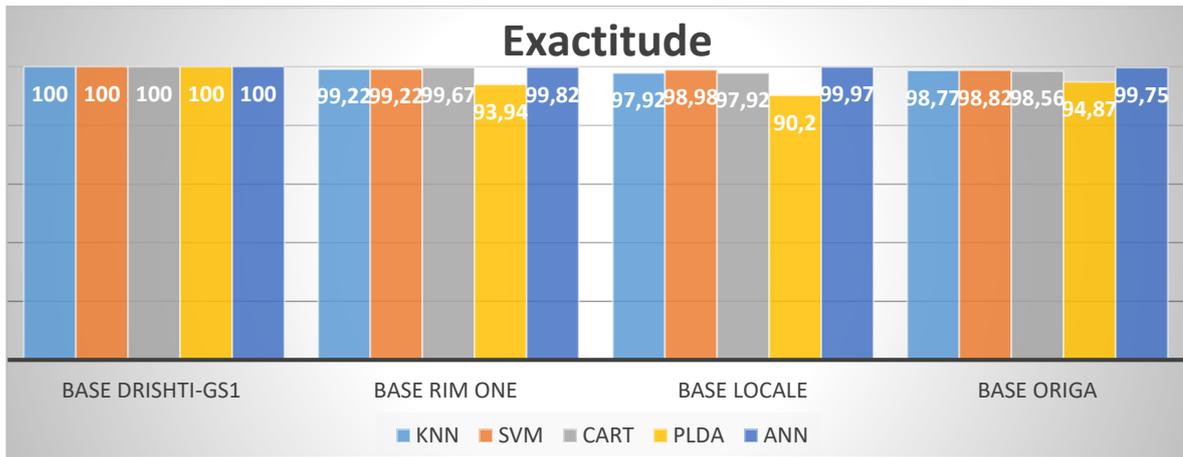


Figure IV.16 : Résultats de l'exactitude sur les différentes bases de données en utilisant les cinq classifieurs.

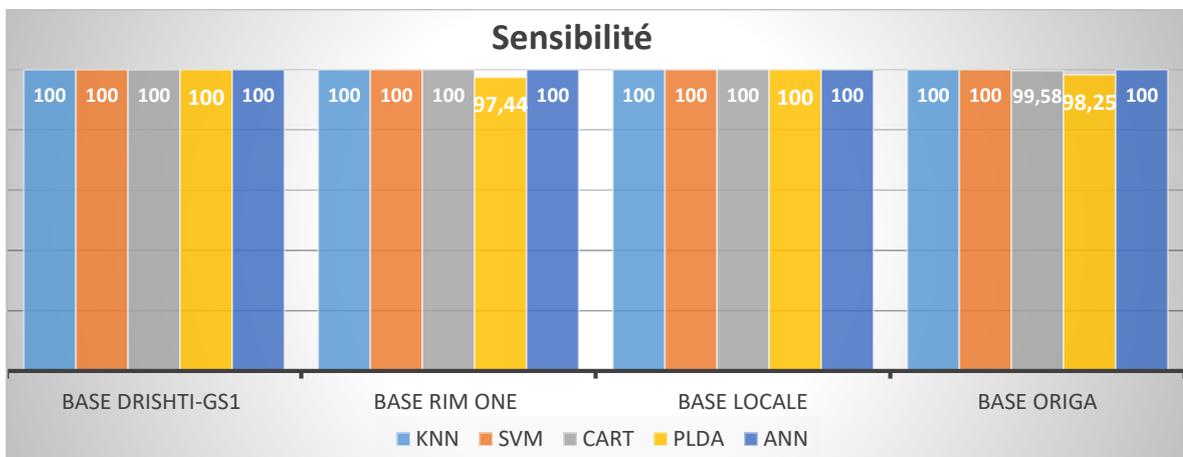


Figure IV.17 : Résultats de la sensibilité sur les différentes bases de données en utilisant les cinq classifieurs.

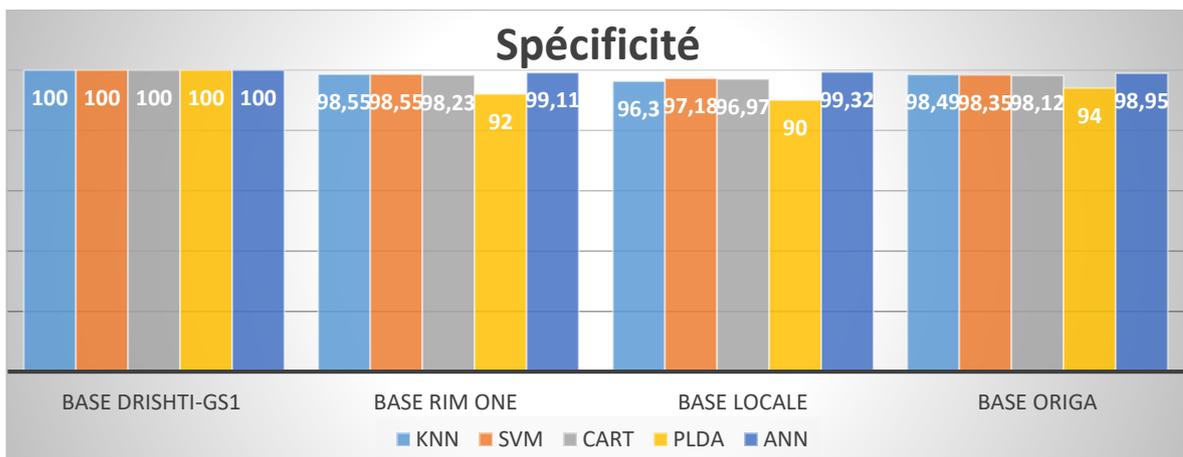


Figure IV.18 : Résultats de la sensibilité sur les différentes bases de données en utilisant les cinq classifieurs.

Les figures (IV.16), (IV.17) et (IV.18) montrent que les résultats obtenus sont très satisfaisants et indiquent que le classifieur ANN donne les meilleures performances sur toutes

les bases de données. Cependant, nous avons comparé leurs résultats avec d'autres méthodes disponibles dans la littérature.

Les tableaux IV.7, IV.8 et IV.9 présentent une comparaison entre notre meilleur classifieur (ANN) et les techniques existantes dans l'état de l'art pour la classification du glaucome en utilisant les bases de données DRISHTI-GS1, RIM-ONE et ORIGA, respectivement. Ces résultats surpassent donc les autres méthodes et prouvent que l'ANN a correctement classé toutes les images des quatre bases de données avec une Acc, SE et Sp de 100 %.

Auteurs	Méthodes	Acc (%)	Se (%)	Sp (%)
Chakravarty et al. [48]	SVM	76.8	-	-
Sreng et al. [53]	SVM	90.00	-	-
Shinde [54]	SVM + NN+Adaboost	100	100	100
Diaz-Pinto et al. [56]	XceptionNet network	75.25	-	-
<i>méthode Proposée</i>	<i>ANN</i>	<i>100</i>	<i>100</i>	<i>100</i>

Tableau IV.7 : Performance de la classification du glaucome à partir de la base de données **DRISHTI-GS1** comparée aux méthodes existantes.

Auteurs	Méthodes	Acc (%)	Se (%)	Sp (%)
Das et al. [47]	If condition	-	94.28	-
Sreng et al. [53]	SVM	97.37	-	-
Shinde [54]	SVM + NN+Adaboost	100	100	100
Diaz-Pinto et al. [56]	XceptionNet network	71.2	-	-
Gómez-Valverde et al. [57]	VGG19	-	87.0	89.0
<i>méthode Proposée</i>	<i>ANN</i>	<i>99.82</i>	<i>100</i>	<i>99.11</i>

Tableau IV.8 : Performance de la classification du glaucome à partir de la base de données **RIM-ONE** comparée aux méthodes existantes.

Auteurs	Méthodes	Acc (%)	Se (%)	Sp (%)
Guo et al. [51]	Forêt aléatoires	76.9	79.9	73.8
Sreng et al. [53]	SVM	83.59	-	-
Sudhan et al. [61]	DenseNet-201- DCNN	96.9	97.03	96.33
Latif et al. [62]	ODGNet	95.75	94.75	94.9
<i>méthode Proposée</i>	<i>ANN</i>	<i>99.75</i>	<i>100</i>	<i>98.95</i>

Tableau IV.9 : Performance de la classification du glaucome à partir de la base de données **ORIGA** comparée aux méthodes existantes.

Ainsi, pour évaluer les résultats obtenus en utilisant la base de données locale pour la segmentation et la classification du glaucome, nous avons validé les performances de notre

système par un groupe d'experts en ophtalmologie. Ils ont confirmé que le système proposé a mieux classé l'état de chaque patient.

En résumé, le système proposé est efficace pour la détection du glaucome, ce qui peut aider les ophtalmologistes à établir un diagnostic fiable et précoce pour prévenir la perte de vision.

4. Conclusion

Dans ce chapitre, nous avons développé un système de détection du glaucome à partir d'images rétiniennes. Un ensemble de méthodes de segmentation du disque et du cup basées sur les techniques de traitement d'images classiques et d'apprentissage profond ont été présentées. Les résultats de cette étape montrent que l'utilisation du deep learning est plus robuste par rapport aux méthodes classiques car il détecte les régions d'une manière automatique sans nécessité d'une étape de prétraitement ou d'ajustement de paramètres.

Parmi les architectures testés dans cette thèse pour la segmentation du DO et CO, le modèle SegNet modifié combiné avec VGG19 a surpassé les autres modèles implémentés et même les travaux existants dans l'état de l'art.

Ensuite, un ensemble de paramètres tels que le RCD, le RRD et la vérification du NRR dans la règle ISNT ont été calculés pour la classification du glaucome. Cette dernière est effectuée en utilisant cinq classifieurs supervisés qui sont : KNN, SVM, CART, PLDA ANN. Les résultats obtenus montrent que le classifieur ANN a donné la meilleure performance pour distinguer les cas sains des cas glaucomateux. Les méthodes proposées sont évaluées sur les bases de données RIM-ONE, DRISHTI-GS1, ORIGA et une base collectée localement. Les résultats obtenus montrent que notre système est efficace pour la détection du glaucome avec une grande précision, ce qui peut aider les ophtalmologistes dans le diagnostic précoce de cette maladie.

Chapitre V :
Détection automatique de la rétinopathie
diabétique : Méthodes et Résultats

1. Introduction

La rétinopathie diabétique est une pathologie rétinienne et un résultat du diabète à long terme. Il affecte les petits vaisseaux rétiniens, produisant des changements de diamètre, de largeur et de tortuosité. Cette maladie est la principale cause de cécité chez les patients diabétiques. Pour cela, un diagnostic précoce est très important pour éviter la perte de vision.

Dans ce chapitre, nous décrirons un système de détection de la RD à partir des images rétiniennes couleurs en utilisant les techniques de traitement d'images et l'intelligence artificielle. Ce système est basé sur deux parties principales : l'extraction des vaisseaux rétiniens et la classification des images à l'aide des caractéristiques morphologiques calculées à partir des images binaires. Pour évaluer la performance du système proposé, nous avons utilisé différentes bases de données publiques.

2. Méthodes proposées

Notre recherche vise à développer un outil automatique pour la classification binaire de la RD basée sur la segmentation de l'arbre vasculaire rétinien. Ce système passe par quatre étapes principales qui sont : le prétraitement, la segmentation du réseau rétinien, l'extraction d'un ensemble de caractéristiques géométriques à partir des images segmentées, et la classification à l'aide de l'apprentissage supervisé.

L'organigramme suivant résume notre système proposé pour la détection automatique de la RD à partir des images rétiniennes.

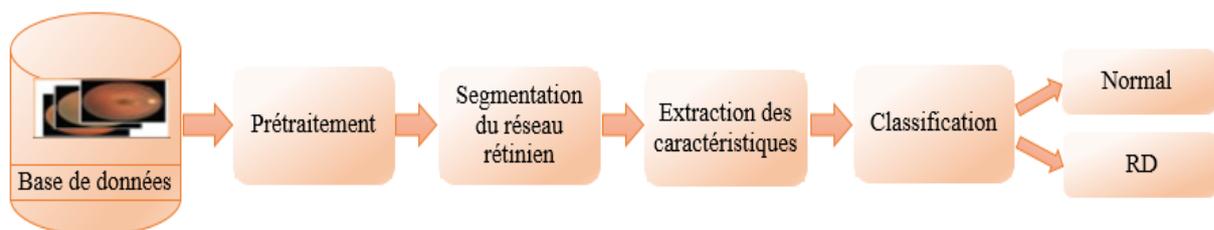


Figure V.1 : Organigramme du système proposé pour la classification de la rétinopathie diabétique.

Dans ce qui suit, nous allons détailler chaque étape séparément.

2.1 Prétraitement et augmentation des données

Les images rétiniennes prises lors d'un examen du fond de l'œil sont souvent faiblement contrastées ce qui rend la détection des vaisseaux rétiniens difficile. L'étape du prétraitement est presque controversée dans le domaine de traitement d'images. Pour résoudre ce problème, nous avons utilisé le canal vert de l'image du fond de l'œil couleur, où le réseau vasculaire est

clairement visible et apparaît avec un meilleur contraste. Ce canal est utilisé dans l'étape de segmentation.

2.2. Segmentation du réseau vasculaire rétinien

Les changements dans les vaisseaux sanguins rétiens comptent parmi les indicateurs importants du diagnostic de la RD. Par conséquent, la détection de cette région est très importante pour aider les ophtalmologues à reconnaître cette maladie au premier stade.

Dans cette thèse, nous avons utilisé deux méthodes pour segmenter l'arbre vasculaire : les techniques de traitement d'images et les algorithmes basés sur le deep learning.

L'organigramme suivant récapitule l'ensemble des algorithmes utilisés pour la segmentation du réseau rétinien.

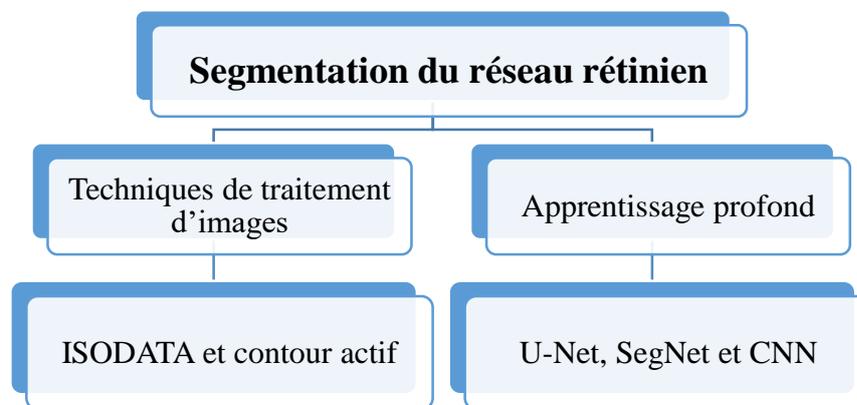


Figure V.2 : Nos méthodes utilisées pour la segmentation de l'arbre vasculaire rétinien.

Dans ce qui suit, nous décrierons chaque méthode séparément.

