

UNIVERSITE BLIDA1

Faculté de Technologie
Département de l'Electronique

THESE DE DOCTORAT

Génie Biomédical

**Système d'Etude de la Baisse de l'Acuité
Visuelle**

Par

BOUACHERIA Mohamed

Devant le jury composé de

GUESSOUM Abderrezak	Professeur, U. de Blida -1-	Président
CHEGGAGA Nawal	Maître de Conférence A, U. de Blida -1-	Examinatrice
MEZIANE Abdelkrim	Directeur de recherche, CERIST, ALGER	Examineur
CHERFA Yazid	Professeur, U. de Blida -1-	Directeur de thèse
CHERFA Assia	Maître de Conférence A, U. de Blida -1-	Co-directrice de thèse

Blida, Février 2022

RESUME

ملخص:

الجلوكوما هو اعتلال عصبي تنكسي يصيب العين، وينتج عنه تدهور تدريجي، ودائم لألياف العصب البصري، مما يؤدي في النهاية إلى العمى. مع 64.3 مليون حالة قدرتها منظمة الصحة العالمية في عام 2010 ، يُعتبر سارق البصر الصامت السبب الأكثر شيوعًا للعمى الدائم في جميع أنحاء العالم. إن الطبيعة اللاعرضية لفقدان البصر خلال المراحل المبكرة من الجلوكوما، وطبيعته التي لا رجعة فيها، خلال المراحل اللاحقة، تجعل تشخيص وعلاج الجلوكوما في غاية الأهمية للوقاية من المرض. يعد عمل أطروحتنا جزءًا من نظام مساعدة لتشخيص الجلوكوما، بناءً على التحليل المتزامن لصور قاع العين، وصور OCT البقعية والحجرة الأمامية. تم إثبات على أن هذه الطريقة هي أكثر دقة (98.03 بالمائة) في الكشف عن الجلوكوما، من الاعتماد فقط على خصائص قاع العين (97 بالمائة) . بناءً على هذا الأداء، يمكن استخدام نظام الدعم التشخيصي الخاص بنا لمساعدة أطباء العيون في إجراءات فحص الجلوكوما الخاصة بهم، لتزويدهم برأي ثانٍ ، وبالتالي المساعدة في الفحص الشامل.

الكلمات المفتاحية: الجلوكوما، ألياف العصب البصري، العمى، قاع العين، نظام الدعم التشخيصي.

Résumé:

Le glaucome est une neuropathie oculaire dégénérative, qui se traduit par la dégénérescence graduelle, progressive et permanente des fibres nerveuses optiques, conduisant finalement à la cécité. Avec 64.3 millions cas estimés par l'organisation mondiale de la santé en 2010, ce voleur silencieux de la vue est considéré comme la cause la plus fréquente de la cécité irréversible dans le monde. La nature asymptomatique de la perte de vision au cours des stades précoces du glaucome, et sa nature irréversible pendant les stades ultérieurs, rendent le diagnostic et le traitement du glaucome extrêmement importants, pour la prévention de la maladie. Notre travail de thèse entre dans le cadre du développement d'un système d'aide au diagnostic du glaucome, basé sur l'analyse simultanée des images fond d'œil, des images OCT maculaires et de la chambre antérieure. Cette méthode s'est avérée plus précise (98.03%) dans la détection du glaucome, que de se fier uniquement aux caractéristiques du fond d'œil (97%). D'après cette performance, notre système d'aide au diagnostic peut être utilisé pour aider les ophtalmologues dans leurs routines de dépistage du glaucome, afin de leur fournir un deuxième opinion, ainsi les aider dans le dépistage de masse.

Mots clés: glaucome, fibres nerveuses optiques, cécité, fond d'œil, OCT, système d'aide au diagnostic.

Abstract:

Glaucoma is a degenerative ocular neuropathy that results in the gradual, progressive and permanent degeneration of the optic nerve fibers, ultimately leading to blindness. With 64.3 million cases estimated by the World Health Organization in 2010, this silent thief of sight is considered as the most common cause of irreversible blindness worldwide. The asymptomatic nature of vision loss during the early stages of glaucoma, and its irreversible nature during the later stages, make the diagnosis and treatment of glaucoma extremely important for the prevention of the disease. Our thesis work consists on the development of a glaucoma diagnostic aid system, based on the simultaneous analysis of fundus images, macular and anterior chamber OCT images. This method was found to be more accurate (98.03%) in detecting glaucoma, than relying solely on fundus characteristics (97%). Based on this performance, our diagnostic support system can be used to assist ophthalmologists with their glaucoma screening routines, to provide them with a second opinion, thereby assisting them with mass screening.

Keywords: Glaucoma, optic nerve fibers, blindness, fundus images, OCT, diagnostic support system.

Remerciements

Avant tout, je remercie Dieu tout puissant de m'avoir donné le courage et la patience et tant de force pour terminer ce modeste travail.

Mes sincères remerciements à Mr Y.CHERFFA et Mme A.CHERFA, pour tous leurs précieux conseils et les orientations données lors de la réalisation de ce travail.

Je remercie aussi les membres du jury pour avoir accepté d'examiner cette thèse.

Mes plus chaleureux remerciements vont à mes parents, pour le soutien que je trouve toujours auprès de vous ainsi que pour votre aide et vos conseils tout au long de mes études.

Sommaire

RESUME	i
Remerciements	iv
Introduction	1
1 Aspect Médical	5
1.1 Structure et fonctions de l'œil	5
1.1.1 Segment antérieur (SA)	6
1.1.2 Segment postérieur (SP)	7
1.2 Glaucome	9
1.2.1 Epidémiologie	10
1.2.2 Formes du glaucome	12
1.3 Diagnostic du glaucome	14
1.3.1 Glaucome et la pression interne de l'œil	15
1.3.2 Glaucome et l'imagerie médicale	16
1.3.3 Examen complémentaire du champ visuel	26
Discussion	26
2 Etat de l'art	29
2.1 Bases de données rétinienne	29
2.2 Analyse des images fond d'œil pour le dépistage du glaucome	30
2.2.1 Etat de l'art des systèmes d'aide au diagnostic du glaucome (fond d'œil)	31
2.2.2 Evaluation et discussion	43
2.3 Analyse des images OCT pour le dépistage du glaucome	49
2.3.1 Etat de l'art des systèmes d'aide au diagnostic du glaucome (OCT)	49
2.3.2 Evaluation et discussion	54
2.3.3 Etat de l'art des systèmes de classification des images AS-OCT	58
2.3.4 Evaluation et discussion	61
2.4 Etat de l'art des combinaisons multi-modalités pour le dépistage du glau- come	64
2.4.1 Etat de l'art des systèmes hybrides pour le dépistage du glaucome (OCT/fond d'oeil)	64
2.4.2 Evaluation et discussion	66
Discussion	68
3 Analyse des images fond d'œil pour la détection du glaucome	69
3.1 Extraction de la région d'intérêt	70
3.1.1 Base de données utilisée	71

3.1.2	Réseau de neurones convolutionnel proposé	72
3.2	Segmentation du disque optique	76
3.2.1	Prétraitement	77
3.2.2	Segmentation proposée du disque optique	81
3.3	Segmentation du cup optique	87
3.3.1	Prétraitement	88
3.3.2	Segmentation proposée du cup optique	92
3.4	Détection du glaucome	96
3.4.1	Détermination automatique des indications cliniques du glaucome .	97
3.4.2	Détection du glaucome	100
	Discussion	104
4	Combinaison OCT/fond d'œil pour la détection du glaucome	106
4.1	Prétraitement de l'image OCT	108
4.1.1	Filtrage des images OCT par ondelettes	108
4.2	Segmentation et évaluation du complexe GCC	113
4.2.1	Segmentation de l'ILM	113
4.2.2	Segmentation du GCC	116
4.2.3	Mesure et analyse de l'épaisseur de la couche GCC	118
4.3	Détection du glaucome basée sur des caractéristiques hybrides	120
4.3.1	Bases de données utilisées	121
4.3.2	Comparaison des deux classificateurs	122
4.4	Classification de l'angle irido-cornéen	124
4.4.1	Base de données utilisée	125
4.4.2	Classification des images AS-OCT par AlexNet	126
4.4.3	Classification des images AS-OCT par VGGNet	130
4.4.4	Classification des images AS-OCT par un réseau CNN séquentiel . .	132
	Discussion	135
5	Résultats et discussion	138
5.1	Evaluation de l'analyse proposée des images fond d'œil	140
5.2	Evaluation de la combinaison OCT/fond d'œil proposée	145
5.3	Evaluation de la classification des images AS-OCT	151
	Discussion	152
	Conclusion	155

Liste des figures

1.1	Représentation schématique de l'anatomie de l'œil.	6
1.2	Représentation schématique d'une coupe de la rétine.	8
1.3	Vision normale, Glaucome précoce, Glaucome avancé, Glaucome sévère. . .	9
1.4	Premières causes de cécité dans le monde en 2010, Source: The World Health Organization (WHO).	11
1.5	Aspect anatomique d'un angle irido-cornéen ouvert.	13
1.6	Aspect anatomique d'un angle irido-cornéen fermé.	14
1.7	Aspect photographique d'un fond d'œil sain.	17
1.8	Changement structural de l'excavation et le disque optique. (A) cas de glaucome, (B) cas sain.	18
1.9	Évaluation clinique de la règle ISNT pour un nerf optique normal. (A) disque optique, (B) mesures ISNT.	19
1.10	Mésures de l'échelle DDLS.	19
1.11	Examen du fond d'œil à l'ophtalmoscope indirect.	21
1.12	Un volume OCT 3-D composé d'une série de coupes transversales appelées B-scans. Chaque profil de colonne 1-D dans un B-scan est appelé un A-scan. Le tissu rétinien est composé de plusieurs couches qui sont représentées sur un B-scan maculaire du volume OCT.	23
1.13	Différentes régions pour le diagnostic du glaucome. Première ligne: région prépapillaire, deuxième ligne: région radiale, et troisième ligne: région maculaire.	24
1.14	Exemple d'une image AS-OCT avec les paramètres à mesurer. (B) AIC, (C) DOA, (D) STI.	25
1.15	Exemples de l'examen de champ visuel. à gauche: sujet sain, à droite: sujet glaucomateux	26
3.1	Organigramme général de la méthode proposée.	70
3.2	Exemples des images prises de la base de données MESSIDOR.	71
3.3	Exemples des segments extraits des images fond d'oeil de la base de données MESSIDOR.	73
3.4	Architecture détaillée du CNN utilisé pour l'extraction du ROI.	75
3.5	Organigramme général de la méthodologie proposée pour la segmentation du disque optique.	77
3.6	Représentation de l'image couleur dans l'espace RGB. Première colonne : image en couleurs, deuxième colonne : le canal bleu, troisième colonne : le canal vert, quatrième colonne : le canal rouge.	78
3.7	Amélioration de la région du disque par correction gamma. (A) canal rouge de la ROI, (B) correction gamma.	80
3.8	Exemple de segmentation et élimination des vaisseaux sanguins. (A) image améliorée, (B) transformée Chapeau Bas de forme, (C) seuillage des vaisseaux, (D) élimination des vaisseaux, (E) lissage de l'image.	82

3.9	Segmentation par la méthode Chan-Vese selon les positions possibles de courbe.	84
3.10	Résultats de la segmentation primaire du disque optique. Première colonne : images initiales, deuxième colonne : images segmentées.	85
3.11	Étapes intermédiaires de segmentation des contours actifs géodésiques. (A) image initiale, (B) image d'amplitude du gradient, (C) image de vitesse g calculée à l'aide de l'équation 3.15.	87
3.12	Segmentation finale du disque optique. (A) et (D) images initiales, (B) et (E): résultats de segmentation avant et après correction présentés en contours noirs et blancs respectivement, (C) et (F) résultats finaux (ajustement d'ellipse).	88
3.13	Organigramme général de la méthodologie proposée pour la segmentation du cup optique.	89
3.14	Représentation de l'image ROI dans l'espace HSV. (A) l'image dans l'espace HSV, (B) canal H, (C) canal S, (D) canal V.	90
3.15	Représentation de l'image ROI dans l'espace $l^*a^*b^*$. (A) l'image dans l'espace $l^*a^*b^*$, (B) canal l , (C) canal: a , (D) canal b	90
3.16	Image d'intérêt finale pour la segmentation du cup optique. (A) fusion des composantes H et l , (B) égalisation de l'histogramme.	91
3.17	Élimination des vaisseaux et de la région à l'extérieur du disque. (A) image d'intérêt, (B) élimination des vaisseaux, (C) élimination de la région hors disque.	92
3.18	Représentation schématique de la segmentation d'images en graphe.	93
3.19	Segmentation du cup optique. (A) image d'intérêt, (B) élimination des vaisseaux sanguins et de la zone non-discale, (C) segmentation de Felzenszwalb, (D) segmentation primaire du cup, (E) correction convexe et de l'ellipse, (F) résultat final (le contour blanc pour le disque optique et le contour noir est pour le cup optique).	96
3.20	Comparaison des histogrammes du rapport CDR entre les images normales et de glaucome représentées en vert et en rouge respectivement. (A) CDR vertical, (B) CDR horizontal, (C) CDR régional.	98
3.21	Mesure de l'échelle DDLS. (A) l'épaisseur minimale n'est pas égale à 0, (B) cas d'absence du bord neuro-rétinien.	100
3.22	Exemple de processus de classification.	101
3.23	Exemples des deux bases de données utilisées pour la classification. Première ligne: Base de données locale, deuxième ligne: La base de données HRF.	103
3.24	Exemple des arbres de décision utilisées.	104
3.25	Distribution de la base de données d'apprentissage utilisée. (A) représentation du CDR Horizontal en fonction du CDR Vertical, (B) représentation du CDR Horizontal en fonction du CDR Vertical.	105
4.1	Organigramme général de la méthode proposée.	107
4.2	Processus de décomposition en ondelettes discrète (DWT) d'un signal 1D.	109
4.3	Décomposition en DWT d'une image OCT.	110
4.4	Débruitage des images OCT maculaires par seuillage des coefficients DWT. (A) image bruitée, (B) seuillage doux, (C) seuillage dur.	111
4.5	Exemples de pré-traitement des images OCT maculaires. (A) et (C) images initiales, (B) et (D) résultats de prétraitement.	112
4.6	Couches constituantes du complexe GCC.	114

4.7	Segmentation de l'ILM. (A) image d'entrée avec l'initialisation T (rectangle jaune), (B) contours segmentés, (C) extraction finale de l'ILM.	116
4.8	Segmentation du complexe GCC. (A) image OCT maculaire d'entrée, (B) initialisation des germes du marcheur aléatoire (rouge pour le fond et blanc pour l'objet), (C) extraction du GCC, (D) Segmentation finale du GCC. . . .	119
4.9	Mesure de l'épaisseur du GCC. Premier ligne: cas sain. Deuxième ligne: cas glaucomateux.	120
4.10	Exemples des deux bases de données utilisées pour la classification multimodalité. Première ligne : la base de données publique [31], deuxième ligne : la base de données locale.	121
4.11	Exemple des arbres de décision utilisés pour la classification multimodalité.	123
4.12	Caractéristiques structurelles maculaires des cas C_1 et C_2	124
4.13	Exemples de la base de données AGE. Première ligne : images présentant un angle ouvert. Deuxième ligne : images présentant un angle fermé. . . .	126
4.14	L'architecture du modèle AlexNet.	127
4.15	Exemple de l'application du Dropout. (A) un réseau de neurones avec deux couches cachées avant le Dropout, (B) le réseau après l'application du Dropout.	128
4.16	Fonctions de précision et de pertes du modèle AlexNet. (A) fonction de précision, (B) fonction des pertes.	130
4.17	L'architecture du modèle VGGNet.	130
4.18	Fonctions de précision et des pertes du modèle VGGNet. (A) fonction de précision, (B) fonction des pertes.	132
4.19	Fonctions de précision et de pertes du modèle séquentiel. (A) fonction de précision, (B) fonction de pertes.	135
4.20	Exemples de déformations maculaires. (A) dégénérescence maculaire liée à l'âge (DMLA). (B) maculopathie. (C) néovascularisation de la choroïde. . .	136
5.1	Exemples de segmentation finale réalisée par le système proposé. Première ligne: exemples de la base de données locale, deuxième ligne: exemples de la base de données HRF, troisième ligne: exemples de la base de données de Mahmudi et al. Contour blanc: segmentation du disque, contour noir : segmentation du cup.	141
5.2	Exemples des segmentations du disque optique. Contour noir: segmentation primaire du disque optique, contour blanc: segmentation finale du disque optique.	142
5.3	Mauvaise segmentation du cup à cause des vascularisations dans le disque optique, contour noir est obtenu par l'algorithme, contour rouge est la vérité terrain.	142
5.4	Importance des indicateurs de glaucome dans le modèle RF proposé. . . .	144
5.5	Comapraison entre la vérité terrain et les résultats obtenus pour la segmentation de l'ILM. Contour bleu: segmentation obtenue, contour jaune: vérité terrain, contour violet: les pixels où la segmentation est superposée sur la vérité terrain.	146
5.6	Exemples de segmentation finale de la membrane ILM. Première ligne: exemples de la base de données locale, deuxième ligne: exemples de la base de données de T. Mahmudi et al., troisième ligne: exemples de la base de données de M. Golabbakhsh et al.	147

- 5.7 Exemples de segmentation finale du complexe GCC. Première ligne: exemples de la base de données locale, deuxième ligne: exemples de la base de données de T. Mahmudi et al., troisième ligne: exemples de la base de données de M. Golabbakhsh et al. Contour bleu : segmentation de l'ILM, contour rouge: segmentation du GCC. 148
- 5.8 Exemples de la correction manuelle de la segmentation du complexe GCC. Contour bleu: Segmentation de l'ILM, contour rouge: segmentation du GCC, contour violet: correction des parties mal segmentées du complexe GCC. 149
- 5.9 Importance des indicateurs de glaucome dans le modèle RF hybride proposé. 152

Liste des tableaux

2.1	Bases de données des images rétiniennes (fond d'œil).	30
2.2	Bases de données des images rétiniennes (OCT).	30
2.3	Résumé des différentes approches d'analyse des images fond d'œil, pour l'aide au diagnostic du glaucome.	45
2.4	Résumé des différentes approches d'analyse des images OCT, pour l'aide au diagnostic du glaucome.	56
2.5	Résumé des différentes approches d'analyse des images AS-OCT, pour la classification du glaucome.	63
2.6	Résumé des différentes approches basées sur des combinaisons multi-modalités pour la détection du glaucome.	67
3.1	Description de l'architecture CNN à onze couches proposée.	76
3.2	Moyenne (μ) et écart-type (σ) des CDR verticaux, horizontaux et régionaux des images normales et glaucomateuses	97
4.1	Performance du modèle AlexNet en fonction du taux d'apprentissage.	129
4.2	Architecture détaillée du modèle VGG.	131
4.3	Performance du modèle VGGNet en fonction du taux d'apprentissage.	132
4.4	Description détaillée des modèles séquentiels implémentés.	134
4.5	Performance du modèle séquentiel à 8 couches de convolution en fonction du taux d'apprentissage.	135
5.1	Comparaison des performances de la segmentation entre la méthode proposée et les travaux antérieurs.	143
5.2	Comparaison de performance de la mesure du rapport CDR entre la méthode proposée et les travaux antérieurs.	143
5.3	Comparaison des mesures de performances du classificateur proposé avec ceux rapportés dans la littérature.	143
5.4	Comparaison des capacités de diagnostic du glaucome.	145
5.5	Comparaison des mesures de performances de la segmentation de l'ILM proposé avec celles reportées dans la littérature.	146
5.6	Comparaison des mesures de performances de la segmentation de l'ILM proposé avec celles reportées dans la littérature.	149
5.7	Comapraison de performance des deux classificateurs.	150
5.8	Performance de la technique proposée pour la détection du glaucome par rapport à la littérature.	151
5.9	Performances des différents modèles implémentés pour la classification des images AS-OCT.	152
5.10	Performance de la technique proposée pour la la classification de la chambre antérieure de l'œil par rapport à la littérature.	153

Liste des abreviations

AGE	Angle closure Glaucoma Evaluation challenge
AIC	Angle Irido-Cornéen
ARESM	Adaptative Region-based Edge Smoothing Model
AS-OCT	Anterior Segment Optical Coherence Tomography
AUC	Area Under the Curve
CDR	Cup to Disc Ratio
CNN	Convolutional Neural Network
CV	Champs Visuel
DAO	Diagnostic Assisté par Ordinateur
DDLS	Disk Damage Likelihood Scale
DMLA	Dégénérescence Maculaire Liée à l'Age
DOA	Distance de l'Ouverture de l'Angle
DWT	Discrete Wavelet Transform
FCM	Fuzzy C-Means
FN	False Negative
FP	False Positive
GAF	Glaucome À Angle Fermé
GAO	Glaucome À Angle Ouvert
GCC	Ganglion Cell Complex
GCC	Ganglion Cell Layer
GLCM	Gray Level Co-occurrence Matrix
GMM	Gaussian Mixture Model
HOG	Histogram Oriented Gradients
HOS	High Order Spectra
HRF	High Resolution Fundus
HSV	Hue Saturation Value
ILM	Internal Limiting Membrane
INL	Inner Nuclear Layer
IPL	Inner Plexiform Layer
IPT	Inverse Polar Transform
ISNT	Inférieur Supérieur Nasal Temporal
LBF	Local Binary Fitting
LBP	Local Binary Pattern
LRN	Local Response Normalization
LS-SVM	Least-Square Support Vector Machine
MCDN	Multi-Context Deep Network
MLP	Multi Layer Perceptron
MSDA	Multi-Scale Discriminative Aggregation
MST	Minimum Spanning Tree
OCT	Optical Coherence Tomography
OPL	Outer Plexiform Layer
P	Précision

PCANN	Pulse Coupled Artificial Neural Network
PIO	Pression Intra-Oculaire
PPA	PrePapillary Atrophy
RDR	Rim to Disc Ratio
ReLU	Rectified Linear Unit
RGB	Red Green Blue
RNFL	Retinal Nerve Fiber Layer
ROI	Region Of Interest
RPE	Retinal Pigment Epithelium Layer
SA	Segment Antérieure
Se	Sensibilité
SLIC	Simple Linear Iterative Clustering
SP	Segment Postérieure
Sp	Spécificité
SPL	Statistical Pixel Level
STI	Surface entre le Trabéculum et l'Iris
SVM	Support Vector Machine
SWFCM	Spatially Weighted Fuzzy C-Means
TN	True Negative
TP	True Positive
TT	Trace Transform
WCT	Wavelet based Contourlet Transform

INTRODUCTION

Introduction

Le glaucome est une neuropathie oculaire dégénérative, qui se traduit par la dégénérescence graduelle, progressive, et permanente des fibres nerveuses optiques conduisant finalement à la cécité. Avec 64.3 millions de cas, estimés par l'organisation mondiale de la santé en 2010, ce voleur silencieux de la vue est considéré comme la cause la plus fréquente de la cécité irréversible dans le monde. La nature asymptomatique de la perte de vision au cours des stades précoces du glaucome, et sa nature irréversible pendant les stades ultérieurs, rendent le diagnostic et le traitement du glaucome extrêmement importants pour la prévention de la maladie. Pour cela, un examen attentif de la rétine (effectué par un ophtalmologue), est nécessaire pour détecter les anomalies liées au glaucome, avant l'atténuation du champ visuel du patient. Mais, le nombre de patients nécessitant ces examens est en constante augmentation, en raison de la forte prévalence du glaucome, et le vieillissement de la population. De l'autre côté, les systèmes d'aide au diagnostic basés sur l'imagerie rétinienne offrent un nouvel alternatif au dépistage manuel. Par conséquent, plusieurs solutions informatiques ont été développées ces dernières années, dont le but est d'analyser les différentes images rétinienne, afin d'identifier les différentes pathologies oculaires. L'objectif principal d'un système d'aide au diagnostic du glaucome, est de déterminer si une image présente (ou pas) une anomalie liée au glaucome, et où seulement les images jugées suspects par le système nécessiterait une intervention de l'ophtalmologue. Ce processus peut considérablement améliorer la qualité du diagnostic, en réduisant la charge de travail des experts médicaux, et permettre une couverture géographique plus large.

Notre travail vise à développer des solutions robustes d'analyse des différentes images rétiniennes, fond d'œil et OCT, et d'aide à la décision pour le diagnostic du glaucome.

Objectifs de la thèse

L'objectif principal de notre étude, est de développer un système d'analyse des images fond d'œil et OCT, capable de détecter les dégénérescences causées par le glaucome. Au cours de notre étude, quatre objectifs principaux ont été fixés :

1. Développer un algorithme de mesure des indicateurs du glaucome, à partir des images fond d'œil, afin de détecter les pertes pathologiques des fibres nerveuses;
2. Développer un algorithme pour la segmentation, et l'analyse du complexe des cellules ganglionnaires, afin d'identifier les amincissements pathologiques liés aux pertes des fibres nerveuses;
3. Combiner les caractéristiques extraites des deux modalités, afin de fournir une analyse profonde de la tête du nerf optique et de la macula, pour les cas sains et glaucomateux;
4. Développer un algorithme de classification directe de la chambre antérieure oculaire, afin d'identifier la forme du glaucome des cas jugés suspects, par le système précédent.

Structure de la thèse

Ce travail est divisé en cinq chapitres, un aperçu sur chacun d'eux est donné ci-dessous :

- **Chapitre 1 : Aspect Médical**

Ce chapitre présente les informations médicales de bases, nécessaires pour la bonne compréhension de la problématique, et des termes techniques présentés dans notre thèse.

Les différentes modalités d'imagerie rétinienne sont aussi introduites, avec les techniques les plus employées par les ophtalmologues, pour le dépistage du glaucome.

- **Chapitre 2 : Etat de l'art**

Dans le deuxième chapitre, une étude bibliographique est présentée sur les différentes approches existantes dans la littérature, pour la détection et l'aide au diagnostic du glaucome, à partir de l'analyse des différentes images rétiniennes, fond d'œil, tomographie par cohérence optique (OCT), et l'imagerie de la chambre antérieure.

- **Chapitre 3 : Analyse des images fond d'œil pour la détection du glaucome**

Dans ce chapitre, nous présentons un système d'analyse des images fond d'œil, dont l'objectif est l'aide au diagnostic du glaucome. Cette tâche est effectuée sur la base des indicateurs de glaucome, mesurés après la segmentation du disque et du cup optiques: les rapports CDR, la vérification de la loi ISNT, et l'échelle DDLS. Ces caractéristiques sont considérées comme les meilleurs repères pour la détection du glaucome, puisqu'elles fournissent une bonne description de la déformation du cup, due à la dégénérescence des fibres nerveuses.

- **Chapitre 4 : Combinaison OCT/fond d'œil pour la détection du glaucome**

Une combinaison des indicateurs précédents, avec des caractéristiques structurales du complexe des cellules ganglionnaires, est présentée dans le quatrième chapitre, afin de corriger les limitations présentées par le premier système.

- **Chapitre 5 : Résultats et discussion**

Une évaluation détaillée des différents résultats de segmentation, et de classification obtenues dans les deux derniers chapitres, est présentée dans le cinquième chapitre. Ce dernier résume également les contributions principales de notre thèse, et propose des perspectives pour les futurs travaux, afin d'améliorer l'aide au diagnostic du glaucome.

Finalemment, ce travail se termine par une conclusion générale, qui récapitule les différents travaux entretenus dans notre thèse, tout en mettant en valeur les principaux résultats obtenus.

CHAPITRE 1
ASPECT MÉDICAL

1 Aspect Médical

De nos cinq sens, la vue est la plus sollicitée. Elle nous permet de percevoir les couleurs, les formes et les distances. Elle est essentielle pour apprécier le monde qui nous entoure, et communiquer avec les autres. Par conséquent, les complications possibles de la vision peuvent entraîner une incapacité à fonctionner normalement, et réduire la qualité de vie. Ceci montre toute l'importance accordée à l'étude des facteurs, qui pourraient avoir un impact négatif sur la vision. Parmi ces facteurs, on peut citer la maladie du glaucome, considérée comme la principale cause de cécité permanente dans le monde.

L'œil, organe récepteur des informations visuelles, est affecté directement par le glaucome, souvent à cause d'une élévation anormale de la pression dans l'œil. Il entraîne une perte graduelle, et irréversible du champ visuel, pouvant mener à la cécité, qui est peut-être évitée, si la maladie est détectée à l'état précoce.

1.1 Structure et fonctions de l'œil

Directement relié au cerveau, l'œil est un globe de 2.2 à 2.5 centimètres, et pesant 7 à 8 grammes. Mobile grâce à 6 muscles extra-oculaires, il est constitué d'organes vivants (rétine, iris, cornée, cristallin...), pour assurer la capture et le traitement de l'information visuelle (images, textures, couleurs, position et mouvement), puis sa transmission au cortex visuel, par l'intermédiaire du nerf optique[1] [2] [3].

Appartenant au système nerveux central, l'œil est relativement bien isolé du reste de l'organisme, grâce à ses barrières hémato-rétiniennes. Il peut être décomposé en deux parties (Figure 1.1) :

- le segment antérieur (SA), composé de la cornée, l'humeur aqueuse, l'iris, les corps ciliaire et du cristallin ;
- le segment postérieur (SP), composé du vitré, la rétine, la choroïde et de la sclère.

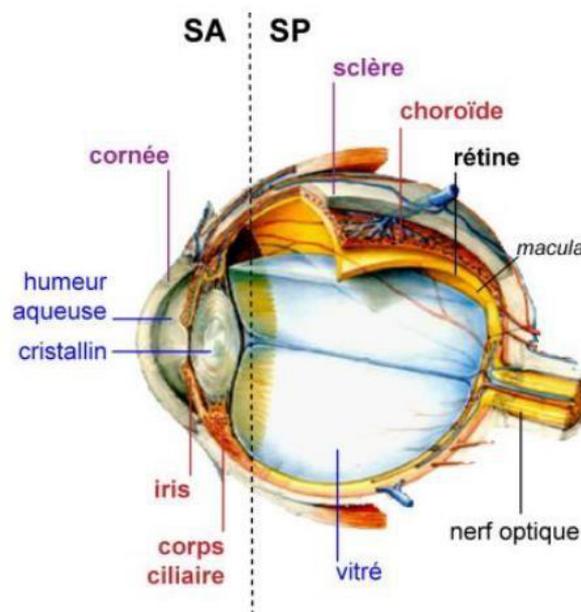


FIGURE 1.1: Représentation schématique de l'anatomie de l'œil.

1.1.1 Segment antérieur (SA)

Constitué d'éléments optiques, à savoir, la cornée, l'humeur aqueuse, l'iris, les corps ciliaires et le cristallin, le segment antérieur permet de focaliser les rayons lumineux sur la rétine, et de collecter les images du monde extérieur.

- **La cornée:** est la première structure oculaire traversée par la lumière. Elle constitue la barrière entre les environnements, extérieur et intérieur de l'œil, et concentre la lumière sur la rétine.

- **L'iris:** est la partie colorée de l'œil (donne la couleur aux yeux) qui délimite un orifice, par lequel passe la lumière, et dont le diamètre varie pour réguler l'intensité de la

lumière entrante.

- **Le cristallin:** est la structure responsable de la projection fine de l'image sur la rétine. Il baigne dans l'humeur aqueuse. Cette dernière est un liquide transparent, contenu entre la cornée et le cristallin (chambre antérieure de l'œil), et secrété par les corps ciliaires. L'humeur aqueuse est sous forme de gel, et est entourée d'une enveloppe transparente, constituée d'eau, de collagène et de glycosaminoglycanes.

1.1.2 Segment postérieur (SP)

Il est composé du vitré, de la choroïde, de la sclère et de la rétine, qui joue le rôle de récepteur de l'information lumineuse, et assure l'essentiel du processus neurologique de la vision, grâce à ses photorécepteurs, et à d'autres cellules qui traitent, et transmettent l'information visuelle vers le cerveau, par l'intermédiaire du nerf optique.

- **La rétine:** est le tissu nerveux tapissant la partie interne de l'œil. Elle reçoit le signal lumineux concentré par la cornée, et le transforme en signal électrique nerveux envoyé au cerveau. Il s'agit d'un tissu neuronal très fin (de 0.1 à 0.5 mm d'épaisseur), organisée en dix couches de cellules (Figure 1.2).

La rétine possède une **macula**, qui est une zone de la rétine, située à côté du nerf optique, et qui est responsable de la vision centrale, et de l'acuité visuelle. Elle est caractérisée par la présence d'une petite région, où se situe le point focal postérieur du système optique, la **fovéa** (la zone rétinienne la plus sensible). Cette dernière est la région la plus riche en photorécepteurs, de type cônes, responsables de la vision diurne.

- **La choroïde:** La choroïde appartient à la tunique intermédiaire de l'œil (l'uvée). Pigmentée par des mélanocytes, cette membrane est fortement vascularisée, permettant ainsi l'apport de nutriments et d'oxygène aux photorécepteurs de la rétine. Elle s'épaissit dans le segment antérieur, pour former l'iris et les corps ciliaires.