2.2.1. Techniques de traitement d'images classiques pour segmenter le réseau rétinien

Dans cette étude, nous avons implémenté différentes approches de traitement d'images pour améliorer la segmentation de l'arbre vasculaire.

Notre contribution, consiste à combiner deux méthodes pour une détection précise [146]. Cette méthode hybride est divisée en deux parties principales : prétraitement et segmentation. Chacune de ces deux parties est présentée dans les sections suivantes.

2.2.1.1. Prétraitement

Dans cette étape, nous avons éliminé les petits artefacts d'acquisition en appliquant un filtre gaussien [111] (figure V.3.b). Notre algorithme est basé sur l'extraction des courbures principales maximales dans chaque pixel pour segmenter avec précision les vaisseaux. Cette approche cherche à extraire les valeurs propres maximales de l'image filtrée à l'aide de la matrice hessienne [114] (voir section 2.1.6 du chapitre 3), qui sont considérées comme des courbures principales maximales. Ces dernières sont les principaux indicateurs qui révèlent la

présence de vaisseaux sanguins (figure V.3.c). Enfin, la technique CLAHE est appliquée afin d'améliorer le contraste de l'image obtenue (figure V.3.d).

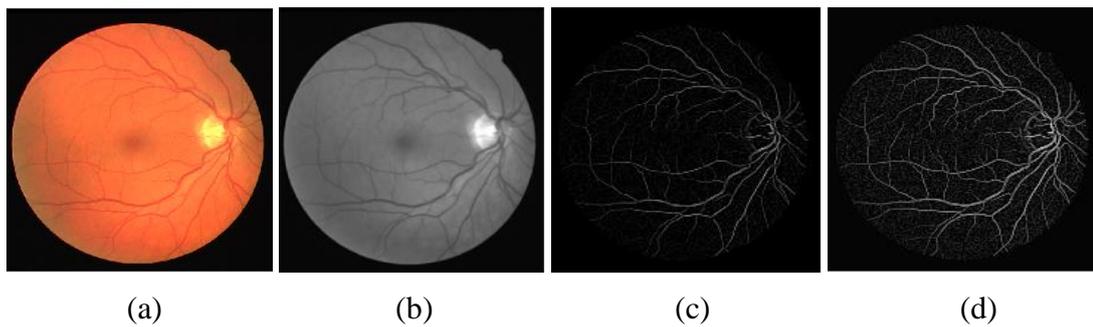


Figure V.3 : Etape de prétraitement. (a) Image originale ; (b) Image filtrée ; (c) Image des courbures principales ; (d) Image améliorée.

2.2.1.2. Segmentation des vaisseaux sanguins

A ce niveau, pour extraire les vaisseaux rétiniens, nous avons utilisé une méthode de seuillage basée sur l'algorithme ISODATA [116] (figure V.4.a). Les résultats de cette méthode sont introduits comme masque dans un modèle déformable basé sur le contour actif. Ce modèle est appliqué à l'image des courbures principales maximales pour améliorer le résultat de la segmentation des petits vaisseaux (figure V.4.b).

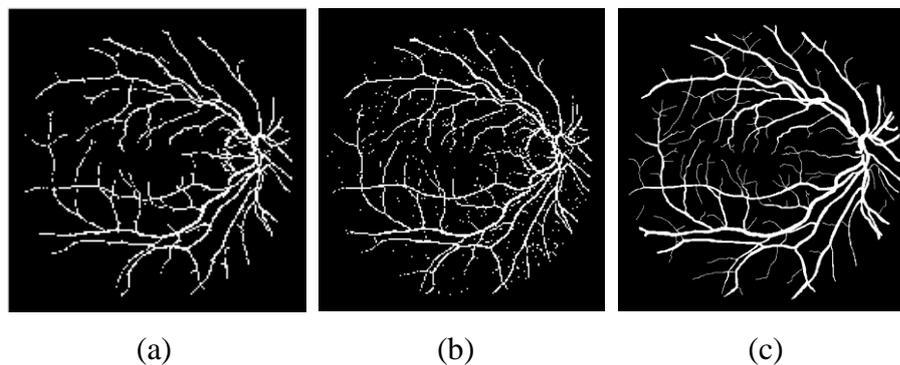


Figure V.4 : Segmentation des vaisseaux sanguins. (a) seuillage ISODATA ; (b) contour actif (vaisseaux sanguins finaux) ; (c) segmentation manuelle.

2.2.1.3. Résultats et discussion

Le système proposé a été testé sur la base de données DRIVE.

Le tableau 1 montre la comparaison de la méthode proposée avec les méthodes disponibles dans la littérature pour la segmentation des vaisseaux sanguins rétiniens en termes de sensibilité, de spécificité et d'exactitude. Les résultats obtenus par notre approche proposée sont plus performants que les résultats obtenus dans la littérature puisque les taux obtenus ont atteint une sensibilité, une spécificité et une exactitude moyennes de 89%, 99% et 96%, respectivement.

Les résultats présentés indiquent que la méthode proposée est capable d'extraire avec une grande précision les gros vaisseaux sanguins rétiniens. Alors qu'elle a raté les vaisseaux très fins. Cela peut influencer sur le résultat de l'étape de classification.

Auteurs	Méthodes	Se (%)	Sp (%)	Acc (%)
S. Wilfred Franklin et al. [147]	ANN	65,5	85	95,03
Luiz Carlos Rodrigues et al. [65]	Seuillage d'hystérésis	-	-	94,65
<i>Méthode proposée</i>	<i>ISODATA et contour actif</i>	<i>89</i>	<i>99</i>	<i>96</i>

Tableau V.1 : Comparaison des performances des méthodes classiques de segmentation des vaisseaux rétiniens.

C'est pour cela, nous avons proposé une nouvelle technique de segmentation basée sur les algorithmes d'apprentissage profond.

2.2.2. Méthodes de deep learning pour l'extraction du réseau rétinien

La segmentation manuelle des petits et grands vaisseaux rétiniens par des experts est une tâche fastidieuse et nécessite beaucoup de temps. Néanmoins, une segmentation automatique est nécessaire, afin de minimiser le temps et d'aider au diagnostic de différentes pathologies rétiniennes. Pour toutes ces raisons, nous proposons six architectures de deep learning pour réaliser la segmentation sémantique du réseau vasculaire rétinien.

2.2.2.1. Augmentation des données

Pour entraîner et évaluer une architecture du deep learning, une grande base de données est recommandée. Dans notre travail, nous n'avons que 85 images rétiniennes en couleur (40 images de la base DRIVE et 45 de la base HRF) avec une bonne segmentation manuelle des vaisseaux rétiniens, ce qui peut entraîner un problème de sur-apprentissage.

Pour remédier à ce problème et rendre l'entraînement plus robuste, nous avons introduit une étape d'augmentation des données. Cette dernière est réalisée à l'aide de transformations géométriques appliquées sur les images des canaux verts telles que la division des images en petits blocs, des rotations, translations, zoom...etc. Les mêmes opérations sont appliquées aux images labélisées. Dans cette phase, nous avons appliqué deux stratégies pour augmenter l'ensemble d'apprentissage :

✓ Division d'image en petits blocs de taille 32x32, application des rotations et retournements selon l'axe horizontal et l'axe vertical. A l'aide de ces opérations, nous avons construit une base contenant 21760 blocs.

✓ Division des images en blocs de taille 64 * 64 pixels. Ensuite, chaque bloc est retourné le long des axes horizontaux et verticaux. En conséquence, nous avons obtenu 6800 blocs.

Ces patches sont utilisés dans la phase d'apprentissage. Pour la phase de test, nous avons évalué nos méthodes sur les images d'amélioration (canal vert sans augmentation des données).

La figure suivante indique quelques exemples de blocs de taille 64x64.

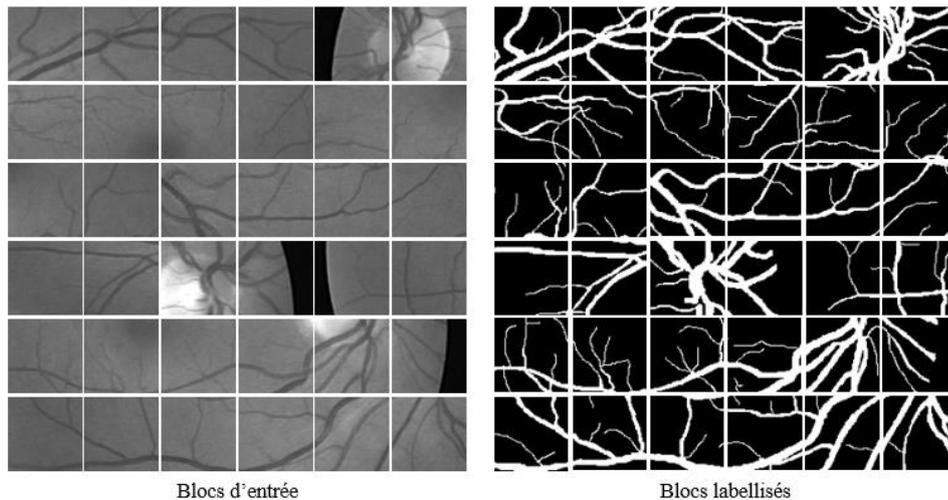


Figure V.5 : Exemples de blocs utilisés pour l'apprentissage.

L'avantage de ce travail est de former et de tester nos modèles implémentés uniquement sur le canal vert sans aucune étape de prétraitement supplémentaire.

2.2.2.2. Segmentation du réseau rétinien

La segmentation précise des petits vaisseaux est un challenge à cause de leur taille minime, faible contraste et intensité similaire au fond. Dans cette partie, nous avons implémenté différents modèles de deep learning pour une détection précise du réseau rétinien : SegNet, U-Net et CNN [148, 149].

Notre contribution dans cette partie consiste à modifier les architectures existantes d'un côté et à construire des réseaux de neurones convolutifs d'un autre côté.

A. SegNet originale

Comme première expérience, nous avons utilisé une architecture SegNet composée de trois étages dans l'encodeur, dont chacun contient deux couches de convolution et une couche de max pooling de taille 2x2. Chaque couche de convolution est suivie d'une couche de normalisation et de la fonction ReLU. Dans le premier étage, 64 filtres de convolution de taille

3x3 sont utilisés, 128 filtres sont utilisés dans le deuxième étage et 256 filtres dans le troisième étage. Une couche de Drop Out est insérée pour éviter le problème du sur-apprentissage.

La partie décodeur est symétrique du codeur et comporte le même nombre de convolutions et le même nombre d'étages. La dernière couche est la fonction Softmax qui est utilisée pour extraire l'image segmentée (figure V.6).

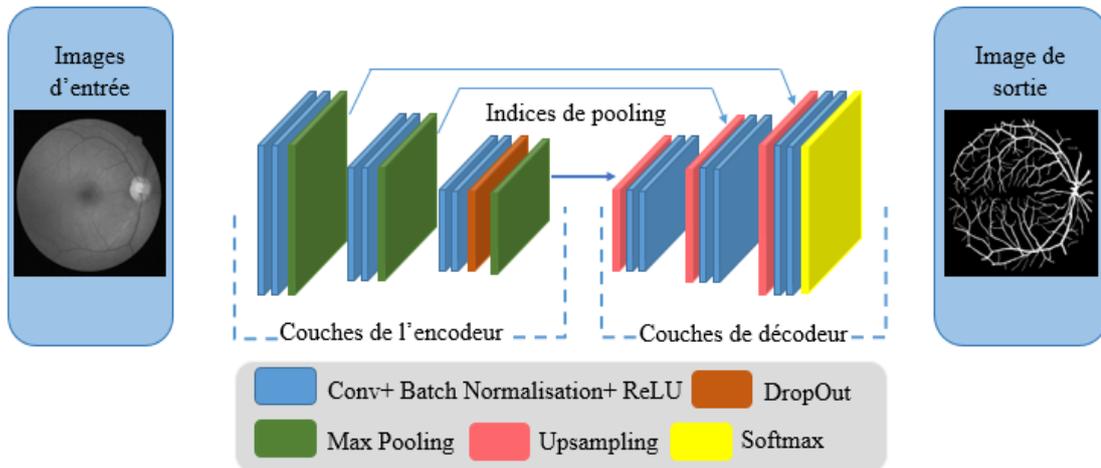


Figure V.6 : Architecture SegNet originale.

B. SegNet modifié

Le modèle SegNet modifié contient trois blocs d'encodage et trois blocs de décodage.

Chaque bloc d'encodage est composé de deux couches de convolution de taille 3x3 et une couche de max pooling. Le nombre de filtres est 64, 128 et 256. Chaque couche convolutive est suivie par BN et Leaky ReLU.

Les blocs de décodeurs sont symétriques aux encodeurs et utilisent les indices de max pooling et une couche de déconvolution pour sur-échantillonner les caractéristiques et produire le résultat final. Cette architecture est illustrée dans la figure V.7.

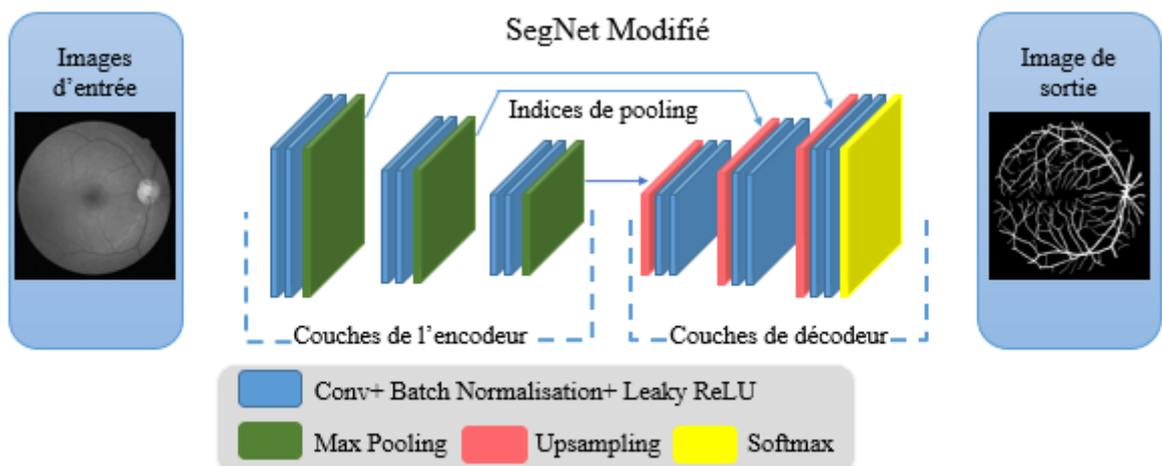


Figure V.7 : Architecture SegNet modifié proposée.

C. U-Net originale

L'architecture U-Net utilisée dans cette partie comprend deux parties principales :

La partie descendante est composée de trois étages, chaque étage étant constituée de deux couches de convolution avec des filtres de taille 3x3 et de nombres différents (64, 128 et 256 pour les trois étages, respectivement) et d'une couche de max pooling de taille 2x2. Chaque couche de convolution est suivie par la fonction ReLU afin d'extraire le maximum des caractéristiques. Ainsi, une couche Drop Out est insérée pour éviter le problème de sur-apprentissage.