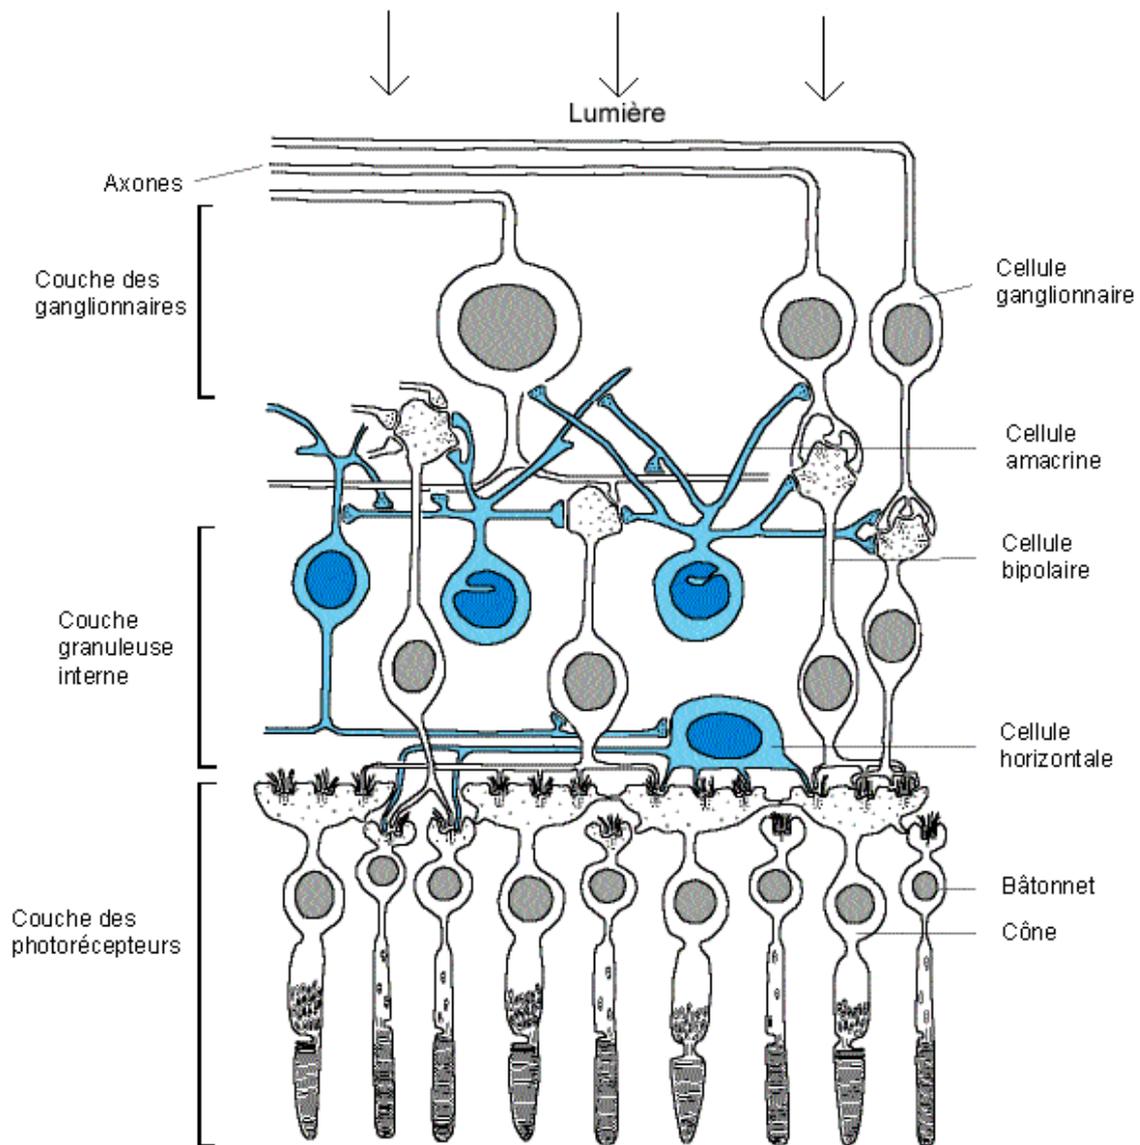


FIGURE 1.2: Représentation schématique d'une coupe de la rétine.

- **La sclère:** également appelée sclérotique (signifiant 'dur' en grec), correspond au blanc de l'œil. Elle constitue la tunique externe du segment postérieur, et se prolonge dans le segment antérieur jusqu'à la cornée. Elle enveloppe ainsi les 5/6 du globe oculaire, assurant sa rigidité et son tonus. Ce tissu de protection, a une structure tendineuse, particulièrement résistante, permettant de contenir la pression intraoculaire, tout en protégeant l'œil des agressions mécaniques et thermiques.

La vision est un processus complexe, au cours duquel la lumière entre par la cornée, et est transmise vers le cristallin, qui la concentre sur la rétine. Cette énergie lumineuse active les neurones des photorécepteurs de la rétine, où la lumière est convertie en un

signal électrique. Ce dernier est transmis vers le cerveau, le long du nerf optique, pour former les images que nous percevons.

1.2 Glaucome

Le glaucome est une maladie de l'œil qui affecte le nerf optique. Il est souvent dû à une élévation anormale de la pression dans l'œil, appelée **hypertension oculaire**. Il entraîne une perte graduelle et irréversible du champ visuel, pouvant mener à la cécité[4] [5].

Cette maladie se produit généralement pour les deux yeux, mais, une hypertension oculaire commence souvent à s'accumuler dans un œil. Ces dommages peuvent provoquer des modifications visuelles graduelles, et une perte de la vue. Souvent, la vision périphérique (côté) est affectée en premier, de sorte que le changement de vision peut être suffisamment petit, pour ne pas être remarqué. Avec le temps, même la vision centrale (directe) commencera à être perdue (Figure 1.3).



FIGURE 1.3: Vision normale, Glaucome précoce, Glaucome avancé, Glaucome sévère.

Dans les formes les plus courantes du glaucome, la pression de l'œil s'accumule très lentement. Souvent, il n'y a pas de symptômes inconfortables ou douloureux. Dans les

formes moins courantes, les symptômes peuvent être plus graves. Ces symptômes peuvent inclure :

- Une Vision floue;
- Une douleur oculaire et à la tête;
- Des nausées ou vomissements;
- L'apparition de cercles colorés en arc-en-ciel autour des lumières vives;
- Une perte soudaine de la vue.

Le glaucome touche des personnes de tout âges, des bébés, aux personnes âgées. Bien que tout le monde puisse être sujet à un glaucome, les personnes à risque le plus élevé, comprennent les personnes de plus de 60 ans, les personnes ayant un historique familial du glaucome, les personnes d'origine africaine, asiatique ou hispanique, les personnes qui utilisent des stéroïdes, et les personnes ayant une pression oculaire élevée, ou qui ont été blessées aux yeux.

Les pertes de vue résultantes du glaucome sont irréversibles. Cependant, une détection précoce et un traitement soigneux, tout au long de la vie avec des médicaments, ou une chirurgie peuvent maintenir la vision.

1.2.1 Epidémiologie

Le glaucome est la principale cause de la cécité irréversible dans le monde (Figure 1.4). Le nombre de personnes atteintes du glaucome dans le monde, était estimé à 64.3 millions en 2010, passant à 76.0 millions en 2020, et prévisionnellement à 111.8 millions en 2040. La prévalence varie selon les régions géographiques, et est la plus élevée en Afrique (4.20% de la population africaine)[6].

En Algérie, une enquête nationale a été réalisée en 2008 [7], dans le but d'évaluer la prévalence des principales causes de cécité dans la population algérienne, âgée de 40 ans

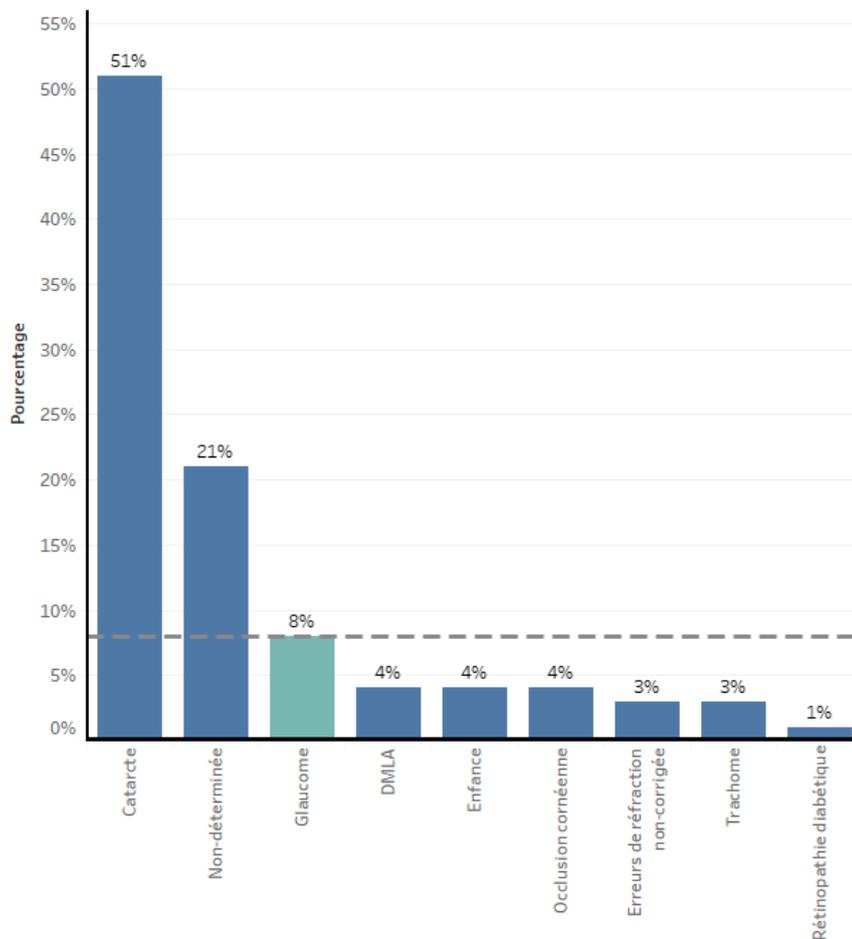


FIGURE 1.4: Premières causes de cécité dans le monde en 2010, Source: The World Health Organization (WHO).

et plus. La prévalence du glaucome a été estimée à 4.9% de la population. Ce taux est plus important dans les régions du Sud, qui sont moins médicalisées. Seulement 1.6% des patients étaient connus et traités, alors que 3.3% ont été dépistés lors de l'enquête.

Ainsi, le glaucome apparaît comme la deuxième cause de cécité en Algérie, après la cataracte, et juste avant le diabète. Avec 450.000 à 500.000 glaucomateux en Algérie, la population du sud du pays est particulièrement exposée[7].

1.2.2 Formes du glaucome

La classification du glaucome est basée principalement sur les mécanismes, par lesquels le drainage de l'humeur aqueuse est réduit, conduisant à une augmentation de la Pression Intra-Oculaire (PIO) [8]. Fondamentalement, la maladie peut être classée en glaucome primitif (ou primaire), dans lequel il n'y a pas d'autre cause secondaire ou distante de l'élévation de la PIO, glaucome secondaire, dans lequel l'élévation de la PIO résulte d'une autre maladie oculaire, et le glaucome développemental (ou congénital), dans lequel l'élévation de la PIO résulte d'anomalies développementales de l'angle irido-cornéen (l'angle formé par l'iris et la cornée) de la chambre antérieure, survenant pendant la période embryonnaire.[9]

Le glaucome primaire est divisé en glaucome primaire à angle ouvert (qui englobe à la fois le glaucome primaire à angle ouvert conventionnel, et le glaucome à tension normale), et le glaucome primaire à angle fermé.

a. Glaucome à angle ouvert

Le glaucome à angle ouvert est le type chronique, et le plus connu de la maladie, comptant 90% des cas de glaucome [6]. Dans cette forme, l'angle entre l'iris et la cornée (angle irido-cornéen) est bien ouvert, mais le drainage de l'humeur aqueuse est lent, par rapport à sa production, du fait de l'amincissement des canaux de drainage, il en résulte alors une élévation anormale de la pression intra-oculaire (Figure 1.5).

b. Glaucome à angle fermé

Cette forme est due au blocage des canaux de drainage, par l'effet de la fermeture de l'angle (Figure 1.6). Il en résulte alors une élévation soudaine de la pression de l'œil. Les symptômes et les dommages dus à ce type sont généralement plus rapides et perceptibles, ce qui exige une intervention médicale immédiate.

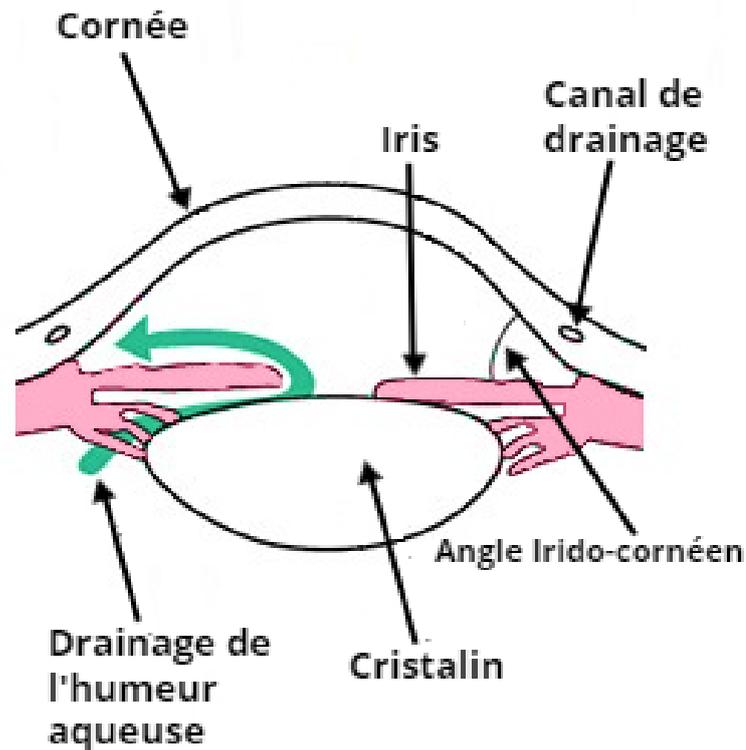


FIGURE 1.5: Aspect anatomique d'un angle irido-cornéen ouvert.

c. Glaucome congénital

Le glaucome congénital, ou d'une manière générale les glaucomes de l'enfant, regroupent un vaste ensemble de problèmes différents, dont l'approche diagnostique et thérapeutique est très différente du glaucome de l'adulte [10]. Cette forme de glaucome correspond à une anomalie de développement d'origine génétique, qui entraîne au cours des trois premières années de la vie, une augmentation de la PIO, et par la suite, éventuellement, un glaucome. Cette anomalie de développement peut être isolée, ou associée à d'autres malformations oculaires ou générales.

d. Glaucome à pression normale

Comme son nom l'indique, cette forme rare de glaucome survient, alors que la tension intra-oculaire est normale, mais, qu'il existe des lésions visibles, au niveau du nerf optique. Dans ce cas, il est probable que le nerf optique soit anormalement sensible, ou souffre moins, d'un excès de tension oculaire, que d'une irrigation insuffisante, par les

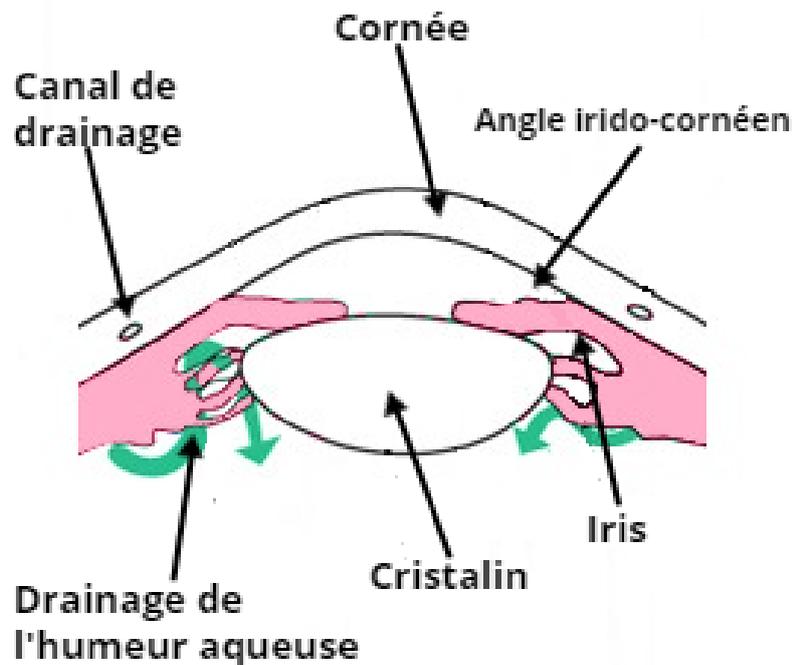


FIGURE 1.6: Aspect anatomique d'un angle irido-cornéen fermé.

vaisseaux sanguins qui l'entourent. Cette forme de glaucome nécessite la prise en charge de tous les facteurs de risque vasculaires (tension artérielle et diabète). Une prise en charge par le médecin généraliste est donc également nécessaire.

1.3 Diagnostic du glaucome

Le diagnostic et l'évaluation du glaucome sont basés sur quatre paramètres :

- La pression intraoculaire (POI), ou **la tonométrie**, qui peut se mesurer à l'aide d'un tonomètre, entrant en contact avec l'œil, ou des systèmes non-contact à air pulsé, et bientôt par des capteurs enregistrant la pression sur tout le long du jour;
- L'angle irido-cornéen, qui peut désormais s'évaluer par un OCT (Optical Coherence Tomography);
- L'aspect du nerf optique, visible généralement par l'examen fond d'œil, permettant de mesurer très précisément la perte des fibres nerveuses, qui constituent le nerf optique;

- Le champ visuel, pour mesurer le retentissement du glaucome sur la fonction visuelle, en particulier dans la périphérie de la vision, qui est très longtemps la seule à être touchée [11].

Tous ces systèmes bénéficient de technologies avancées et automatisées, permettant un diagnostic précis, et un suivi rigoureux de la stabilité des lésions du nerf optique, et de l'atteinte de la fonction visuelle [12].

1.3.1 Glaucome et la pression interne de l'œil

Un certain nombre de conditions, telles que le glaucome congénital et le glaucome à angle fermé, montrent clairement qu'une augmentation de la PIO est suffisante pour entraîner une neuropathie optique glaucomateuse.

Cependant, les médecins ont progressivement compris que le glaucome pouvait survenir, même lorsque la pression oculaire était normale, ce qui complique parfois le diagnostic. Aujourd'hui, la pression oculaire est considérée comme un facteur de risque majeur du glaucome, et pas un outil de diagnostic de cette pathologie oculaire.

Remarque: Une pression intraoculaire est considérée élevée, si elle dépasse 21 mm Hg (La valeur moyenne de la pression oculaire dans la population est de 15 mm Hg).

La tonométrie est un examen qui permet de mesurer la pression intra-oculaire. En effet, une pression existe au sein du globe oculaire, et est assurée par le corps vitré, et contrôlée par la sortie de l'humeur aqueuse. Elle peut être mesurée de deux manières:

- **Tonométrie d'aplanation:** la surface de l'œil est insensibilisée avec des gouttes oculaires. Le menton et le front sont appuyés sur l'appareil d'examen (appelé lampe à fente). La lampe à fente est équipée d'une petite sonde de mesure, appliquée directement sur la surface de l'œil, et exerce une légère pression sur l'œil. La valeur de la pression intra-oculaire est obtenue par rapport à la déformation de la cornée (le temps mis par la cornée pour s'aplatir).

- **Tonométrie sans contact:** lors de ce procédé, les gouttes oculaires ne sont pas nécessaires, car la surface des yeux n'est pas touchée (méthode sans contact). L'appareil délivre un jet d'air indolore, court, mais puissant, sur l'œil maintenu ouvert. Ce jet d'air aplatit légèrement la surface de l'œil. L'appareil enregistre cette légère déformation de l'œil, et calcule en conséquence la pression intra-oculaire.

1.3.2 Glaucome et l'imagerie médicale

La détection des dommages et de changements structurels dus au glaucome, est l'un des aspects les plus importants, et les plus difficiles de la gestion du glaucome. Ces dernières années, les instruments d'imagerie fournissant des mesures quantitatives, et objectives de l'amincissement du bord neuro-rétinien, de l'atrophie de la couche des fibres nerveuses rétiniennes (RNFL), et de l'excavation du cup optique, sont de plus en plus utilisés dans la gestion clinique des patients atteints de glaucome.

Le développement rapide de ces techniques d'imagerie, permet aux cliniciens, de mieux gérer les patients du glaucome en exploitant plusieurs modalités, au lieu de s'appuyer sur un seul outil de diagnostic. Aussi, la plupart des instruments incluent une base de données normative avec des analyses indiquant si une mesure est «en dehors des limites normales», ou «dans les limites normales». En outre, chacun fournit une mesure de la qualité de l'image, afin que le clinicien puisse déterminer si l'image est de qualité suffisante, pour être utilisée dans les décisions de gestion clinique [13].

a. Fond d'œil

L'imagerie du fond d'œil est largement utilisée pour identifier le glaucome, en examinant la rétine et la tête du nerf optique pour détecter les signes de lésions du glaucome. La Figure 1.7 montre les points de repère les plus importants dans une image fond d'œil d'un sujet sain. Dans cet examen, appelé **ophtalmoscopie**, les médecins ophtalmologues cherchent des signes indiquant qu'une perte structurelle des cellules ganglionnaires et de leurs fibres s'est déjà produite. Les cellules ganglionnaires sont dispersées sur toute la rétine et leurs fibres convergent vers la tête du nerf optique, comme des routes menant à

une grande ville. La couche de fibres nerveuses devient assez épaisse juste au niveau de la tête du nerf optique, et au fur et à mesure que les fibres s'empilent, et plongent dans l'ouverture. La tête du nerf optique, souvent appelée **disque optique**, est principalement remplie de fibres. Il reste de l'espace au milieu du disque optique, appelée **cup optique**, et les fibres sont regroupées autour de ce dernier dans le bord neuro-rétinien [14].

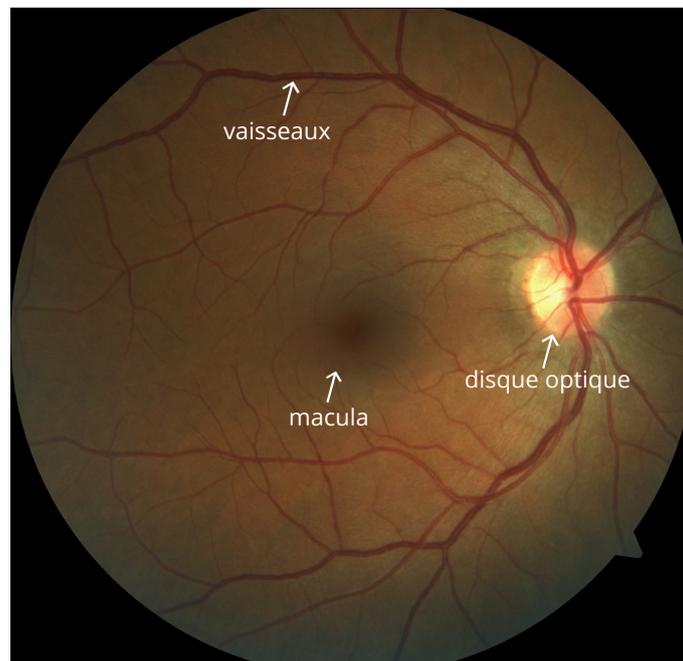


FIGURE 1.7: Aspect photographique d'un fond d'œil sain.

Nous voulons tous avoir beaucoup de fibres nerveuses, et donc un gros bord neuro-rétinien (et par soustraction, une petite excavation). Lorsque nous comparons la taille du cup optique, à la taille du disque entier, nous parlons d'un rapport cup/disque (Cup to Disc Ratio: CDR). Plus ce rapport est grand, plus il y a d'espace vide dans la tête du nerf optique. Cet espace peut être créé lorsque les cellules nerveuses meurent. La plupart des personnes dans la population ont en moyenne un rapport cup/disque d'environ 0.4. Un rapport plus important que cette moyenne, soulève le soupçon que le glaucome a peut-être déjà commencé (Figure 1.8).

De plus, le bord neuro-rétinien dans les yeux sains, montre une configuration caractéristique. Il est généralement le plus large dans le bord inférieur, suivi des bords supérieur et nasal, et le plus mince dans le bord temporal (Figure 1.9). C'est la loi ISNT

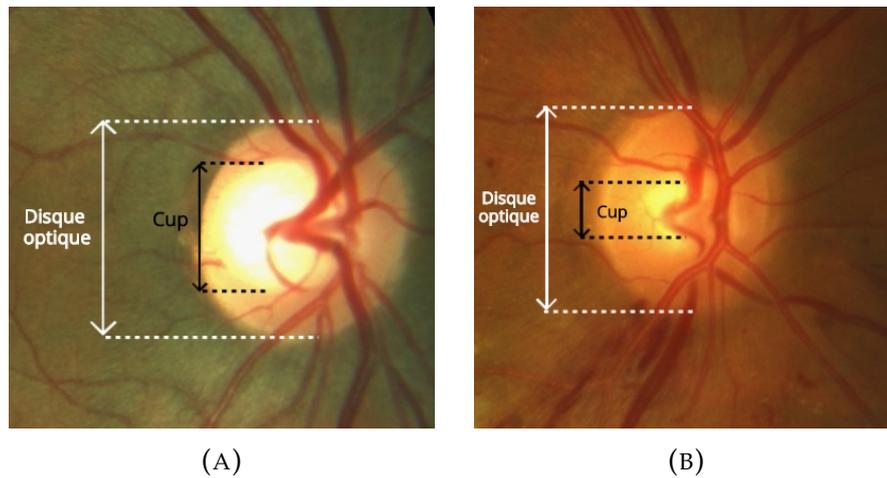


FIGURE 1.8: Changement structurel de l'excavation et le disque optique. (A) cas de glaucome, (B) cas sain.

(Inferieur > Supérieur > Nasal > Temporal) [15].

Cependant, une étude récente utilisant des photographies du disque optique, a remis en cause la valeur de cette règle dans le diagnostic du glaucome [15]. En utilisant des images SD-OCT de l'épaisseur de la couche de fibres nerveuses rétiniennes pré-papillaires, la sensibilité de la règle ISNT pour différencier le glaucome précoce et un disque normal n'était que de 63.2%, avec une spécificité de 50%.

Pour différencier le glaucome précoce du cas normal, d'autres paramètres visuels et oculaires sont plus fiables que la règle ISNT.

En raison des grandes variations de l'aspect normal du disque, des difficultés de diagnostic peuvent survenir. L'influence de la taille du disque optique, ou des changements focaux du bord neuro-rétinien n'a pas été prise en compte par le CDR. Les grands disques ont des CDR plus grands (mais peuvent avoir des bords neuro-rétiniens normaux), et sont donc plus susceptibles d'être classés comme glaucomeux. Alors que les plus petits étaient plus susceptibles d'être classés comme normaux, malgré qu'ils pouvaient montrer des dommages glaucomeux au niveau de la tête du nerf optique. L'échelle de probabilité de dommages du disque (Disc Damage Likelihood Scale: DDLS) a été énoncée par Spaeth et al. [16], pour intégrer la taille du disque et la largeur du bords neuro-rétinien

dans un tableau de classement clinique en 2002, et elle a montré une reproductibilité inter-observatrice élevée.

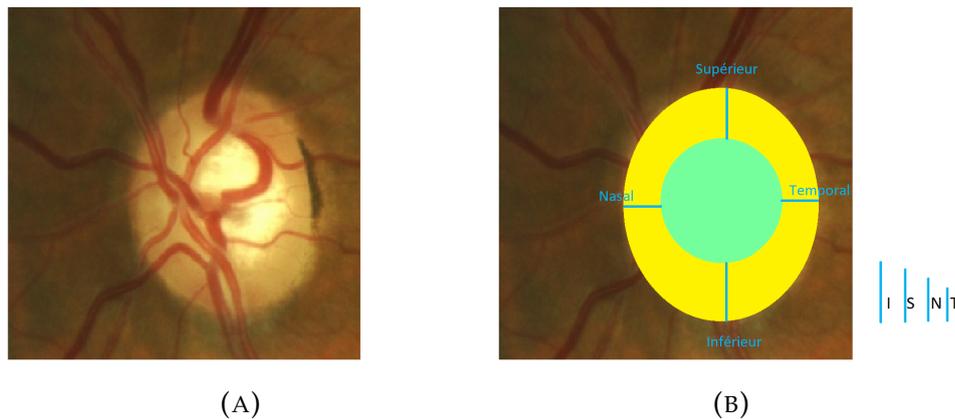


FIGURE 1.9: Évaluation clinique de la règle ISNT pour un nerf optique normal. (A) disque optique, (B) mesures ISNT.

Cette échelle est mesurée en calculant le rapport entre l'épaisseur minimale du bord neuro-rétinien, et le diamètre du disque optique. Si l'épaisseur est nulle (pas de bord neuro-rétinien) l'angle de l'intersection est mesuré (Figure 1.10).

Sévérité du glaucome	L'échelle DDLS	Rapport DDLS
Disque non endommagé	1	0.4 ou plus
	2	Entre 0.9 et 0.39
	3	Entre 0.2 et 0.29
	4	Entre 0.1 et 0.19
Dommage de glaucome	5	Moins que 0.1
	6	0 avec un angle inférieur à 45°
	7	0 avec un angle entre 46° et 90°
Neuropathie optique glaucomateuse	8	0 avec un angle entre 91° et 180°
	9	0 avec un angle entre 181° et 270°
	10	0 avec un angle supérieur à 270°

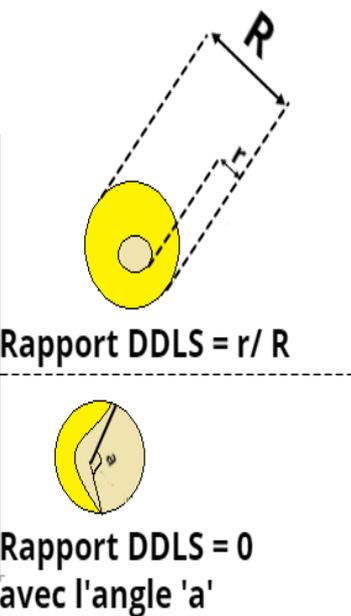


FIGURE 1.10: Mésures de l'échelle DDLS.

b. Déroulement de l'examen de fond d'œil

Une dilatation de la pupille est nécessaire afin de visualiser plus nettement les différentes structures de l'œil. Cette dilatation est réalisée à l'aide d'un collyre. Ce collyre

est dit « mydriatique», et doit être instillé dans l'œil au moins 30 minutes avant l'examen, afin de permettre son efficacité.

A la suite de l'examen, la vision reste floue pendant quelques heures. Il est contre indiqué de conduire immédiatement après l'examen, et la présence d'un tiers est conseillée après un fond d'œil. Le port de lunettes de soleil après l'examen peut également être conseillé, en raison du risque d'éblouissement important, secondaire à la dilatation de la pupille réalisée.

Le collyre utilisé peut provoquer une sensation passagère de brûlure, voire un goût désagréable dans la bouche. Cette sensation disparaît au bout de quelques secondes. Une fois les pupilles complètement dilatées (soit 20 à 45 minutes après l'instillation du produit), l'examen lui-même peut débiter.

L'examen dure 5 à 10 minutes, et mobilise l'une des techniques suivantes :

- **Fond d'œil par ophtalmoscopie indirecte (ou à image inversée)**

Cette méthode permet d'obtenir une image inversée de tout le fond de l'œil, et d'observer le relief de la rétine. Pour cela:

1. Le médecin pose sur son front un ophtalmoscope binoculaire (appareil optique utilisé ici comme source lumineuse);
2. Il allume sa lumière frontale, puis il prend une puissante lentille convergente (faisant converger les rayons lumineux), et la tient à bout de bras, entre lui et l'œil du patient. Ainsi, une image de la rétine se forme sur la lentille, et le praticien peut l'étudier.

La Figure 1.11 montre un examen de fond d'œil par ophtalmoscopie indirecte fait à l'hôpital Frantz Fanon.

- **Fond d'œil par biomicroscopie (ou lampe à fente)**



FIGURE 1.11: Examen du fond d'œil à l'ophtalmoscope indirect.

Cette technique permet d'analyser très finement les détails du fond de l'œil. L'examen comprend plusieurs étapes :

1. Le médecin vous fait asseoir le patient devant une lampe à fente (microscope produisant un faisceau lumineux, qui éclaire l'intérieur de l'œil);
2. Il positionne son menton et son front sur les supports prévus à cet effet, et il regarde la direction indiquée par l'ophtalmologiste ;
3. Grâce à la lumière, l'ophtalmologiste peut observer les yeux à travers le microscope, pour obtenir l'image de la rétine.