La partie ascendante contient un nombre d'étages identique à celui du chemin de contraction, est constituée de couches convolutives transposées. Cette partie combine les informations obtenues par une séquence de convolutions ascendantes et de concaténations avec des caractéristiques à haute résolution provenant du chemin descendant. Le résultat de l'ensemble de ce processus est une image étiquetée présentant la segmentation sémantique du réseau rétinien.

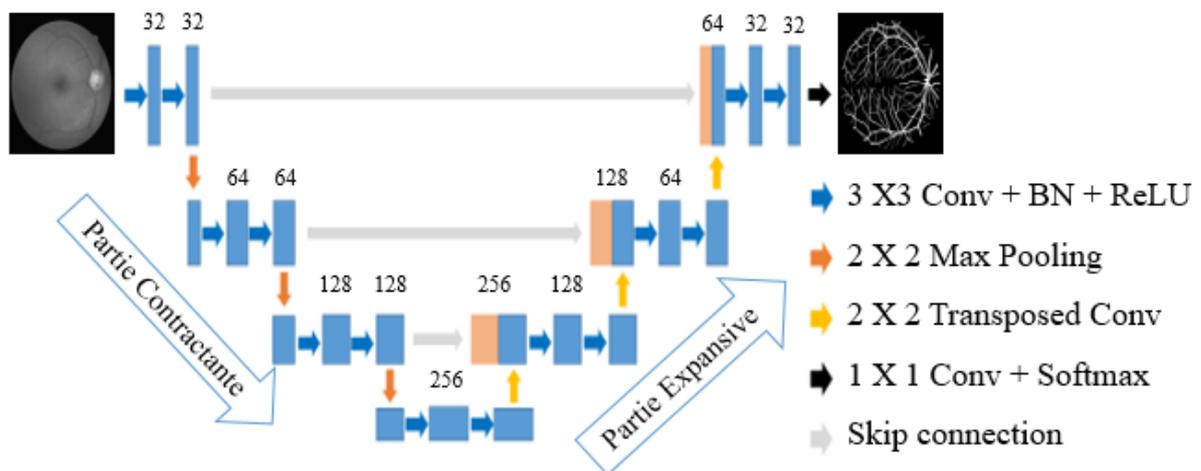


Figure V.8 : Architecture U-Net originale.

D. U-Net modifié

Afin d'extraire le réseau rétinien nous avons utilisé la même architecture U-Net modifiée décrite dans le chapitre 4.

Rappelons que ce réseau se diffère du modèle original dans la fonction d'activation et le pooling. Dans notre architecture U-Net, nous avons ajouté la couche de normalisation par lots (BN) après chaque couche de convolution. Nous avons également remplacé la fonction d'activation (ReLU) par la fonction Leaky ReLU et la couche de max pooling par la couche de average pooling pour les parties encodage et décodage.

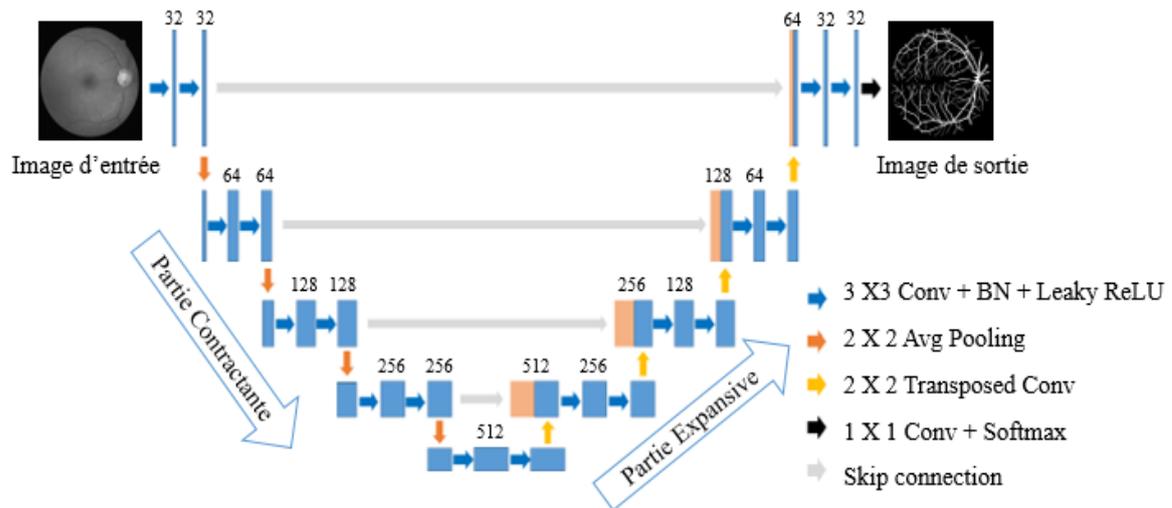


Figure V.9 : Notre réseau U-Net modifié proposé pour la segmentation des vaisseaux sanguins.

E. CNN 1

Dans cette partie, nous avons construit notre propre modèle qui est un simple CNN composé de 5 couches convolutives avec des filtres de taille de 3x3, chacune étant suivie d'une couche de normalisation, de la fonction ReLU et d'une couche de Maxpooling de 2x2. Le nombre des filtres de convolution utilisés est 8, 16, 32, 64 et 128 de la première vers la dernière couche CONV, respectivement. Une couche de dropout est ensuite insérée. Enfin, une couche de déconvolution avec deux filtres de taille 12x12 suivie la fonction Soft max sont appliquées pour produire l'image segmentée. Le CNN proposé est décrit et résumé à la figure V.10.

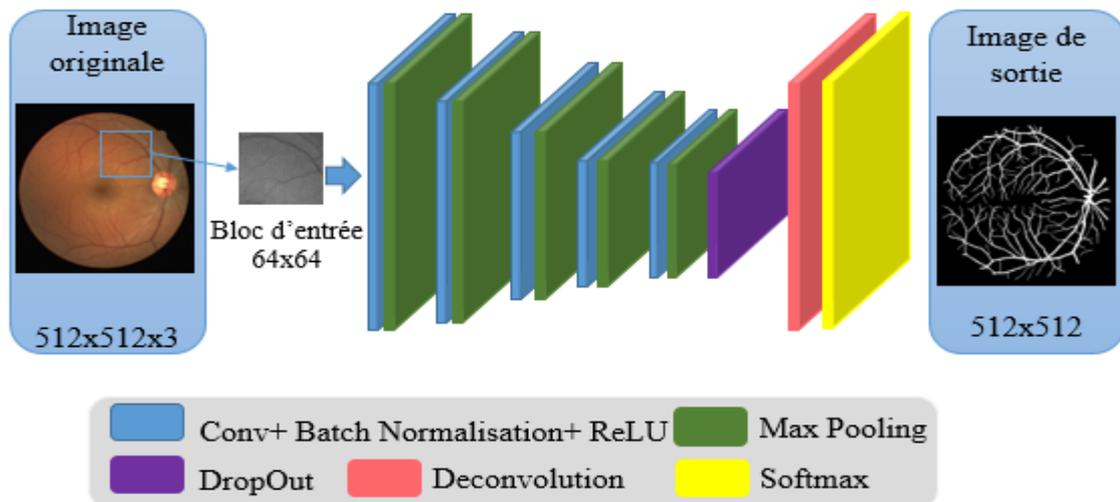


Figure.V.10 : l'architecture de notre CNN1 construit.

F. CNN 2

Pour segmenter les vaisseaux sanguins, nous avons construit un autre CNN plus profond, qui est composé d'un ensemble de couches convolutionnelles, normalisation par lots, fonction

d'activation Leaky ReLU, average pooling et une couche de convolution transposée (déconvolution) comme le montre la figure V.11.

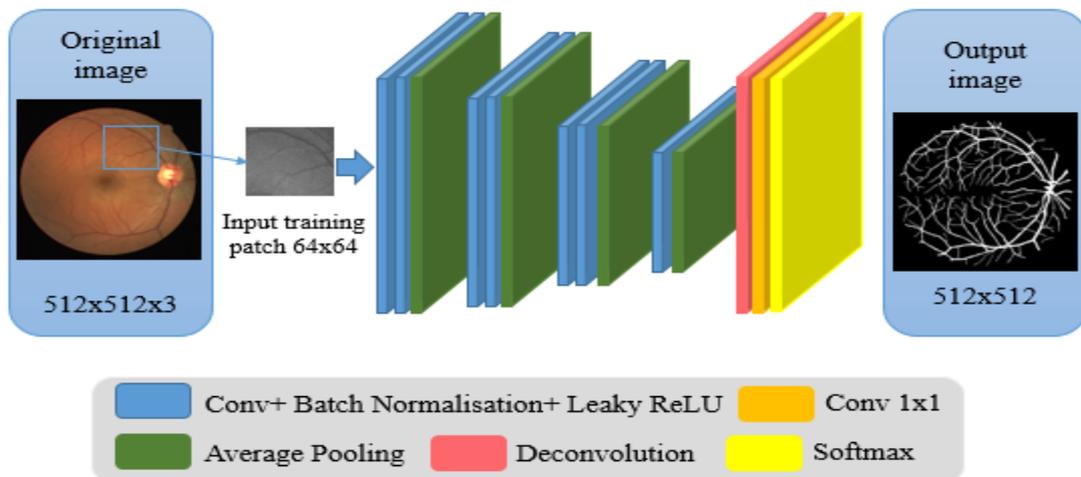


Figure V.11 : Le deuxième CNN profond proposé pour la segmentation des vaisseaux rétiniens.

Le CNN proposé est un réseau de codage-décodage développé pour la segmentation sémantique des images. Le réseau d'encodeurs est généré pour produire un ensemble de cartes de caractéristiques, composé de quatre blocs. Les trois premiers blocs (bleu, vert et jaune) sont composés de deux couches de convolution 3x3, chacune suivie d'une couche de normalisation par lots et d'une fonction Leaky ReLU. Un average pooling de taille 2x2 est appliqué pour réduire la taille de l'image à la moitié. Alors que le dernier bloc (rose) est composé d'une couche de convolution 3x3, suivie d'une normalisation par lots, Leaky ReLU et 2x2 average pooling.

Le réseau de décodeurs (violet) comprend une convolution transposée pour échantillonner les cartes de caractéristiques, suivie d'une couche de convolution 1x1. Enfin, les fonctions de perte de Softmax et d'entropie croisée sont utilisées pour classer chaque pixel en vaisseaux (en blanc) ou en arrière-plans (en noir). La figure V.12 illustre une description complète de notre modèle CNN pour la segmentation sémantique des arbres vasculaires.

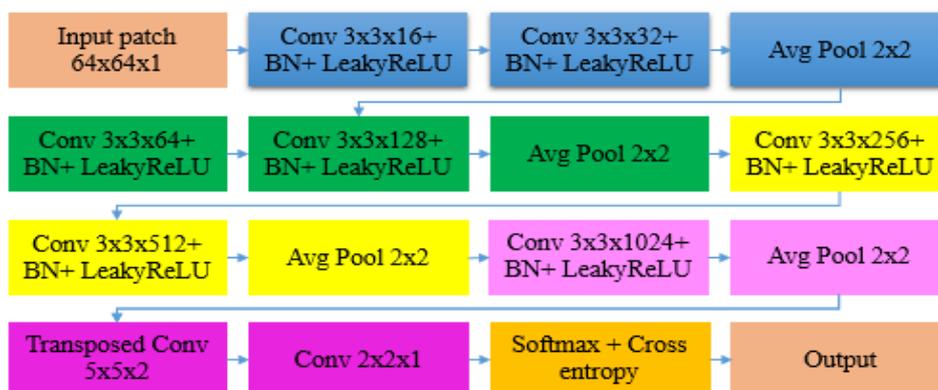


Figure V.12 : Description détaillée de notre deuxième CNN.

2.2.2.3. Résultats et discussion

Pour évaluer quantitativement les performances de nos méthodes de segmentation des vaisseaux sanguins et de classification de la rétinopathie diabétique, six paramètres ont été calculés : le coefficient de dice, l'indice de jaccard (IoU), l'exactitude (Acc), la sensibilité (Se), la spécificité (SP) et l'aire sous courbe (AUC).

Pour implémenter les algorithmes proposés pour l'extraction de l'arbre vasculaire et la reconnaissance DR à partir d'images de fond d'œil, nous avons utilisé le même matériel mentionné dans le chapitre 4. En plus, afin de former nos modèles proposés, optimiser les poids du réseau et minimiser la quantité de mémoire GPU requise, l'optimiseur Adam est utilisé avec un taux d'apprentissage initial égal à 10^{-4} et 100 époques. Tous ces paramètres sont fixés expérimentalement après plusieurs expériences. Les valeurs de paramètre sélectionnées fournissent simultanément la plus grande précision et la plus faible perte.

Ces architectures sont testées sur trois bases de données accessibles au public : DRIVE qui contient 40 images, HRF se compose de 45 images et Messidor englobe 1200 images. Les images ont été acquises avec différents appareils et varient donc en intensité et en contraste. Dans ce travail, nous avons formé notre modèle pour l'extraction d'arbres vasculaires sur un ensemble de données de mélange qui comprenait des blocs extraits à partir des images des bases DRIVE et HRF, et nous l'avons testé sur les images originales de chaque base de données séparément.

Les figures V.13 et V.14 ci-dessous montrent les performances des différents modèles en utilisant les deux bases d'apprentissage et en testant les bases DRIVE et HRF, respectivement.

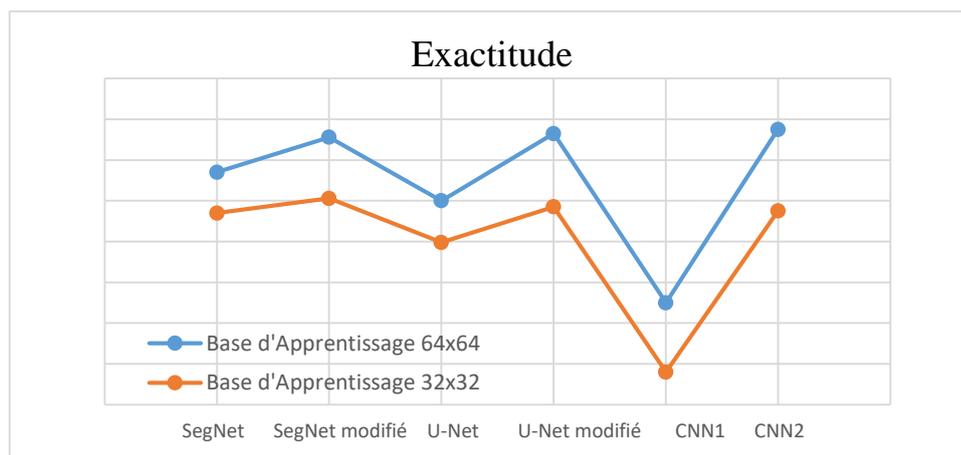


Figure V.13 : Comparaison entre les résultats d'utilisation des deux bases d'apprentissage en testant la base **DRIVE**.