Remarque: Cet examen entraîne une petite gêne visuelle pendant quelques heures, du fait de la dilatation de la pupille. La vision peut être un peu floue, et l'on peut être gêné par une forte luminosité. On évite donc de travailler sur écran, ou de conduire pendant les 2 heures qui suivent la visite.

c. Tomographie par lumière cohérente (OCT)

La tomographie par cohérence optique (OCT) est une modalité d'imagerie non invasive, relativement récente. Elle a été introduite par Huang et al. en 1991 [17], et fournit une vue en coupe 3D de haute résolution des tissus tapissant la rétine, en utilisant les propriétés de réflectivité de la lumière infrarouge. Un exemple de volume OCT est illustré

dans la Figure 1.12. Les volumes OCT sont composés d'une série de coupes 2D, appelées B-scans, et chaque B-scan comprend une série de d'images colonnes 1D, appelées les A-scans, qui se trouvent dans la direction parallèle à la propagation de la lumière vers le tissu. Le tissu intra-rétinien est une structure multicouche, qui transforme la lumière en signaux neuronaux, pour une analyse ultérieure par le cerveau. Il est généralement divisé en 7 couches, adjacentes séparées par 8 frontières. Les couches intra-rétiniennes, ordonnées de haut en bas, sont les suivantes (Figure 1.12):

1. **Membrane Limitante Interne:** en anglais Internal Limiting Membrane (ILM), est la frontière entre la rétine et les corps ciliaires;
2. **Couche des Fibres Nerveux :** en anglais Retinal Nerve Fibre Layer (RNFL), est la couche des fibres axonales des cellules ganglionnaires;
3. **Couche des Cellules Ganglionnaires + Couche Plexiforme Interne :** en anglais Ganglion Cell Layer (GCL) et Inner Plexiform Layer (IPL), elle contient les noyaux des cellules ganglionnaires, dont les axones deviennent les fibres nerveuses optiques, qui transportent le signal généré vers le cerveau;
4. **Couche Nucléaire Interne :** en anglais Inner Nuclear Layer (INL), est la couche des corps cellulaires, et des noyaux des neurones intégrateurs;
5. **Couche Plexiforme Externe :** en anglais Outer Plexiform Layer (OPL), est la couche des parties synaptiques de la tige, et des cellules coniques;
6. **Couche des photorécepteurs :** subdivisée en segments internes (Inner Segments : IS), et segments externes (Outer Segments : OS);
7. **Épithélium Pigmentaire rétinien :** en anglais Retinal Pigment Epithelium Layer (RPE), couche de cellules cuboïdes ; imprégnées de mélanine, chargées de fournir une nutrition essentielle, et d'éliminer les déchets des cellules photoréceptrices.

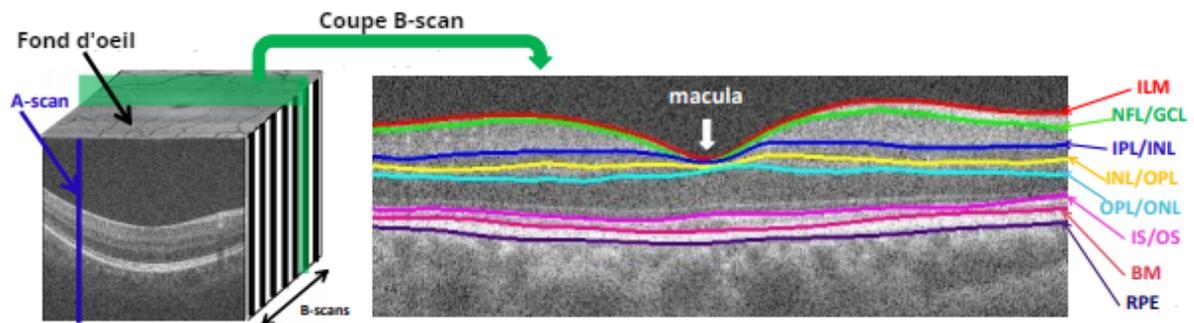


FIGURE 1.12: Un volume OCT 3-D composé d'une série de coupes transversales appelées B-scans. Chaque profil de colonne 1-D dans un B-scan est appelé un A-scan. Le tissu rétinien est composé de plusieurs couches qui sont représentées sur un B-scan maculaire du volume OCT.

d. OCT et glaucome

La tomographie par cohérence optique est particulièrement utile dans les cas du glaucome, car elle fournit une évaluation quantitative et objective des couches cellulaires rétiniennes, ce qui permet d'assurer un diagnostic et un suivi plus précis du glaucome. Un des principaux changements structurels au cours de la maladie du glaucome, est la perte des fibres nerveuses rétiniennes, et des cellules ganglionnaires maculaires, au niveau de la région pré-papillaire, et au centre du macula, respectivement. Cette perte progressive et chronique est une caractéristique de la maladie, et a été suggérée comme un critère pour le diagnostic du glaucome dans les études cliniques de la maladie [18].

En cas de glaucome, l'OCT est utile pour l'analyse de l'épaisseur de la couche des fibres nerveuses rétiniennes (RNFL), en une localisation normalisée autour de la tête du nerf optique. Pour ceci, l'OCT produit un balayage circulaire autour du disque optique, à partir duquel la couche RNFL peut être visualisée et analysée (Figure 1.13.(A) et (B)). En plus, des balayages radiaux à travers le disque optique sont appliqués, pour détecter et évaluer les déformations du cup (Figure 1.13 (C) et (D)).

L'épaisseur du complexe GCC, qui constituent 30% à 35% de l'épaisseur totale de l'épaisseur maculaire (Figure 1.13 (E) et (F)), a une meilleure capacité à détecter le glaucome, en cas de myopie élevée, que l'épaisseur du RNFL péripapillaire, bien que l'épaisseur du GCC maculaire et l'épaisseur du RNFL péripapillaire soient liées à la longueur axiale.

Ainsi, l'évaluation du GCC pourrait être l'un des meilleurs paramètres pour diagnostiquer un glaucome [19].

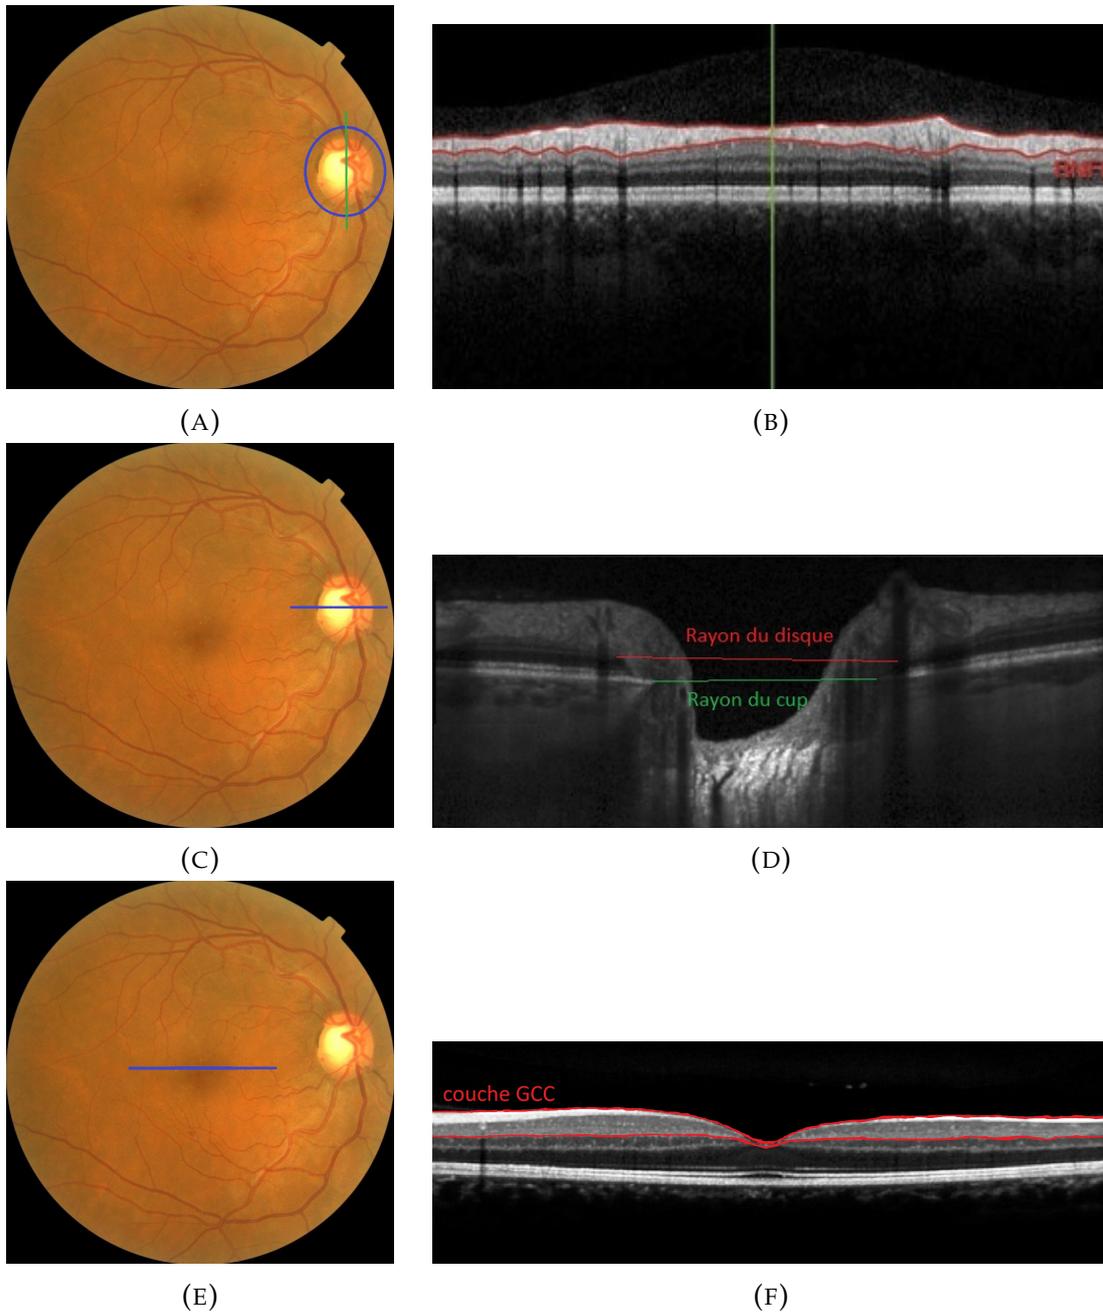


FIGURE 1.13: Différentes régions pour le diagnostic du glaucome. Première ligne: région prépapillaire, deuxième ligne: région radiale, et troisième ligne: région maculaire.

e. Imagerie de la chambre antérieure

L'évaluation de la chambre antérieure en OCT, peut offrir des informations supplémentaires, pour le diagnostic du glaucome et l'identification de sa forme. Les paramètres quantitatifs les plus utilisés sont :

- **L'angle irido-cornéen (AIC)(Figure 1.14 (B)):** défini comme l'angle entre l'iris et la cornée. En évaluant ce paramètre, on peut identifier la forme du glaucome (Glaucome à angle ouvert ou fermé);
- **La distance de l'ouverture de l'angle (DOA) (Figure 1.14 (C)):** définie comme la distance perpendiculaire, entre la cornée et la partie antérieure de l'iris, à 500 μm ou à 750 μm ;
- **La surface entre le trabéculum et l'iris (STI)(Figure 1.14 (D)):** le trabéculum qui est situé à l'intersection entre l'iris et la cornée, joue le rôle d'un filtre pendant l'évacuation de l'humeur aqueuse. Les patients ayant un angle irido-cornéen étroit, présentent une faible diminution de cette surface.

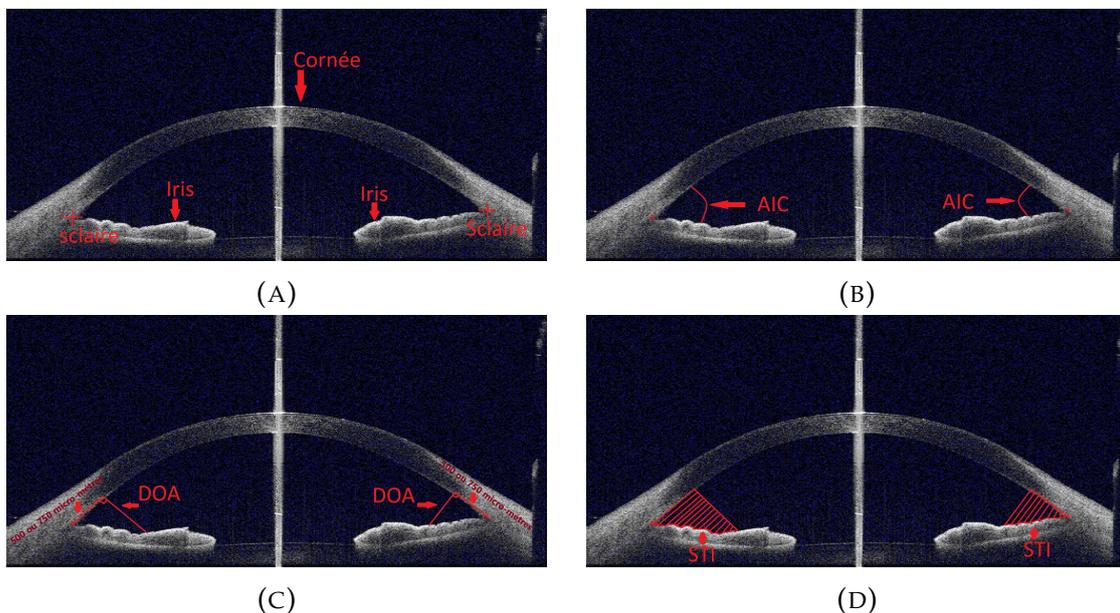


FIGURE 1.14: Exemple d'une image AS-OCT avec les paramètres à mesurer. (B) AIC, (C) DOA, (D) STI.

1.3.3 Examen complémentaire du champ visuel

L'examen du champ visuel permet au médecin de suivre cliniquement les pertes de vision causées par le glaucome, en indiquant à quoi ressemble le monde pour le patient.

Comme son nom l'indique, cet examen permet de mesurer le champ de vision du patient, et de détecter les changements qui sont non remarquables par le patient, tant que le glaucome n'a pas atteint un stade avancé.

Ils existent plusieurs types d'examens du champ visuel (CV), dont le plus utilisé est celui de Humphrey (Humphrey Visual Field). Cette méthode consiste à fixer un point lumineux au centre de la vision du patient, et à allumer des points de test au niveau de sa vision périphérique, en marquant les endroits flous en gris, et les points aveugles en noir [20].

La Figure 1.15 montre deux examens de champ visuel. A gauche, il s'agit d'un sujet sain, ne présentant aucune perte du champ visuel (les points noirs marqué à gauche sont les points aveugles normales (normal blind spot)). A droite, il s'agit d'un glaucomateux, montrant des pertes importantes au niveau de sa vision centrale et périphérique.

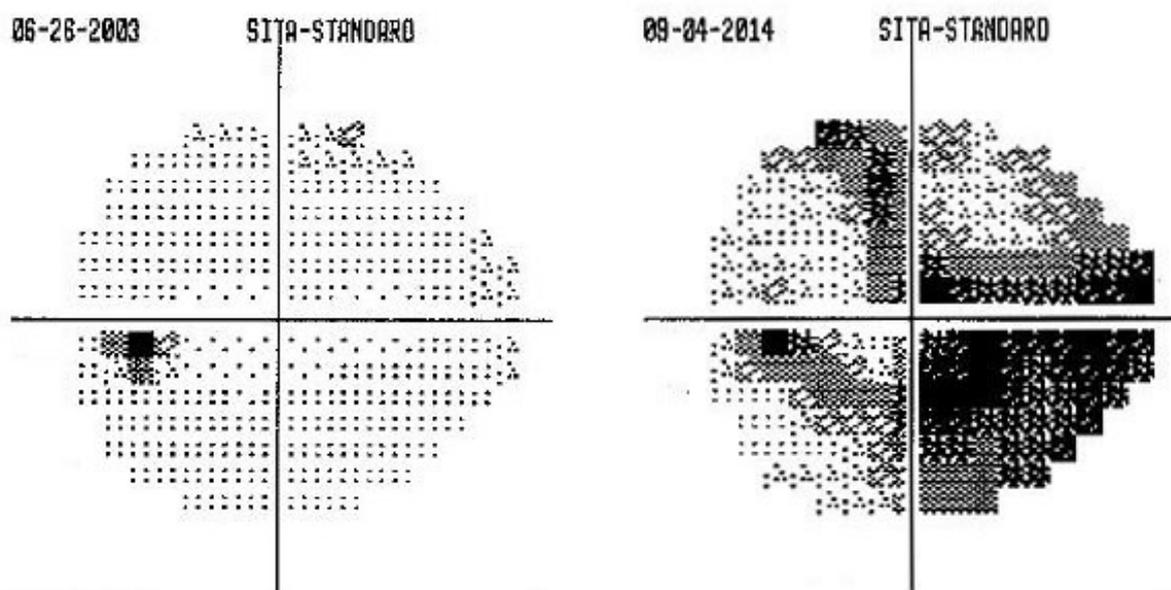


FIGURE 1.15: Exemples de l'examen de champ visuel. à gauche: sujet sain, à droite: sujet glaucomateux

Discussion

Dans ce chapitre, nous avons pu présenter le contexte médical concernant l'anatomie de l'œil, la maladie du glaucome, ainsi qu'une explication approfondie sur les différents outils de diagnostic.

La possibilité de détecter et d'évaluer la progression du glaucome, à l'aide de plusieurs modalités d'imagerie, ouvre le champ à la conception des systèmes d'aide au diagnostic, pour cette pathologie oculaire. Le chapitre suivant présente un état de l'art sur les différentes techniques existantes dans la littérature, pour la détection du glaucome.

CHAPITRE 2
ÉTAT DE L'ART

2 Etat de l'art

La capacité à détecter automatiquement les pertes des fibres nerveuses, dans les images rétiniennes, conduit naturellement au développement des systèmes informatiques, pouvant générer un diagnostic automatique du glaucome.

Ce diagnostic peut être utilisé, soit comme une suggestion pour l'ophtalmologue (Diagnostic Assisté par Ordinateur ou DAO), ou comme un système de dépistage individuel, ou de masse pour la maladie du glaucome. Ce dernier est l'application qui apporterait le plus de bénéfices aux patients atteints du glaucome.

2.1 Bases de données rétiniennes

Plusieurs bases de données rétiniennes sont gratuitement accessibles aux chercheurs. Dans cette section, nous discutons les référentiels disponibles pour le diagnostic du glaucome, ainsi que d'autres pathologies rétiniennes. Les chercheurs peuvent utiliser ces bases de données, au lieu de passer par le processus de 'Collection de Données' pendant chaque étude.

La plupart de ces bases de données sont destinées aux études de diagnostic de la rétinopathie diabétique, et peu sont liées au glaucome. Par conséquent, il y a un besoin de bases de données référentielles supplémentaires, afin d'améliorer sa compréhension. Les tables 2.1 et 2.2 présentent un résumé des bases de données disponibles, contenant des images rétiniennes.

TABLE 2.1: Bases de données des images rétiniennes (fond d'œil).

Base de données	Images		Résolution	Pathologies			Vérité terrain
	Saines	Pathologiques		Glaucome	Rétinopathie	Autre	
DRION-DB [21]		110	600x400		—		Segmentation: disque optique
HRF [22]	15	30	3504x2336	✓	✓		Segmentation: disque optique, fovéa et vaisseaux
ORI GA [23]	482	168	3072x2048	✓		✓	classification
DRIVE [24]	7	33	768x584		✓	✓	Segmentation: vaisseaux
MESSIDOR [25]	0	1200	1440x960, 2240x1488, 2304x1536		✓	✓	classification
RIM-ONE [26]	118	51	—	✓		✓	Segmentation: disque optique
DIARETBD1 [27]	5	84	1500x1152		✓		Segmentation: lésions
Drishti-GS [28]	31	80	2049x1757	✓			Segmentation: disque optique

TABLE 2.2: Bases de données des images rétiniennes (OCT).

Base de données	Volumes		Résolution	Pathologies			Vérité terrain
	Sains	Pathologiques		Glaucome	Rétinopathie	Autre	
AROI	0	25	128x1024x512		✓	✓	Segmentation: Frontières des couches maculaires
OCTID[29]	206	264	500x1024x512		✓	✓	Classification
R. Rasti et al. [30]	50	98	...x1024x512		✓	✓	Classification
T. Mahmudi et al. [31]	50	0	128x1024x512			
M. Golabba-khsh et al. [32]	0	22	128x1024x512	✓		✓	Segmentation et recalage des vaisseaux

2.2 Analyse des images fond d'œil pour le dépistage du glaucome

En détectant les défauts de la couche des fibres nerveuses, qui sont reliés à l'amincissement anormal du bord neuro-rétinien, le glaucome peut être facilement détecté, en mesurant des indicateurs extraits des images fond d'œil, comme : le rapport CDR, la vérification de la loi ISNT, la mesure de l'échelle DDLS ...etc. Certains des travaux récents sont discutés ci-dessous.

2.2.1 Etat de l'art des systèmes d'aide au diagnostic du glaucome (fond d'œil)

Le développement d'une méthode de diagnostic simple du glaucome utilisant des images du fond d'œil, a été proposé par **N. Inoue et al. (2005)** [33]. Ils décrivent un algorithme d'analyse de l'histogramme de l'image fond d'œil, pour déterminer les seuils à utiliser par la suite pour la segmentation du cup, et du disque optiques. Bien que le rapport CDR a été mesuré dans ce travail, aucun résultat clair n'est donné, et les images utilisées pour les tests ne sont pas clairement décrites.

Une approche basée sur un modèle déformable, est présentée par **J. Xu et al. (2007)** [34], pour une détection robuste des contours du disque et du cup optiques. Dans cette méthode, le contour se déforme vers l'emplacement où l'énergie est minimale, puis, il s'auto-agrège en deux groupes, points de contour et points incertains, qui sont mis à jour, à l'aide d'informations locales et globales de l'image.

D. W. K. Wong et al. (2008) [35] ont proposé un système d'analyse d'images fond d'œil, dont le but est la détermination automatique du rapport CDR. Ils utilisent les techniques du level-set pour segmenter le disque et le cup optiques, en déterminant des contours initiaux, estimés après l'analyse des histogrammes des images fond d'œil. L'erreur entre la valeur CDR réelle et celle obtenue par leur système, était de 0.0825 et 0.1465, pour les cas du glaucome et les cas sains, respectivement.

J. Nayak et al. (2008) [36] ont présenté une nouvelle méthode pour la détection du glaucome, en utilisant trois paramètres : le rapport CDR, la vérification de la loi ISNT, et le déplacement de la tête du nerf optique vers le côté nasal. Le disque et le cup optiques ont été segmentés par les méthodes de seuillage, et la morphologie mathématique. Ils ont obtenu une sensibilité, spécificité et précision de 1, 0.8 et 0.9, respectivement.

S. Kavitha et al. (2010) [37] ont effectué une détection du glaucome, où le disque optique est segmenté en appliquant des opérations morphologiques sur le canal rouge de l'image fond d'œil. Le cup est segmenté par la coopération entre les contours actifs et les algorithmes d'analyse des composantes RGB. Dans leur approche, la classification finale est basée seulement sur la valeur du rapport CDR.

Un filtre de détection de contours a été proposé par **Y. Hatanaka et al. (2011)** [38], pour déterminer les frontières du disque optique. Ils ont également mis en œuvre une méthode de passage à zéro, pour extraire la zone du cup optique, et calculer le rapport CDR en se basant sur le profil vertical du disque. En utilisant 45 images, dont 23 sont des images de glaucome, un AUC de 0.947 a été obtenu avec cette méthode.

C. Ho et al. (2011) [39] ont intégré les techniques de restaurations d'images rétiniennes et les modèles de contours actifs, pour l'identification correcte des régions du disque et du cup optiques. Leur méthode se compose de deux phases majeures : la première inclut la segmentation et l'élimination de l'arbre vasculaire rétinien, et la mesure du rapport CDR avec la vérification de la loi ISNT. La seconde consiste à détecter les anomalies au niveau de l'arbre vasculaire. Cette combinaison facilite la distinction des cas sains, des cas de glaucome.

G. D. Joshi et al. (2011) [40] ont proposé une nouvelle approche pour la segmentation robuste du disque et du cup optiques. Leur étude est basée sur l'analyse des paramètres géométriques, des points d'intérêt autour du disque optique, dans un espace de paramètres multidimensionnel. Ils présentaient aussi une nouvelle segmentation du cup optique basée sur les caractéristiques anatomiques, comme les courbes des vaisseaux sanguins au niveau de la frontière du cup. Leur étude a été évaluée sur 138 images, dont 105 images présentaient un glaucome, et montrait une robustesse importante contre les variations géométriques, et photométriques trouvées dans la base de données, avec une erreur moyenne du rapport CDR vertical calculé de 0.09.

F. Yin et al. (2012) [41] ont présenté une méthode basée sur un modèle statistique de l'image fond d'œil, pour la segmentation des disque et cup optiques. Leur système combine les algorithmes de sélection optimale des canaux RGB, et la transformée de Hough. La méthode a été testée dans une base de données de 325 images fond d'œil, et a obtenu un coefficient de Dice de 0.91, et 0.81 pour la segmentation des disque et cup respectivement, et une erreur absolue de 0.1 pour le calcul du rapport CDR.

D. W. K. Wong et al. (2012) [42] localisaient le disque optique en extrayant une région d'intérêt, en détectant les pixels de haute intensité, et en prenant le centre et le rayon comme référence. Ensuite, l'approche du Level-set variationnelle a été utilisée pour la segmentation du disque, en considérant le contour de la région d'intérêt comme contour initial. Pour la segmentation du cup, l'approche Level-set basée sur le seuillage est appliquée dans le canal vert de l'image, afin d'extraire la région cup dans le disque optique. Cet algorithme est testé sur la base de données publique ORIGA, contenant 650 images fond d'œil, et a obtenu une erreur moyenne de 0.04 pour la mesure automatique du CDR.

Y. Xu et al. (2013) [43] ont proposé une classification des superpixels, pour la localisation automatique et précise du cup optique, dans les images fond d'œil numériques. Dans ce travail, un Clustering Itératif Linéaire Simple (SLIC) est utilisé pour diviser l'image en superpixels, et une classification SVM, basée sur les paramètres de couleur, intensité et information locale est réalisée pour séparer les pixels du cup, des pixels du bord neuro-rétinien. La base de données ORIGA est utilisée pour évaluer la méthode, qui a obtenu une erreur absolue du CDR mesuré de 0.104.

J. Cheng et al. (2013) [44] proposent une nouvelle approche de segmentation du disque et du cup optiques, par la classification des superpixels dans les images fond d'œil. Pour la segmentation du disque, l'analyse d'histogramme et les paramètres statistiques du centre du disque, sont utilisés pour la classification. Pour la segmentation du cup, ils ont ajouté les paramètres de localisation au vecteur de paramètres. Leurs segmentations ont été évaluées dans une base de données de 650 images, et ont présentées une erreur

moyenne de 9.5%, et 24.1% pour le disque, et le cup respectivement.

M. Rama et al. (2013) [45] ont proposé un système pour l'identification automatisée des classes normales et des classes de glaucome, en utilisant les algorithmes des spectres d'ordre supérieur (High Order Spectra : HOS), et la transformée de Trace (Trace Transform : TT). Les caractéristiques extraites par ces deux algorithmes sont transmises à un classificateur SVM avec une fonction linéaire, polynomiale d'ordre 1, 2 et 3, et une fonction radiale, afin de sélectionner le meilleur noyau pour la prise de décision. Le classificateur SVM avec la fonction polynomiale d'ordre 3, a pu détecter les images présentant un glaucome et les images normales, avec une précision de 0.916, et une sensibilité et une spécificité de 0.90, et 0.93 respectivement, surpassant les autres classificateurs.

N. M. Nour et al. (2013) [46] ont proposé une autre approche pour la segmentation du disque et du cup optiques. L'algorithme commence par la séparation des canaux RGB, et l'extraction des régions d'intérêt. Dans chacun de ces canaux, une analyse statistique est réalisée, afin de déterminer un seuil multiple, qui segmente les deux régions du disque et du cup. Bien que le rapport CDR soit mesuré dans ce travail, aucune décision n'est prise pour le diagnostic du glaucome.

J. A. De la Fuente-Arriga et al. (2014) [47] ont présenté une approche pour la détection de la région du cup optique, à l'aide des points de référence dans les images fond d'œil, et la combinaison de la méthode de seuillage d'Otsu, avec les opérations morphologiques. Les centroïdes du disque optique, ainsi que les différents masques des quatre quadrants (inférieur, supérieur, nasal et temporal), ont été utilisés par la suite, pour identifier le déplacement entre les vaisseaux sanguins, et le centroïde du disque, afin de détecter la présence du glaucome. Cette méthode a réussi dans 62 images sur 67, obtenant une sensibilité de 0.93, une spécificité de 0.916, et une précision de 0.913.

N. M. Tan et al. (2014) [48] ont utilisé un classificateur SVM, les level-set et l'algorithme des superpixels SLIC, pour segmenter le disque et le cup optiques, et calculer le rapport

CDR. Comme Y. Xu et al. [43], la base de données ORIGA est utilisée pour évaluer les résultats. Une erreur moyenne de 0.248 est obtenue par l'algorithme proposé.

D. Yadav et al. (2014) [49] ont présenté une étude d'analyse des variations des paramètres de texture, lorsque l'image fond d'œil présente un glaucome. Ces paramètres sont extraits autour du cup optique, par la méthode GLCM (Gray Level Co-occurrence Matrix), et constituent l'entrée d'un réseau de neurones. Leur système a permis d'identifier le glaucome avec une précision de 0.72.

Un système d'identification automatique du glaucome a été développé par **A. A. Salam et al. (2015)** [50]. Leur algorithme fournit une nouvelle méthodologie pour détecter le glaucome, en combinant la valeur du rapport CDR, avec des paramètres hybrides de texture et d'intensité. Cette combinaison a été évaluée, en utilisant une base de données locale, composée de 50 images fond d'œil, dont 35 sont saines. Une sensibilité, spécificité et précision de 1, 0.88 et 0.92 sont obtenues, respectivement.

Une méthode similaire à Y. Xu et al. [43] a été proposée par **H. Alghmdi et al. (2015)** [51]. L'objectif est de développer une approche automatique pour la mesure du rapport CDR, afin de faciliter le dépistage du glaucome. Dans ce travail, l'algorithme du SLIC est utilisé pour l'extraction des paramètres des superpixels, qui sont utilisés pour l'apprentissage d'un classificateur de réseau de neurones, pour détecter les limites du disque et du cup optiques. Finalement, le CDR est calculé à la base de ces segmentations. Leur étude a montré, qu'en entraînant un classificateur non-linéaire sur un ensemble de paramètres consistants, le disque et cup optiques peuvent être correctement estimés, même avec des images à faible contraste. Les résultats ont également montré l'efficacité de leur approche, avec une sensibilité de 92%, et une spécificité de 88%.

A. Agrawal et al. (2015) [52] ont publié un article, où ils ont décrit une nouvelle méthode de diagnostic assisté par ordinateur, pour la détection automatique du glaucome. Ils ont proposé une technique d'analyse d'histogramme, afin d'étudier certains paramètres

statistiques de l'image fond d'œil, pour déterminer une valeur de seuil consistante, capable de segmenter le disque et le cup optiques. Bien que leur décision fût basée seulement sur la valeur du rapport CDR, les résultats expérimentaux qu'ils ont obtenu révèlent une précision de 0.9. La même équipe dans [53] a ajouté les paramètres de l'épaisseur du bord neuro-rétinien, avec un classificateur SVM. Ce paramètre a permis d'améliorer la performance de leur système à une précision, spécificité et sensibilité de 0.9, 1.0 et 0.8, respectivement .

Une nouvelle méthode de détection automatique du glaucome, à partir d'images numériques du fond d'œil est proposée par **A. M. Jose et al. (2015)** [54]. Leur méthodologie utilise la segmentation du disque et du cup optiques, pour mesurer le rapport CDR. Le disque optique est segmenté en utilisant des opérations morphologiques, et une méthodologie hybride de level-set. Le cup optique est segmenté en détectant d'abord les vaisseaux sanguins, à l'aide du classificateur SVM, puis les points de courbure, au niveau des vaisseaux linéaires. Leur méthodologie produit une erreur moyenne de mesure du CDR moindre que 0.021, par rapport à l'observation des experts.

La technique proposée par **W. Ruengkitpinyo et al. (2015)** [55] est basée sur l'analyse de l'épaisseur du bord neuro-rétinien, et la vérification de loi ISNT, au lieu de mesurer uniquement le rapport CDR. Dans leur approche, le cup optique est segmenté en utilisant la méthode de A. M. Jose et al. (2015) [54] (article précédent). La région segmentée du cup optique a ensuite été divisée en quatre régions d'image, pour créer des masques ISNT, de 45 degrés chacun. La précision obtenue en se basant sur le CDR seulement, et la vérification de la loi ISNT avec le CDR, est de 0.8, et 0.95, respectivement.

P. S. Mittapalli et al. (2016) [56] ont présenté deux méthodes de segmentation pour la détection des disque et cup optiques. La première, détecte le disque en utilisant le modèle de contour actif LBFE (Local Binary Fitting Energy), qui intègre des informations locales de l'image, en chaque point d'intérêt. La deuxième méthode détecte le cup, et est basée sur le clustering SWFCM (Spatially Weighted Fuzzy C-Means). Ils ont obtenu un F-score

de 0.945 et 0.89, pour la segmentation du disque et du cup ,respectivement.

A. Diaz et al. (2016) [57] ont proposé un algorithme automatique pour le diagnostic du glaucome. Ils utilisent les caractéristiques anatomiques de la tête du nerf optique, telles que la morphologie et la position des vaisseaux sanguins, et du cup optique, afin de faire la distinction entre un fond d'œil sain, et un fond d'œil glaucomateux. Ces caractéristiques ont été analysées dans plusieurs espaces colorimétriques, par la transformée stochastique de la ligne de partage des eaux. Leur algorithme a été évalué sur 53 images (24 images normales et 29 images glaucomateuses), et a obtenu une spécificité et une sensibilité de 0.81 et 0.87 respectivement, en utilisant l'espace colorimétrique Luv.

La vérification de la loi ISNT a été aussi utilisée par **P. Das et al. (2016)** [58]. Leur méthode utilise la transformée de la ligne de partage des eaux, et l'approximation circulaire, pour la segmentation simultanée, du disque et du cup optiques. La règle ISNT est évaluée en calculant l'aire du bord neuro-rétinien, dans les quatre quadrants ISNT. Cette méthode a été développée, et testée sur quatre bases de données accessibles au public, HRF, MESSIDOR, DRIONS-DB, RIM-ONE, et une base de données locale. Elle a atteint une sensibilité de 0.918, et une précision de 0.941.