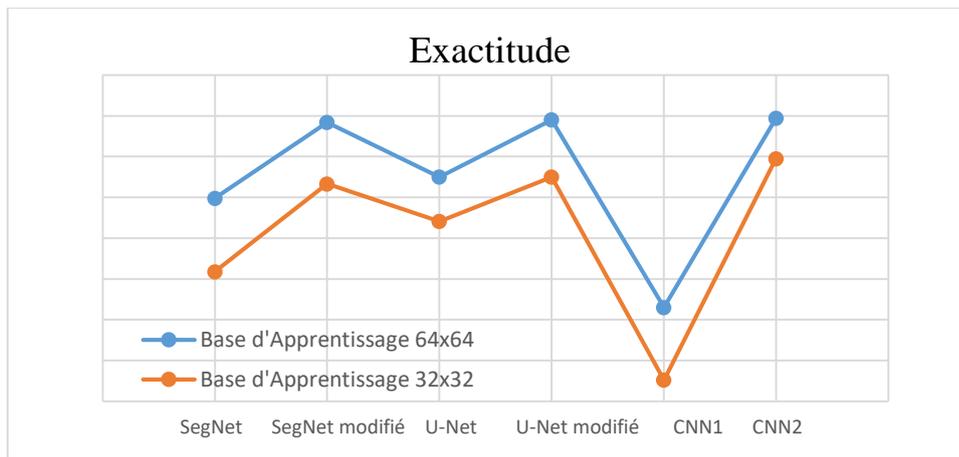


Figure V.14 : Comparaison entre les résultats d'utilisation des deux bases d'apprentissage en testant la base **HRF**.

En comparant entre ces tracés, nous remarquons que les résultats d'utilisation de la base d'apprentissage avec des blocs de taille 64x64 (tracé bleu) sont meilleurs par rapport à des blocs de taille 32x32 (tracé orange). Par conséquent, la formation d'un modèle à l'aide de petits blocs réduit l'efficacité de détection des vaisseaux minces en raison de leur petit diamètre et d'une intensité similaire à l'arrière-plan. Mais les résultats sont encore assez bons.

Ainsi, tous les résultats qualitatifs et quantitatifs mentionnés dans ce qui suit se rapportent aux performances de nos modèles en les entraînant sur la base d'apprentissage 64x64.

Les figures V.15 et V.16 présentent quelques exemples de résultats de segmentation sémantique des vaisseaux rétiens provenant des ensembles de données DRIVE et HRF, respectivement. A partir de ces figures, nous pouvons observer qualitativement que les résultats de segmentation binaire produits par nos modèles proposés sont très encourageants.

En plus, en comparant visuellement entre les résultats, il est clair que les résultats du CNN2 sont très similaires aux images labélisées et meilleurs que les autres modèles. Donc, notre modèle CNN2 proposé a pu extraire avec une grande précision les vaisseaux épais et minces avec moins d'erreurs de segmentation.

En revanche, le modèle CNN1 est le moins fiable car il a raté les petits vaisseaux. Ces résultats médiocres sont dus à sa simplicité et l'insuffisance de nombres de couches de convolutions qui extraient les informations les plus pertinentes selon la profondeur du modèle.

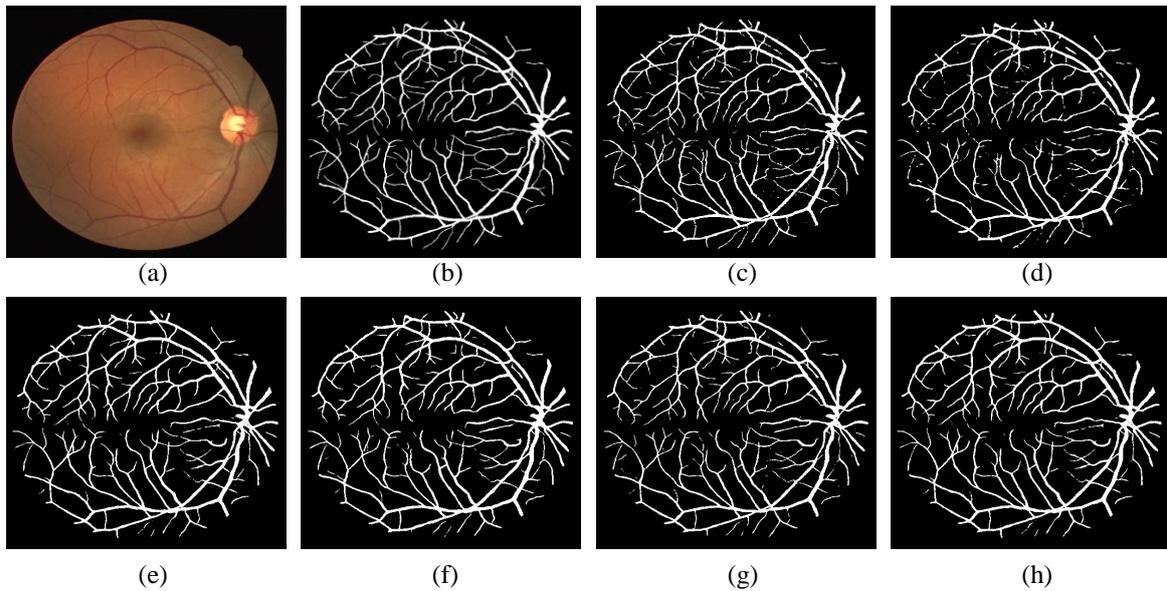


Figure V.15 : Exemple de résultats des vaisseaux sanguins de l'ensemble de données **DRIVE**. (a) Image d'entrée ; (b) Images labélisées ; (c) Notre CNN2 ; (d) U-Net modifié ; (e) SegNet modifié ; (f) SegNet ; (g) U-Net ; (h) CNN1.

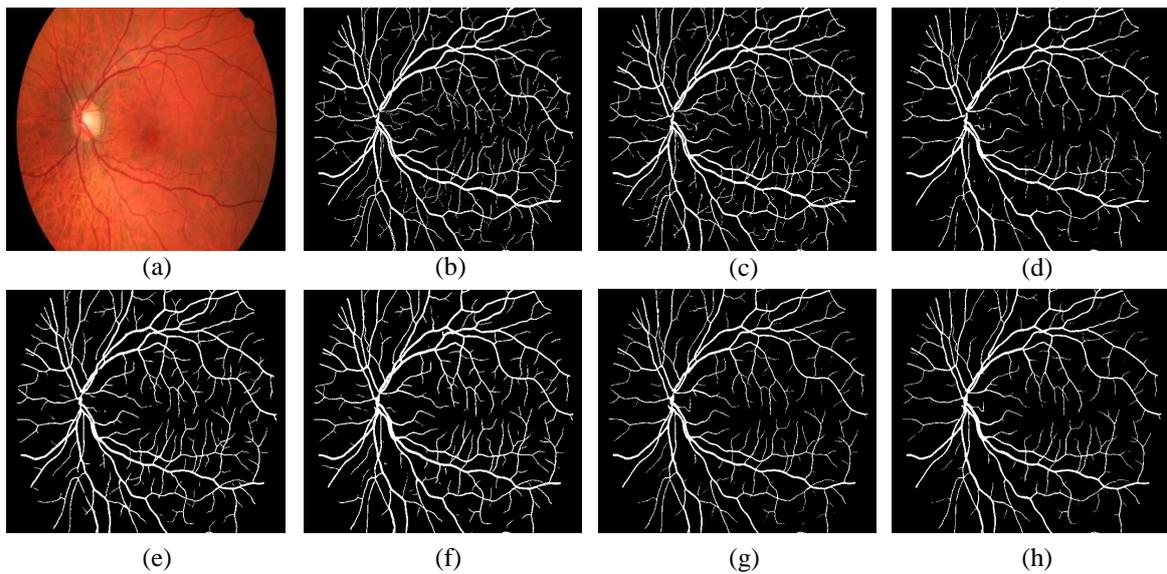


Figure V.16 : Exemple de résultats des vaisseaux sanguins de l'ensemble de données **HRF**. (a) Image d'entrée ; (b) Images labélisées ; (c) Notre CNN2 ; (d) U-Net modifié ; (e) SegNet modifié ; (f) SegNet ; (g) U-Net ; (h) CNN1.

Le tableau V.2 illustre les résultats de nos modèles proposés : SegNet, SegNet modifié, U-Net, U-Net modifié, CNN1 et CNN2 pour l'extraction du réseau rétinien sur les bases DRIVE et HRF, respectivement en utilisant la base d'apprentissage 64x64. Les valeurs en gras représentent les meilleurs résultats obtenus. D'après ce tableau, nous constatons que les résultats obtenus sont satisfaisants. Ainsi, les modèles SegNet modifié et U-Net modifié sont plus performants que U-Net et SegNet originaux.

Bases de données	Méthodes	Acc (%)	IoU (%)	Dice (%)	Se (%)	Sp (%)	AUC (%)
DRIVE	SegNet	97.70	92.60	95.65	96.74	99.64	98.01
	SegNet modifiée	99.56	93.75	96.87	97.46	99.69	98.32
	U-Net	96.98	92.02	94.88	95.88	99.59	97.54
	U-Net modifiée	99.65	94.02	96.35	96.74	99.83	98.17
	CNN1	93.80	89.72	92.22	93.80	99.10	96.02
	CNN2	99.75	95.60	97.74	98.08	99.84	98.88
HRF	SegNet	97.98	93.95	96.87	97.98	99.50	98.49
	SegNet modifiée	99.84	95.16	98.34	98.57	99.86	98.69
	U-Net	97.41	93.49	96.32	97.38	99.45	98.14
	U-Net modifiée	99.90	97.45	98.68	98.47	99.89	99.01
	CNN1	93.52	89.52	93.18	94.23	98.97	96.11
	CNN2	99.94	98.09	99.09	98.85	99.95	99.37

Tableau V.2 : Performance d'extraction du réseau vasculaire rétinien sur les différentes bases de données.

De plus, quantitativement, l'architecture CNN2 a donné les meilleurs résultats en terme de Acc, Se, Sp, IoU, dice et AUC sur les deux bases de données. Ce modèle est donc sélectionné pour comparer avec les travaux existants dans la littérature.

Le tableau V.3 présente les résultats obtenus à partir de notre modèle par rapport à d'autres réseaux d'apprentissage en profondeur récemment proposés pour la segmentation sémantique de l'arbre vasculaire sur l'ensemble de données DRIVE en utilisant différentes mesures. Ces résultats indiquent que l'architecture proposée obtient une performance plus élevée par rapport aux techniques existantes avec un dice de 97,74% et un IoU de 95,60%.

Auteurs	Méthodes	Acc(%)	IoU(%)	Dice(%)	Se(%)	Sp(%)	AUC(%)
Jin et al. [68]	DUNet	95.66	95.66	82.37	79.63	98	98.02
Samuel and Veeramalai [69]	DNN	96.09	--	--	82.82	97.38	97.86
Jiang et al. [70]	M3FCN	97.06	--	83.21	83.25	98.38	98.80
Ma et al. [72]	WA-Net	95.66	--	82.22	78.75	98.13	97.94
Sathamantavathi and Indumathi [75]	EEA U-Net	95.77	--	97.70	79.18	97.08	--
Li and Rahadja [78]	BSEResu-Net	95.74	--	83.24	83.24	97.57	98.20
Boudegga et al. [77]	RV-Net	98.19	--	86.5	84.48	99	--
Abdelmaksoud et al. [88]	U-Net	96.58	--	78.84	72.58	98.89	97.84
Méthode proposée	CNN2	99.75	95.60	97.74	98.08	99.84	98.88

Tableau V.3 : Résultats de la segmentation des vaisseaux sanguins dans la base de données DRIVE par rapport aux méthodes existantes dans la littérature.

Le tableau V.4 présente les résultats que nous avons obtenus par rapport aux travaux connexes de segmentation sémantique des vaisseaux sanguins pour l'ensemble de données HRF. Les résultats présentés montrent que, pour toutes les mesures, notre approche surpasse les autres méthodes précédentes et obtient un dice et IoU de 99,09 % et 98,09, respectivement.

Auteurs	Méthodes	Acc(%)	IoU(%)	Dice(%)	Se(%)	Sp(%)	AUC(%)
Jin et al. [68]	DUNet	96.51	--	--	74.64	98.74	98.31
Samuel and Veeramalai [69]	DNN	85.31	--	--	86.55	85.23	94.50
Ozgunalp et al. [71]	SegNet	93.23	--	--	73.72	94.85	--
Sathamantavathi and Indumathi [75]	EEA U-Net	92.44	--	70.80	65.89	97.99	--
Li and Rahadja [78]	BSEResu-Net	96.37	--	82.37	80.67	97.96	98.37
Abdelmaksoud et al. [88]	U-Net	95.6	--	76.2	70.14	98.25	95.30
<i>Méthode proposée</i>	<i>CNN2</i>	<i>99.94</i>	<i>98.09</i>	<i>99.09</i>	<i>98.85</i>	<i>99.95</i>	<i>99.37</i>

Tableau V.4 : Résultats de la segmentation des vaisseaux sanguins dans la base de données HRF comparativement aux méthodes existantes dans la littérature.

En comparant avec les résultats obtenus de la segmentation sémantique des vaisseaux sanguins avec les travaux de la littérature, les résultats de l'ensemble de données DRIVE (tableau V.3) suggèrent que l'architecture proposée surpasse les techniques existantes en termes de dice, d'Acc, de Se, de SP et d'AUC. Les résultats indiqués sur l'ensemble de données HRF (tableau V.4) prouvent que notre méthode a donné une plus grande précision dans la séparation des vaisseaux sanguins de l'arrière-plan.

En outre, à partir de ces tableaux, nous observons que les résultats obtenus sur la base de données HRF qui se compose d'images à haute résolution sont plus élevés que ceux obtenus sur la base de données DRIVE qui contient des images de qualité inférieure. Nous pouvons remarquer que notre méthode est plus sensible et plus efficace pour détecter les vaisseaux à partir d'images de haute qualité que d'images de basse qualité. En conséquence, pour améliorer les résultats DRIVE, une étape de prétraitement peut être utilisée. Donc la qualité de l'image a un impact majeur sur les résultats.

Puisque les résultats de notre modèle développé CNN2 sont très satisfaisants, cela peut nous permettre de les utiliser comme entrée dans l'étape d'extraction de caractéristiques.

2.3. Extraction de caractéristiques

La rétinopathie diabétique provoque une malformation du réseau vasculaire rétinien en modifiant sa forme (dilatation, obstruction, tortuosité, etc.). Cette région est donc un facteur important pour reconnaître et identifier cette pathologie. Le diagnostic précoce de la RD à partir de la structure des vaisseaux rétiniens est un défi critique pour prévenir la cécité.

En outre, un ensemble de caractéristiques morphologiques peuvent être calculées à partir des images segmentées en appliquant la morphologie mathématique et les méthodes de détection des contours. Dans cette partie, nous avons extrait six caractéristiques, qui sont comme suit :

- ✓ ***La surface*** : Au stade précoce de la RD, une occlusion et une dilatation microvasculaires se produisent, ce qui peut mener à la prolifération de formes définies par la croissance de néovaisseaux. Il est à noter que la taille de l'arbre vasculaire contribue à l'émergence des néovaisseaux.
- ✓ ***Le périmètre*** : Pour obtenir la valeur de périmètre, le détecteur de canny est appliqué pour extraire les contours du vaisseau.
- ✓ ***Le diamètre*** : Les changements de diamètre des vaisseaux réiniens sont considérés comme des indicateurs déterminants des anomalies des vaisseaux sanguins. Le diamètre est calculé en utilisant la distance euclidienne entre deux points a et b, en utilisant les équations suivantes (eq. V.1 et V.2) :

$$Distance = \sqrt{|X_a - X_b|^2 + |Y_a - Y_b|^2} \quad (V.1)$$

$$Diamètre = 2 * Distance \quad (V.2)$$

- ✓ ***Les points de bifurcation*** : L'élévation des nombres de points de bifurcation illustre la présence de néovaisseaux. Ces points sont extraits et comptés à partir de l'image du vaisseau par l'application de la transformation « hit-or-miss ». Dans une image squelette, un point de bifurcation est un pixel connecté à trois autres pixels ou plus.
- ✓ ***Le nombre de segments*** : Pour séparer les vaisseaux sanguins en segments, les points de bifurcation sont retirés de l'image segmentée en utilisant l'opération XOR. Ensuite, nous avons calculé le nombre de segments obtenus.
- ✓ ***La tortuosité*** : Elle est définie comme l'un des principaux symptômes d'anomalies dans les vaisseaux sanguins et la caractéristique la plus importante qui apparaît dans les anomalies réiniennes (les vaisseaux pathologiques sont plus tortueux que les vaisseaux sains). La tortuosité (T) d'un segment est donnée par le rapport entre sa longueur (L) et la distance (D) entre ses extrémités comme montre l'équation suivante (eq. V.3) :

$$T = L/D \quad (V.3)$$

Dans ce travail, la distance euclidienne est utilisée pour calculer la distance entre les extrémités d'un segment.

98,94 % et 95,22 %, respectivement et elles sont supérieures à 97,48 %, 96,22 %, 98,83 % et 96,96 %, respectivement, pour la base de données de **Messidor**.

Nous remarquons que les résultats obtenus sont satisfaisants. Ainsi, en testant nos classifieurs sur de petites bases données (HRF), les performances de SVM et PLDA sont supérieures aux autres classifieurs pour les quatre métriques. Tandis que l'utilisation de la base de données Messidor (grand nombre d'images), les algorithmes SVM et KNN surpassent les classifieurs CART, PLDA et ANN.

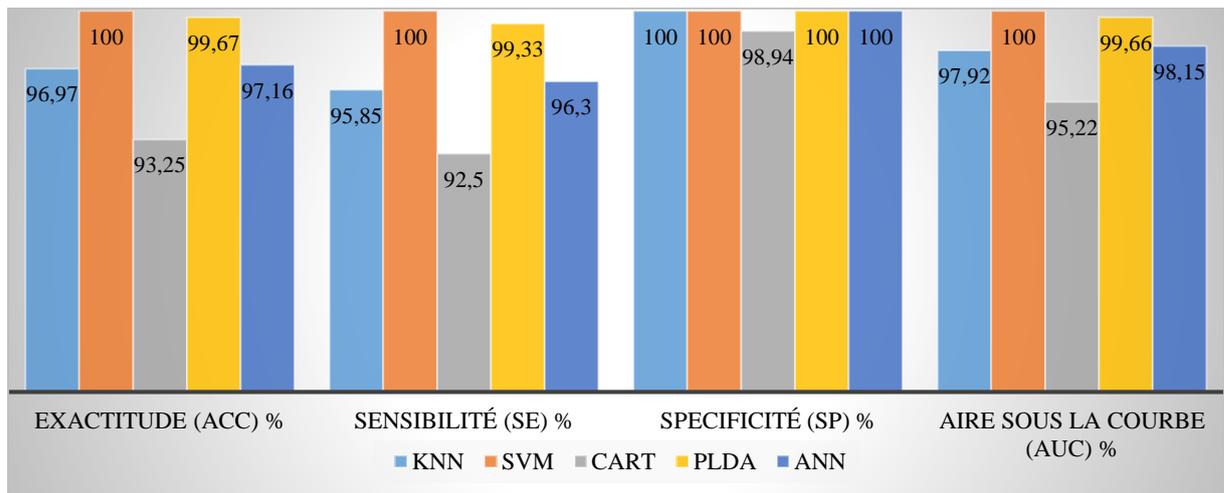


Figure V.17 : Résultats de performance en utilisant différents classifieurs pour la base de données HRF.

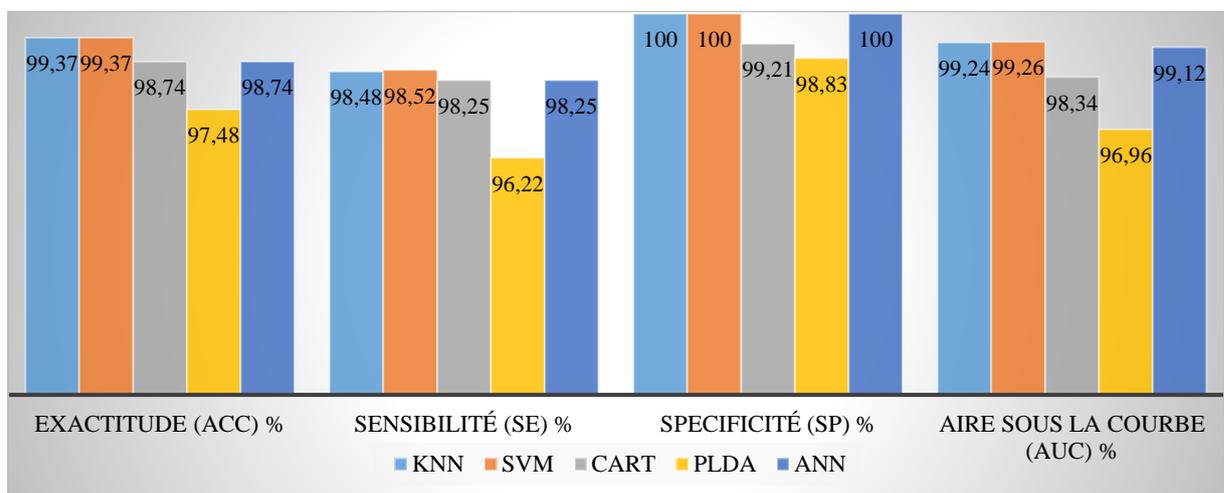


Figure V.18 : Résultats de performance en utilisant différents classifieurs pour la base de données Messidor.

De plus, en comparant les résultats des cinq classifieurs, nous constatons que sur l'ensemble de données HRF (figure V.17), les meilleurs résultats sont obtenus en utilisant le classifieur SVM avec un Acc, Se, Sp et AUC de 100 %. Alors que les faibles résultats sont obtenus avec

le classifieur CART avec un Acc, SE, Sp, et AUC de 93.25%, 92.5%, 98.94%, et 95,22%, respectivement, en raison d'un nombre insuffisant d'échantillons d'entraînement.

Sur l'ensemble de données Messidor (figure V.18), le classifieur SVM produit les meilleurs résultats avec un Acc, Se, Sp, et AUC de 99,37%, 98,52%, 100%, et 99,26%, respectivement. Le classifieur PLDA donne les moins bons résultats avec des Acc, Se, Sp et AUC de 97,48 %, 96,22 %, 98,83 % et 96,96 %, respectivement, parce qu'il est utilisé pour classer de petits ensembles de données.

Donc, cela prouve que PLDA est dédié à la classification de petites bases d'images alors que SVM s'adapte automatiquement avec la quantité de données ce qui nous permet de conclure que le SVM est le classifieur le plus performant dans notre système.

En plus, le classifieur SVM sur l'ensemble de données HRF donne les meilleurs résultats que l'ensemble de données Messidor en terme d'exactitude, sensibilité et AUC. HRF ne contient que 30 images haute résolution. Il atteint une Acc de 100% parce que les vaisseaux rétinien et les caractéristiques sont bien extraits. Cependant, le second jeu de données Messidor englobe 1200 images de bonne et de mauvaise qualité. En outre, il se compose des images saines et des images avec les trois grades de la RDNP (minime, modéré et sévère). Cette base a obtenu une Acc de 99,37%. Dans ce cas, le stade minime associé à l'apparence des MAs peut être confondu avec le cas sain, ce qui diminue l'exactitude de la classification. Nous remarquons aussi que la précision du système est légèrement réduite en augmentant le nombre d'images et en ajoutant les grades de la RD.

Comme le SVM proposé est le plus performant pour la classification binaire de la RD, il est choisi pour la comparaison avec les autres techniques de l'état de l'art. Les tableaux V.5 et V.6 comparent les résultats obtenus par SVM avec ceux des travaux connexes pour les ensembles de données HRF et Messidor, respectivement.

Auteurs	Méthodes	Acc(%)	Se(%)	Sp(%)	AUC(%)
Nair and Muthuvel [81]	MCS-NS	91.66	100	83.33	--
Sultana and Rajasekhar [82]	SVM	86.36	--	--	--
Abdelmaksoud et al. [88]	SVM	96.66	100	93.3	99
Méthode proposée	SVM	100	100	100	100

Tableau V.5 : Résultats de la classification des RD dans la base de données du HRF comparativement aux méthodes existantes dans la littérature.

Auteurs	Méthodes	Acc(%)	Se(%)	Sp(%)	AUC(%)
Hajabdollahi et al. [91]	VGG-16 modifié	92	83.70	98.33	96.11
Gayathri et al. [84]	Random forest	99.7	99.9	99.9	--
Baget-Bernaldiz et al. [93]	DLA	94.79	97.32	94.57	0.959
Wang et al. [87]	Multichannel-Based SSGAN	96.6	97	96.8	98.3
Abdelmaksoud et al. [88]	SVM	75	86	50	72
Notre méthode classique [146]	CART	93	91	100	--
Méthode proposée	SVM	99.37	98.52	100	99.26

Tableau V.6 : Résultats de la classification des RD dans la base de données de Messidor comparativement aux méthodes existantes dans la littérature.

Sur l'ensemble de données HRF, SVM a bien dépassé les méthodes existantes. Par ailleurs, pour l'ensemble de données Messidor, le SVM surpasse les autres approches disponibles dans la littérature en termes de Sp et AUC et donne des résultats comparables en terme de Acc et Se. Par conséquent, les résultats obtenus sont satisfaisants et le classifieur sélectionné avait correctement classé la plupart des images des deux bases de données.

L'extraction automatique et rapide des vaisseaux réiniens et la détection de la RD sont essentielles pour aider les spécialistes à diagnostiquer rapidement et précisément les patients. Les réseaux d'apprentissage profond prennent du temps. Il est donc difficile de créer un modèle optimisé à la fois rapide et précis. Pour évaluer et prouver la rapidité de notre système proposé, nous avons calculé les temps d'exécution de chaque étape du prétraitement à la classification. L'analyse du temps de traitement est une mesure importante dans l'élaboration d'un système médical.

Ce paramètre varie en fonction de la complexité du système, des performances de la machine (en particulier du GPU) et de la taille de l'image. Plus la complexité est grande, plus l'image est longue. Dans notre cas, pour segmenter le système vasculaire réinien d'une image de 512x512 pixels, notre CNN a pris 0,5 s. L'étape d'extraction des fonctions a nécessité environ 4 secondes pour calculer les fonctions d'une image. L'étape de classification a nécessité 0,5 s pour classer une image. Par conséquent, notre système a besoin globalement de 6 s maximum pour classer une image.

En résumé, le système de détection de la RD proposé dans cette thèse est fiable et rapide produisant des résultats précis pour les deux parties : segmentation et classification.

3. Conclusion

Le développement de systèmes automatiques devient une nécessité pour détecter plusieurs maladies oculaires y compris la RD afin d'aider les ophtalmologistes à établir un diagnostic précoce et précis pour prévenir la cécité.

Dans cette étude, nous avons mis en œuvre un système de détection automatique de la RD à partir d'images rétinienne couleur. Il est basé sur la segmentation des vaisseaux sanguins en utilisant les techniques de traitement d'images classiques et les nouvelles méthodes de deep learning. Ensuite, six caractéristiques géométriques sont extraites à partir des images segmentées. Enfin, pour la classification binaire de la RD, cinq classifieurs supervisés : SVM, KNN, CART, PLDA et ANN sont appliqués. Les techniques proposées sont évaluées sur trois bases de données publiques : DRIVE, HRF, CHASE_DB1 et Messidor.

Les petits réseaux vasculaires sont difficiles à détecter. C'est pour cela que nous avons implémenté de nombreux algorithmes. Les résultats sont comparés qualitativement avec la segmentation manuelle de l'arbre vasculaire réalisée par des experts en ophtalmologie et quantitativement en utilisant plusieurs métriques : La sensibilité, la spécificité, l'exactitude, l'AUC, le coefficient de Dice et l'indice de Jaccard.

En comparant entre les résultats de nos méthodes implémentées, nous avons observé que les modèles de deep learning ont considérablement amélioré la segmentation des gros et petits vaisseaux par rapport aux méthodes classiques. Parmi ces modèles, notre réseau construit CNN2 a donné les meilleurs résultats surpassant les autres travaux.

Pour la classification de RD, le classifieur SVM a atteint les meilleures performances pour toutes les bases de données testées. Ce qui signifie qu'il a pu distinguer précisément entre les cas sains et les cas pathologiques.

Les résultats expérimentaux obtenus prouvent que notre système est plus performant que les méthodes existantes pour les étapes de segmentation et de classification. Enfin, la combinaison de l'apprentissage profond et des algorithmes d'apprentissage automatique rend notre approche efficace pour le dépistage automatique de la RD, ce qui peut aider les spécialistes dans leur pratique clinique.

En conclusion, le système proposé utilisant le modèle d'apprentissage profond pour la segmentation du système vasculaire rétinien et les algorithmes d'apprentissage automatique pour l'étape de classification est plus efficace pour la détection et le dépistage automatiques de la rétinopathie diabétique.

Conclusion générale

L'œil est l'organe complexe et fragile. Il est sujet de différentes maladies, dans notre recherche nous nous concentrons sur le glaucome et la rétinopathie diabétique qui sont parmi les premières causes de cécité à travers le monde. Le glaucome est caractérisé par l'altération progressive de la papille optique, généralement associées à une augmentation de la POI. En parallèle, la RD est une complication du diabète qui affecte les petits vaisseaux sanguins de la rétine, entraînant une détérioration de la vision. Bien que ces conditions diffèrent dans leurs causes et leurs types, elles partagent un besoin commun de dépistage précoce et d'une prise en charge adéquate pour prévenir la perte de vision irréversible. Par conséquent, les recherches récentes visent à mieux détecter et identifier ces pathologies dans un stade précoce en développant des systèmes automatiques basés sur l'utilisation des algorithmes informatisés pour l'analyse des images rétinienne.