J. Ayub et al. (2016) [59] ont basé leur étude sur la détection automatisée du glaucome, à l'aide du rapport CDR. Dans ce travail, les pixels du disque, et du cup optiques sont détectés et classés par l'algorithme conventionnel du K-means. La performance de cette méthode a été évaluée sur 100 images fond d'œil, d'une base de données locale. Elle a donné une précision moyenne de 0.92, pour l'identification du glaucome, et une erreur quadratique moyenne de 0.002, pour la mesure du CDR. L'inconvénient majeur de cette méthode, est qu'elle n'arrive pas à fournir des contours lisses à la fin de la segmentation.

Le rapport CDR est également utilisé dans le travail de **D. Patil et al. (2016)** [60]. Cette méthode est similaire à [52] , où les régions du disque et du cup optiques sont extraites par l'algorithme de multi-seuillage. Le rapport CDR est ensuite calculé dans

deux bases de données : MESSIDOR et RIM-One. Les résultats de cette méthode n'étaient pas convaincants avec une précision de 0.67, pour la détection du glaucome.

Une méthode qui applique une technique de classification non-stationnaire est proposé par **S. Maheshwari et al. (2017)** [61]. Dans ce travail, la méthode de décomposition en mode variationnel (VMD) est utilisée de manière itérative, pour décomposer l'image fond d'œil. Diverses caractéristiques, à savoir, les entropies de Kapoor, Renyi et de Yager, et les dimensions fractales, sont extraites de chaque composante VMD. Ensuite, l'algorithme de ReliefF est utilisé pour la sélection des caractéristiques discriminantes, qui sont ensuite transmises à un classificateur LS-SVM, pour la classification des fonds d'œil sains et glaucomateux. Cet algorithme a obtenu des taux de précision de 0.95 et 0.94, en utilisant des stratégies de validation croisée triple, et décuple respectivement.

K. Nirmala et (2017) [62] ont fait coopérer la transformée en ondelettes (Wavelet based Contourlet Transform: WCT), avec les filtres de Gabor. Dans cette méthode, les paramètres sont extraits des images fond d'œil, à l'aide de la transformation d'ondelettes. Ces images sont ensuite classifiées en images saines ou glaucomateuses, par un classificateur bayésien. La précision du système est de 0.89, mais elle peut encore être améliorée, en améliorant la méthode de prélèvement des vaisseaux sanguins, qui ont été éliminés par le filtre de Gabor dans ce travail.

N. Sengar et al. (2017) [63] ont proposé une nouvelle technique de détection du glaucome, mais uniquement dans les cas de suspicion. Au lieu de mesurer le rapport CDR, la décision dans ce travail, est basée sur l'apparition des hémorragies autour du disque optique, qui sont considérées comme un signe de présence du glaucome. Un total de 140 images de fond d'œil, dont 40 présentent un glaucome précoce, sont testées pour évaluer la fiabilité de leur algorithme, qui a atteint une précision de 0.935.

K. Thakkar et al. (2017) [64] ont présenté un algorithme d'extraction de quatre caractéristiques de la tête du nerf optique : le rapport CDR, la vérification de la loi ISNT, l'analyse d'intensité des pixels du cup optique et des vaisseaux sanguins, et l'analyse

géométrique du cup. Ces caractéristiques sont combinées pour classer l'image fond d'œil, dans l'une des trois classes : cas de glaucome, cas sain, ou cas non-déterminé. Cet algorithme est testé dans la base de données 'STARE', et une base de données locale, mais aucune information de sa performance n'est mentionnée.

Dans le travail de **A. Spetiarini et al. (2017)** [65], des paramètres statistiques sont extraits de la région du disque optique dans l'image fond d'œil. Ces paramètres comprennent : l'intensité moyenne, l'écart-type, le troisième moment, l'entropie...etc. La classification est faite par un classificateur K-means, et a donné une précision moyenne de 0.952.

P. E. Adjei et al. (2018) [66] ont proposé un algorithme qui segmente, et qui mesure les disque et cup optiques, en utilisant l'algorithme de PCANN (Pulse Coupled Artificial Neural Network). Dans ce travail, deux paramètres de prédiction du glaucome sont extraits : le rapport CDR vertical, et la vérification de la loi ISNT. Un total de 126 images de fond d'œil, sont utilisées pour l'évaluation de l'algorithme, qui a obtenu une précision, une sensibilité et une spécificité de 0.9, 0.88 et 0.91, respectivement.

S. Nawaldgi et al. (2018) [67] ont proposé une nouvelle technique d'analyse des images couleur de fond d'œil, où le disque et le cup optiques ont été segmentés à l'aide d'un seuillage adaptatif. Des paramètres structurels, comme le rapport CDR, et la surface du bord neuro-rétinien au niveau de la tête du nerf optique, sont utilisés avec la vérification de la loi ISNT, afin de détecter la présence du glaucome.

S.T. Fatima Bokhari et al. (2018) [68] ont combiné le rapport CDR, avec le rapport entre la surface du bord neuro-rétinien et celle du disque optique (Rim to Disc Ratio : RDR). Dans ce travail, une combinaison entre la transformée de Fourier, les contours actifs, et la transformée circulaire de Hough a permis une bonne segmentation du disque optique. Une deuxième combinaison entre les opérateurs morphologiques, les contours actifs, et la transformée circulaire de Hough a été utilisée pour la segmentation du cup optique.

Cet algorithme est testé sur une base de données de 200 images fond d'œil, et a obtenu des mesures de CDR et de RDR extrêmement proches des mesures cliniques réelles.

T. R. Kausu et al. (2018) [69] ont présenté une nouvelle méthode pour l'identification du glaucome, basée sur la combinaison du paramètre invariant dans le temps (le rapport CDR), avec les paramètres extraits par la transformée d'ondelettes. La segmentation du disque optique a été réalisée par l'algorithme FC-Means (FCM), alors que la segmentation du cup, est réalisée par et le seuillage d'Otsu. Cette méthode a atteint un taux de précision de 0.97, avec une sensibilité de 0.98, en utilisant un classificateur perceptron multicouches (Multi Layer Perceptron : MLP), sur un total de 86 images fond d'œil, dont 35 présentent un glaucome.

Une nouvelle solution pour segmenter simultanément le disque et le cup optiques est proposée par **M. S. Haleem et al. (2018)** [70]. Cette méthode est basée sur le modèle déformable ARESM (Adaptive Region-based Edge Smoothing Model), qui met à jour itérativement les points des contours des deux régions, en minimisant leurs fonctions d'énergie. Leur classification a atteint un taux de précision de 0.91 et 0.89, pour le disque et le cup, respectivement, dans la base de données Rim-One. Et un taux de 0.95 et 81, dans la base de données Drishti-GS.

En se basant sur le fait que la dimension fractale peut être utilisée pour identifier les objets dont les dimensions sont irrégulières, une nouvelle approche pour la détection du glaucome est proposée par **S. C. Shetty et al. (2018)** [71]. Ceci se fait, à l'aide d'une analyse périmétrique fractale de la région du cup, segmentée par le modèle K-means à partir des images fond d'œil. Cet algorithme a classé l'œil sain, et l'œil affecté par le glaucome, avec une efficacité de 92% sur un ensemble de 50 images.

Un travail similaire est proposé par **S. Sepatiarini et al. (2018)** [72], où ils diagnostiquent la présence du glaucome en détectant la présence des atrophies prépapillaires

(PrePapillary Atrophies : PPA). Ces dernières sont associées à deux pathologies : le glaucome et la myopie, et peuvent être observées à partir des images fond d'œil. Dans cette méthode, la classification est faite par un classificateur ANN à rétropropagation, à l'aide de trois paramètres sélectionnés par la méthode du rapport de gain : l'écart-type, la régularité, et le troisième moment. Les performances de la méthode proposée, atteignent une précision de 0.95, 0.96 et 0.96 pour trois bases de données différents : D1, D2 issues d'un hôpital local, et la base de données publique Rim-One.

N. A. Mohamed et al. (2019) [73] ont développé un système automatisé pour le dépistage du glaucome. Les pixels de l'image de fond d'œil ont été classifiés par la méthode des SLIC, afin de générer un nombre souhaité de superpixels. Après ce processus, les caractéristiques de la moyenne, de variance, d'aplatissement et d'asymétrie sont extraites, à l'aide de l'algorithme SPL (Statistical Pixel Level). Ces caractéristiques sont classifiées par l'algorithme SVM, pour séparer la région du cup de la région du disque optique. A la fin, la présence du glaucome est détectée par la mesure du rapport CDR. Cette méthode a été testée avec la base de données publique RIM-One, et a atteint une précision de 0.986, et une sensibilité de 0.923.

La classification des superpixels de l'image fond d'œil a été aussi proposée par **Z. Rahman et al. (2019)** [74]. Comme la méthode précédente, l'algorithme des SLIC a été adopté pendant le processus de segmentation, en ajoutant les caractéristiques de texture et d'histogramme, et les paramètres fractals aux paramètres extraits dans [61]. Quatre classificateurs sont testés dans cette étude : SVM, Adaboost, Rusboost et Random Forest. Ce dernier a donné la meilleur performance, avec une précision de classification: 0.993, 0.98 et 0.993 dans les bases de données : DRION, MESSIDOR et ONHSD respectivement.

Une méthode de décomposition similaire à celle utilisée dans [61] est présentée dans l'étude de **D. K. Agrawal et al. (2019)** [75], où un total de 505 images fond d'œil sont décomposées en utilisant la méthode QB-VMD (Quasi Bivariate Variational Mode Decomposition), en des images de sous-bandes (SBI), limitées et centrées autour d'une fréquence

particulière. Soixante-dix paramètres sont extraits de chaque sous-bande, et sont normalisés et sélectionnés par l'algorithme ReliefF. Finalement, les paramètres réduits sont classés à l'aide d'un classificateur LS-SVM (Least-Squares Support-Vector Machine). Les précisions de la détection du glaucome obtenues sont 0.85 et 0.86, en utilisant des stratégies de validation croisée triple et décuple, respectivement.

Un système de prédiction des risques du glaucome est réalisé par **X. Zhao et al. (2019)** [76]. Ce système est composé de trois phases principales : premièrement, le disque optique est localisé en utilisant des opérateurs morphologiques, et l'algorithme de la fenêtre glissante (sliding window). Deuxièmement, un réseau de neurones d'architecture U-Net est développé pour la séparation simultanée du disque et du cup optiques. Troisièmement, les mesures cliniques, y compris le rapport CDR, les caractéristiques liées au bord neuro-rétinien, et les caractéristiques cachées, telles que les moments statistiques, l'entropie et l'énergie, sont combinées, et transmises à plusieurs classificateurs. Ce système a atteint une précision de 0.82.

Le travail de **T. R. Bisneto et al. (2020)** [77] vise la détection précoce du glaucome, à travers un réseau de neurones d'adversaires génératifs, relié à des paramètres définis à partir d'indices de diversité taxonomiques. Ce classificateur est utilisé pour délimiter la région du disque, et extraire les paramètres mentionnés, afin de détecter la présence des anomalies du glaucome. Avec un taux de 0.78, la précision de ce modèle n'a pas été satisfaisante.

B. Biswal et al. (2020) [78] ont présenté deux nouveaux algorithmes de segmentation pour le disque et le cup optiques. Le premier utilise la transformée polaire inverse (Inverse Polar Transform : IPT), pour segmenter le disque optique, tandis que le second utilise la somme maximale des vaisseaux, pour extraire la région complète du cup. Cette méthode est testée sur plusieurs bases de données, y compris ORIGA, DIARETDB1, DIARETDB0, DRIVE, CHASE_DB1.

Le système proposé par **I. Qureshi et al. (2020)** [79] comprend des étapes de prétraitement d'images fond d'œil, d'extraction de paramètres, et d'évaluation du glaucome. Le prétraitement consiste à transformer l'image RGB en une image de niveaux de gris, et à améliorer son contraste. Les régions du disque et du cup optiques ont été segmentées lors de l'étape d'extraction des paramètres. Enfin, le rapport CDR est calculé pour évaluer le glaucome dans l'image. Le système proposé est testé sur 398 images de fond d'œil, provenant de quatre bases de données publiques, obtenant une valeur moyenne de sensibilité 0.90, de spécificité 0.97, et de précision 0.96 dans le diagnostic du glaucome.

A. O. Jashua et al. (2020) [80] ont évalué les performances du CDR sur les deux bases de données publiques : RIMONE v3 et DRISHTI-GS. Leurs résultats montrent que la mesure de CDR seule est insuffisante, pour détecter le glaucome à un stade précoce, atteignant une précision de 0.879 dans la détection du glaucome précoce à modéré, en utilisant un seuil de 0.6 pour le CDR.

P. Elangovan et al. (2020) [81] ont présenté un système de détection du glaucome, basé sur des paramètres statistiques calculés à partir des régions segmentées du disque et du cup optiques. Un modèle amélioré du FCM basé sur la reconstruction morphologique, et le filtrage d'appartenance est utilisé, pour segmenter simultanément les deux régions. Le rapport CDR est ensuite mesuré à partir de ces segmentations. En outre, plusieurs paramètres statistiques, tels que l'entropie du cup, l'entropie du bord neuro-rétinien, et l'aplatissement sont calculés. Sur la base de ces valeurs, les images du glaucome sont séparées des images saines.

2.2.2 Evaluation et discussion

Sur la base de l'étude bibliographique, réalisée sur les différentes approches d'analyse des images fond d'œil, nous identifions certains défis, limitations et résultats importants pour une détection précoce et précise du glaucome.

Le rapport CDR est la caractéristique la plus utilisée dans la littérature pour la détection du glaucome. Cependant, comme prouvé dans [80], un diagnostic basé seulement sur ce rapport n'est pas consistant, surtout dans les stades précoces de la maladie. Par conséquent, les approches basées sur la combinaison de plusieurs caractéristiques et indicateurs du glaucome, sont plus précises, car elles fournissent une analyse plus profonde des dommages liés au glaucome, que lorsque le CDR est la seule caractéristique prise en considération.

Dans certaines méthodes de classification, des caractéristiques structurelles et texturales sont extraites de l'image entière du fond d'œil, ou d'une sous-image contenant seulement le disque optique. Les caractéristiques des parties de l'image à l'extérieur du disque, ne portent aucune information significative sur le glaucome (les changements dus au glaucome se produisent à l'intérieur du disque). Ces caractéristiques peuvent donc biaiser l'identification des images glaucomateuses.

L'échelle DDLS, et la vérification de la loi ISNT se sont avérées très efficaces pour détecter le glaucome, en particulier, lorsqu'elles sont combinées avec le CDR. La loi ISNT assure une détection des amincissements pathologiques au niveau du bord neuro-rétinien, et l'échelle DDLS évalue la sévérité du glaucome, en classifiant ces dommages en 10 stades.

Les sous-segmentations, et sur-segmentations du cup optique, sont considérées comme le défi le plus important dans l'analyse des images fond d'œil, en raison du faible contraste à l'intérieur du disque optique, et de la non perceptibilité des frontières dues à la présence des vaisseaux sanguins entre le cup et le disque. Par conséquent, un pré-traitement efficace est nécessaire avant la segmentation du cup.

Le tableau 2.3 résume les différentes approches d'analyse des images rétiniennes (fond d'œil) étudiées dans la section précédente.

TABLE 2.3: Résumé des différentes approches d'analyse des images fond d'œil, pour l'aide au diagnostic du glaucome.

Auteurs	Approches de Segmentation		Performance		Bases de Données	Classification		Avantages	Inconvénients
	Disque Optique	Cup Optique	Mesure	Valeur		Caractéristiques	Classificateurs		
N. Inoue et al (2005)	Seuillage	Seuillage	—	—	—	—	—	Segmentation simultanée du disque et du cup optiques	Aucune interprétation des résultats.Segmentation sensible au bruit
J Xu et al (2007)	Modèle déformable	—	Précision de segmentation	94%	100 images BD locale	—	—	Robuste contre le bruit	Aucune segmentation du cup optique
D. Wong et al (2008)	Level-set	Level-set+ Seuillage	Erreur moyenne	D: 0.08 C:0.14	104 images	—	—	Mesure automatique du CDR	Erreur élevée pour la segmentation du cup sensible au bruit et à la qualité de l'image
J. Nayak et al (2008)	Seuillage+ Morphologie mathématique	Seuillage+ Morphologie mathématique	Sensibilité Spécificité Précision	1 0.8 0.909	61 images	CDR ISNT	ANN	Combinaison de plusieurs caractéristiques pour la classification	Mesure automatique du CDR
S.Kavitha et al. (2010)	Morphologie mathématique	Contours actifs	—	—	CDR	—	—	Mesure automatique du CDR	Aucune interprétation des résultats.Décision sur basée le seul paramètre (CDR)
Y.Hatanaka et al. (2011)	Gradient	Gradient	AUC	0,947	45 images	—	—	Mesure automatique du CDR	Aucune décision malgré la mesure du CDR. Peu d'images pour l'évaluation
C. Ho et al. (2011)	Croissance de région	Contours actifs	—	—	—	—	—	Mesure automatique du CDR, et vérification de la loi ISNT	Aucune décision malgré la mesure du CDR et la vérification de la loi ISNT
G. D. Joshi et al. (2011)	Chan-Vese	r-bend	F-score Erreur(CDR)	D:0.97 C:0.84 0.09	138 image BD locale	—	—	Mesure précise du CDR	Aucune décision malgré la mesure du CDR
F. Yin et al (2012)	Modèle déformable	ASM	Coéf Dice Erreur(CDR)	D:0.92 C:0.81 0.106	ORIGA	—	—	Mesure précise et automatique du CDR	coéf Dice faible pour la segmentation du cup optique
D. Wong et al (2012)	Leve-set	Leve-set+ Seuillage	Erreur	0.04 (CDR)	ORIGA	—	—	Grande précision de mesure du CDR	Pas de décision malgré la mesure du CDR
Y. Xu et al (2013)	SLIC+SVM	SLIC+SVM	Erreur (CDR)	0.104	ORIGA	—	—	Segmentations simultanées	Erreur importante de mesure du CDR

J. Cheng et al (2013)	SLIC+SVM	SLIC+SVM	Erreur(D) Erreur(C)	0.09 0.24	650 images BD locale	CDR	SVM	Segmentation simultanée du disque et du cup optiques	Mauvais resultat pour la segmentation du cup optique
M. Rama et al (2013)	—	—	Précision Sensibilité	0.91 0.9	60 images BD locale	hybrides	SVM polynomial	Combinaison de plusieurs Caractéristiques	Aucune mesure clinique n'est mesurée
N. M. Nour et al. (2013)	Seuillage	Seuillage	F-score Précision Spécificité Sensibilité	D: 0.59 C: 0.51 0.7/0.6 1/0.9 0.4/0.3	DRIVE	—	—	Mesure automatique du CDR	Segmentations sensibles au bruit, F-score et précision faibles
J. Arriga et al. (2014)	Transformée de Hough + Contours actifs	Otsu + Morphologie mathématique	Précision Spécificité Sensibilité	0.913 0.916 0.93	67 images BD locale	CDR ISNT déplacement des vaisseaux	—	Combinaison de plusieurs caractéristiques	Classificateur utilisé n'est pas mentionné
Tan et al (2014)	SLIC+level-set+SVM	SLIC+ level-set	Erreur (CDR)	0.248	ORIGA	—	—	Segmentation du cup indépendante de celle du disque optique	Erreur moyenne trop élevée
D. Yadav et al. (2014)	—	—	Précision	0.72	20 images BD locale	GLCM	ANN	Classification directe segmentation du cup et disque optiques	Faible précision, base de donnée trop petite
A.Salam et al. (2015)	Seuillage + Morphologie mathématique	Croissance de région + Morphologie mathématique	Précision	0.92 0.88 1	50 images BD locale	CDR + caractéristiques hybrides	SVM linéaire	Segmentations et Classification directes	Une faible spécificité de la classification
Alghmdi et al. (2015)	SLIC+ ANN	SLIC+ ANN	Spécificité Sensibilité	0.88 0.92	60 images BD locale	CDR	ANN	Segmentations robustes	Décision basée sur une seule caractéristique (CDR)
A. Agrawal et al. (2015)	Seuillage	Seuillage	Précision	0.9 1 0.8	60 images BD locale	CDR Epaisseur du bord neuro-retinien	SVM	combinaison de plusieurs caractéristiques pour la classification	Une sensibilité faible de la classification
A. M. Jose et al. (2015)	Level-set	SVM	Erreur (CDR)	0.021	BD locale Nombre d'images n'est pas mentionné	—	—	Mésure précise du CDR	Malgré la mesure du CDR aucune décision n'est faite
D. Patil et al (2016)	Seuillage	Seuillage	Précision	0.67	MESSIDOR+ RIM-ONE	—	—	mesure automatique du CDR	Précision trop faible

Ruengkitpinyo et al (2015)	—	Multi-scale vessel tracking	Précision	0.95 0.8	100 images BD locale	CDR +ISNT	—	Précision importante pour la classification	aucun classificateur n'est utilisé, classification basée sur un seuil du CDR
A. Diaz et al (2016)	—	Transformée Watershed	Spécificité Sensibilité	0.81 0.87	Drive + 53 images d'une BD locale	CDR +ISNT+ ACDR	Seuils de CDR et ACDR : 0.56 et 0.3	Segmentation directe du cup	aucun classificateur n'est utilisé, classification basée sur des seuils
P. Das et 2016)	Transformée Watershed	Transformée Watershed	Précision Spécificité Sensibilité	0.94 0.95 0.91	HRF, Messidor, DRIONS, RIM-ONE	NRR +ISNT	—	combinaison de plusieurs caractéristiques	aucun classificateur n'est utilisé
J. Ayub et al (2016)	K-means	K-means	Erreur du CDR	0.002	100 images BD locale	—	—	Mesure très précise du CDR	Malgré la mesure du CDR aucune décision n'est faite
Maheshwari et al. (2017)	—	—	Précision	0.98 0.96	MIAG +BD locale	Caractéristiques de EWT	LS-SVM	Classification directe, nombre minimal de Caractéristiques est utilisé	Testé sur une seule base de donnée publique
K. Nirmala et al. (2017)	—	—	Precision	0.89	FAU	WBCT	Naive Bayes	Classification directe	Mesures cliniques ne sont pas présent en considération
N. Sengar et al. (2017)	Seuillage adaptatif	—	Précision	0.935	140 images BD locale	Présence ou absence des hémorragies	—	Détection efficace des hémorragies reliées au glaucome	déformation de cup n'est pas mesurée
K. Thakkar et al. (2017)	Morphologie mathématique Transformée de Hough	Morphologie mathématique Seuillage	—	—	STARE+ BD Locale	—	—	Mesure automatique du CDR	Aucune interprétation des résultats.
P. E. Adjei et al. (2018)	PCANN + Seuillage	PCANN + Seuillage	Précision Spécificité Sensibilité	0.9 0.91 0.88	120 images BD locale	CDR +ISNT	seuillage du CDR et ISNT	Combinaison du CDR Avec la loi ISNT	Aucun classificateur n'est utilisé pour la décision
S. Bokhari et al. (2018)	Transformée de Hough + Contours actifs	Transformée de Hough + Contours actifs	—	—	200 images	—	—	Mesures obtenues sont proches des mesures cliniques	Mauvaise interprétation des résultats

T. R. Kausu et al. (2018)	FC-means	Otsu	Précision Sensibilité	0.97 0.98	86 images BD locale	CDR+ Caractéristiques de EWT	MLP	Combinaison de plusieurs caractéristiques	Segmentation du cup sensible à la non-uniformité de l'image
M. Haleem et al. (2018)	ARESM	ARESM	Précision	D:0.91 C:0.89	RIM-ONE + Drishti-GS	—	—	Segmentation Robuste- du disque optique	Précision faible pour la segmentation du cup optique
S. C. Shetty et al. (2018)	—	K-means	Précision	0.92	50 images BD locale	Dimention fractale	Seuillage de La dimention fractale	Segmentation du cup indépendante de celle du disque optique	Aucun classificateur n'est utilisé pour la décision
Sepatiarini et al. (2018)	Seuillage	—	Précision	0.96	RIM-ONE	Caractéristique de PPA	ANN	Détection précise de l'atrophie de PPA	Déformation du cup n'est pas mesurée
Mohamed et al. (2019)	SLIC+SVM	SLIC+SVM	Précision Sensibilité	0.98 0.92	RIM-ONE	CDR	Seuillage de CDR	Grande précision pour la segmentation du disque et du cup optiques	Aucun classificateur n'est utilisé pour la décision
Z. Rahman et al. (2019)	SLIC+SVM	SLIC+SVM	Précision	0.993 0.98 0.993	DRION MESSIDOR ONHSD	—	—	Grande précision pour la segmentation du disque et cup optiques	Aucune décision n'est faite
D.Agrawal et al. (2019)	—	—	Précision	0.861	RIM-ONE	QB-VMD	LS-SVM	Classification directe du glaucome	Précision faible pour la classification
X. Zhao et al (2019)	ANN	ANN	AUC	0.889	ORIGA	Paramètres cachés+CDR+ ISNT	SVM+SMOT	Grande précision pour la segmentation du disque et cup optiques	La méthode exige une grande base de données
T.Bisneto et al. (2020)	GAN	—	Précision	0.78	RIM-ONE Drishti-GS	—	—	Segmentation automatique	Précision faible pour la segmentation
B. Biswal et al. (2020)	SWT+ TPI	Seuillage	Précision	D:0.997 C:0.994	ORIGA, DIARETDB0 et DRIVE	—	—	Grande précision pour la segmentation du disque et du cup optiques	Aucune décision n'est faite
I. Qureshi et al. (2020)	—	—	Précision Spécificité Sensibilité	0.96 0.97 0.90	398 images BD locale	CDR	—	Grande précision de la classification	Décision basée sur une seule caractéristique (CDR)
A. Jashua et al. (2020)	—	—	Précision	0.87	RIMONE v3 DRISHTI-GS	CDR	—	Performance de CDR est évaluée	Aucun classificateur n'est utilisé
Elangovan et al. (2020)	FCM Morphologie mathématique	FCM Morphologie mathématique	Précision	0.92 0.98 0.87	RIM-ONE	CDR,entropie aplatissement	un seuil de chaque caractéristique	Performance de plusieurs Performance est évaluée	Aucun classificateur n'est utilisé

2.3 Analyse des images OCT pour le dépistage du glaucome

La technologie OCT est capable de visualiser les différentes couches rétiniennes, ce qui est crucial pour la détection précoce de nombreuses pathologies oculaires, y compris le glaucome. Dans ce contexte, plusieurs systèmes de segmentation des couches rétiniennes, et de l'analyse de leurs épaisseurs, afin de détecter les amincissements pathologiques causés par le glaucome, sont rapportés dans la littérature.

2.3.1 Etat de l'art des systèmes d'aide au diagnostic du glaucome (OCT)

M. Abrmoff et al. (2009) [82] ont combiné un algorithme de Graph-Cut 3D multi-échelles, et un algorithme KNN de classification des voxels, pour segmenter le cup et le bord de la tête du nerf optique, dans les données SD-OCT de 34 patients atteints de glaucome. Ils ont rapporté que la corrélation de l'algorithme à trois experts indépendants, était de 0.90, 0.87 et 0.93, respectivement.

M. A. Mayer et al. (2010) [83] ont proposé un nouvel algorithme de segmentation de la couche RNFL, dans les images OCT de domaine spectral, qui peut être appliqué sur des coupes de sujets sains et glaucomateux, en utilisant les mêmes paramètres. Le processus de segmentation est basé sur la minimisation d'une fonction d'énergie à deux termes: un terme de gradient, et un terme de lissage local. L'algorithme est évalué en comparant les résultats de la segmentation automatisée, avec celle effectuée manuellement. L'erreur absolue moyenne de la segmentation est de 2.9 et 3.6 μm pour les coupes glaucomateuses et saines, respectivement.

Q. Yang et al. (2010) [84] ont proposé un nouvel algorithme de segmentation de neuf couches intra-rétiniennes dans les images OCT maculaires. Le processus de segmentation est basé sur l'extraction simultanée des caractéristiques de gradient locales et globales, et l'algorithme du recherche du chemin le plus court (Shortest Path Search algorithm), pour

optimiser la segmentation des contours. Malgré la segmentation de la couche RNFL, aucune décision n'est faite pour l'identification du glaucome.

Le dommage glaucomateux dans les images SD-OCT est détecté par **J. Xu et al. (2011)** [85]. Dans ce travail, l'image 3D est convertie en une matrice de caractéristiques 2D, partitionnée en plus d'une centaine de superpixels. Ces derniers sont segmentés en regroupant les pixels voisins homogènes, à l'aide de l'algorithme N-cut. Un classificateur LogiBoost est utilisé pour détecter les anomalies glaucomateuses, au niveau de la couche RNFL. Des valeurs d'AUC de 0.85, et 0.70 ont été rapportées pour les cas sains, et glaucomateux respectivement.

K. A. Vermeer et al. (2011) [86] ont présenté une méthode pour la segmentation tridimensionnelle de la couche RNFL dans les images OCT. Certaines coupes ont été segmentées manuellement, et utilisées pour l'apprentissage d'un modèle SVM, afin de segmenter les pixels qui appartiennent à la couche RNFL, où la fluidité des contours détectés était garantie par l'algorithme Level-set, après la classification des pixels. Les erreurs moyennes pour la segmentation des deux frontières de la couche RNFL, étaient comprises entre 4 et 6 μm .

Y. Wang et al. (2013) [87] ont proposé un algorithme de mesure du rapport CDR, dans les images SD-OCT, où la membrane ILM est segmentée à l'aide du seuillage d'Otsu, et la couche RPE est extraite en utilisant la méthode proposée par **R. Koprowski et al.** [88]. Après la segmentation, les points de référence au niveau de l'ILM et la RPE sont détectés, afin de mesurer le rapport CDR avec une erreur moyenne absolue de 0.12.

Une nouvelle méthode de classification automatisée de texture, pour la détection du glaucome à partir des images OCT est proposée par **N. Anantrasirichai et al. (2013)** [89]. Dans cette étude, ils exploitent les informations de l'image OCT, en particulier les épaisseurs, et la texture des couches internes de la rétine, pour identifier les cas de glaucome,

à l'aide d'un classificateur SVM. Cet algorithme est testé sur 24 images OCT d'une résolution de 512×1024 , dont 10 présentent un glaucome, et a atteint une précision de 0.851, en combinant les caractéristiques de textures, avec l'épaisseur de la couche RNFL.

F. R. Silva et al. (2013) [90] ont modélisé 10 algorithmes d'apprentissage automatique, en se basant sur 20 caractéristiques, telles que, l'épaisseur moyenne de la couche RNFL, la loi des quatre quadrants ISNT, les paramètres de test du champ visuel, et le test d'Hemfield du glaucome (GHT). Ces caractéristiques sont extraites à partir de 100 images OCT, dont 62 présentent un glaucome. L'AUC le plus élevé de 0.94 a été obtenu à l'aide du classificateur Random Forest.

P. Agrawal et al. (2014) [91] ont présenté une méthode automatisée de mesure de l'épaisseur de la couche RNFL, à l'aide de l'opérateur Sobel. Le procédé implique un prétraitement de l'image OCT à l'aide d'un filtre médian, pour éliminer le bruit Speckle, suivi de la segmentation de la couche RNFL, à l'aide des techniques de seuillage, et la morphologie mathématique pour mesurer, et analyser son épaisseur. Aucune mesure de performance de l'algorithme n'est mentionnée dans leur article.

S. Chandrappa et al. (2015) [92] ont proposé une technique pour la segmentation de la couche RNFL, à partir des images SD-OCT maculaires. Le processus de segmentation proposé est basé sur la coopération entre l'algorithme de fusion de régions (Region Merging algorithm), et les opérateurs morphologiques. Cette technique est testée sur un ensemble de 50 images SD-OCT maculaires, mais, aucune mesure de performance n'est mentionnée.

Un travail similaire a été proposé par **D. Kaba et al. (2015)** [93], où la couche RNFL, et les deux frontières de la rétine, ont été segmentées dans les images SD-OCT. Dans ce travail, les couches sont détectées en adaptant la technique de segmentation Graph-Cut, avec l'algorithme Max-Flow. 120 coupes SD-OCT sont utilisées pour évaluer cet algorithme, qui a atteint un coefficient de Dice de 0.94, pour la segmentation de la couche

RNFL.

H. Muhammad et al. (2017) [94] ont utilisé un réseau CNN, basé sur l'apprentissage par transfert avec l'architecture AlexNet, pour extraire les caractéristiques discriminantes de 102 images SD-OCT. Un classificateur Random Forest est utilisé par la suite, pour classer ces caractéristiques afin d'identifier les cas de glaucome. Un score AUC de 0.97 a été atteint dans cette étude.

J. Duan et al. (2017) [95] ont présenté une nouvelle technique pour la segmentation précise des couches rétiniennes, en se basant sur la distance géodésique dans les images OCT 2D et 3D. Cette distance est efficacement calculée à l'aide de l'équation d'Eikonal via la méthode de balayage rapide. Le processus de segmentation est effectué par la suite, en résolvant les équations différentielles des distances géodésiques, afin de détecter les frontières des neuf couches intra-rétiniennes.

A. Ramzan et al. (2018) [96] ont développé une nouvelle méthode, pour l'extraction de la membrane ILM et la couche RPE, dans les images SD-OCT. Dans cette méthode, les frontières du disque et du cup optiques ont été estimées à l'aide d'un seuillage adaptatif, et des points de repère au niveau de la RPE et l'ILM. Les cas glaucomateux présentant un rapport CDR supérieur à 0.5 ont été identifiés. Ils ont rapporté une erreur moyenne de 0.119 pour la mesure du CDR, avec un écart-type de 0.023, et une précision de classification de 0.79.