Au cours de cette thèse, afin de mieux comprendre les causes et les conséquences du glaucome et de la RD, nous avons tout d'abord décrit l'anatomie de l'œil avec ses différentes structures en se basant sur les régions affectées par ces deux maladies. Nous avons mis en évidence les types, les stades de chaque pathologie ainsi que les examens cliniques employés pour l'exploration et le suivi d'évolution du glaucome et de la RD. Nous avons aussi cité les travaux récemment publiés à propos de ces sujets, les bases de données publiques disponibles et notre base d'images collectée localement. Dans la partie qui suit, les algorithmes de traitement d'images, d'apprentissage automatique et d'apprentissage profond utilisés dans notre travail sont mis en place. A ce niveau, nous avons présenté le principe fondamental des réseaux de neurones convolutifs avec ses différentes couches ainsi que les architectures les plus populaires pour la segmentation et la classification des images. Dans les deux derniers chapitres, les expérimentations réalisées pour la segmentation et la classification ainsi que les résultats obtenus en utilisant plusieurs bases de données sont présentés. Nous avons également effectué une comparaison entre les méthodes de traitement d'images classique et les algorithmes de deep learning.

Dans cette recherche nous avons proposé deux systèmes différents pour l'aide au diagnostic en ophtalmologie dont chacun traite et analyse une maladie. Ces systèmes utilisent les modèles d'apprentissage profond pour la segmentation sémantique des régions pertinentes à partir des images du fond d'œil et l'apprentissage automatique supervisé pour la classification des

maladies. Nous avons aussi effectué une étude comparative entre les différentes techniques de segmentation et de classification pour construire des systèmes fiables et précis. Pour évaluer quantitativement les performances des méthodes proposées, plusieurs paramètres sont calculés tels que l'exactitude, l'indice de jaccard, le coefficient de dice, la sensibilité et la spécificité. Ces derniers sont mesurés en testant différentes bases de données et en comparant entre les résultats prédites et l'annotation des experts. Ainsi pour relier les deux systèmes du glaucome et de la RD, nous avons appliqué les mêmes algorithmes de classification (SVM, KNN, CART, PLDA et ANN) sur les caractéristiques correspondantes à chaque maladie.

Pour la détection automatique du glaucome en utilisant des photographies de la tête du nerf optique, après l'implémentation et la comparaison entre les résultats des divers outils en utilisant les bases d'images RIM-ONE, DRISHTI-GS, ORIGA et notre base de données collectée localement, nous avons constaté que les meilleurs résultats de la segmentation du disque optique et cup optique sont obtenus en utilisant l'architecture SegNet modifiée avec le modèle pré-entraîné VGG19 pour l'initialisation des couches et des poids. En outre, le classifieur ANN a surpassé les autres méthodes et a pu distinguer entre un cas normal et un cas glaucomateux avec une exactitude dépassant les 99 %. Cette classification est accomplie en se basant sur trois paramètres clés employés cliniquement par les spécialistes qui sont : le RCD, le RRD et la règle ISNT. Ces paramètres sont calculés à partir des images segmentées.

Pour le diagnostic automatique de la RD à partir des images rétiniennes couleurs prises des bases DRIVE, HRF et Messidor et après le développement et le test des différentes méthodes, nous avons constaté que les meilleurs résultats de la segmentation de l'arbre vasculaire rétinienne sont obtenus en utilisant notre architecture construite CNN2. Cette architecture a réussi à extraire avec une grande précision les gros et les petits vaisseaux qui sont difficiles à détecter en raison de leur taille minime et leur faible intensité. En revanche, pour toutes les bases d'images le classifieur SVM a pu différencier entre un cas normal et un cas atteint de la RD avec une grande précision en se basant sur les caractéristiques géométriques calculées à partir des vaisseaux sanguins segmentés.

Ainsi, les résultats obtenus sont très satisfaisants et mêmes dans certains cas ils dépassent les résultats des travaux existants dans la littérature. Donc les systèmes proposés peuvent aider et associer les spécialistes en ophtalmologie dans leurs pratiques cliniques pour détecter le pathologies en un temps minime. Dans l'ensembles les résultats obtenus ont répondu aux questions posées au début de cette thèse et nous avons pu développer des approches robustes qui ont contribué dans l'analyse des images rétiniennes et la détection des pathologies oculaires. De plus, elles ont donné de résultats promoteurs en testant des images de haute résolution ainsi

que des images avec une résolution médiocre acquises de différents appareils surtout pour la segmentation automatique des régions d'intérêt qui représente un défi majeur dans la pratique.

Perspectives :

Malgré les progrès réalisés au cours de cette thèse, il reste encore beaucoup à découvrir et à accomplir dans la détection de ces maladies oculaires. La recherche continue dans ces domaines pour identifier de nouvelles stratégies et développer des programmes de dépistage plus efficaces et plus fiables.

Les travaux futurs qui peuvent être ajoutés pour enrichir ce travail sont :

- Le développement d'autres méthodes de segmentation et de classification pour améliorer les résultats obtenus.
- La classification des grades du glaucome.
- La détection automatique du glaucome par deep learning.
- L'utilisation d'autres caractéristiques des vaisseaux réiniens telles que les microanévrismes, les hémorragies et les exsudats pour classer les stades de la RD.
- La classification des différents grades de la RD
- La collecte d'autres bases d'images plus grandes englobant des cas normaux, des cas glaucomateux et des cas de la RD.
- L'implémentation d'un système automatique de détection de ces deux pathologies.
- Le développement d'un système automatique qui détecte et traite différentes maladies oculaires.

Références

- [1] Tham, Y.-C.; Li, X.; Wong, T.Y.; Quigley, H.A.; Aung, T.; Cheng, C.-Y. Global prevalence of glaucoma and projections of glaucoma burden through 2040: A systematic review and meta-analysis. *Ophthalmology* 2014, 121, 2081–2090.
- [2] International Diabetes Federation. *IDF Diabetes Atlas*, 9th edition. Brussels, Belgium: International Diabetes Federation, 2019.
- [3] WILLOUGHBY, Colin E., PONZIN, Diego, FERRARI, Stefano, et al. Anatomy and physiology of the human eye: effects of mucopolysaccharidoses disease on structure and function—a review. *Clinical & Experimental Ophthalmology*, 2010, vol. 38, p. 2-11.
- [4] ADDO, Richard T. (ed.). *Ocular drug delivery: advances, challenges and applications*. Springer, 2016. <https://doi.org/10.1007/978-3-319-47691-9>
- [5] Wang, Y.X., Panda-Jonas, S., Jonas, J.B., 2021. Optic nerve head anatomy in myopia and glaucoma, including parapapillary zones alpha, beta, gamma and delta: Histology and clinical features. *Progress in Retinal and Eye Research* 83, 100933. <https://doi.org/10.1016/j.preteyeres.2020.100933>
- [6] Thylefors B and Negrel AD, “The global impact of glaucoma”. *Bull World Health Organization*, 72(3):323–326, 1994.
- [7] Quigley HA and Broman AT, “The number of people with glaucoma worldwide in 2010 and 2020”. *Br J Ophthalmol* 90:262–267, 2006.
- [8] World Health Organization WHO. (8 October 2019). ‘World report on vision’. URL: <http://www.who.int/publications-detail/world-report-on-vision>
- [9] Tiar, M. (18 March 2018). ‘Necessity to include glaucoma in the nomenclature of chronic diseases’, Algeria press service. URL: <https://www.aps.dz/sante-science-technologie/71269-necessite-d-inclure-le-glaucome-dans-la-nomenclature-des-maladies-chroniques>
- [10] Quigley, H. A., & Broman, A. T. (2006). The number of people with glaucoma worldwide in 2010 and 2020. *British Journal of Ophthalmology*, 90(3), 262-267.
- [11] Bertaud, S., Aragno, V., Baudouin, C., & Labbé, A. (2018). Le glaucome primitif à angle ouvert. *La Revue de Médecine Interne*. doi:10.1016/j.revmed.2018.12.001
- [12] Letessier, J.-B. (2013). Le Glaucome. *Revue Francophone d’Orthoptie*, 6(3), 100–110. doi:10.1016/j.rfo.2013.09.001
- [13] Weinreb, R. N., Aung, T., & Medeiros, F. A. (2014). The pathophysiology and treatment of glaucoma: a review. *JAMA*, 311(18), 1901-1911.
- [14] Ogurtsova K, da Rocha Fernandes JD, Huang Y, Linnenkamp U, Guariguata L, Cho NH, Cavan D, Shaw JE, Makaroff LE. *IDF Diabetes Atlas: Global estimates for the prevalence of diabetes for 2015 and 2040*. *Diabetes Res. Clin. Pract.* 2017; 128:40-50. <https://doi.org/10.1016/j.diabres.2017.03.024>.
- [15] Koblin K, Barbara E. Overview of Epidemiologic Studies of Diabetic Retinopathy. *Ophthalmic Epidemiol.* 2007;14(4):179-183. <https://doi.org/10.1080/09286580701396720>.
- [16] Boyd SR., Advani A, Altomare F, Stockl F. Retinopathy. *Can. J. Diabetes.* 2013; 37:137-141. <https://doi.org/10.1016/j.jcjd.2013.01.038>.
- [17] Early Treatment Diabetic Retinopathy Study Research Group. Classification of diabetic retinopathy from fluorescein angiograms. *ETDRS report number 11*. *Ophthalmology.* 1991;98(5 Suppl):807-822.
- [18] Wilkinson CP, Ferris FL 3rd, Klein RE, et al. Proposed international clinical diabetic retinopathy and diabetic macular edema disease severity scales. *Ophthalmology.* 2003;110(9):1677-1682.
- [19] Heiting, G. (July 2020). ‘Glaucoma. Eye Conditions and Diseases’. ALL ABOUT VISION. URL: <https://www.allaboutvision.com/conditions/glaucoma/>
- [20] Moseley, M. J., Evans, N. M., & Fielder, A. R. (1989). Comparison of a new non-contact tonometer with Goldmann applanation. *Eye*, 3(3), 332-337.

- [21] Touboul, D., Roberts, C., Kérautret, J., Garra, C., Maurice-Tison, S., Saubusse, E., & Colin, J. (2008). Correlations between corneal hysteresis, intraocular pressure, and corneal central pachymetry. *Journal of Cataract & Refractive Surgery*, 34(4), 616-622.
- [22] Hashemi H, Khabazkhoob M, Emamian MH, Shariati M, Fotouhi A. Central Corneal Thickness in a Population-Based, Cross-sectional Study: The Tehran Eye Study. *Cornea*. 2012;31(7):767-772. doi:10.1097/ICO.0b013e31823b5e3a
- [23] Delgado, M.F., Nguyen, N.T.A., Cox, T.A., Singh, K., Lee, D.A., Dueker, D.K., Fechtner, R.D., Juzych, M.S., Lin, S.C., Netland, P.A., Pastor, S.A., Schuman, J.S., Samples, J.R., 2002. Automated perimetry: A report by the American Academy of Ophthalmology. *Ophthalmology* 109, 2362–2374. [https://doi.org/10.1016/S0161-6420\(02\)01726-8](https://doi.org/10.1016/S0161-6420(02)01726-8)
- [24] Anderson AJ, Johnson CA. Frequency-doubling technology perimetry. *Ophthalmol Clin North Am*. 2003;16(2):213-225. doi: [10.1016/s0896-1549\(03\)00011-7](https://doi.org/10.1016/s0896-1549(03)00011-7)
- [25] American Academy of Ophthalmology. (2021). *Fundamentals and Principles of Ophthalmology*. Chapter 4: Evaluation of the Retina.
- [26] Dutta, M. K., Mourya, K. A., Singh, A., Parthasarathi, M., Burget, R., and Riha, K. (2014). ‘Glaucoma detection by segmenting the super pixels from fundus colour retinal images’. 2014 International Conference on Medical Imaging, m-Health and Emerging Communication Systems (MedCom), pp. 86-90. DOI: [10.1109/medcom.2014.7005981](https://doi.org/10.1109/medcom.2014.7005981)
- [27] Dnyaneshwari D. Patil, Ramesh R. Manza, PhD et al, Primary Open Angle Glaucoma Diagnosis using Neuro Retinal Rim Ratio, *International Journal of Computer Applications (IJCATM)* (0975 – 8887) National Conference on Digital Image and Signal Processing 2016.
- [28] Pardha Saradhi Mittapalli, Giri Babu Kande, Segmentation of optic disk and optic cup from digital fundus images for the assessment of glaucoma, *Biomedical Signal Processing and Control*, volume 24 pages 34–46, février 2016.
- [29] Anum A. Salam, Tehmina Khalil, M. Usman Akram, Amina Jameel, Imran Basit, Automated detection of glaucoma using structural and no structural features, SpringerPlus, December 2016.
- [30] H. A. Nugroho, W. K. Z. Oktoeberza, A. Erasari, A. Utami and C. Cahyono, "Segmentation of optic disc and optic cup in colour fundus images based on morphological reconstruction," 2017 9th International Conference on Information Technology and Electrical Engineering (ICITEE), 2017, pp. 1-5, doi: 10.1109/ICITEED.2017.8250456.
- [31] Priyadharsini, R., A. Beulah, and T. Sree Sharmila. “Optic Disc and Cup Segmentation in Fundus Retinal Images Using Feature Detection and Morphological Techniques.” *Current Science* 115, no. 4 (2018): 748–52. <https://www.jstor.org/stable/26978284>.
- [32] Wei Zhou, Yugen Yi, Yuan Gao, Jiangyan Dai, "Optic Disc and Cup Segmentation in Retinal Images for Glaucoma Diagnosis by Locally Statistical Active Contour Model with Structure prior", *Computational and Mathematical Methods in Medicine*, vol. 2019, Article ID 8973287, 16 pages, 2019. <https://doi.org/10.1155/2019/8973287>
- [33] Khan TM, Mehmood M, Naqvi SS, Butt MFU. A region growing and local adaptive thresholding-based optic disc detection. *PLoS One*. 2020 Jan 30;15(1):e0227566. doi: 10.1371/journal.pone.0227566. PMID: 31999720; PMCID: PMC6991997.
- [34] Zilly, J., Buhmann, J. M. and Mahapatra, D. (2017). ‘Glaucoma detection using entropy sampling and ensemble learning for automatic optic cup and disc segmentation’. *Computerized Medical Imaging and Graphics*, 55, pp. 28-41. DOI: <https://doi.org/10.1016/j.compmedimag.2016.07.012>
- [35] Sevastopolsky, A. (2017). ‘Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network’. *Pattern Recognition and Image Analysis* 27, no. 3, pp. 618-624. DOI: <https://doi.org/10.1134/S1054661817030269>
- [36] Al-Bander, B., Zheng, Y. (2018). ‘Dense fully convolutional segmentation of the optic disc and cup in colour fundus for glaucoma diagnosis’. *Symmetry* 10 (4), 87. DOI: <https://doi.org/10.3390/sym10040087>

- [37] Yu, S., Xiao, D., Frost, S., Kanagasingam, Y. (2019). 'Robust optic disc and cup segmentation with deep learning for glaucoma detection'. *Computerized Medical Imaging and Graphics*, 74, pp. 61–71. DOI: <https://doi.org/10.1016/j.compmedimag.2019.02.005>
- [38] Afolabi, O. J., Fulufhelo, V. N. and Gugulethu, M. H. (2019). 'Segmentation of Optic Cup and Disc for Diagnosis of Glaucoma on Retinal Fundus Images'. 2019 (SAUPEC/RobMech/PRASA), pp. 183-187. DOI: [10.1109/RoboMech.2019.8704727](https://doi.org/10.1109/RoboMech.2019.8704727)
- [39] Qin, P., Wang, L., Hongbing, Lv. (2019). 'Optic Disc and Cup Segmentation Based on Deep Learning'. 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), pp. 1835-1840. DOI: [10.1109/ITNEC.2019.8729455](https://doi.org/10.1109/ITNEC.2019.8729455)
- [40] Božić-Štulić, D., Braović, M. and Stipaničev, D. (2020). 'Deep learning based approach for optic disc and optic cup semantic segmentation for glaucoma analysis in retinal fundus images'. *International Journal of Electrical and Computer Engineering Systems*, 11, no. 2, pp. 111-120. <https://doi.org/10.32985/ijeces.11.2.6>
- [41] Tabassum, M., Khan, T.M., Arsalan, M., Naqvi, S.S., Ahmed, M., Madni, H.A., & Mirza, J. (2020). 'CDED-Net: Joint Segmentation of Optic Disc and Optic Cup for Glaucoma Screening'. *IEEE Access*, 8, pp. 102733-102747. DOI: <https://doi.org/10.1109/ACCESS.2020.2998635>
- [42] Liu, B., Pan, D. & Song, H. Joint optic disc and cup segmentation based on densely connected depthwise separable convolution deep network. *BMC Med Imaging* 21, 14 (2021). <https://doi.org/10.1186/s12880-020-00528-6>
- [43] Panda, R., Puhan, N.B., Mandal, B. et al. GlaucoNet: Patch-Based Residual Deep Learning Network for Optic Disc and Cup Segmentation Towards Glaucoma Assessment. *SN COMPUT. SCI.* 2, 99 (2021). <https://doi.org/10.1007/s42979-021-00491-1>
- [44] T. Shyamalee and D. Meedeniya, "Attention U-Net for Glaucoma Identification Using Fundus Image Segmentation," 2022 International Conference on Decision Aid Sciences and Applications (DASA), 2022, pp. 6-10, doi: 10.1109/DASA54658.2022.9765303.
- [45] H.N. Veena, A. Muruganandham, T. Senthil Kumaran, A novel optic disc and optic cup segmentation technique to diagnose glaucoma using deep learning convolutional neural network over retinal fundus images, *Journal of King Saud University - Computer and Information Sciences*, Volume 34, Issue 8, Part B, 2022, Pages 6187-6198, <https://doi.org/10.1016/j.jksuci.2021.02.003>.
- [46] Anushikha Singh, Malay Kishore Dutta, M. ParthaSarathi, Vaclav Uher and Radim Burget. Image processing based automatic diagnosis of glaucoma using wavelet features of segmented optic disc from fundus image. *Computer Methods and Programs in Biomedicine* 124, pp. 108-120, 2016.
- [47] Pranjal Das, S. R. Nirmala and Jyoti Prakash Medhi. Detection of Glaucoma Using Neuroretinal Rim Information. *IEEE*, pp.6, 2016.
- [48] Chakravarty, A. and Sivaswamy, J. (2016), 'Glaucoma classification with a fusion of segmentation and image-based features'. 2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI), pp. 689–692. DOI: [10.1109/ISBI.2016.7493360](https://doi.org/10.1109/ISBI.2016.7493360)
- [49] Karkuzhali, S.; Manimegalai, D. Computational intelligence-based decision support system for glaucoma detection. *Biomed. Res.* 2017, 28, 976–1683.
- [50] Soltani, A., Battikh, T., Jabri, I. and Lakhoua, N. (2018). 'A new expert system based on fuzzy logic and image processing algorithms for early glaucoma diagnosis'. *Biomedical Signal Processing and Control*, 40, pp. 366-377. <https://doi.org/10.1016/j.bspc.2017.10.009>
- [51] Guo, F., Mai, Y., Zhao, X., Duan, X., Fan, Z., Zou, B. and Xie, B. (2018). 'Yanbao: A mobile app using the measurement of clinical parameters for glaucoma screening'. *IEEE Access*, 6, pp. 77414–77428. DOI: [10.1109/ACCESS.2018.2882946](https://doi.org/10.1109/ACCESS.2018.2882946)
- [52] Raja, C., Vinodhkumar, N. (2020). 'An Efficient Segmentation of Optic Disc Using Convolution Neural Network for Glaucoma Detection in Retinal Images'. *European Journal of Molecular & Clinical Medicine*. Issue 03, 07, pp. 2609-2627. DOI: https://ejmcm.com/article_3793.html

- [53] Sreng, S., Maneerat, N., Hamamoto, K. and Win, K. Y. (2020). ‘Deep Learning for Optic Disc Segmentation and Glaucoma Diagnosis on Retinal Images’. *Applied sciences, Appl. Sci.*, Issue 14, 10, 4916. DOI: <https://doi.org/10.3390/app10144916>
- [54] Shinde, R. (2021). ‘Glaucoma Detection in Retinal Fundus Images Using U-Net and Supervised Machine Learning Algorithms’. *Intelligence-Based Medicine*, no 5, 100038. DOI: <https://doi.org/10.1016/j.ibmed.2021.100038>.
- [55] Pathan, S., Kumar, P., Pai, R. M., & Bhandary, S. V. (2021). Automated segmentation and classification of retinal features for glaucoma diagnosis. *Biomedical Signal Processing and Control*, 63, 102244. doi:10.1016/j.bspc.2020.102244
- [56] Diaz-Pinto, A., Morales, S., Naranjo, V., Köhler, T., Mossi, J.M., Navea, A. (2019). ‘CNNs for automatic glaucoma assessment using fundus images: An extensive validation’. *Biomed. Eng. Online*, 18, 29. DOI: <https://doi.org/10.1186/s12938-019-0649-y>
- [57] Gómez-Valverde, J.J., Antón, A., Fatti, G., Liefers, B., Herranz, A., Santos, A., Sánchez, C.I., Ledesma-Carbayo, M.J. (2019). ‘Automatic glaucoma classification using color fundus images based on convolutional neural networks and transfer learning’. *Biomed. Opt. Express*, Issue 2, 10, pp. 892–913. DOI: <https://doi.org/10.1364/BOE.10.000892>
- [58] Elangovan, P, Nath, MK. Glaucoma assessment from color fundus images using convolutional neural network. *Int J Imaging Syst Technol.* 2021; 31: 955– 971. <https://doi.org/10.1002/ima.22494>
- [59] Juneja, M., Thakur, N., Thakur, S., Uniyal, A., Wani, A., & Jindal, P. (2020). GC-NET for classification of glaucoma in the retinal fundus image. *Machine Vision and Applications*, 31, 1-18. DOI:10.1007/s00138-020-01091-4
- [60] Ovreiu, S., Paraschiv, E. A., & Ovreiu, E. (2021, July). Deep Learning & Digital Fundus Images: Glaucoma Detection using DenseNet. In 2021 13th International Conference on Electronics, Computers and Artificial Intelligence (ECAI) (pp. 1-4). IEEE.
- [61] Sudhan, M. B., Sinthuja, M., Pravinth Raja, S., Amutharaj, J., Charlyn Pushpa Latha, G., Sheeba Rachel, S., ... & Waji, Y. A. (2022). Segmentation and Classification of Glaucoma Using U-Net with Deep Learning Model. *Journal of Healthcare Engineering*, 2022.
- [62] Latif, J., Tu, S., Xiao, C., Ur Rehman, S., Imran, A., & Latif, Y. (2022). ODGNet: a deep learning model for automated optic disc localization and glaucoma classification using fundus images. *SN Applied Sciences*, 4(4), 1-11.
- [63] Chengzhang Zhu, Beiji Zou, Rongchang Zhao, Jinkai Cui, Xuanchu Duan, Zailiang Chen, Yixiong Liang, “Retinal vessel segmentation in colour fundus images using Extreme Learning Machine”, *CDATA Computerized Medical Imaging and Graphics*, 2016.
- [64] Jyotiprava Dash, Nilamani Bhoi, “A thresholding based technique to extract retinal blood vessels from fundus images”, *Future Computing and Informatics Journal* 2, pp. 103-109, 2017.
- [65] Luiz Carlos Rodrigues, Maurício Marengoni, “Segmentation of optic disc and blood vessels in retinal images using wavelets, mathematical morphology and Hessian-based multi-scale filtering”, *Biomedical Signal Processing and Control* 36, pp. 39–49, 2017.
- [66] Meng Li, Zhenshen Ma, Chao Liu, Guang Zhang, and Zhe Han, “Robust Retinal Blood Vessel Segmentation Based on Reinforcement Local Descriptions”, *BioMed Research International*, 9 pages, 2017.
- [67] Meng Qu, Chun Ni, Mufan Chen, Linghan Zheng, Ling Dai, Bin Sheng, Ping Li, Qiang Wu, “Automatic diabetic retinopathy diagnosis using adjustable ophthalmoscope and multi-scale line operator”, *Pervasive and Mobile Computing*, 2017.
- [68] Jin Q, Meng Z, Pham TD, Chen Q, Wei L, Su R. DUNet: A deformable network for retinal vessel segmentation. *Knowl. Based Syst.* 2019; 178:149-162. <https://doi.org/10.1016/j.knosys.2019.04.025>.
- [69] Samuel PM, Veeramalai T. Multilevel and Multiscale Deep Neural Network for Retinal Blood Vessel Segmentation. *Symmetry*. 2019; 11(7). <https://doi.org/10.3390/sym11070946>.

- [70] Jiang Y, Zhang H, Ning T, Li C. Automatic Retinal Blood Vessel Segmentation Based on Fully Convolutional Neural Networks. *Symmetry*. 2019; 11(9):1112. <https://doi.org/10.3390/sym11091112>.
- [71] Ozgunalp U, Fan R, Serener A. Semantic Segmentation of Retinal Vessels Using SegNet. In 2020 28th Signal Processing and Communications Applications Conference (SIU). 2020; 1-4. <https://doi.org/10.1109/SIU49456.2020.9302055>.
- [72] Ma, Y, Li X, Duan X, Peng Y, Zhang Y. Retinal Vessel Segmentation by Deep Residual Learning with Wide Activation. *Comput. Intell. and Neurosci.* 2020;8822407. <https://doi.org/10.1155/2020/8822407>.
- [73] Lv Y, Ma H, Li J, Liu S. Attention Guided U-Net With Atrous Convolution for Accurate Retinal Vessels Segmentation. *IEEE Access.* 2020; 8:32826-32839. <https://doi.org/10.1109/ACCESS.2020.2974027>.
- [74] Jiang Y, Falin W, Jing G, Liu W. Efficient BFCN for Automatic Retinal Vessel Segmentation. *J. Ophthalmol.* 2020; 2020:6439407. <https://doi.org/10.1155/2020/6439407>.
- [75] Sathananthavathi V, Indumathi G. Encoder Enhanced Atrous (EEA) Unet architecture for Retinal Blood vessel segmentation. *Cognit. Syst. Res.* 2021; 67:84-95. <https://doi.org/10.1016/j.cogsys.2021.01.003>.
- [76] LIN, Zefang, HUANG, Jianping, CHEN, Yingyin, et al. A high resolution representation network with multi-path scale for retinal vessel segmentation. *Computer Methods and Programs in Biomedicine*, 2021, vol. 208, p. 106206.
- [77] Boudegga H, Elloumi Y, Akil M, Hedi Bedoui M, Kachouri R, Ben Abdallah A. Fast and efficient retinal blood vessel segmentation method based on deep learning network. *Comput. Med. Imaging Graph.* 2021; 90:101902. <https://doi.org/10.1016/j.compmedimag.2021.101902>
- [78] Li D, Rahardja S. BSEResU-Net: An attention-based before-activation residual U-Net for retinal vessel segmentation. *Comput. Methods Programs Biomed.* 2021; 205:106070. <https://doi.org/10.1016/j.cmpb.2021.106070>.
- [79] Xiaomei Xu, Yixin Wang, Yu Liang, Siyuan Luo, Jianqing Wang, Weiwei Jiang, Xiaobo Lai, "Retinal Vessel Automatic Segmentation Using SegNet", *Computational and Mathematical Methods in Medicine*, vol. 2022, Article ID 3117455, 11 pages, 2022. <https://doi.org/10.1155/2022/3117455>
- [80] Deng, Xiangyu, and Jinhong Ye. "A retinal blood vessel segmentation based on improved D-MNet and pulse-coupled neural network." *Biomedical Signal Processing and Control* 73 (2022): 103467. <https://doi.org/10.1016/j.bspc.2021.103467>
- [81] Nair AT, Muthuvel K. Blood vessel segmentation and diabetic retinopathy recognition: an intelligent approach. *Comput. Methods Biomech. Biomed. Eng.: Imaging Vis.* 2020; 8(2):169-181. <https://doi.org/10.1080/21681163.2019.1647459>.
- [82] Sultana R, Rajasekhar KS. Diabetic Retinopathy Classification Using HARALICK Features. *Int. J. Recent Technol. Eng.* 2019; 7(6):5.
- [83] Qomariah, DUN, Tjandrasa H, Fatichah C. Classification of Diabetic Retinopathy and Normal Retinal Images using CNN and SVM. In 2019 12th International Conference on Information Communication Technology and System (ICTS). 2019, 152-157. <https://doi.org/10.1109/ICTS.2019.8850940>.
- [84] Gayathri, S, Krishna AK, Gopi VP, PalanisamyP. Automated Binary and Multiclass Classification of Diabetic Retinopathy Using Haralick and Multiresolution Features. *IEEE Access.* 2020; 8:57497-57504. <https://doi.org/10.1109/ACCESS.2020.2979753>.
- [85] Kumar S, Adarsh A, Kumar B, Singh AK. An automated early diabetic retinopathy detection through improved blood vessel and optic disc segmentation. *Opt. Laser Technol.* 2020; 121:105815. <https://doi.org/10.1016/j.optlastec.2019.105815>.
- [86] Bilal Anas, Sun G, Li Y, Mazhar S, Khan AQ. Diabetic Retinopathy Detection and Classification Using Mixed Models for a Disease Grading Database. *IEEE Access.* 2021; 9:23544-23553. <https://doi.org/10.1109/ACCESS.2021.3056186>.