J. Wang et al. (2018) [97] ont conçu un réseau de neurones avec l'architecture SD-net, pour la mise en œuvre de la segmentation des différentes couches intra-rétiniennes, dans les images SD-OCT, pour ensuite, faire la détection du glaucome à l'aide du vecteur de l'épaisseur de la couche RNFL. Le SD-net est un modèle qui imite le comportement d'un ophtalmologue pour diagnostiquer le glaucome avec le rapport OCT. Il donne un seuil d'épaisseur à chaque point de la couche RNFL, afin de détecter les amincissements pathologiques, causés par le glaucome. Ce système a atteint un coefficient de Dice de 0.92

pour la segmentation de la RNFL, et une précision de diagnostic de 0.85.

S. Maetschke et al. (2019) [98] ont proposé une technique de Deep Learning, pour la classification directe des volumes OCT brutes, et non-segmentés de la tête du nerf optique, à l'aide d'un réseau de neurones convolutif (CNN) de 6 couches cachées. Dans cette étude, la régression logistique s'est avérée être la technique d'apprentissage la plus performante, avec un score AUC de 0.89.

K. A. Thakoor et al. (2019) [99] ont décrit, et évalué plusieurs modèles CNNs, pour la détection automatique du glaucome en se basant sur la cartographie de la couche RNFL, à partir des images OCT. Tous les modèles ont montré une grande précision dans la détection des amincissements pathologiques dus au glaucome, avec des scores AUC allant de 0.93 à 0.989, prouvant l'efficacité des CNNs dans la classification des images OCT.

Récemment, **G. Garcia et al. (2020)** [100] ont proposé une comparaison entre les modèles de classification traditionnels, et les algorithmes de l'apprentissage profond (Deep Learning), afin d'analyser si ces modèles traditionnels peuvent les surpasser pour la détection du glaucome, à partir des images SD-OCT, en particulier, lorsque la base d'apprentissage est petite. Leurs résultats montrent que leur modèle hybride (SVM+MLP), a atteint un score AUC de 0.85, surpassant le modèle profond, qui a atteint un score 0.74.

A. P. Yow et al. (2020) [101] ont évalué la performance de la segmentation automatique de la couche RNFL, à partir des images OCT, et à l'aide d'un modèle d'apprentissage profond d'architecture U-Net. Dans ce travail, les coupes péri-papillaires sont extraites des volumes OCT, et une annotation manuelle est effectuée sur ces coupes, pour l'apprentissage et l'évaluation du modèle. La précision du diagnostic dans la détection du glaucome, à l'aide de l'épaisseur RNFL annotée manuellement, était comparable à la précision utilisant la segmentation RNFL automatisée (84%), dans une base de données locale constituée de 500 images SD-OCT.

A. C. Thompson et al. (2020) [102] ont développé un algorithme d'apprentissage profond (sans segmentation), pour la prédiction des probabilités des dommages structuraux causés par le glaucome, dans les images SD-OCT circulaires. Un total de 20806 images provenant de 1154 yeux, dont 612 sont atteints du glaucome, sont incluses dans l'apprentissage et le test du modèle proposé. Avec un score AUC de 0.96, ce dernier a donné de meilleures performances que les systèmes basés sur l'analyse des paramètres d'épaisseur de la couche RNFL, pour l'identification des dommages glaucomateux (si présents) dans les images OCT, en particulier pendant la phase précoce de la maladie.

2.3.2 Evaluation et discussion

Après l'analyse des systèmes d'aide au diagnostic du glaucome basés sur les images fond d'œil, et les systèmes basés sur les images OCT, il est à noter que l'erreur du CDR était moindre, lorsqu'il est mesuré à partir des images OCT. De plus, les systèmes basés sur l'OCT ont fourni une analyse plus approfondie de la tête du nerf optique, en analysant les épaisseurs des différentes couches rétiniennes. Mais, en termes de classification, les systèmes basés sur le fond d'œil étaient plus précis dans l'identification des cas de glaucome. Cela est dû au fait que, les amincissements et déformations pathologiques des couches rétiniennes, ne sont pas nécessairement causées par le glaucome. Aussi, ce dernier n'affecte que les couches externes de la rétine, donc inclure d'autres couches, peut conduire à un faux diagnostic du glaucome.

D'autre part, il convient de mentionner que les changements structurels dus au glaucome, et aux autres pathologies oculaires, modifient considérablement l'apparence de l'image OCT. Par conséquent, il est crucial que malgré les changements d'épaisseur, ou d'emplacement des couches rétiniennes, leur organisation logique doit être conservée.

L'autre défi majeur dans la segmentation des images OCT, est le bruit Speckle inévitable, qui diminue la qualité de l'image, et complique son analyse. Ce bruit, est à la base des problèmes existants dans l'identification des différentes couches rétiniennes, et d'autres caractéristiques structurelles, et texturales présentes dans les images OCT. C'est

pour cette raison, que presque toutes les méthodes étudiées dans la section précédente, incluent une étape de prétraitement. Le tableau 2.4 résume les différentes approches d'analyse des images rétiniennes (OCT) étudiées dans la section précédente.

TABLE 2.4: Résumé des différentes approches d'analyse des images OCT, pour l'aide au diagnostic du glaucome.

Auteurs	Approches de Segmentation		Performance		Bases de données	Classification		Avantages	Inconvénients
	Couche RNFL	Autre	Mesure	Valeur		Caractéristiques	Classificateurs		
M.Abrmoff et al. (2009)	—	Graph-Cut (Disque et cup)	—	—	34 Volumes SD-OCT	—	—	Estimation précise du rapport CDR	Aucune décision n'est faite
M. Mayer et al (2010)	Leve-set	Level-set (ligne RPE)	Erreur moyenne	2.9 et 3.6 μ m	204 images SD-OCT	—	—	Détection automatique et précise des frontières du RNFL et RPE	Anomalies au niveau de la RNFL et de la RPE non détectées
Q.Yang et al (2010)	Gradient	Gradient (9 couches rétinienne)	Erreur moyenne	3.39 μ m	43 volumes SD-OCT	—	—	Segmentation de neuf couches rétinienne	Algorithme testé seulement sur des images saines
J. Xu et al (2011)	N-cut	—	AUC	0.85 0.70	96 images SD-OCT	Caractéristiques de la RNFL	LogitBoost	Identification précise des amincissements pathologiques au niveau de la RNFL	Méthode n'est pas testée sur les coupes maculaires
K.Vermeer et al. (2011)	SVM	—	Erreur moyenne	4et6 μ m	18 Volumes SD-OCT	—	—	Cartographie précise de la couche RNFL	Aucune identification du glaucome n'est faite
Y. Wang et al (2013)	—	Otsu (ILM)	Erreur moyenne (CDR)	0.12	—	CDR	—	Mesure précise du CDR	Aucun classificateur n'est utilisé pour la détection
N.Anantra-sirichai et al. (2013)	—	—	Précision	0.851	24 images SD-OCT	Caractéristiques de la RNFL	SVM	Décision basée sur la texture et l'épaisseur de la RNFL	Méthode testée sur une petite base de données
F.Silva et al. (2013)	—	—	AUC	0.94	100 SD-OCT	Caractéristiques de la RNFL+ champ visuel	Random Forest	Combinaison de plusieurs caractéristiques pour la classification	Méthode n'est pas testée sur les coupes maculaires
P.Agrawal et al (2014)	Opérateur Sobel	—	—	—	—	—	—	Segmentation automatique de la couche RNFL	Aucune mesure de performance n'est mentionnée
S.Chandrappa et al. (2015)	Region merging +morphologie mathématique	—	—	—	50 images SD-OCT maculaires	—	—	Segmentation automatique de la couche RNFL	Aucune mesure de performance n'est mentionnée. Aucune décision n'est faite
D. Kaba et al (2015)	Graph-Cut+ Max-Flow	—	Dice	0.94	120 coupes SD-OCT	—	—	Segmentation précise de la RNFL	Aucune décision n'est faite

H.Muhammad et al. (2017)	---	---	AUC	0.97	102 images SD-OCT	---	CNN+ Random Forest	Extraction des caractéristiques discriminantes	RNFL n'est pas segmentée
J. Duan et al (2017)	---	Contours actifs	---	---	---	---	---	Segmentation de plusieurs couches	Aucune décision n'est faite
A.Ramzan et al (2018)	---	Seuillage (ILM+RPE)	Précision	0.79	---	CDR	---	Temps de calcul minimal pour la détection du glaucome	Diagnostic basé seulement sur la valeur du CDR
J.Wang et al (2018)	ANN (SD-net)	---	Dice Précision	0.92 0.85	---	Epaisseur de la RNF	ANN	Segmentation précise de la RNFL	Méthode n'est pas compatible sur les coupes maculaires
S.Maetschke et al. (2019)	---	---	AUC	0.89	624 volumes SD-OCT	---	Deep learning	Classification directe des images OCT	RNFL n'est pas segmentée
K.Thakoor et al. (2019)	CNN	---	AUC	0.93	322 images SD-OCT	---	---	Détection précise du glaucome	Méthode n'est pas testée sur les coupes maculaires
G.Garcia et al (2020)	---	---	ROC Précision	0.85 0.82	392 images SD-OCT	---	SVM+ MLP	Classification directe des images OCT	RNFL n'est pas segmentée. Les épaisseurs des couches ne sont pas prises en considération
A.Yow et al (2020)	CNN (U-net)	---	Précision	0.84	500 images SD-OCT	---	---	Segmentation précise de la couche RNFL	Aucune décision n'est faite
A.Thompson et al. (2020)	---	---	AUC	0.96	20806 images SD-OCT	---	CNN	Classification directe des images OCT	RNFL n'est pas segmentée.

2.3.3 Etat de l'art des systèmes de classification des images AS-OCT

Outre l'analyse des couches rétiniennes, la Tomographie par Cohérence Optique est une modalité d'imagerie efficace, pour identifier visuellement les structures du segment antérieur de l'œil, en obtenant des coupes transversales de la chambre antérieure, en une seule image (AS-OCT). Cette dernière révèle toute la cornée, les deux angles irido-cornéens, et la partie antérieure du cristallin [103] [104].

La facilité d'obtenir une image aussi complète, rend l'AS-OCT adapté à la mesure précise de l'angle de drainage, et à l'analyse des structures de la chambre antérieure. Par contre, cette analyse nécessite une intervention longue et subjective de la part de l'ophtalmologue, ce qui peut compromettre la reproductibilité de ces mesures. Dans la littérature, plusieurs techniques de segmentation et de classification des images AS-OCT sont étudiées, afin de faciliter la classification du glaucome à partir de ces images. Nous en citons quelques-unes.

J. Tian et al. (2011) [105] ont développé une nouvelle méthode de la détection automatique de la ligne de Schelbe, dans les images OCT de haute résolution (HD-OCT) de la chambre antérieure, pour mesurer par la suite, l'angle irido-cornéen. Ces deux paramètres sont mesurés après la segmentation de la cornée et de l'iris, par la coopération d'un seuillage, et d'opérations morphologiques. Cette méthode a été testée sur 40 images HD-OCT, et a obtenu une erreur moyenne de 4.24 pixels, pour la mesure de l'angle. L'inconvénient majeur de cette méthode, est qu'elle n'est valable que pour les images HD-OCT, et ne peut pas être mise en œuvre avec d'autres modalités d'imagerie de la chambre antérieure.

Une méthode similaire est proposée par **Y. Xu et al. (2012)** [106]. Cette méthode localise automatiquement les deux régions des angles irido-cornéen, et extrait les caractéristiques des histogrammes, des gradients orientés (Histogramme of Oriented Gradients : HOG) de ces régions, afin de classifier l'angle en ouvert ou fermé, en utilisant un classificateur SVM. Cette méthode est testée sur une base de données contenant 2048

images AS-OCT, et a atteint un score AUC de 0.835, et une spécificité de 0.85 pour la classification de l'angle irido-cornéen.

S. I. Niwas et al. (2014) [107] ont analysé le processus de la détermination manuelle des points de repère dans les images AS-OCT, tels que la distance d'ouverture de l'angle, l'angle irido-cornéen, et la surface entre l'iris et le trabéculaire pour identifier la forme du glaucome. Ils ont utilisé à la fois des algorithmes d'apprentissage supervisés et non-supervisés, avec un classificateur AdaBoost pour obtenir des précisions allant de 0.84 à 0.87.

S. N. Ni et al. (2014) [108] ont présenté une nouvelle stratégie pour la classification de la forme du glaucome à partir des images AS-OCT, en se basant sur la forme de l'angle irido-cornéen. La distance d'ouverture de l'angle, la moyenne de courbure de l'iris, le descripteur de forme de triangularité, et d'autres paramètres sont utilisés avec le classificateur KNN, pour l'identification de la forme du glaucome. Cette méthode est testée sur 264 images AS-OCT, et a atteint un score AUC de 0.98.

S. Niwas et al. (2016) [109] ont défini un nouvel algorithme pour l'évaluation objective des images AS-OCT, en utilisant les caractéristiques LBP (Local Binary Pattern), extraites à l'aide de la transformée d'ondelettes. Ces caractéristiques sont ensuite envoyées à un classificateur Bayésien, afin d'obtenir une évaluation complète, sur la qualité de l'image. Bien qu'aucune évaluation du glaucome n'est incluse dans cet algorithme, celui-ci permet d'obtenir un rapport précis et objectif, sur la qualité de l'image avant le diagnostic.

H. Fu et al. (2017) [110] ont proposé une nouvelle méthode de segmentation, et de mesure des images AS-OCT. Dans ce travail, ils récupéraient d'abord les K plus proches voisins, dans un ensemble d'images manuellement étiquetées, pour estimer les emplacements des marqueurs initiaux dans l'image d'entrée. Ces marqueurs sont par la suite

raffinés à l'aide d'un modèle déformable, pour les utiliser dans la segmentation des structures majeures de l'image AS-OCT. Enfin, des paramètres cliniques tels que l'angle irido-cornéen, sont mesurés.

La même équipe en 2018 [111], ont proposé un modèle d'apprentissage profond multi-contexte (Multi-context Deep Network : MCDN), pour la classification directe des images AS-OCT, et pour la détection du glaucome à angle fermé. De plus, ils ont incorporé des paramètres cliniques estimés, pour améliorer la précision de la classification. Ce modèle a été testée sur un total de 4135 images AS-OCT, et a atteint un score AUC de 0.94, et une précision de 0.89, avec une spécificité et une sensibilité de 0.89 et 0.88, respectivement.

Q. Shang et al. (2019) [112] ont présenté une nouvelle méthode, pour l'extraction automatique de la région de l'iris dans les images AS-OCT, à l'aide de l'algorithme de l'amélioration des structures curvilignes, basé sur un tenseur de phase locale. Cette méthode a été évaluée sur un ensemble de 200 images AS-OCT, atteignant un taux de précision de 0.992 pour la segmentation de l'iris. L'avantage majeur de ce travail, est qu'il facilite l'identification des angles irido-cornéens occlusables, avant l'apparition de tous les symptômes du glaucome.

C. Yuan et al. (2019) [113] ont proposé une nouvelle architecture CNN (ResNet152), pour classifier automatiquement les angles irido-cornéens en angles fermés ou ouverts, et pour déterminer les coordonnées de l'éperon scléral. Cette méthode a été évaluée sur la base de données AGE, contenant 4800 images AS-OCT, et a atteint un score AUC de 1.0, et une erreur moyenne de 12 pixels pour la détection des points de l'éperon scléral.

Récemment, **H. Hao et al. (2020)** [114] ont présenté un modèle CNN, pour la classification de l'angle irido-cornéen, qui est non seulement capable d'identifier l'angle fermé de l'angle ouvert, mais également capable de le classifier en trois sous-classes, à partir des images AS-OCT. Dans cette méthode, un bloc d'agrégation discriminante multi-échelle (Multi-scale Discriminative Aggregation : MSDA), est utilisé pour l'apprentissage des

caractéristiques multi-échelles au niveau de chaque coupe, tandis qu'un bloc contenant deux couches de convolution, est utilisé pour l'apprentissage de la dynamique temporelle de ces caractéristiques, au niveau de chaque séquence. Ce modèle est testé sur la base de données AGE, et a atteint un taux de précision de 1.0.

Inspiré par [114], **P. Li et al. (2020)** [115] ont proposé un système efficace basé sur l'apprentissage profond, pour détecter avec précision la fermeture de l'angle irido-cornéen, en se basant sur la localisation des points de l'éperon scléral. Dans cette étude, le problème de la localisation de l'éperon scléral est reformulé en une tâche de régression par pixel, où un modèle CNN de six couches est optimisé, pour prédire la probabilité pour que chaque point de l'image AS-OCT, appartienne aux points de l'éperon scléral, dont les coordonnées numériques sont estimées, à l'aide de l'algorithme du maximum de vraisemblance. Les deux régions centrées sur les deux points détectés, sont rognées et transmises à un réseau ResNet18, pour la classification. Comme [114] et [113], ce modèle est testé sur la base de données AGE, et a atteint une précision de 1.0.

2.3.4 Evaluation et discussion

Contrairement aux images OCT rétinienne, l'analyse des images de la chambre antérieure a attiré moins l'attention des chercheurs, pour fournir un diagnostic de glaucome assisté par ordinateur. Cela est dû au fait que le glaucome ne peut pas être détecté en analysant les images AS-OCT, car la seule information qu'elles fournissent est le type de glaucome (si présent).

D'après l'étude bibliographique, réalisée sur les approches d'analyse des images de la chambre antérieure oculaire, il est à noter que cette analyse est plus consistante lorsqu'elle est effectuée après la détection du glaucome, en utilisant l'une des modalités d'imagerie mentionnées précédemment. La caractéristique la plus importante extraite de ces images, est la forme de l'angle irido-cornéen. Cette dernière, nous permet de classer le type de glaucome (si présent), en glaucome à angle ouvert ou glaucome à angle fermé.

Le tableau 2.5 résume les différentes approches d'analyse des images rétiniennes (AS-OCT), étudiées dans la section précédente.

TABLE 2.5: Résumé des différentes approches d'analyse des images AS-OCT, pour la classification du glaucome.

Auteurs	Approches de Segmentation		Performance		Bases de données	Classification		Avantages	Inconvénients
	Cornée	Iris	Mesure	Valeur		Caractéristiques	Classificateurs		
J.Tian et al. (2011)	Seuillage+ Morphologie mathématique	Seuillage+ Morphologie mathématique	Erreur moyenne (en pixel)	4.24	40 images SD-OCT	—	—	Mesure automatique et précise de l'angle iridoconéen	La méthode n'est valable que pour les images HD-OCT
Y.Xu et al. (2012)	HOG	HOG	AUC Spécificité	0.83 0.85	2048 images AS-OCT	Caractéristiques de la transformée de HOG	SVM	Classification a surpassé les méthodes basées sur les caractéristiques cliniques	Les cas intermédiaires n'ont pas été inclus dans la classification
S.I.Niwas et al. (2014)	—	—	Précision	0.84	156 Images AS-OCT BD locale	Caractéristiques du score Laplacien	AdaBoost	La classification est basée sur un grand ensemble de caractéristiques	L'iris et la cornée ne sont pas segmentés
S.Ni et al. (2014)	Seuillage	Seuillage	AUC	0.98	264 images SS-OCT BD locale	Caractéristiques géométriques	KNN	Combinaison de plusieurs caractéristiques pour la classification	La méthode n'est pas testées sur les images AS-OCT
S.Niwas et al (2016)	—	—	Précision	0.82	194 images AS-OCT BD locale	LBP	Naive Bayes	Analyse précise de la qualité des images AS-OCT	Aucune aide au diagnostic du glaucome n'est incluse
H.Fu et al (2017)	KNN+ Graph-Cut	KNN+ Graph-Cut	Précision Sensibilité Spécificité	0.51 0.75 0.85	100 images AS-OCT BD locale	Caractéristiques cliniques	SVM	Mesure automatique des paramètres cliniques à partir des images AS-OCT	Précision trop faible
H.Fu et al (2018)	—	—	AUC Précision Sensibilité	0.94 0.89 0.88	7375 images AS-OCT BD locale	—	MCDN	Classification directe des images AS-OCT	L'iris et la cornée ne sont pas segmentés
Q.Shang et al (2019)	CSE	CSE	Précision	0.992	200 images AS-OCT BD locale	—	—	Segmentation précise de l'image AS-OCT	Aucun aide au diagnostic du glaucome n'est incluse
C.Yuan et al (2019)	—	—	AUC	1	AGE	—	CNN	Classification directe des images AS-OCT	Méthode testée sur une seule base de données
H.Hao et al (2020)	—	—	Précision	1	AGE	—	CNN	Modèle capable de classifier les images AS-OCT en 3 sous classes	Méthode testée sur une seule base de données
P.Li et al. (2020)	—	—	Précision	1	AGE	—	CNN	Classification directe des images AS-OCT	Méthode testée sur une seule base de données

2.4 Etat de l'art des combinaisons multi-modalités pour le dépistage du glaucome

La plupart des approches existantes pour la détection automatique du glaucome, analysent principalement une des trois modalités mentionnées précédemment, et identifient les cas de glaucome à l'aide des caractéristiques fournies par cette modalité. Par conséquent, les performances de ces approches sont limitées aux informations extraites de l'image analysée. Récemment, plusieurs auteurs ont combiné les informations extraites des images fond d'œil, avec celles des images OCT, afin d'améliorer la précision de l'identification du glaucome.

2.4.1 Etat de l'art des systèmes hybrides pour le dépistage du glaucome (OCT/fond d'oeil)

C. S. Fathima et al. (2019) [116] ont présenté un système de détection de glaucome, en utilisant les images fond d'œil, et les images OCT du même œil. Dans ce travail, les techniques de clustering K-means, et de seuillage d'Otsu sont utilisées pour l'extraction des caractéristiques structurelles des images fond d'œil. L'épaisseur de la couche RNFL est par la suite mesurée à partir de l'image OCT correspondante. Ces caractéristiques sont combinées et transmises à un classificateur SVM, pour l'identification des cas de glaucome, non-glaucome et des cas suspects. Ce système a été évalué sur un ensemble de 150 paires d'images fond d'œil-OCT, et a atteint une précision de 0.90.

G. An et al. (2019) [117] ont développé un nouvel algorithme de la détection automatique du glaucome, chez les patients atteints de glaucome à angle ouvert (GAO), basé sur l'analyse des volumes OCT, et leurs images fond d'œil correspondantes. Un classificateur CNN est utilisé pour détecter la présence du glaucome, en se basant sur plusieurs images telles que: l'image fond d'œil en niveaux de gris, les cartographies des épaisseurs de la

couche RNFL, et du complexe GCC ... etc. Les données utilisées pour évaluer cet algorithme, sont extraites à partir de 208 patients de GAO, et il a atteint une précision de 0.963.

Z. Cheng et al. (2019) [118] ont combiné les caractéristiques structurelles et texturales extraites des images OCT, et des images fond d'œil, respectivement. Dans cette méthode, un réseau de neurones U-Net est utilisé pour extraire les caractéristiques de la lame criblée de la sclère (les fibres nerveuses sortant de l'œil), à partir des images OCT de la tête du nerf optique, et le rapport CDR avec les caractéristiques structurelles dans l'image fond d'œil. L'identification des cas de glaucome est ensuite achevée à l'aide d'un classificateur Random Forest. L'algorithme a donné une précision de 0.937, en se basant uniquement sur les caractéristiques du fond d'œil, et 0.968, en faisant leur combinaison avec celles de l'OCT.

T. Shehryar et al. (2020) [119] ont proposé un système hybride de diagnostic assisté par ordinateur, qui intègre à la fois les technologies d'imagerie fond d'œil, et celles de l'OCT, pour la détection fiable du glaucome. Dans ce travail, la couche externe de la rétine (RNFL) est analysée, en prenant en compte une variété de caractéristiques structurelles et texturales, extraites des images fond d'œil, tandis que les couches internes sont examinées dans les images OCT, afin de calculer le rapport CDR. Le contour du cup optique est extrait de la membrane ILM, en utilisant une coopération entre les opérateurs morphologiques et la technique du seuillage. De même, le contour du disque optique est extrait à partir des points de terminaison dans la couche RPE. Ce système a été testé sur un ensemble de 50 images fond d'œil, et 50 images SD-OCT, et a atteint un taux de précision de 0.76 et 0.84, en se basant sur les caractéristiques structurelles et texturales de fond d'œil respectivement, de 0.94 en se basant sur les caractéristiques des images OCT, et de 0.96 en prenant en considération leur combinaison pour la détection du glaucome (un classificateur SVM est utilisé dans tous les cas).

2.4.2 Evaluation et discussion

Au cours des deux dernières années (2018-2020), certains chercheurs ont tenté de combiner plusieurs modalités d'imagerie oculaire pour détecter le glaucome. Ces tentatives se sont avérées plus efficaces, car elles analysent les caractéristiques cliniques, structurelles, et texturales de la tête du nerf optique sous différents angles.

Le défi principal de la combinaison multi-modalités pour la détection du glaucome, est la fusion de caractéristiques multiples, extraites des images fond d'œil et OCT. Comme certaines sont mesurables à partir des deux images, la redondance peu perturber le classificateur, et conduire à une classification biaisée. Aussi, l'absence d'une des images doit être prise en considération, car les OCT ne sont pas toujours disponibles, ou sont trop bruitées pour être analysées.

Finalement, bien que nombreuses études aient prouvé la liaison entre la présence du glaucome et l'amincissement du complexe GCC, au niveau de la région maculaire, ce paramètre n'a jamais été utilisé comme caractéristique pour l'identification du glaucome. Sa combinaison avec les indicateurs du glaucome, extraits des images fond d'œil, peuvent améliorer la précision de la détection de cette pathologie, en particulier dans les stades précoces de la maladie.

Le tableau 2.6 résume les différentes approches multi-modalités étudiées dans la section précédente.

TABLE 2.6: Résumé des différentes approches basées sur des combinaisons multi-modalités pour la détection du glaucome.

Auteurs	Approches de segmentation		Performance		Bases de données	Classification		Avantages	Inconvénients
	Fond d'œil	OCT	Mésure	Valeur		Caractéristiques	Classificateurs		
C.Fathima et al. (2019)	K- means + Seuillage Otsu (Disque et cup)	Filtre Sobel+ Seuillage Otsu (Couche RNFL)	Précision (Fond d'œil) Précision (OCT)	0.90 0.92	150 paires d'images OCT et fond d'œil BD locale	Fond d'œil:CDR +RDR+ISNT OCT: Epaisseur de la RNFL	SVM	Combinaison des caractéristiques structurelles et texturales des images fond d'œil et OCT	Performance des segmentations n'est pas discutée. Précision faible pour la classification
G.An et al (2019)	CNN Disque et cup	CNN RNFL et GCC	AUC	0.963	208 paires d'images OCT et fond d'œil	Fond d'œil:CDR OCT: Epaisseur de la RNFL et GCC	Random Forest	Classification basée sur plusieurs images quantifiées extraites des données OCT et fond d'œil	Nécessite une large base de données pour l'apprentissage
Z.Cheng et al (2019)	Seuillage Otsu (Disque et cup)	U-Net (Lamina Cribrosa)	Précision (Fond d'œil) Précision (OCT+ Fond d'œil)	0.937 0.968	32 paires d'images OCT et fond d'œil BD locale	Fond d'œil:CDR +caractéristiques structuruelles OCT:profondeur et déformation de la lamina cribrosa	Fandom Forest	Combinaison des caractéristiques structurelles des images fond avec la déformation de la Lamina Cribrosa pour la détection du glaucome	Nécessite des images OCT de haute résolution
T.Shehryar et al. (2020)	Seuillage (Disque et cup)	Seuillage+ Morphologie mathématique (ILM+RPE)	Précision (Fond d'œil) Précision (OCT) Précision (OCT+ Fond d'œil)	0.84 0.94 0.96	50 paires d'images OCT et fond d'œil BD locale	Fond d'œil: caractéristiques structuruelles et texturales. OCT: CDR	SVM	Mesure précise du CDR Segmentation précise des couches RPE et RNFL	Déformation du cup n'est pas prise en considération dans l'image fond d'œil

Discussion

Plusieurs travaux qui visent l'aide au diagnostic du glaucome, par l'analyse des différentes images rétiniennes (fond d'œil et OCT), ont été étudiés dans ce chapitre. D'après cette bibliographie, nous proposerons deux systèmes d'analyse des images rétiniennes pour le diagnostic du glaucome. Le premier est basé uniquement sur les images fond d'œil (détaillé dans chapitre 3), ou les indicateurs cliniques du glaucome (rapport CDR, vérification de la loi ISNT et l'échelle DDLS), sont extrait après la segmentation du disque et du cup optiques. Le deuxième système a pour objectif d'améliorer la précision du premier système (détaillé dans chapitre 4), en ajoutant des caractéristiques structurelles du complexe des cellules ganglionnaire (GCC), extraites des images OCT maculaires. Au meilleur de nos connaissances, nous sommes les premiers à opter pour une méthodologie de détection du glaucome hybride, basée sur ces deux types de caractéristiques.

CHAPITRE 3

ANALYSE DES IMAGES FOND D'ŒIL POUR LA DÉTECTION DU GLAUCOME

3 Analyse des images fond d'œil pour la détection du glaucome

D'après l'étude bibliographique, il est à noter qu'un système efficace d'analyse des images fond d'œil, pour l'aide au diagnostic du glaucome, doit inclure :

1. Un algorithme robuste pour l'extraction de la région d'intérêt dans les images fond d'œil, qui contient seulement la tête du nerf optique;
2. Une segmentation précise du disque et du cup optiques;
3. Une mesure fiable des indicateurs de glaucome : le rapport CDR, l'épaisseur du bord neuro-rétinien, l'échelle DDLS ... etc;
4. Un algorithme de classification pour identifier les cas de glaucome.

L'objectif de notre travail, est de développer un système qui inclut toute information clinique, extraite des images fond d'œil pour détecter le glaucome, en particulier dans son état précoce.

La méthode proposée inclut tous les indicateurs du glaucome mesurés à partir des images fond d'œil : le rapport CDR, la vérification de la loi ISNT, et l'échelle DDLS afin d'identifier les cas sains des cas pathologiques. Figure 3.1 montre l'organigramme général de la méthode proposée.

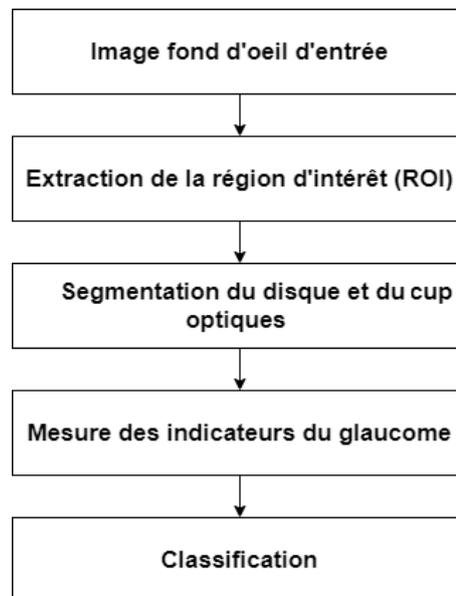


FIGURE 3.1: Organigramme général de la méthode proposée.

3.1 Extraction de la région d'intérêt

Dans les images fond d'œil, la région d'intérêt (Region Of Interest : ROI) pour la détection du glaucome, est la région contenant à la fois le disque et le cup optiques en son centre. L'extraction de cette zone est utilisée comme étape de prétraitement, avant la segmentation de ces deux derniers, afin d'automatiser le processus de l'analyse du fond d'œil.

De multiples algorithmes de localisation du disque optique ont été rapportés dans la littérature, avec la principale limitation de la confusion entre le disque, et les lésions lumineuses causées par d'autres pathologies rétiniennes, comme la Dégénérescence Maculaire Liée à l'Age (DMLA), et la rétinopathie diabétique (si présentes)[120][121][122]. Afin d'effectuer la tâche de l'extraction de cette zone, nous avons conçu un réseau de neurones convolutionnel (CNN) à onze couches, pour identifier chaque segment (taille de 200x200 pixels) de l'image d'entrée comme étant : arrière-plan, lésion lumineuse, ou région du disque.

L'architecture du CNN proposée, ainsi que la base de données utilisée pour son apprentissage, sont détaillées ci-dessous.

3.1.1 Base de données utilisée

La base de données MESSIDOR [25] (Méthodes d'Évaluation de Systèmes de Segmentation et d'Indexation Dédiées à l'Ophtalmologie Rétinienne) comprend 1200 images fond d'œil, dont 800 ont été acquises après dilatation de la pupille, et 400 sans dilatation, avec une résolution de 1440x960, 2240x1488 ou 2304x1536 pixels. Pour chacune de ces images, deux diagnostics sont fournis : le stade de la rétinopathie, et le risque de l'œdème maculaire. La Figure 3.2 montre des exemples d'images fond d'œil de la base de données MESSIDOR.

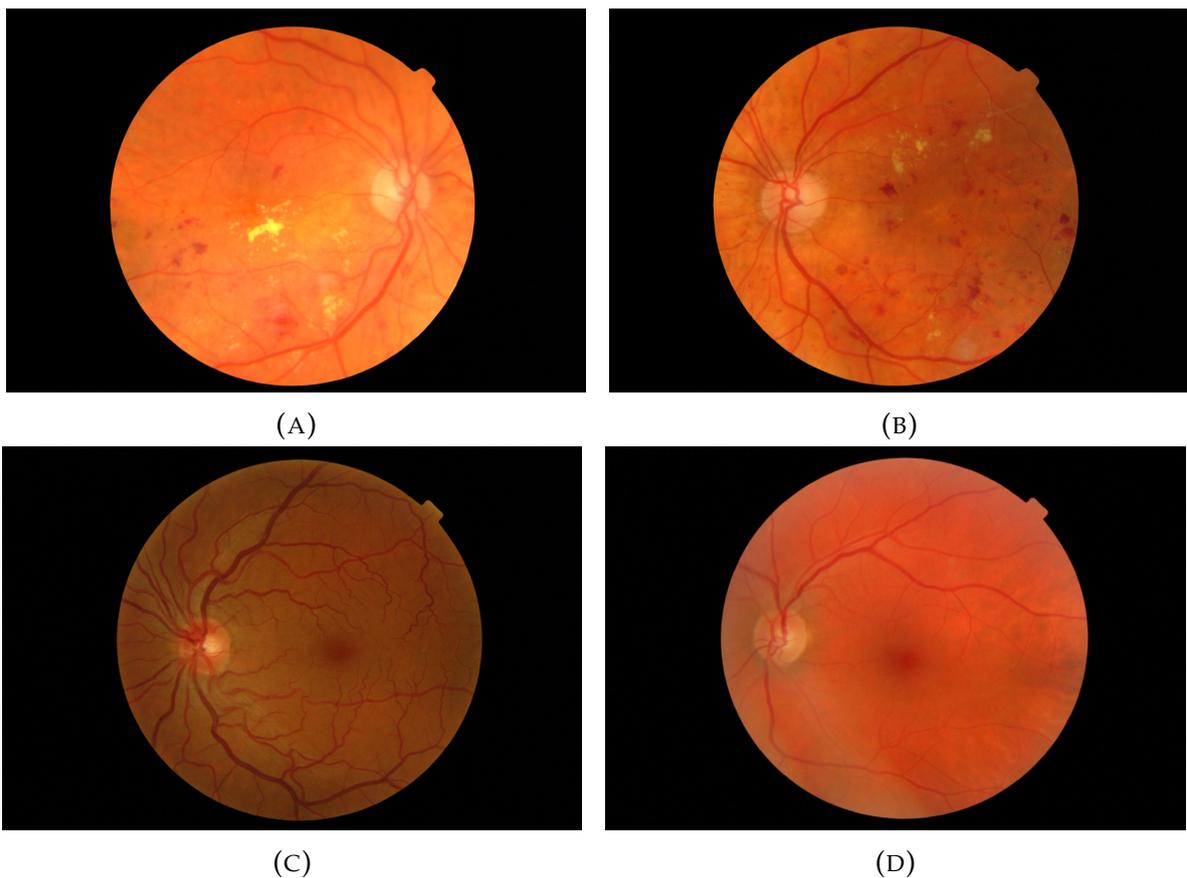


FIGURE 3.2: Exemples des images prises de la base de données MESSIDOR.

Le choix de cette base de données a été motivé par le fait que:

- Les images incluses dans cette base de données, peuvent être utilisées gratuitement pour la recherche et l'éducation;
- Les données sont collectées à partir de plusieurs centres d'ophtalmologie, et sont donc de qualités différentes;
- Toutes les formes de lésions lumineuses qui peuvent être confondues avec le disque optique sont incluses.

Chacune des 1200 images de la base de données MESSIDOR a été redimensionnée à la taille 1500x1500, et divisée en 900 segments de taille 200x200 pixels. Finalement, chaque segment obtenu a été étiqueté à une des trois classes : arrière-plan, lésions lumineuses ou région du disque optique. Pour appartenir à cette dernière, le disque doit être au centre, et totalement inclus dans le segment, pour assurer par la suite une segmentation adéquate (Figure 3.3, première ligne). Par contre, la classe arrière-plan inclut le fond de l'image, les régions de la fovéa, les hémorragies (si présentes), et les segments où le disque est partiellement visible (Figure 3.3, troisième ligne).

La classe supplémentaire des lésions lumineuses, permet l'identification correcte des exsudats, pour éviter de les confondre avec le disque optique, puisque les deux sont considérés comme les seules structures lumineuses dans le fond d'œil (Figure 3.3, deuxième ligne).

Les segments obtenus sont par la suite transmis à un modèle CNN à 11 couches, pour identifier chaque segment des images fond d'œil, en l'une des trois classes mentionnées précédemment, où le segment attribué à la classe disque est considéré comme région d'intérêt. L'architecture du modèle est détaillée dans la section suivante

3.1.2 Réseau de neurones convolutionnel proposé

Les architecture des réseaux de neurones artificiels CNN vise à l'apprentissage automatique des caractéristiques de bas niveau, comme l'intensité, les couleurs et l'orientation,

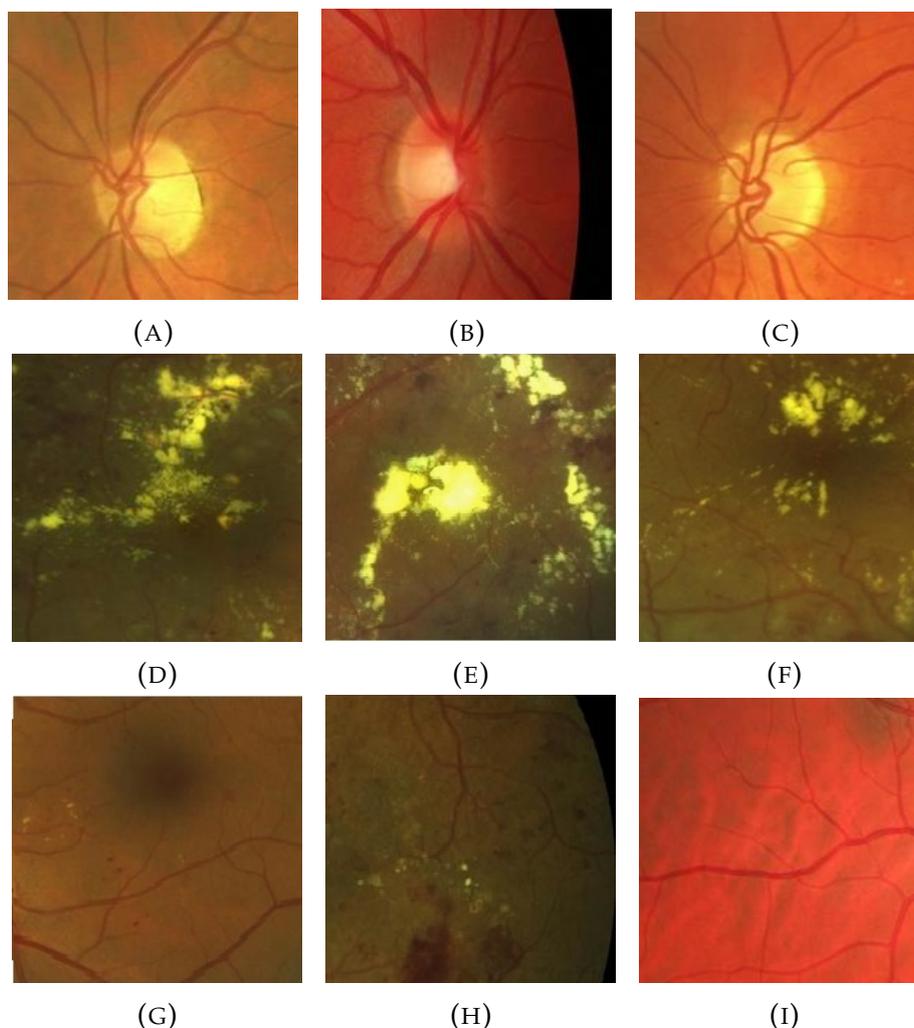


FIGURE 3.3: Exemples des segments extraits des images fond d'œil de la base de données MESSIDOR.

et de haut niveau comme la texture, et les formes dans les images médicales, ce qui aide à la détection et à la classification de différentes maladies [123][124]. Les CNNs se composent généralement de plusieurs couches, y compris les convolutions, les poolings, et les couches entièrement connectées (fully connected). La sortie de chaque couche est appelée carte d'activation, et peut être l'entrée d'une autre couche.

Un ensemble de filtres linéaires est appliqué à l'image d'entrée, ou à la carte d'activation au niveau des couches de convolution, pour extraire les caractéristiques significatives de haut et de bas niveau. L'équation 3.1 montre un exemple de convolution avec un noyau de taille 3x3 :

$$y(l, m, n) = \sum_{k=1}^3 \sum_{i=1}^3 \sum_{j=1}^3 w(l, i, j, k) x(i + m - 1, j + n - 1, k) + b(l) \quad (3.1)$$

Où $x(i, j, k)$ est l'image d'entrée en niveaux de gris (k représente un des trois plans RGB), et $w(l, i, j, k)$ et $b(l)$ représentent les poids et les biais de la couche de convolution, avec l est l'indice de la couche.

La couche de pooling se situe généralement après la couche de convolution, et est utilisée pour réduire le nombre de caractéristiques (i.e. les poids et les biais) du réseau, en sous-échantillonnant les cartes d'activation, et pour améliorer ainsi la robustesse des caractéristiques extraites. Le processus du pooling peut être réalisé soit en utilisant un ensemble de filtres linéaires, qui calculent la moyenne des pixels à l'intérieur du masque (Average Pooling), soit en utilisant un ensemble de filtres non-linéaires, qui calculent la valeur maximale des pixels à l'intérieur du masque (Max Pooling). Le max pooling avec un masque de 2x2 génère des caractéristiques fiables, et est défini comme le montre l'équation 3.2 :

$$z(l, m + 1, n + 1) = \max \begin{bmatrix} y(l, 2m + 1, 2n + 1) & y(l, 2m + 1, 2n + 2) \\ y(l, 2m + 2, 2n + 1) & y(l, 2m + 2, 2n + 2) \end{bmatrix} \quad (3.2)$$

Où z et y représentent la sortie et l'entrée de la couche de pooling.

La sortie de la couche finale de pooling ou de convolution, est aplatie (la sortie de la couche finale et de toutes les couches de pooling ou de convolution, est une matrice tridimensionnelle; l'aplatir veut dire mettre toutes ses valeurs dans un vecteur), puis introduite dans la couche entièrement connectée. Les sorties des couches de convolution, ou des premières couches entièrement connectées, sont généralement traitées à l'aide de la fonction d'activation ReLU (REctified Linear Unit) définie dans l'équation 3.3 :

$$a_i = \begin{cases} b_i & \text{si } b_i > 0 \\ 0 & \text{sinon} \end{cases} \quad (3.3)$$

Où b_i et a_i représentent l'entrée et la sortie générées de la fonction ReLU. Cependant, la fonction d'activation SoftMax (Équation 3.4) est utilisée à la fin du réseau, pour calculer la distribution de probabilité de chacune des sorties de la couche entièrement connectée finale, où c_i est la i^{eme} sortie de la dernière couche, l est le nombre de classes et a_i est l'activation SoftMax correspondante.

$$a_i = \frac{e^{-c_i}}{\sum_{i=0}^l e^{-c_i}} \tag{3.4}$$

Afin d'extraire la ROI dans l'image fond d'œil d'entrée, nous avons conçu un réseau de neurones convolutionnel à 11 couches, pour détecter la région la plus probable à contenir la tête du nerf optique. L'architecture détaillée du modèle est illustrée dans la figure 3.4.

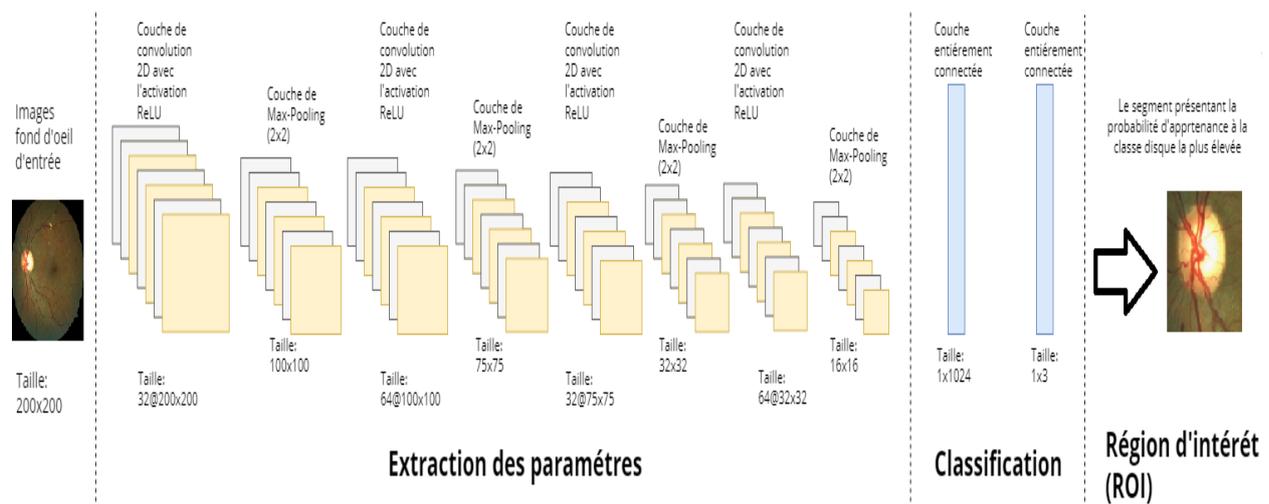


FIGURE 3.4: Architecture détaillée du CNN utilisé pour l'extraction du ROI.

À l'entrée du CNN, l'image fond d'œil est redimensionnée pour conserver la même taille standard de 1500x1500 pixels, et est découpée en 900 segments de taille 200x200 (Le pas vertical et horizontal entre chaque deux segments est 50 pixels). Ceux-ci sont convolutionnés par un ensemble de quatre couches de convolution consécutives, chacune contenant 32 ou 64 filtres (taille de noyau 3x3), avec une seule couche de max-pooling (taille de noyau 2x2) entre chaque deux couches (Chaque couche est détaillée dans la table 3.1). La sortie des quatre étages de pooling et de convolution est ensuite transmise à une couche entièrement connectée, avec 1024 neurones. Les caractéristiques de cette

couche sont à la fin classifiées en 3 classes, dans la couche de sortie à l'aide de la fonction d'activation SoftMax.

TABLE 3.1: Description de l'architecture CNN à onze couches proposée.

Couches	Nom de la couche	Neurones	Noyaux
0	Image d'entrée	1X200X200	-
1	1 ^{ere} convolution	32@200x200	3x3
-	Activation ReLU	ReLU	-
2	1 ^{ere} max pooling	32@100x100	2x2
3	2 ^{eme} convolution	64@100x100	3x3
-	Activation ReLU	ReLU	-
4	2 ^{eme} max pooling	64@50x50	2x2
5	3 ^{eme} convolution	32@50x50	3x3
-	Activation ReLU	ReLU	-
6	3 ^{eme} max pooling	32@25x25	2x2
7	4 ^{eme} convolution	64@25x25	3x3
-	Activation ReLU	ReLU	-
8	4 ^{eme} max pooling	64@13x13	2x2
9	Fully connected	1x1024	-
10	Soft-max	3	-
11	Couche de Sortie	3	-

3.2 Segmentation du disque optique

La segmentation du disque optique est essentielle pour déterminer les caractéristiques liées au glaucome, telles que le rapport CDR, l'amincissement pathologique du bord neuro-rétinien, détectable en vérifiant la loi ISNT, et en mesurant l'échelle DDLS, et la déformation du cup optique, etc. Leur détermination automatique est une tâche assez compliquée, car elle implique une segmentation précise du disque et du cup optiques.

En outre, la position du disque est utilisée comme longueur de référence pour mesurer les distances dans les images fond d'œil, en particulier, pour la localisation de la fovéa [125]. De plus, son centre agit comme point de repère pour les opérations de recalages multimodalités.

Dans cette section, la méthodologie proposée pour la segmentation du disque optique est présentée dans la figure 3.5. Après avoir extrait la ROI nécessaire pour réduire les altérations, qui pourraient survenir lors de l'étape principale d'analyse du disque optique, et pour diminuer le temps de calcul, en traitant une petite partie de l'image au lieu de l'image entière. Elle subit une série d'opérations de prétraitement afin d'améliorer le contraste, d'éliminer les vaisseaux sanguins, et de corriger l'intensité de l'image pour minimiser les erreurs de segmentation. Cette tâche est accomplie par la coopération de deux algorithmes de segmentation (Chan-Vese et les Contour Actifs Géodésiques). La méthodologie est discutée plus en détails dans cette section.

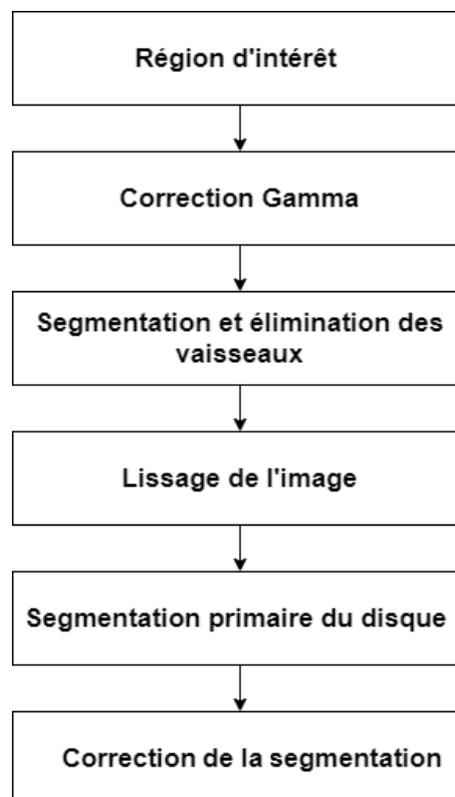


FIGURE 3.5: Organigramme général de la méthodologie proposée pour la segmentation du disque optique.

3.2.1 Prétraitement

Afin d'atteindre une précision de segmentation élevée, il est crucial d'avoir une étape de prétraitement, pour rendre le système d'aide au diagnostic le plus robuste possible. En analysant les trois canaux des images fond d'œil, on peut observer que le canal rouge

présente le meilleur contraste autour du disque optique, tandis que, le canal bleu souffre d'une mauvaise (très fine) plage dynamique des niveaux de gris, et le canal vert présente un flou important autour du disque, ce qui peut biaiser le processus de segmentation (Figure 3.6). Par conséquent, le canal rouge est sélectionné pour la segmentation, puisqu'il révèle un contraste maximal autour du disque.

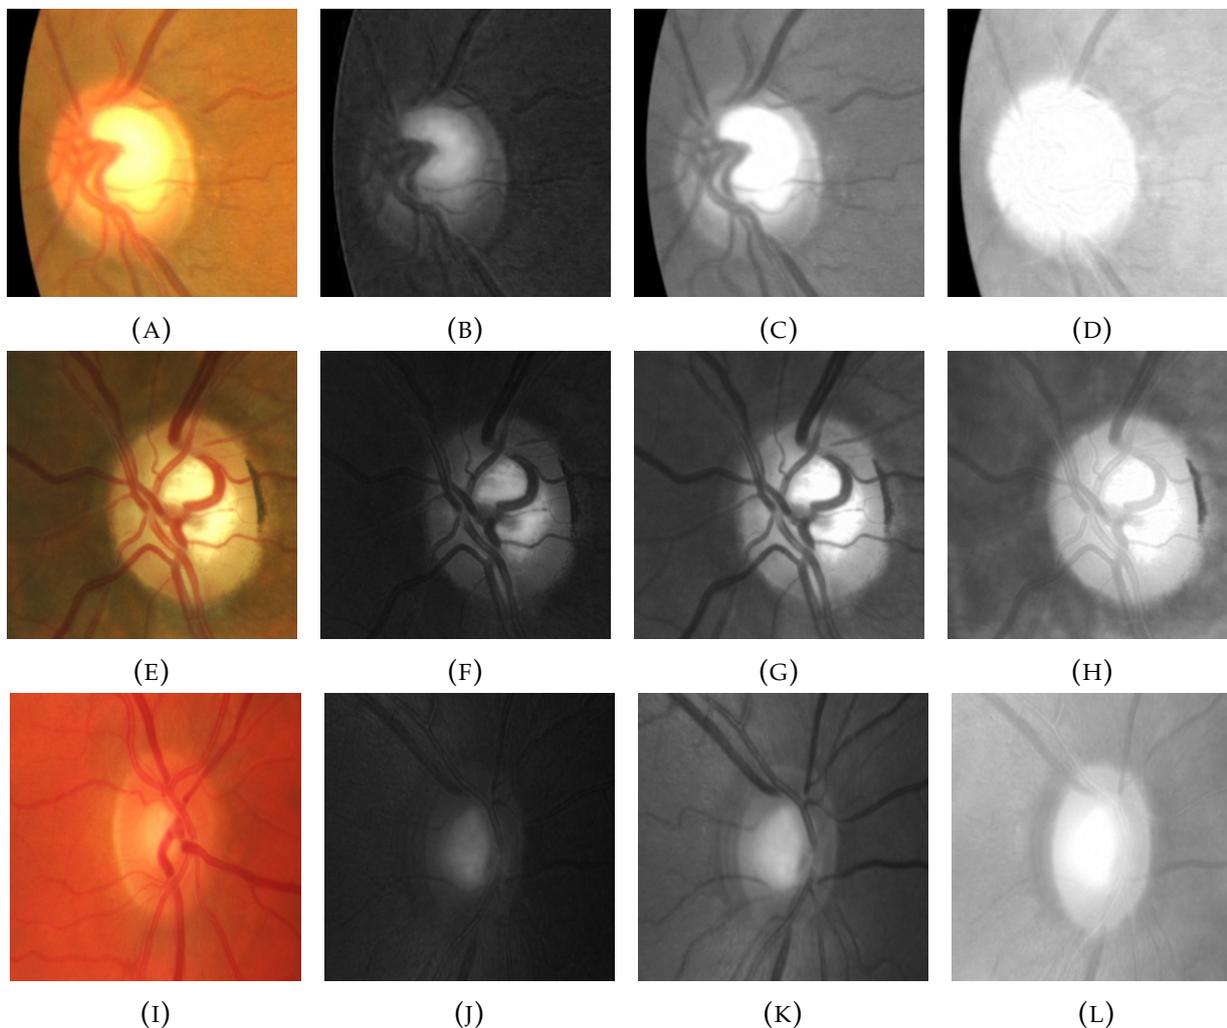


FIGURE 3.6: Représentation de l'image couleur dans l'espace RGB. Première colonne : image en couleurs, deuxième colonne : le canal bleu, troisième colonne : le canal vert, quatrième colonne : le canal rouge.

a. Correction Gamma adaptative

La correction Gamma constitue une famille de techniques de modification des histogrammes, obtenue simplement en variant un paramètre adaptatif γ . La Transformée de

la Correction Gamma (TCG) est montrée dans l'équation 3.5, où I_{max} est l'intensité maximale de l'image d'entrée. L'intensité I de chaque pixel de cette dernière est transformée en $TGC(I)$.

$$TGC(I) = I_{max} \left(\frac{I}{I_{max}} \right)^\gamma \quad (3.5)$$

Cependant, lorsque le contraste est directement modifié par la correction gamma de l'équation 3.5, différentes images avec des distributions d'intensités différentes, présenteront les mêmes changements d'intensité, en raison du paramètre fixe γ . Ce problème est résolu par **S. C. Chia et al. (2013)** [126], en calculant la densité de probabilité (FDP), pour chaque niveau d'intensité de l'image (Equation 3.6).

$$FDP(I) = \frac{n_I}{N} \quad (3.6)$$

Où n_I et le nombre de pixels ayant l'intensité I , et N le nombre total des pixels dans l'image. La Fonction de Distribution Cumulative (FDC) est basée sur la FDP, et est formulée dans l'équation 3.7, alors que la Correction Finale de l'Histogramme (CFH) est obtenue par application de l'équation 3.8.

$$FDC(I) = \sum_{k=0}^I FDP(k) \quad (3.7)$$

$$CFH(I) = FDC(I) I_{max} \quad (3.8)$$

Même si le canal rouge présente le meilleur contraste autour du disque optique, ce dernier apparait, souvent dans la base de données HRF, avec un faible contraste, bruité, et avec des frontières floues (Figure 3.6 dernière ligne). La correction gamma adaptative a remédié à ces problèmes dans la base HRF, sans biaiser la qualité des autres images. Dans notre travail, cette correction n'est appliquée que sur la composante rouge de la région d'intérêt, la figure 3.7 montre un exemple des résultats obtenus.

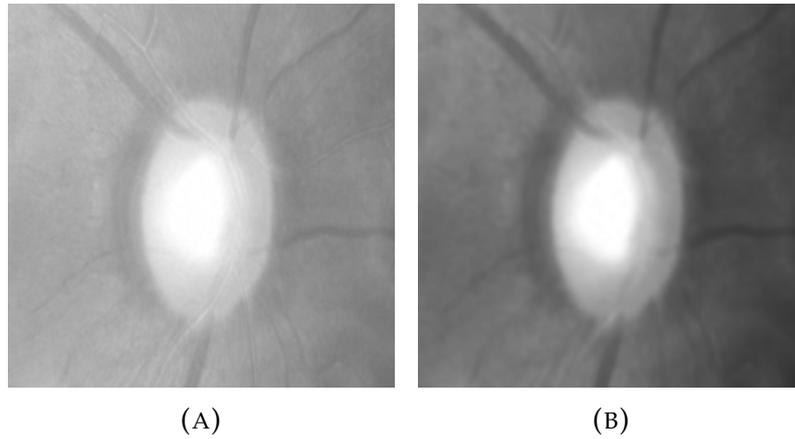


FIGURE 3.7: Amélioration de la région du disque par correction gamma. (A) canal rouge de la ROI, (B) correction gamma.

b. Segmentation et élimination des vaisseaux

Comme il a été mentionné au chapitre 2, le principal défi pour la segmentation du disque optique, est le fait que ce dernier est souvent obscurci par les croisements des vaisseaux sanguins, ce qui rend la tâche de segmentation du disque difficile.

Comme les intensités des vaisseaux sanguins sont inférieures à celles d'autres structures dans les images fond d'œil, ils pourraient être segmentés en se basant seulement sur cette différence d'intensités. Dans cette section, nous proposons une approche basée sur l'opérateur morphologique chapeau haut de forme noir (black top hat), afin d'extraire, et d'éliminer l'arbre vasculaire de l'image ROI améliorée. L'avantage principal de cette approche (Algorithme 1) est la capacité de segmenter la totalité de l'arbre vasculaire, et de récupérer les parties cachées du disque par ce dernier.

Une fois la région d'intérêt est améliorée à l'aide de la correction gamma adaptative, on se focalise à mettre en évidence l'arbre vasculaire. Cette tâche est réalisée à l'aide de l'opérateur morphologique dénommé : chapeau haut de forme noir [127]. Cet opérateur est basé sur la soustraction de l'image ayant subi une fermeture de l'image initiale. Il consiste à extraire tous les détails sombres de l'image, qui ont été éliminés par l'étape de fermeture, et dont la taille ne dépasse pas celle de l'élément structurant. Cette transformation est illustrée dans l'équation 3.9 où I est l'image initiale, \odot l'opération de fermeture

Algorithm 1: Segmentation et élimination de l'arbre vasculaire.

Entrée: Image I de la région d'intérêt;
Résultat: Image I_{finale} sans arbre vasculaire;
Début;
Extraction des vaisseaux;
 $I \Rightarrow$ Image ROI améliorée ;
Définir un élément structurant (SE) de taille 25×25 ;
 $I_f \Rightarrow I \odot SE$ (opération de fermeture);
 $C_{bas} \Rightarrow I_f - I$ (chapeau haut de forme noir);
 $I_v \Rightarrow$ Extraire l'arbre vasculaire par seuillage;
Elimination des vaisseaux;
while $I(i, j)$ dans I **do**
 if $I_v(i, j) == 1$ **then**
 $I(i, j) \Rightarrow median(I(i, j), I(i+, j), I(i + 1, j + 1), I(i + 1, j - 1), I(i, j + 1), I(i - 1, j + 1), I(i + 1, j + 1));$
 end
 else
 Sauter le pixel;
 end
end
Lissage de l'image;
 $I_{finale} \Rightarrow median(I, [50 \times 50])$ (Filtrage médian de l'image I avec une fenêtre de taille 50×50 pixels);
Fin.

et SE l'élément structurant de taille 25×25 , dans ce cas.

$$C_{Bas} = (I \odot SE) - I \quad (3.9)$$

Une fois l'arbre vasculaire éliminé de l'image ROI, un lissage est effectué par un filtre médian de taille 50×50 pixels. Un exemple d'élimination des vaisseaux sanguins est montré dans la figure 3.8. Cet algorithme a permis de remplir avec succès les zones externes et centrales du disque optique cachées par les croisements de l'arbre vasculaire, en récupérant ses vraies frontières.

3.2.2 Segmentation proposée du disque optique

Le disque optique (tête du nerf optique) est la zone lumineuse et ronde contenant le cup optique, où les axones des cellules ganglionnaires quittent l'œil vers le cerveau. La zone entre les frontières du disque et celles du cup est appelée bord neuro-rétinien. La

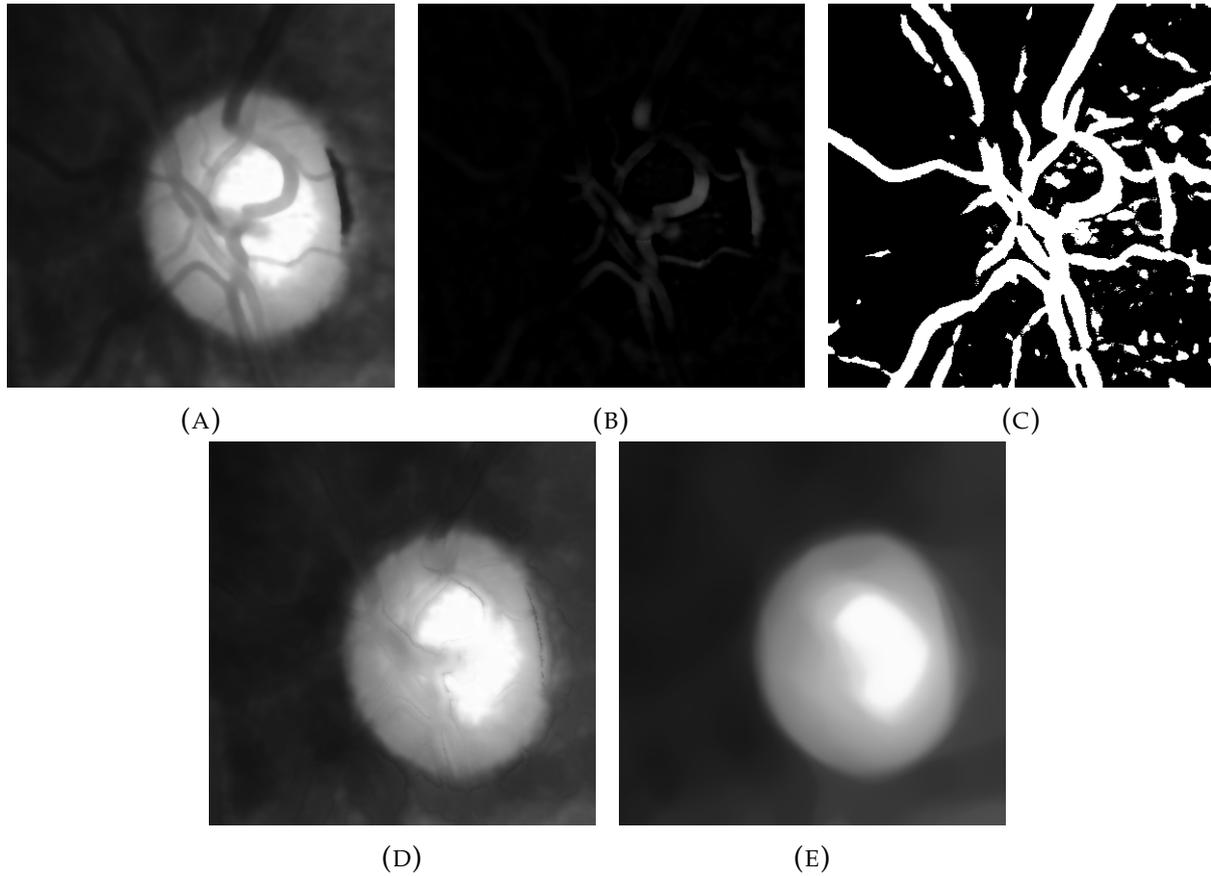


FIGURE 3.8: Exemple de segmentation et élimination des vaisseaux sanguins. (A) image améliorée, (B) transformée Chapeau Bas de forme, (C) seuillage des vaisseaux, (D) élimination des vaisseaux, (E) lissage de l'image.

segmentation des frontières du disque optique est une tâche importante pour la mesure des indicateurs du glaucome, et donc pour la détection de la maladie.

Dans ce travail, la segmentation du disque est mise en œuvre à l'aide d'une coopération séquentielle entre les algorithmes de Chan-Vese, et des Contours Actifs Géodésiques.

a. Segmentation primaire du disque optique

Les méthodes de segmentation par contours actifs sont parmi les méthodes les plus efficaces pour la segmentation des images médicales. Parmi ces méthodes, on peut citer le modèle Chan-Vese [128], qui est basé sur la théorie des ensembles de niveaux (Level-set). Cette approche permet souvent une segmentation précise, grâce à sa capacité à manier naturellement les changements topologiques de l'image.

Ils existent deux classes principales de la méthode level-set : les modèles basés sur les régions, et les modèles basés sur les contours. Les premiers modèles utilisent les informations locales des frontières, pour diriger le contour actif vers les limites de l'objet à segmenter, tandis que les seconds utilisent certains descripteurs pour identifier chaque région d'intérêt, afin de guider le contour vers les frontières souhaitées [129].