- [87] Wang S, Wang X, Hu Y, Shen Y, Yang Z, Gan M, Lei B. Diabetic Retinopathy Diagnosis Using Multichannel Generative Adversarial Network With Semisupervision. *IEEE Transact. Autom. Sci. Eng.* 2021; 18(2):574-585. <https://doi.org/10.1109/TASE.2020.2981637>.
- [88] Abdelmaksoud E, El-Sappagh S, Barakat S, Abuhmed T, Elmogy M. Automatic Diabetic Retinopathy Grading System Based on Detecting Multiple Retinal Lesions. *IEEE Access.* 2021; 9:15939-15960. <https://doi.org/10.1109/ACCESS.2021.3052870>.
- [89] Bilal A, Zhu L, Deng A, Lu H, Wu N. AI-Based Automatic Detection and Classification of Diabetic Retinopathy Using U-Net and Deep Learning. *Symmetry.* 2022; 14(7):1427. <https://doi.org/10.3390/sym14071427>
- [90] A. B. Aujih, L. I. Izhar, F. Mériaudeau and M. Ibrahim Shapiai, "Analysis of Retinal Vessel Segmentation with Deep Learning and its Effect on Diabetic Retinopathy Classification," 2018 International Conference on Intelligent and Advanced System (ICIAS), 2018, pp. 1-6, doi: 10.1109/ICIAS.2018.8540642.
- [91] Hajabdollahi M, Esfandiarpour R, Najarian K, Karimi N, Samavi S, Reza Soroushmehr SM. Hierarchical Pruning for Simplification of Convolutional Neural Networks in Diabetic Retinopathy Classification. 41st Ann. Int. Conf. IEEE Eng. Med. Biol. Soc. 2019; 970-73. <https://doi.org/10.1109/EMBC.2019.8857769>.
- [92] Hemanth DJ, Deperlioglu O, Kose U. An enhanced diabetic retinopathy detection and classification approach using deep convolutional neural network. *Neural Comput. Appl.* 2020; 32(3):707-721. <https://doi.org/10.1007/s00521-018-03974-0>.
- [93] Baget-Bernaldiz M, Romero-Aroca P, Santos-Blanco E, Navarro-Gil R, Valls A, Antonio M, Rashwan HA, Domenec P. Testing a Deep Learning Algorithm for Detection of Diabetic Retinopathy in a Spanish Diabetic Population and with MESSIDOR Database. *Diagnostics.* 2021; 11(8):1385. <https://doi.org/10.3390/diagnostics11081385>.
- [94] Das, S., Saha, S.K. Diabetic retinopathy detection and classification using CNN tuned by genetic algorithm. *Multimed Tools Appl* **81**, 8007–8020 (2022). <https://doi.org/10.1007/s11042-021-11824-w>
- [95] M. S. Ali Mazumder, T. Hossain, F. M. J. Mehedi Shamrat, N. Jahan, Z. Tasnim and A. Khater, "Deep Learning Approaches for Diabetic Retinopathy Detection by Image Classification," 2022 3rd International Conference on Smart Electronics and Communication (ICOSEC), 2022, pp. 1504-1510, doi: 10.1109/ICOSEC54921.2022.9952159.
- [96] da Rocha, D.A., Ferreira, F.M.F. & Peixoto, Z.M.A. Diabetic retinopathy classification using VGG16 neural network. *Res. Biomed. Eng.* 38, 761–772 (2022). <https://doi.org/10.1007/s42600-022-00200-8>
- [97] Li, F., Xiang, W., Zhang, L. et al. Joint optic disk and cup segmentation for glaucoma screening using a region-based deep learning network. *Eye* 37, 1080–1087 (2023). <https://doi.org/10.1038/s41433-022-02055-w>
- [98] Shyla, N.S.J., Emmanuel, W.R.S. Glaucoma detection and classification using modified level set segmentation and pattern classification neural network. *Multimed Tools Appl* 82, 15797–15815 (2023). <https://doi.org/10.1007/s11042-022-13892-y>
- [99] Deshmukh, S.V., Roy, A. (2023). Retinal Blood Vessel Segmentation Based on Modified CNN and Analyze the Perceptual Quality of Segmented Images. In: Woungang, I., Dhurandher, S.K., Pattanaik, K.K., Verma, A., Verma, P. (eds) *Advanced Network Technologies and Intelligent Computing. ANTIC 2022. Communications in Computer and Information Science*, vol 1798. Springer, Cham. https://doi.org/10.1007/978-3-031-28183-9_43
- [100] Jena, P.K.; Khuntia, B.; Palai, C.; Nayak, M.; Mishra, T.K.; Mohanty, S.N. A Novel Approach for Diabetic Retinopathy Screening Using Asymmetric Deep Learning Features. *Big Data Cogn. Comput.* 2023, 7, 25. <https://doi.org/10.3390/bdcc7010025>

- [101] Staal J, Abramoff M, Niemeijer M, Viergever M, Ginneken B. Ridge-Based Vessel Segmentation in Color Images of the Retina. *IEEE transact. Med. imaging.* 2004; 23:501-509. <https://doi.org/10.1109/TMI.2004.825627>.
- [102] Budai A, Bock R, Maier A, Hornegger J, Michelson G. Robust Vessel Segmentation in Fundus Images. *Int. J. Biomed. Imaging.* 2013; 2013:154860. <https://doi.org/10.1155/2013/154860>.
- [103] M. M. Fraz ,P. Remagnin , A. Hoppe , B. Uyyanonvar , A. R. Rudnicka , C. G. Owen, S. A. Barman, "An Ensemble Classification-Based Approach Applied to Retinal Blood Vessel Segmentation", *IEEE Transactions on Biomedical Engineering*, volume 59, 2012, <https://www.idiap.ch/software/bob/docs/bob/bob.db.chasedb1/master/index>.
- [104] A. D. Hoover, V. Kouznetsova and M. Goldbaum, "Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response," *IEEE Transactions on Medical Imaging*, vol. 19, no. 3, pp. 203-210, 2000, doi: 10.1109/42.845178.
- [105] Decencière E, Zhang X, Cazuguel G, Lay B, Cochener B, Trone C, Gain P, et al. Feedback on a publicly distributed image database: The Messidor database. *Image Anal. Stereol.* 2014. <https://doi.org/10.5566/ias.1155>.
- [106] Fumero, F., Alayon, S., Sanchez, J.L., Sigut, J., Gonzalez-Hernandez, M. (2011). 'RIM-ONE: An Open Retinal Image Database for Optic Nerve Evaluation'. *IEEE 24th Symposium on Computer-Based Medical Systems*, pp. 1-6. DOI: [10.1109/CBMS.2011.5999143](https://doi.org/10.1109/CBMS.2011.5999143), Available on : <http://medimrg.webs.ull.es/>
- [107] Sivaswamy, J., Krishnadas, S.R., Joshi, G.D., Jain, M., Tabish, A.U.S. (2014). 'Drishti-gs: Retinal image dataset for optic nerve head (onh) segmentation'. 2014 *IEEE 11th International Symposium on Biomedical Imaging (ISBI)*, pp. 53–56. DOI: [10.1109/ISBI.2014.6867807](https://doi.org/10.1109/ISBI.2014.6867807)
- [108] Carmona EJ, Rincón M, García-Feijó J, Martínez-de-la-Casa JM. Identification of the optic nerve head with genetic algorithms. *Artif Intell Med.* 2008 Jul;43(3), p. 243-259. doi: 10.1016/j.artmed.2008.04.005. Epub 2008 Jun 4. PMID: 18534830.
- [109] Zhang, Z., Yin, F. S., Liu, J., Wong, W. K., Tan, N. M., Lee, B. H., ... & Wong, T. Y. (2010, August). Origa-light: An online retinal fundus image database for glaucoma analysis and research. In 2010 Annual international conference of the IEEE engineering in medicine and biology (pp. 3065-3068). IEEE.
- [110] ZHU, Youlian et HUANG, Cheng. An improved median filtering algorithm for image noise reduction. *Physics Procedia*, 2012, vol. 25, p. 609-616. <https://doi.org/10.1016/j.phpro.2012.03.133>
- [111] A. Kumar and S. S. Sodhi, "Comparative Analysis of Gaussian Filter, Median Filter and Denoise Autoencoder," 2020 7th International Conference on Computing for Sustainable Global Development (INDIACom), New Delhi, India, 2020, pp. 45-51, doi: 10.23919/INDIACom49435.2020.9083712.
- [112] DAVIES, E. Roy. *Machine vision: theory, algorithms, practicalities* Third Edition. Elsevier, 2004.
- [113] G. Yadav, S. Maheshwari and A. Agarwal, "Contrast limited adaptive histogram equalization based enhancement for real time video system," 2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI), Delhi, India, 2014, pp. 2392-2397, doi: 10.1109/ICACCI.2014.6968381.
- [114] Rubini, S. S., & Kunthavai, A. (2015). Diabetic Retinopathy Detection Based on Eigenvalues of the Hessian Matrix. *Procedia Computer Science*, 47, 311–318. doi:10.1016/j.procs.2015.04.001
- [115] Santosh Kumar NC and Radhika Y, "Optimized maximum principal curvatures based segmentation of blood vessels from retinal images", *Biomedical Research*, vol. 30, Issue 2, 2019.
- [116] PILLAI, Sonal Wilson, HERLIN, L. T., et SINGERJI, Ashwin G. Retinal blood vessel extraction using ISODATA clustering and morphological operations. *International Journal of Engineering Research & Technology (IJERT)*, 2017, vol. 6, no 4.
- [117] R. C. Gonzalez and R. E. Woods, "Digital Image Processing", 3rd ed. Prentice Hall, 2008.

- [118] DHANACHANDRA, Nameirakpam, MANGLEM, Khumanthem, et CHANU, Yambem Jina. Image segmentation using K-means clustering algorithm and subtractive clustering algorithm. *Procedia Computer Science*, 2015, vol. 54, p. 764-771.
- [119] GHOSH, Soumi et DUBEY, Sanjay Kumar. Comparative analysis of k-means and fuzzy c-means algorithms. *International Journal of Advanced Computer Science and Applications*, 2013, vol. 4, no 4.
- [120] KASS, Michael, WITKIN, Andrew, et TERZOPOULOS, Demetri. Snakes: Active contour models. *International journal of computer vision*, 1988, vol. 1, no 4, p. 321-331.
- [121] Zhuo Zhang, Jiang Liu, Cherian, N. S., Ying Sun, Joo Hwee Lim, Wing Kee Wong, ... Tien Ying Wong. (2009). Convex hull based neuro-retinal optic cup ellipse optimization in glaucoma diagnosis. 2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. doi:10.1109/iembs.2009.5332913
- [122] Murphy, K.P., 2012. *Machine learning: a probabilistic perspective*. MIT press.
- [123] El Naqa, I., & Murphy, M. J. (2015). What Is Machine Learning? *Machine Learning in Radiation Oncology*, 3–11. doi:10.1007/978-3-319-18305-3_1
- [124] Eve Mathieu-Dupas. Algorithmes des k plus proches voisins pondérés et application en diagnostic. 42èmes Journées de Statistique, 2010, Marseille, France, France. inria-00494814f
- [125] Hassane Hilali. Application de la classification textuelle pour l'extraction des règles d'association maximales. L'université du Québec à Trois-Rivières. Avril 2009
- [126] Robin Genuer, Jean-Michel Poggi. Arbres CART et Forêts aléatoires, Importance et sélection de variables. 2017. (hal-01387654v2)
- [127] HASAN, Mohamadally et BORIS, Fomani. Svm: Machines à vecteurs de support ou séparateurs à vastes marges. Rapport technique, Versailles St Quentin, France. Cité, 2006, vol. 64.
- [128] CORNUÉJOLS, Antoine. Une nouvelle méthode d'apprentissage : Les SVM. Séparateurs à vaste marge. *Bulletin de l'AFIA*, 2002, vol. 51, p. 14-23.
- [129] Xanthopoulos, P., Pardalos, P. M., & Trafalis, T. B. (2012). Linear Discriminant Analysis. *Robust Data Mining*, 27–33. doi:10.1007/978-1-4419-9878-1_4
- [130] Sharma, A., & Paliwal, K. K. (2014). Linear discriminant analysis for the small sample size problem: an overview. *International Journal of Machine Learning and Cybernetics*, 6(3), 443–454. doi:10.1007/s13042-013-0226-9
- [131] Liu, J., Chen, S., Tan, X., & Zhang, D. (2007). Efficient pseudoinverse linear discriminant analysis and its nonlinear form for face recognition. *International Journal of Pattern Recognition and Artificial Intelligence*, 21(08), 1265–1278. doi:10.1142/s0218001407005946
- [132] Alpaydin, E. (2010). *Introduction to machine learning* (2nd ed.). MIT Press.
- [133] Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- [134] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep Learning*. MIT Press, 2016.
- [135] Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2016). Deep learning for health informatics. *IEEE journal of biomedical and health informatics*, 21(1), 4-21.
- [136] Patterson, J., & Gibson, A. (2018). *Deep learning en action: la référence du praticien*. OREILLY
- [137] Dumoulin, V., & Visin, F. (2016). A guide to convolution arithmetic for deep learning. arXiv preprint arXiv:1603.07285.
- [138] IOFFE, Sergey et SZEGEDY, Christian. Batch normalization: Accelerating deep network training by reducing internal covariate shift. In : *International conference on machine learning*. pmlr, 2015. p. 448-456.
- [139] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929-1958.
- [140] Qian, N. (1999). On the momentum term in gradient descent learning algorithms. *Neural networks*, 12(1), 145-151.

- [141] Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
- [142] Badrinarayanan, V., Kendall, A. and Cipolla, R. (2017). ‘SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation’. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39, no. 12, pp. 2481-2495. DOI: [10.1109/TPAMI.2016.2644615](https://doi.org/10.1109/TPAMI.2016.2644615)
- [143] Simonyan, K. and Zisserman, A. (2014). ‘Very Deep Convolutional Networks for Large-Scale Image Recognition’. Computer Vision and Pattern Recognition. Available: [arXiv:1409.1556v6](https://arxiv.org/abs/1409.1556v6)
- [144] Ronneberger, O., Fischer, P. and Brox, T. (2015). ‘U-net: Convolutional networks for biomedical image segmentation’. International Conference on Medical Image Computing and Computer Assisted Intervention, Springer, 9351, pp. 234–241. DOI: https://doi.org/10.1007/978-3-319-24574-4_28
- [145] SCHAFFER, Cullen. Selecting a classification method by cross-validation. Machine learning, 1993, vol. 13, p. 135-143.
- [146] Elaouaber Zineb Aziza, Lazouni Mohamed El Amine, Messadi Mohamed, Bessaid Abdelhafid. Decision tree CART algorithm for diabetic retinopathy classification. In 2019 6th International Conference on Image and Signal Processing and their Applications (ISPA). 2019; 1-5. <https://doi.org/10.1109/ISPA48434.2019.8966905>.
- [147] Franklin SW, Rajan SE. Computerized screening of diabetic retinopathy employing blood vessel segmentation in retinal images. Biocybern. and Biomed. Eng. 2014; 34:117-124. <https://doi.org/10.1016/j.bbe.2014.01.004>.
- [148] Z.A. Elaouaber, A. Feroui, M.E.A. Lazouni & M. Messadi (2023) Blood vessel segmentation using deep learning architectures for aid diagnosis of diabetic retinopathy, Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization, 11:4, 1463-1477, <https://doi.org/10.1080/21681163.2022.2145999>
- [149] Elaouaber, Z.A., Lazouni, M.E.A. & Messadi, M. Retinal vasculature extraction and analysis for diabetic retinopathy recognition. *Res. Biomed. Eng.* (2023). <https://doi.org/10.1007/s42600-023-00279-7>
- [150] Mohammed El Amine Lazouni, Amel Feroui. A new intelligent system for glaucoma disease detection. Int. J. Computer Aided Engineering and Technology, Vol. 11, Nos. 4/5, 2019.
- [151] I. BENSMAIL, M. MESSADI, A. FEROU, A. LAZOUNI and A. BESSAID, "New Methodology Based On Images Processing for the Retinopathy Diabetic Disease Classification", International Journal of Biomedical Engineering and Technology, 2019, ISSN : 1752-6418.