Les modèles basés sur les régions comprennent généralement deux termes : un terme de régularité pour lisser la forme du contour, et un terme de minimisation d'énergie, pour détecter les caractéristiques uniformes de l'image. Le modèle proposé par **Mumford et Shah (1989)** [130] était le premier modèle level-set développé pour la segmentation des images.

Soit Ω le domaine de l'image, $I(x, y)$ le niveau de gris du pixel de coordonnées (x, y) , et C le contour que l'on souhaite segmenter, en utilisant la fonction d'énergie qui sépare Ω en N régions disjointes. La fonction d'énergie du modèle est définie comme le montre l'équation 3.10, où $|C|$ est la longueur du contour, et u une approximation de l'image I .

$$F(u, C) = \int_{\Omega} (u - I(x, y))^2 dx dy + \mu \int_{\Omega/C} |\nabla u|^2 dx dy + \nu |C| \quad (3.10)$$

Le premier terme de l'équation 3.10 est le terme de l'approximation de u , qui force ce dernier à se rapprocher de l'image I . le second est le terme de lissage du contour C , et le troisième est le terme de régularisation, qui réduit la taille du C .

Le modèle de Chan Vese [128] est un modèle simplifié du modèle proposé par D.B. Mumford et al., et s'est avéré être une méthode puissante et flexible, capable de segmenter de nombreux types d'images, y compris les images médicales. Son équation de minimisation d'énergie est définie comme le montre l'équation 3.11, où λ_1 , λ_2 , μ et ν sont des paramètres déterminés par l'utilisateur, qui dans ce travail ont pris les valeurs 2, 0.25, 1, et 1, respectivement. La fonction d'énergie peut être réécrite comme le montre l'équation 3.12.

$$F_{CV}(\phi, c_1, c_2) = \lambda_1 \int_{out(C)} (I(x, y) - c_1)^2 dx dy + \lambda_2 \int_{in(C)} (I(x, y) - c_2)^2 dx dy + \mu \cdot Longuer(C) + v \cdot surface(C) \tag{3.11}$$

$$F_{CV}(\phi, c_1, c_2) = \lambda_1 \int_{out(C)} (I(x, y) - c_1)^2 dx dy + \lambda_2 \int_{in(C)} (I(x, y) - c_2)^2 dx dy + \mu \int_{\Omega} |\nabla H(\phi(x, y))| dx dy + v \int_{\Omega} |H(\phi(x, y))| dx dy \tag{3.12}$$

Où ϕ est la fonction level-set à minimiser, H fonction de Heaviside, $out(C)$ et $in(C)$ indiquent les régions à l'extérieur et à l'intérieur du contour C respectivement, et c_1 et c_2 sont les intensités moyennes de ces deux régions. Le niveau zéro de la fonction ϕ est défini comme : $C = (x, y) : \phi(x, y) = 0$. Ce contour sépare le domaine Ω de l'image en deux régions disjointes : $\Omega_1 = (x, y) : \phi(x, y) > 0$ et $\Omega_2 = (x, y) : \phi(x, y) < 0$. La Figure 3.9 montre les positions possibles de la courbe C , avec $F1(C) = \lambda_1 \int_{in(C)} (I(x, y) - c_1)^2 dx dy$ et $F2(C) = \lambda_2 \int_{out(C)} (I(x, y) - c_2)^2 dx dy$.

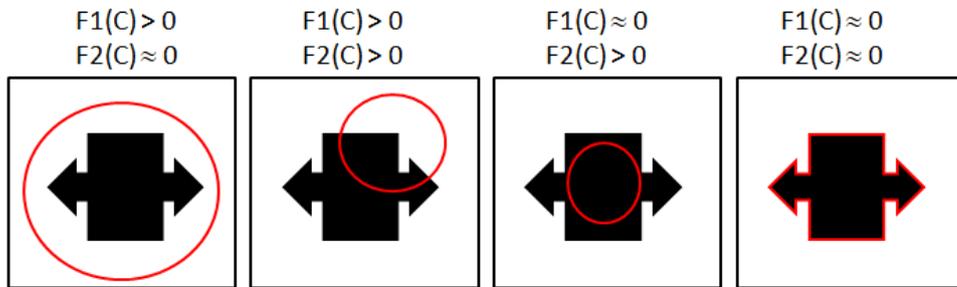


FIGURE 3.9: Segmentation par la méthode Chan-Vese selon les positions possibles de courbe.

Pour segmenter le disque optique, nous implémentons le modèle Chan-Vese, où la courbe C est initialisée aux bords de la région d'intérêt, la figure 3.10 montre un résultat de la segmentation du disque par le modèle Chan-Vese. On remarque clairement que l'algorithme n'est pas sensible aux bruits, et est robuste contre les changements topologiques de l'image. Cependant, dans certains cas, le disque est tellement éclairé que le flou qui

l'entoure provoque une convergence de la courbe, avant qu'elle n'atteigne les vraies limites du disque optique (Figure 3.10 (D)).

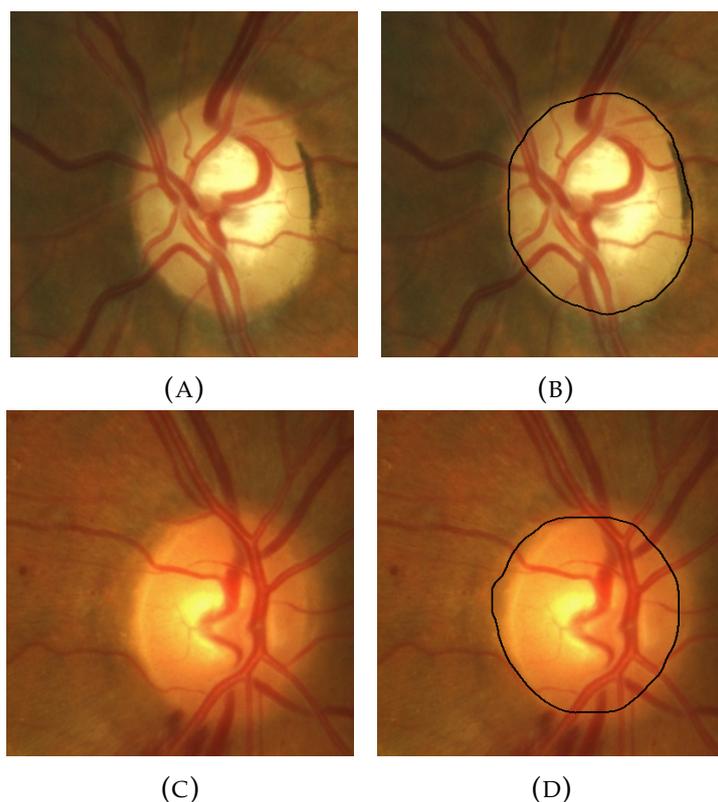


FIGURE 3.10: Résultats de la segmentation primaire du disque optique. Première colonne : images initiales, deuxième colonne : images segmentées.

Pour remédier à ce problème, nous implémentons une correction de la segmentation, basée sur l'algorithme des contours actifs géodésiques, où la segmentation primaire de Chan-Vese est utilisée comme contour initial. Cette coopération permet une correction précise des mauvaises segmentations du disque, sans biaiser les résultats où ce dernier est bien segmenté par le premier algorithme. Cette coopération est décrite en détails dans la section suivante.

b. Correction de la segmentation du disque optique

La méthode des contours actifs géodésiques est une approche de segmentation dérivée des level-set, dans laquelle une fonction d'incorporation ϕ , initialisée par l'utilisateur, évolue selon une fonction d'énergie composée de trois termes : un terme de contrainte de régularité qui lisse le contour, un terme de vitesse, qui ralentit l'évolution de la courbe

aux proximités des contours à segmenter, et un terme de force, pour étendre ou contracter la courbe. L'équation d'évolution de la fonction ϕ est montrée dans l'équation 3.13. Où ϕ est la fonction d'incorporation (fonction distance), g représente le terme de vitesse, et k représente la courbure.

$$\frac{\partial \phi}{\partial t} = -g(I)k \|\nabla \phi\| + \nabla g \cdot \nabla \phi \quad (3.13)$$

Pour déterminer le terme de vitesse g dans la formulation de l'équation précédente, on commence par le calcul des gradients d'intensité de l'image à segmenter. Le potentiel négatif de ces gradients, est ensuite calculé à l'aide d'une fonction de vitesse, qui peut prendre des formes rationnelles ou exponentielles, dont des exemples sont présentés dans les équations 3.14 et 3.15, respectivement.

$$g(s) = \frac{1}{1 + \left(\frac{1}{s}\right)^{1+\alpha}} \quad (3.14)$$

$$g(s) = \frac{1}{1 + \exp\left[-\frac{s-\beta}{\alpha}\right]} \quad (3.15)$$

Ces fonctions de vitesse fournissent un mappage, qui attribue des valeurs strictement positives, proches de 1 dans les régions homogènes, et proches de 0 au niveau des contours. Par conséquent, la courbe évolutive ϕ est ralentie lorsqu'elle est proche des limites des régions homogènes de l'image. La figure 3.11 illustre les images intermédiaires lors du processus de segmentation par contours actifs géodésiques, y compris l'image de vitesse produite en utilisant la fonction 3.15.

Il est à noter que la fonction de vitesse élimine tous les faibles gradients d'intensité, causés par le flou entourant le disque optique. Par conséquent, les contours actifs géodésiques produisent des résultats de segmentation précis et adéquats, à condition qu'une bonne initialisation de ϕ soit fournie. Pour cela, le contour final fourni par l'algorithme de Chan-Vese dans l'étape précédente, est introduit comme état initiale de la fonction ϕ . La figure 3.12 montre un exemple de la correction de la segmentation du disque optique. Par exemple dans le cas montré dans la figure 3.12 (première ligne), l'erreur produite par

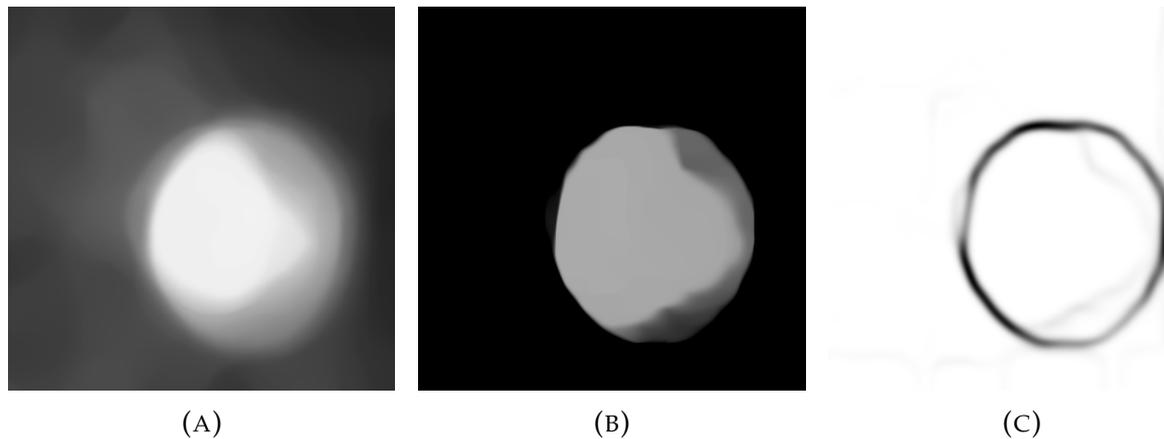


FIGURE 3.11: Étapes intermédiaires de segmentation des contours actifs géodésiques. (A) image initiale, (B) image d'amplitude du gradient, (C) image de vitesse g calculée à l'aide de l'équation 3.15.

l'algorithme de Chan-Vese entrainera une mauvaise mesure du rapport CDR horizontal. De même, le cas montré dans la figure 3.12 (deuxième ligne), présente une bonne segmentation avant la correction, et on remarque que cette dernière a raffiné la segmentation initiale sans la biaiser.

Enfin, un ajustement d'ellipse est effectué pour lisser le contour segmenté. Dans cette technique, une ellipse est calculée autour de tous les pixels du contour segmenté, en minimisant la somme des distances au carré du centre de l'ellipse, à chaque pixel du contour, comme le montre l'équation 3.16. Où X_e et Y_e sont les coordonnées du centre de l'ellipse et X et Y les coordonnées des pixels.

$$Distance = \sqrt{(X - X_e)^2 + (Y - Y_e)^2} \quad (3.16)$$

3.3 Segmentation du cup optique

Après la segmentation du disque optique, l'étape suivante consiste à extraire la région du cup optique, afin de déterminer les caractéristiques utilisées pour le diagnostic du glaucome, telles que le rapport CDR, les pertes au niveau du bord neuro-rétinien... etc. Semblable au disque optique, le cup n'a pas de gradients nets d'intensité, en raison de la présence de nombreuses structures à l'intérieur de la tête du nerf optique (vaisseaux

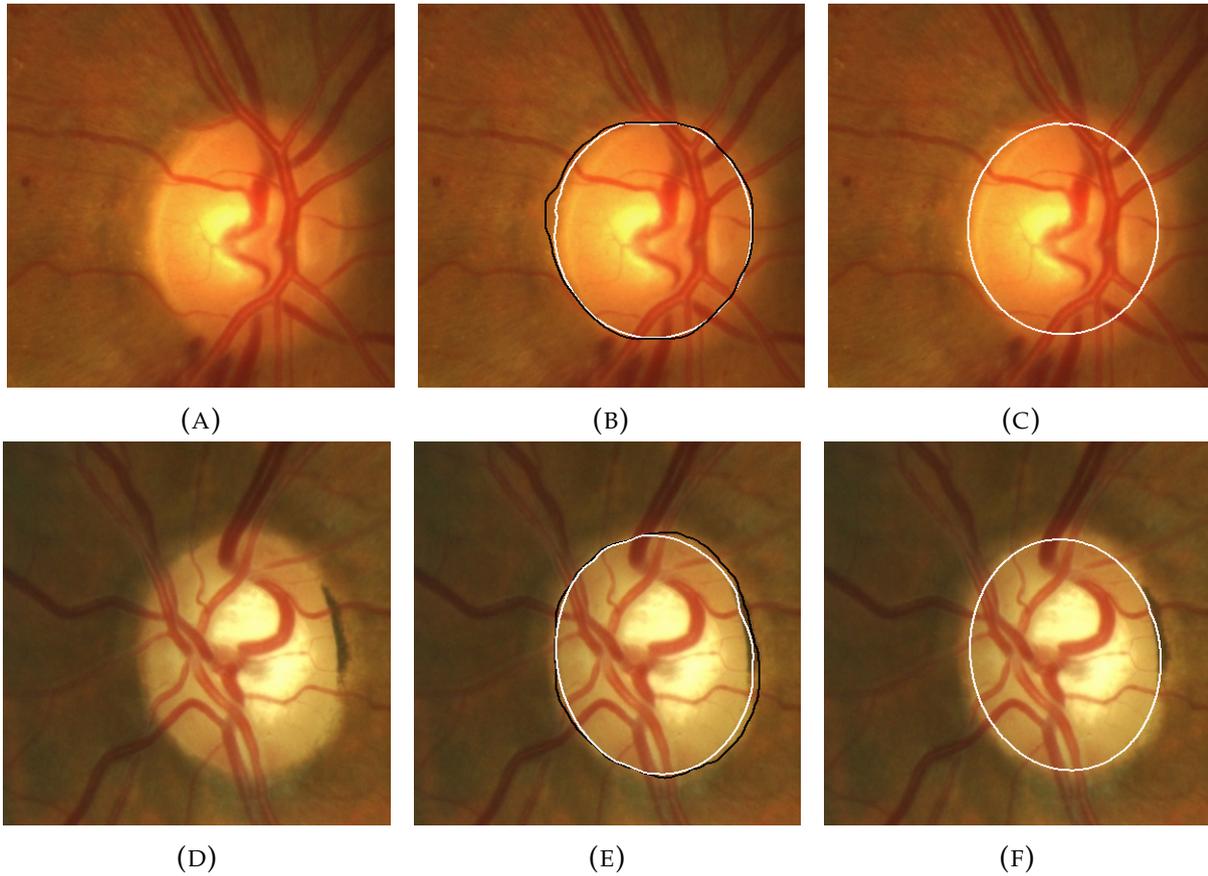


FIGURE 3.12: Segmentation finale du disque optique. (A) et (D) images initiales, (B) et (E): résultats de segmentation avant et après correction présentés en contours noirs et blancs respectivement, (C) et (F) résultats finaux (ajustement d'ellipse).

sanguins, cup optique, bord neuro-rétinien, etc.); il est difficile de déterminer ces vrais contours avec précision.

Afin de résoudre ce problème, nous proposons une méthodologie basée sur les superpixels de Falzenswalb [131] (Figure 3.13), afin de séparer la région du cup, du bord neuro-rétinien à l'intérieur du disque optique. Cette méthodologie est discutée en détails dans cette section.

3.3.1 Prétraitement

La segmentation du cup optique est considérablement plus difficile que celle du disque, en raison non seulement des croisements des vaisseaux sanguins, circonscrivant le disque optique, et chevauchant le cup. Mais aussi du flou important entourant ce dernier. Par

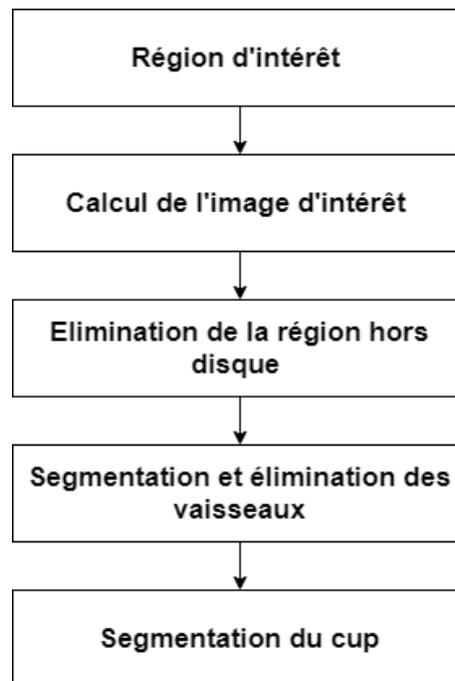


FIGURE 3.13: Organigramme général de la méthodologie proposée pour la segmentation du cup optique.

conséquent, avant la segmentation, une étape de prétraitement a été effectuée pour analyser l'image, réduire l'effet des vaisseaux sanguins, et améliorer le contraste entre et disque et le cup.

a. Calcul de l'image d'intérêt

Sachant que le cup optique apparaît souvent dans les images couleur de fond d'œil avec un faible contraste, et des frontières floues, il est indispensable dans notre étude d'augmenter le contraste, et d'éliminer le bruit et le flou qui l'entourent. Pour cela, une image d'intérêt est calculée afin de faciliter la tâche de segmentation. Elle est obtenue en fusionnant la composante H de l'espace couleur HSV, et la composante I de l'espace $l^*a^*b^*$, avec les coefficients 0.2 et 0.9, respectivement (Équation 3.17).

$$image = (h * 0.2) + (l * 0.9) \quad (3.17)$$

L'espace couleur HSV est un modèle de représentation de couleur naturelle (Figure 3.14), c'est-à-dire, proche de la perception physiologique des couleurs par l'œil humain

[125]. Il est composé de trois composantes :

- La teinte (en anglais: Hue) : correspondant à la perception des couleurs, et permettant de déterminer la couleur souhaitée (rouge, vert, bleu, ...);
- La saturation (ou intensité) : mesurant la pureté des couleurs. Cette composante permet la distinction des couleurs vives, des couleurs pastelées ou délavées;
- La luminance (en anglais: Value) : indiquant la quantité de lumière de la couleur, c'est-à-dire son aspect clair ou sombre.

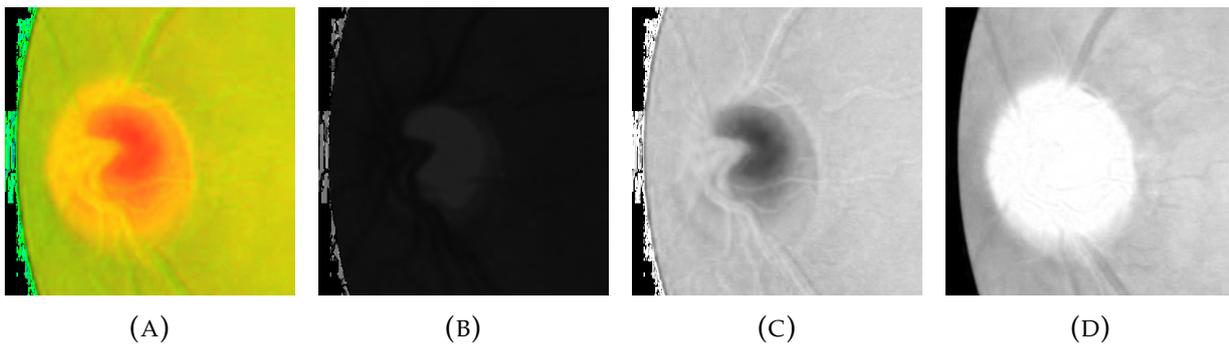


FIGURE 3.14: Représentation de l'image ROI dans l'espace HSV. (A) l'image dans l'espace HSV, (B) canal H, (C) canal S, (D) canal V.

L'espace couleur lab (ou plus précisément $l^*a^*b^*$) est un espace couleur standardisé par la CIE [132]. Il caractérise une couleur à l'aide d'un paramètre d'intensité l^* correspondant à la luminance (ou la clarté), et deux paramètres de chrominance a^* et b^* décrivant la couleur [133]. La figure 3.15 montre les composantes $l^*a^*b^*$ de l'image ROI.

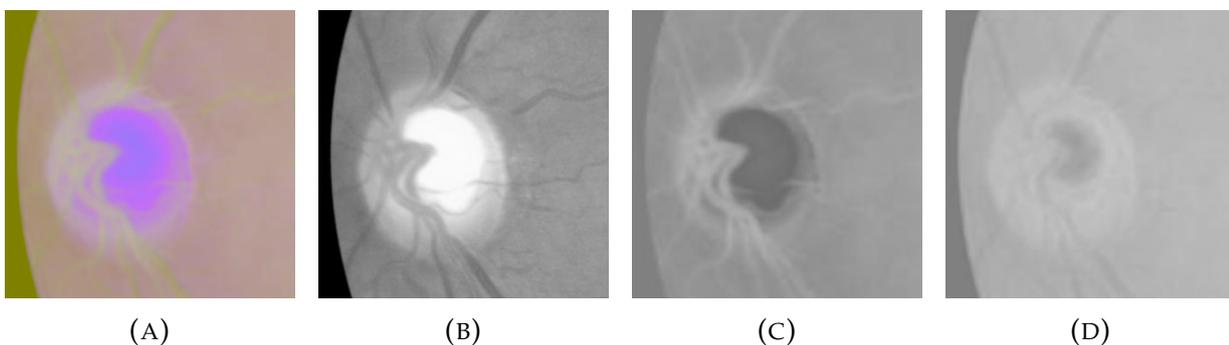


FIGURE 3.15: Représentation de l'image ROI dans l'espace $l^*a^*b^*$. (A) l'image dans l'espace $l^*a^*b^*$, (B) canal l , (C) canal: a , (D) canal b .

Dans le canal H, le cup optique apparaît avec un meilleur contraste, par rapport au bord neuro-rétinien. Par contre, les contours sont très perturbés par la vascularisation des

vaisseaux sanguins sortant de la tête du nerf optique. Ce défaut est corrigé en fusionnant la composante H de l'espace couleur HSV, et la composante I de l'espace $l^*a^*b^*$ (selon l'équation 3.17). Dans cette dernière, les frontières du cup optique sont plus bruitées, mais peu perturbées par les vaisseaux sanguins. En outre, pour éliminer le bruit, et les petites variations dans la région du disque optique, nous appliquons par la suite une égalisation adaptative de l'histogramme de l'image fusionnée. Il en résulte l'image d'intérêt finale, qui servira à la segmentation du cup optique (Figure 3.16).

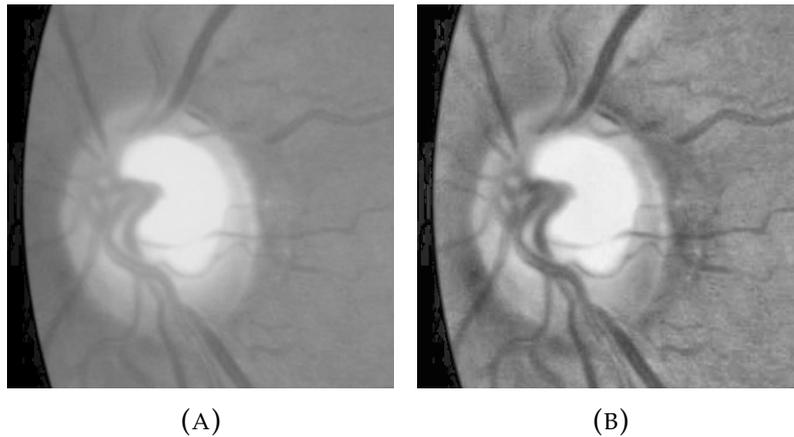


FIGURE 3.16: Image d'intérêt finale pour la segmentation du cup optique. (A) fusion des composantes H et I, (B) égalisation de l'histogramme.

b. Segmentation et élimination des vaisseaux sanguins

La maladie du glaucome est principalement caractérisée par la perte des fibres nerveuses au niveau de la tête du nerf optique. Cependant, à notre connaissance, les vaisseaux sanguins rétiniens ne sont pas significativement affectés par cette pathologie, car il s'agit du nerf optique. Pour cette raison, l'élimination des vaisseaux est une étape importante de prétraitement, car ils ne fournissent aucune information supplémentaire pour le diagnostic du glaucome, et peuvent rendre la segmentation du cup plus difficile.

Après le calcul de l'image d'intérêt, l'arbre vasculaire est éliminé, en utilisant la même technique de l'algorithme 1, sauf qu'après leur élimination, toute la région à l'extérieur du disque optique est supprimée, en appliquant un masque du disque segmenté, sur l'image où les vaisseaux sont éliminés (Figure 3.17).

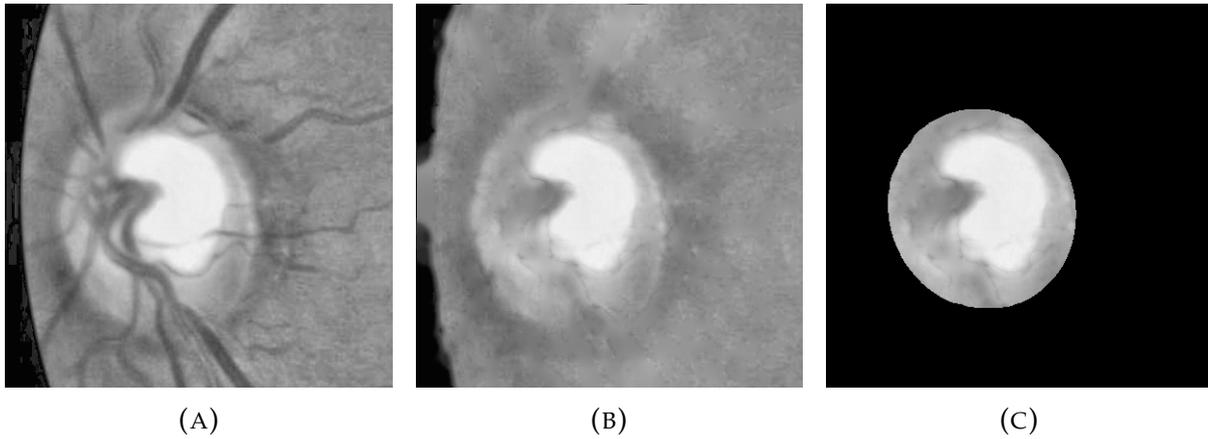


FIGURE 3.17: Élimination des vaisseaux et de la région à l'extérieur du disque. (A) image d'intérêt, (B) élimination des vaisseaux, (C) élimination de la région hors disque.

3.3.2 Segmentation proposée du cup optique

Les techniques de segmentation basées sur la théorie des graphes, modélisent l'image en un graphe $G(V, E)$, où chaque nœud $v_i \in V$ représente un pixel de l'image. Les arêtes $(v_i, v_j) \in E$ sont formées pour relier chaque paire de pixels, avec un poids qui dépend de leur similarité. La tâche de la segmentation dans ces méthodes est accomplie par la génération des sous-graphes, en supprimant les arêtes qui relient les pixels qui ne sont pas similaires [134] (Figure 3.18).

L'algorithme proposé par **Felzenswalb et al. (2004)** [131], est l'un des algorithmes basés sur les graphes les plus efficaces pour la segmentation des images. Soit $G = (V, E)$ un graphe non-orienté avec des sommets (nœuds) $v_i \in V$, représentant l'ensemble d'éléments à segmenter, et des arêtes $(v_i, v_j) \in E$ reliant chaque paire de sommets, avec un poids $w((v_i, v_j))$, qui est une mesure positive de la dissemblance entre les éléments voisins v_i et v_j .

Dans les applications de la segmentation d'images, les éléments de V représentent les pixels de l'image, et les poids w sont des mesures qui décrivent la dissemblance entre chaque deux pixels connectés par la même arête (par exemple la différence d'intensité, de couleur ou d'un autre attribut local).

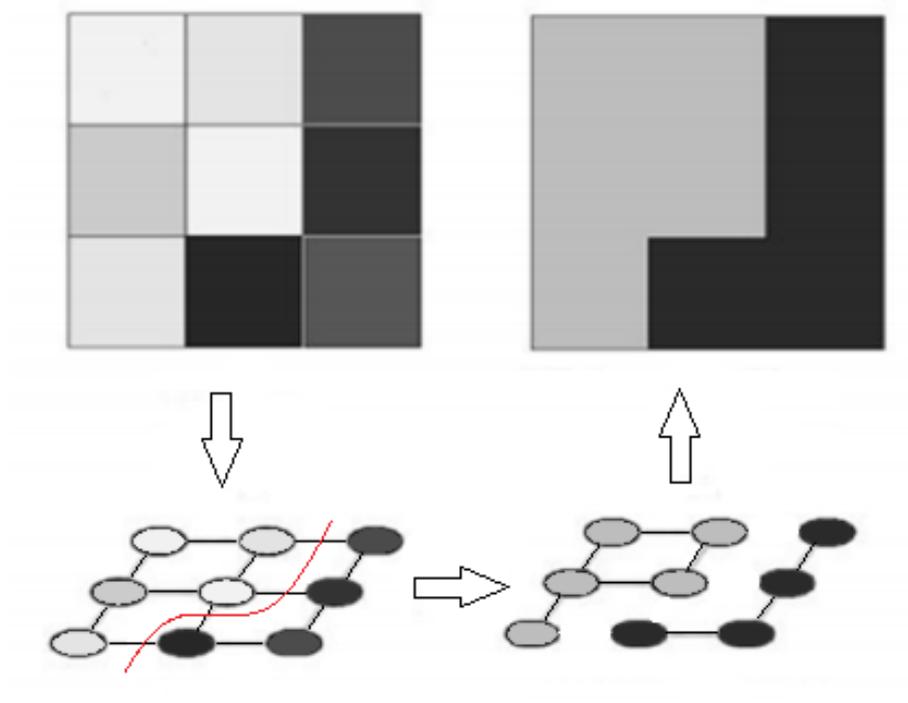


FIGURE 3.18: Représentation schématique de la segmentation d'images en graphe.

Une segmentation S est une partition de V en plusieurs composantes, telle que chaque composante (ou région) $C \subseteq S$ correspond à une composante connexe dans un graphe $G' = (V, E')$, où $E' \in E$. En d'autres termes, les éléments (pixels) de la même composante doivent être similaires, et les éléments des différentes composantes doivent être dissimilaires. Cela signifie que les arêtes entre deux pixels de la même région doivent avoir des poids relativement faibles, et les arêtes entre les pixels des différentes régions doivent avoir des poids plus élevés.

Pour vérifier s'il existe une frontière entre deux composantes, un prédicat D est défini. Ce dernier est basé sur la mesure de dissemblance, entre les éléments le long de la frontière des deux composantes, par rapport à une autre mesure de dissemblance entre les éléments voisins, dans chacune des deux composantes. Le prédicat résultant compare les différences inter-régions, aux différences à l'intérieur de chacune des régions, et est ainsi adaptatif par rapport aux caractéristiques locales de l'image.

On définit la différence interne d'une composante $C \subseteq V$ (Equation 3.18), comme

étant le poids le plus élevé de l'arbre couvrant de poids minimal (Minimum Spanning Tree : MST). Ce dernier est un sous-ensemble du graphe G , qui relie tous les sommets, sans aucun cycle avec un poids total minimal des arêtes.

$$Int(C) = \max_{e \in MST(C,E)} w(e) \quad (3.18)$$

En se basant sur cette mesure, une composante donnée C ne reste connectée que lorsque des arêtes de poids inférieur ou égal à $Int(C)$ sont considérées.

On définit la différence entre deux composantes $C_1, C_2 \subseteq V$, comme étant le poids minimal reliant C_1 et C_2 (Equation 3.19).

$$Dif(C_1, C_2) = \min_{v_i \in C_1, v_j \in C_2, (v_i, v_j) \in E} w((v_i, v_j)) \quad (3.19)$$

Le prédicat de comparaison des régions (Équation 3.20) évalue s'il existe une preuve d'une frontière entre une paire de composantes, en vérifiant si la différence entre elles $Dif(C_1, C_2)$, est plus grande que la différence interne d'au moins une des deux composantes, $Int(C_1)$ et $Int(C_2)$. Une fonction de seuil est utilisée, pour contrôler le degré auquel $Dif(C_1, C_2)$ doit être supérieur à la différence interne minimale (Équation 3.21).

$$D(C_1, C_2) = \begin{cases} \text{Vrai} & \text{Si } Dif(C_1, C_2) > MInt(C_1, C_2) \\ \text{Faux} & \text{Sinon} \end{cases} \quad (3.20)$$

$$MInt(C_1, C_2) = \min(Int(C_1) + \tau(C_1), Int(C_2) + \tau(C_2)) \quad (3.21)$$

Pour les petites composantes (régions), $Int(C)$ ne fournit pas une bonne estimation des caractéristiques locales de la région, dans le cas extrême où $|C| = 1$, $Int(C) = 0$. Par conséquent, nous utilisons une fonction de seuil basée sur la taille de région (Équation 3.22), où $|C|$ désigne la taille de C , et k est un paramètre constant. Autrement dit, pour les petites composantes, nous avons besoin de preuves plus solides pour une frontière [131].

$$\tau(C) = k/|C| \quad (3.22)$$

Le partitionnement de l'image, où les vaisseaux sanguins ont été éliminés, par la méthode de Felzenswalb (Figure 5.3), renvoie quatre composantes : fond (1), cup optique (2), vaisseaux sanguins non-segmentés (3), et bord neuro-rétinien (4). L'algorithme présente une grande capacité à préserver les détails dans les régions à faible variabilité, tout en ignorant les détails à haute variabilité, causés par la vascularisation non-éliminée dans l'étape précédente, à l'intérieur du disque optique, ce qui a permis une segmentation efficace du cup optique.

En raison de certains vaisseaux non segmentés, la segmentation du cup présente des discontinuités au niveau du cup, qui sont rectifiées en utilisant l'algorithme de convexe hull. Ce dernière est une opération morphologique qui renvoie la courbe d'enveloppe (la courbe convexe) de la région, du cup en joignant les ouvertures présentes dans la région segmentée. La courbe obtenue compense les informations perdues dans les parties cachées de la région du cup. Dans notre algorithme, le convexe hull est déterminé à l'aide de quatre éléments structurants $E_i = 1, 2, 3, 4$ dans les Équation 3.23 et 3.24, où I est l'image initiale, et $*$ est l'opérateur morphologique Hit-or-Miss. Le convexe final est obtenu en répétant l'Équation 3.23 et en combinant toutes les résultantes X_i^k au convexe jusqu'à la convergence ($X_k = X_{k-1}$), comme indiqué dans l'Équation 3.24 Enfin, comme segmentation du disque optique, un ajustement d'ellipse est effectué pour donner la segmentation finale du cup (Figure 5.3).

$$X_i^k = (X_{k-1} * B^i) \cup I \quad (3.23)$$

$$ConvexHull = \cup_k X_i^k \quad (3.24)$$

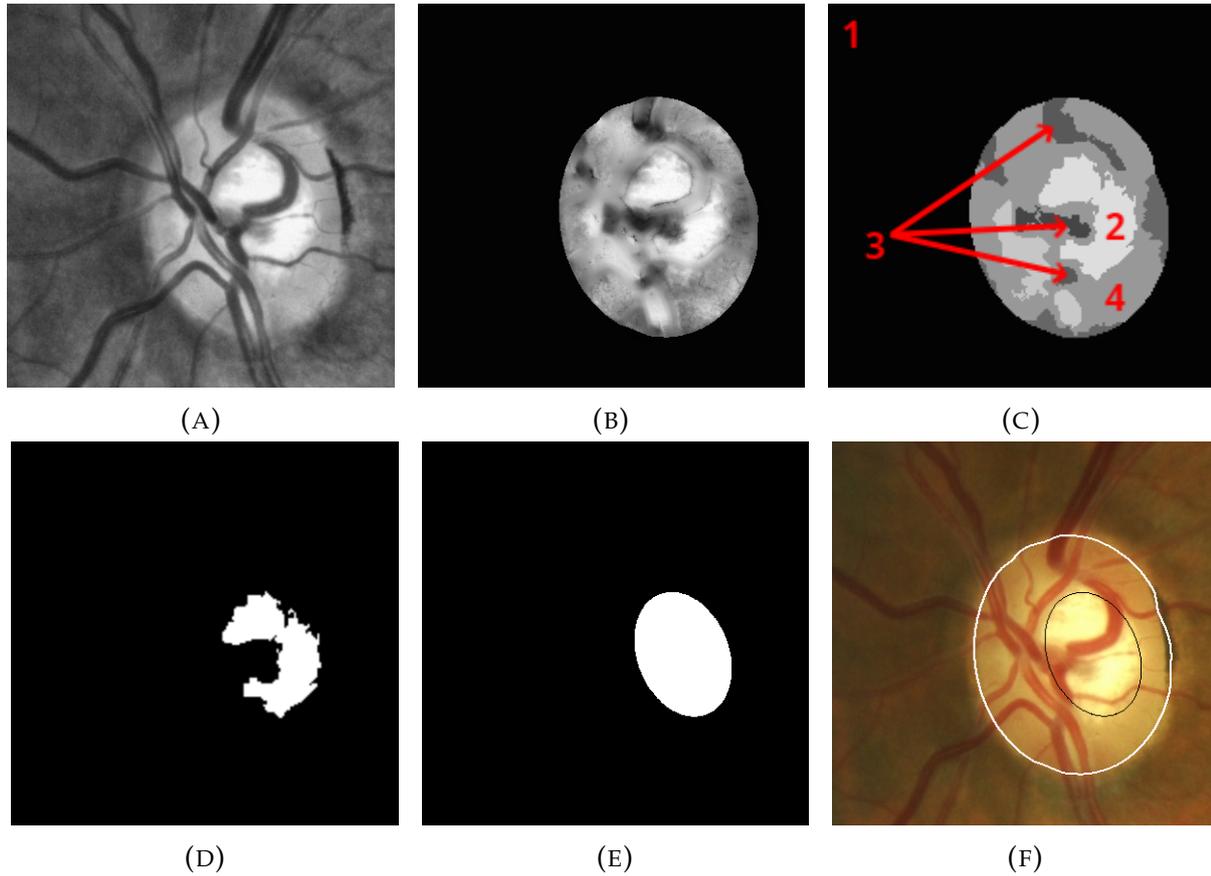


FIGURE 3.19: Segmentation du cup optique. (A) image d'intérêt, (B) élimination des vaisseaux sanguins et de la zone non-discale, (C) segmentation de Felzenszwalb, (D) segmentation primaire du cup, (E) correction convexe et de l'ellipse, (F) résultat final (le contour blanc pour le disque optique et le contour noir est pour le cup optique).

3.4 Détection du glaucome

Après la segmentation du disque et du cup optiques, nous effectuons la classification entre les images saines, et celles présentant un glaucome en se basant sur des indicateurs cliniques de la maladie, tels que le rapport CDR, la vérification de la loi ISNT, et l'échelle DDLS. Dans cette section, nous décrivons le calcul automatique de ces indicateurs à partir des résultats de la segmentation obtenus précédemment. Ensuite, nous présenterons les procédures d'apprentissage, de test, d'évaluation, et le calcul d'importance de chaque indicateur pour l'identification du glaucome.

3.4.1 Détermination automatique des indications cliniques du glaucome

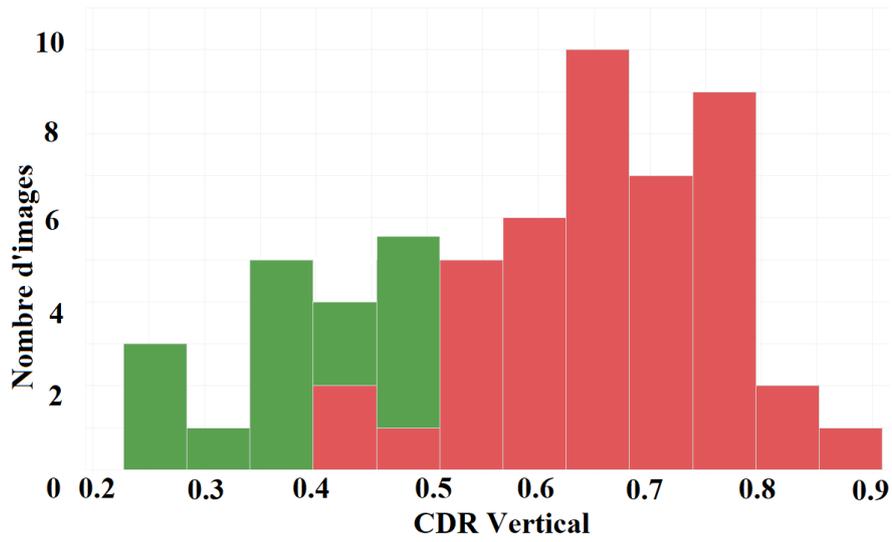
a. Rapport CDR

Comme mentionné au chapitre 2, le rapport Cup/Disque (CDR) est la mesure la plus courante pour le diagnostic du glaucome [135]. Le CDR peut être calculé, en prenant le rapport du diamètre du cup et du disque, dans le sens vertical ou horizontal, ou en prenant le rapport de leurs surfaces. La raison pour laquelle le CDR est inclus dans le diagnostic, est que pendant le glaucome le cup devient anormalement large. Ceci est montré dans la figure 1.8, où la taille du cup est comparée pour un cas sain et pour un cas glaucomateux. On observe que par rapport au disque optique, le cup optique a une taille plus grande en cas de glaucome par rapport à une image normale.

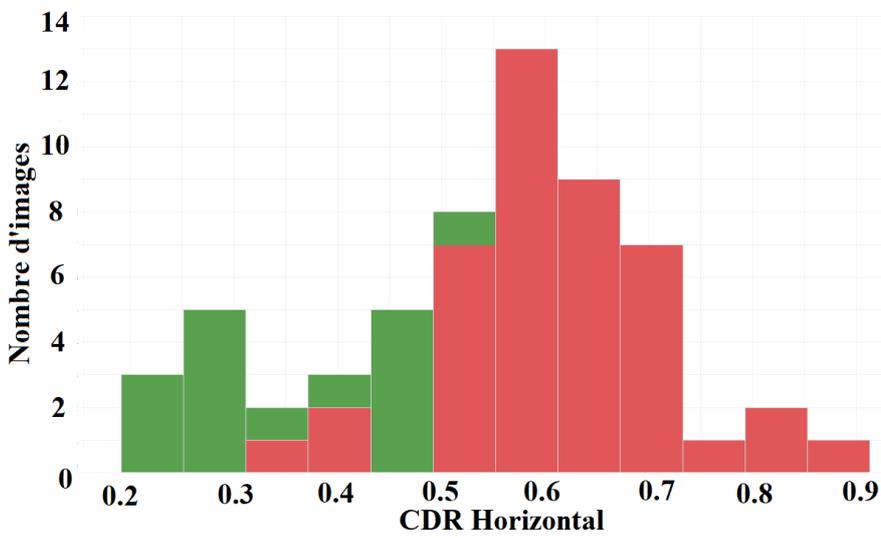
Sur la base des segmentations automatiques obtenues précédemment, le CDR est calculé dans un échantillon de 59 images fond d'œil, fournies par l'hôpital Frantz Fanon de Blida (Table 3.2). Les valeurs moyennes des trois CDRs (vertical, horizontal et régional) montrent une différence significative entre les cas sains et glaucomateux. Mais en observant la figure 3.20, on peut déduire que le CDR n'est pas le seul indicateur de glaucome, puisque certains cas sains peuvent avoir des CDR élevés et vice-versa. Par conséquent, une détection de glaucome basée seulement sur le CDR n'est pas toujours fiable, surtout dans le stade précoce de la maladie.

TABLE 3.2: Moyenne (μ) et écart-type (σ) des CDR verticaux, horizontaux et régionaux des images normales et glaucomateuses .

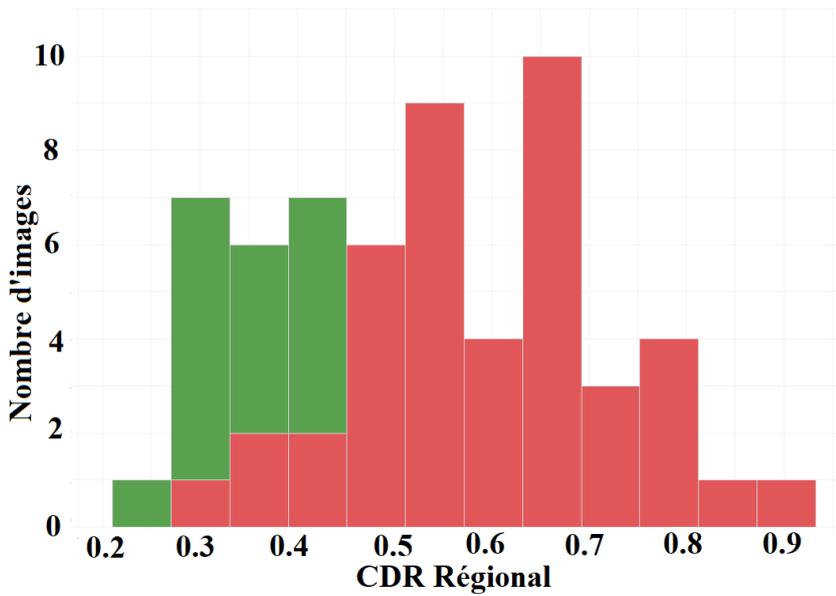
Cas	CDR Vertical	CDR horizontal	CDR régional
	$\mu \pm \sigma$	$\mu \pm \sigma$	$\mu \pm \sigma$
Sain	0,38 \pm 0,08	0,4 \pm 0,1	0,19 \pm 0,05
Glaucome	0,65 \pm 0,11	0,66 \pm 0,09	0,44 \pm 0,13



(A)



(B)



(C)

FIGURE 3.20: Comparaison des histogrammes du rapport CDR entre les images normales et de glaucome représentées en vert et en rouge respectivement. (A) CDR vertical, (B) CDR horizontal, (C) CDR régional.

b. Vérification de la loi ISNT

La règle ISNT stipule que l'épaisseur du bord neuro-rétinien dans les régions Inférieure, Supérieure, Nasale, et Temporale serait généralement la plus grande dans I, suivie de S, N, et T. En bref, la largeur du bord des cas normaux suit l'ordre (I > S > N > T) connu sous le nom de règle ISNT (voir la section 1.3.2).

En cas de glaucome, le bord neuro-rétinien désobéit généralement à la règle ISNT. Bien que ce n'est pas le cas pour tous les patients du glaucome (d'autres pathologies oculaires peuvent provoquer un amincissement anormal du bord neuro-rétinien), cette règle reste toujours une méthode utile pour le diagnostic du glaucome[15].

c. L'échelle DDLS

Comme il est montré dans la section 1.3.2, l'échelle DDLS prétend être supérieure au rapport CDR, dans l'identification des yeux glaucomateux parmi les yeux sains. L'intuition est que, le CDR peut mal classer les gros disques optiques comme glaucomateux, et les petits disques comme sains. Deuxièmement, les changements focaux habituellement associés au glaucome, ne sont pas reflétés dans le CDR, en particulier dans les stades précoces.

Pour résoudre ces problèmes, cette échelle utilise le rapport entre l'épaisseur minimale du bord neuro-rétinien, et le diamètre du disque optique. S'il existe une surface d'absence du bord (épaisseur minimale égale à 0), la circonférence de l'absence du bord est mesurée en degrés (Figure 3.21).

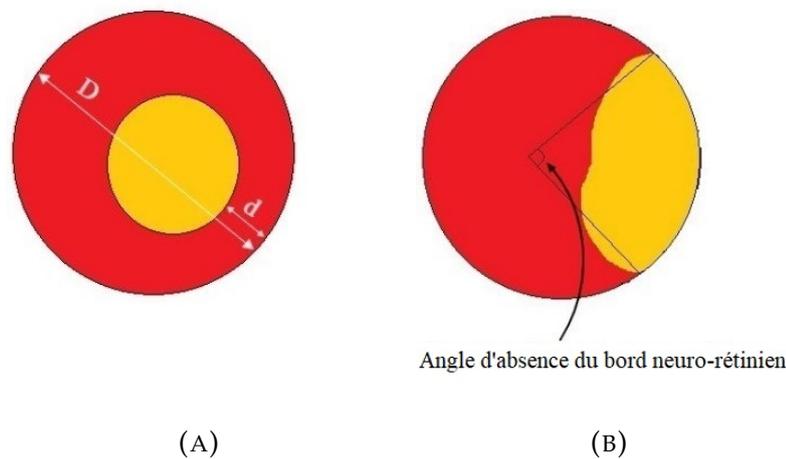


FIGURE 3.21: Mesure de l'échelle DDLS. (A) l'épaisseur minimale n'est pas égale à 0, (B) cas d'absence du bord neuro-rétinien.

3.4.2 Détection du glaucome

La classification est le processus de catégorisation d'un ensemble de données, en différents groupes, en fonction de leurs attributs (caractéristiques). Chaque objet de l'ensemble est affecté à une classe, en fonction d'une décision ou d'une prévision choisie. Une petite proportion de l'ensemble est considérée comme données d'apprentissage, et est utilisée pour construire un classificateur, qui attribue chaque objet à la classe appropriée. Le classificateur est alors prêt à prédire la classe des vecteurs de chaque objet restants (ensemble de test). Après l'apprentissage, une frontière est construite, séparant les vecteurs de caractéristiques, de telle sorte que les objets appartenant à la même classe se trouvent dans la même cotée de la frontière[136].

La figure 3.22 montre un exemple de classification, où les patients ont été divisés en patients à faible risque et à haut risque, en fonction de leur âge, et de leur pression intra-rétinienne. Les cercles négatifs indiquent les patients à faible risque, tandis que les cercles positifs, indiquent ceux à haut risque.

Cette section décrit en détails l'approche proposée pour la classification des images fond d'œil, en images saines ou glaucomateuses, en fonction des indicateurs (précédemment mesurés) avec un classificateur Random Forest.

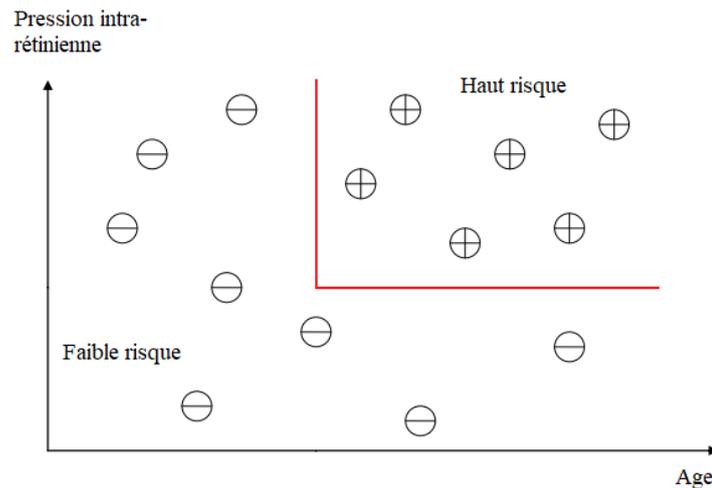


FIGURE 3.22: Exemple de processus de classification.

a. Forêt Aléatoire (Random Forest)

La forêt aléatoire (Random Forest) [137] est un classificateur largement utilisé dans la littérature, en raison de sa capacité à simultanément effectuer une classification et une sélection de caractéristiques. Il est également robuste contre le surapprentissage, ce qui est pertinent lorsqu'il s'agit d'une base d'apprentissage non-équilibrée, ou une base contenant beaucoup de données, qui ont les mêmes caractéristiques.

Ce classificateur est constitué d'un ensemble d'arbres de prévision, appelés 'arbres de décision' [138], dont chacun est capable de prédire une valeur cible lorsqu'on lui présente un sous-ensemble de données. Ces arbres sont tirés de T sous-ensembles échantillonnés aléatoirement de l'ensemble d'apprentissage S . Chaque nœud dans un arbre correspond à une répartition du sous-ensemble, choisi au hasard de $m = \sqrt{d}$ caractéristiques, où d étant la dimensionnalité du vecteur de caractéristiques.

Etant donné un vecteur de caractéristiques $x(j)$, la forêt aléatoire évalue la probabilité $P_i(c|x(j))$ (Equation 3.25), où $c \in \{0,1\}$ est l'indice de la classe, avec 0 correspondant à la classe saine, et 1 la classe glaucomateuse, et i est l'indice de l'arbre de décision dans la forêt aléatoire. La probabilité finale est obtenue en répétant ce processus pour chaque arbre $0 < i < T$ et en calculant la moyenne de réponse de chacun d'eux :

$$P(c|x(j)) = \frac{1}{T} \sum_i^T P(c|x(j)) \quad (3.25)$$

Afin de déterminer la probabilité P (équation 3.26, pour qu'une image I corresponde à un cas sain, ou pathologique, on suit la même procédure que [139]):

$$P(I) = \max(c = 1|x(j)) \quad (3.26)$$

Ce qui signifie que pour une image I , présentant le vecteur de caractéristiques $x(j)$, la probabilité est associée à la certitude maximale du classificateur d'avoir observé des indicateurs de glaucome pathologiques ($c = 1$)

b. Bases de données utilisées

La méthode de classification proposée a été validée expérimentalement avec deux bases de données d'images fond d'œil. La première est une base de données locale, où toutes les images ont été acquises à l'hôpital Frantz Fanon de Blida, avec un rétinographe Topcon 3DOCT-1 Maestro, contenant un ensemble de 60 images fond d'œil, de dimension 2124x2056, et sous format non-compressé.

La deuxième, est la base de données publique HRF (High Resolution Fundus) [22], contenant un ensemble de 15 images fond d'œil saines, 15 images glaucomateuses, et 15 images présentant une rétinopathie diabétique. Ces images sont en format jpg non-compressé, avec une résolution de 3504x2336. La figure 3.23 montre des exemples sains et glaucomateux des deux bases de données.

Les indicateurs mesurés à partir de chaque base de données sont transmis à un classificateur forêt aléatoire, où chacun de ses arbres de décision (le nombre d'arbres a été choisi à 1000) classe ces indicateurs en cas de glaucome ou en cas sain, et la classe qui a obtenu la plupart des votes est la classe affectée au patient.

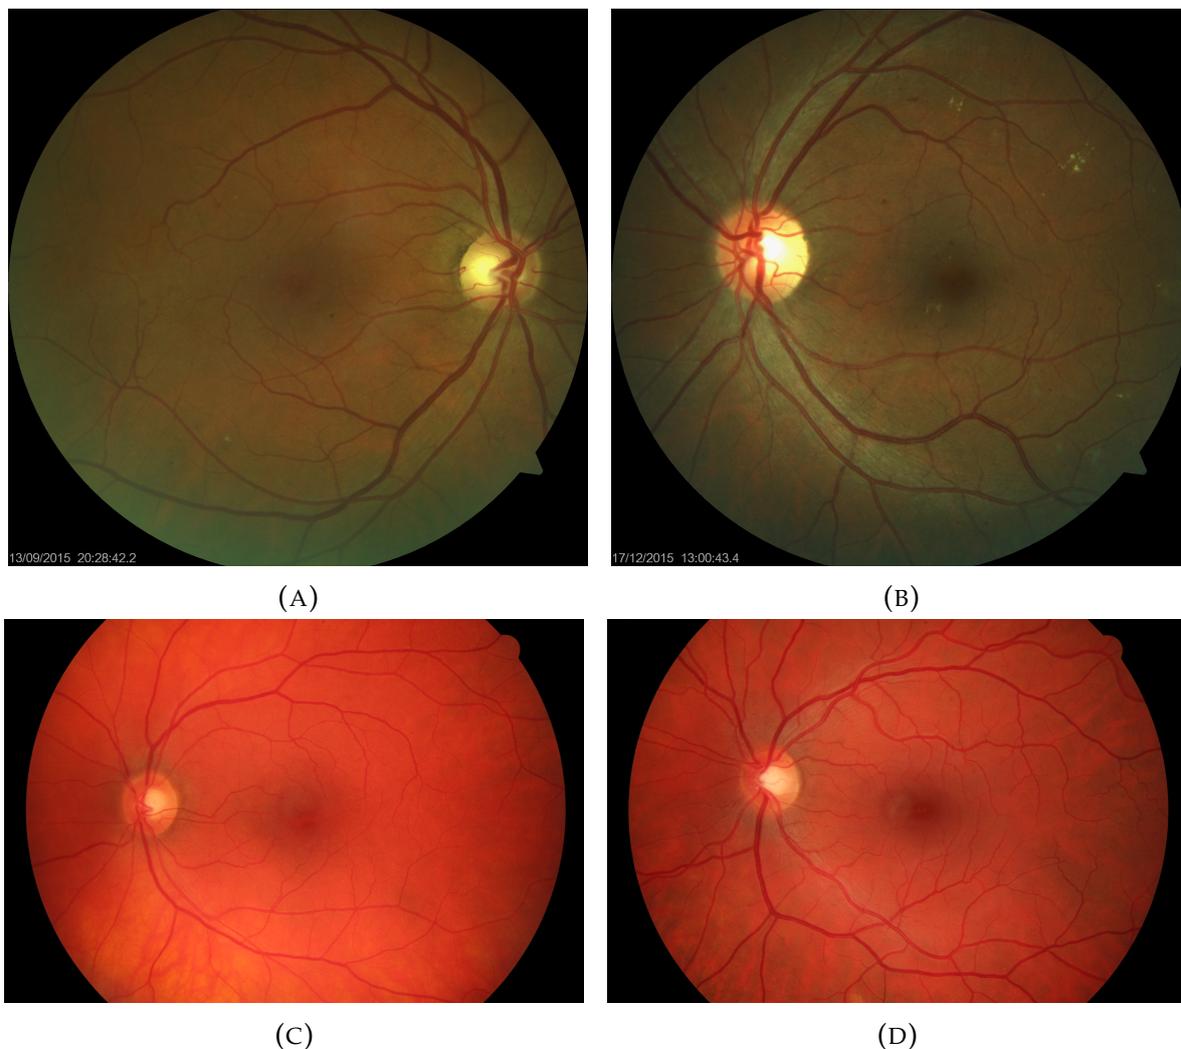


FIGURE 3.23: Exemples des deux bases de données utilisées pour la classification. Première ligne: Base de données locale, deuxième ligne: La base de données HRF.

Pendant la phase d'apprentissage, la base de données est divisée en un ensemble d'apprentissage, et de test, afin de tester la classification sur des données que le modèle n'a jamais rencontré, dans la phase d'apprentissage. Dans notre étude, chaque base de données est divisée comme suit : 80% pour l'apprentissage et 20% pour le test.

La figure 3.24 montre une description de l'un des arbres de décision du modèle forêt aléatoire obtenu. Au niveau du premier nœud (le nœud racine), le classificateur demande si l'échelle DDLS est égale à 3 ou moins, en fonction du résultat, il suit un des deux chemins 'Vrai' ou 'Faux'. Ce dernier, classe les données d'entrée directement comme 'cas de glaucome'. Cependant, le chemin 'Vrai' a besoin d'un deuxième nœud, où il examine le CDR horizontal, en classant les données d'entrée comme 'cas de glaucome'

s'il est supérieur à 0.58 et cas 'sains' si non.

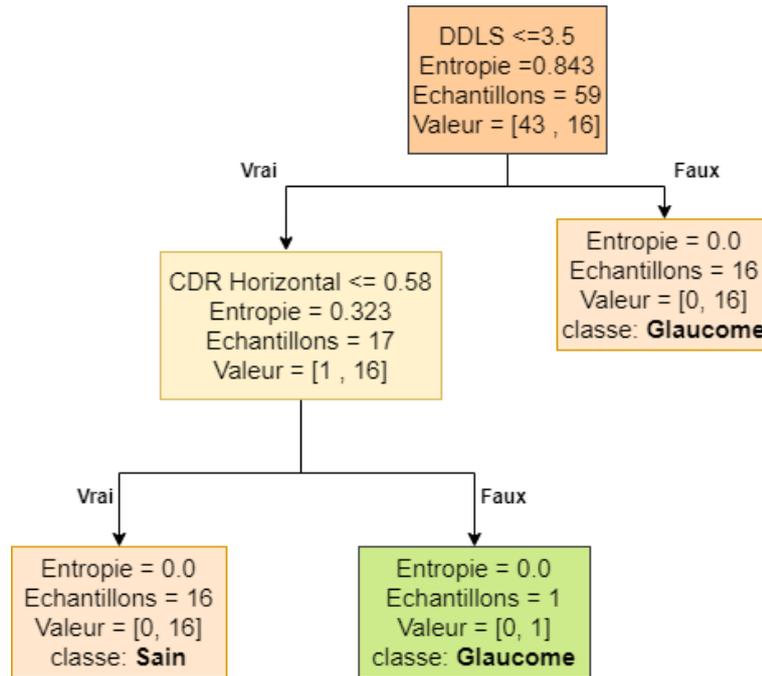


FIGURE 3.24: Exemple des arbres de décision utilisés.

Discussion

L'approche proposée pour détecter automatiquement le glaucome, sur la base des indicateurs extraits des images fond d'œil (CDR, Vérification de la loi ISNT, et l'échelle DDLs), est présentée dans ce chapitre. Les résultats ont révélé que la combinaison proposée des caractéristiques fournit une analyse quantitative, et profonde de la tête du nerf optique, permettant une détection précise de la maladie. L'évaluation de la performance de la classification des images saines et pathologiques est détaillée au chapitre 5.1.4.

Une méthodologie précise pour l'extraction de la région d'intérêt dans l'image fond d'œil (région de la tête du nerf optique), et pour la segmentation du disque et du cup optiques, a assuré une mesure efficace des indicateurs mentionnés précédemment. Deux bases de données publiques (MESSIDOR et HRF) ont été utilisées pour évaluer les algorithmes proposés (Voir Chapitre 5).

Malgré la robustesse de l'algorithme de détection du glaucome proposé, certaines limitations ont été observées. La figure 3.25 montre deux distributions ($f(CDR_Vertical) = CDR_Horizontal$ et $f(CDR_Vertical) = CDR_Rgional$). Il est à remarquer que, malgré que C_1 et C_2 présentent des rapports CDR proches, et la même échelle DDLS, tout en vérifiant la loi ISNT, ils appartiennent à des classes différentes : $C_1 \in \text{classe 'sain'}$ et $C_2 \in \text{classe 'glaucome'}$, ce qui a conduit à une erreur de classification pour le cas C_1 . Cette observation signifie qu'il existe toujours une confusion entre quelques cas de glaucome précoces et des cas sains.

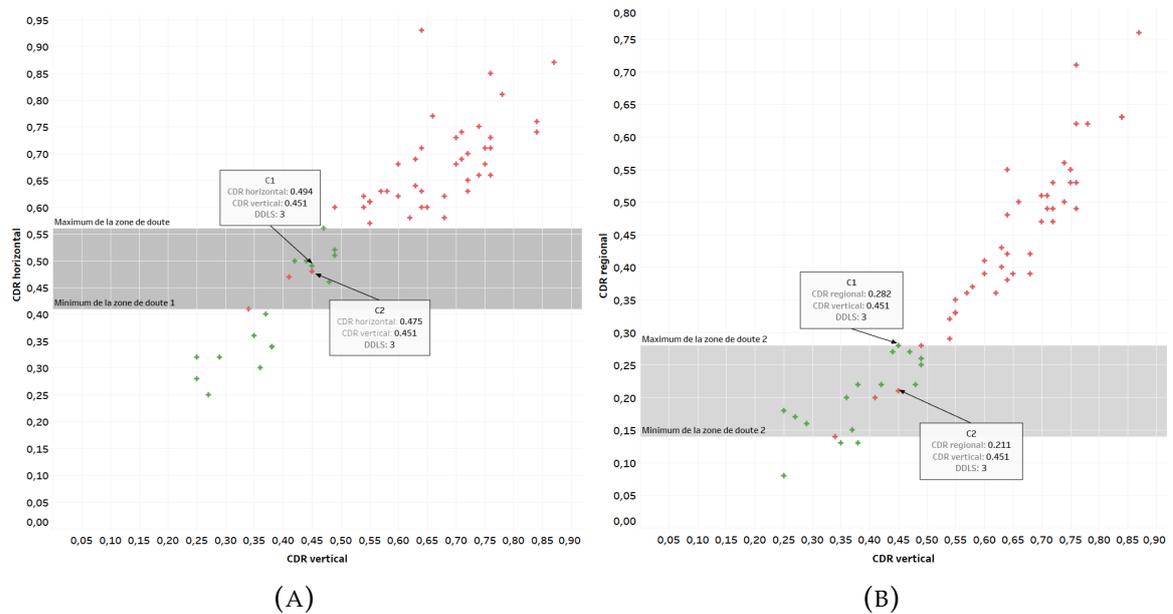


FIGURE 3.25: Distribution de la base de données d'apprentissage utilisée. (A) représentation du CDR Horizontal en fonction du CDR Vertical, (B) représentation du CDR Horizontal en fonction du CDR Vertical.

Dans le prochain chapitre, nous proposerons une solution pour lever cet inconvénient en combinant les indicateurs extraits des images fond d'œil, avec les caractéristiques de l'épaisseur du complexe GCC extraites à partir des images OCT maculaires.

CHAPITRE 4

COMBINAISON OCT/FOND D'ŒIL POUR LA DÉTECTION DU GLAUCOME

4 Combinaison OCT/fond d'œil pour la détection du glaucome

L'étape la plus importante de la prise en charge du glaucome, est sans aucun doute, celle du diagnostic. Un diagnostic précoce est décisif, mais les patients se présentent généralement à l'ophtalmologiste lorsque leur acuité visuelle commence à diminuer, et que les défauts du champ visuel apparaissent. À ce stade, nous ne pouvons que garder cette affection sous contrôle, et éviter des pertes supplémentaires du champ visuel. Malheureusement, ce stade n'est pas toujours détectable à partir des images fond d'œil chez les patients atteints de myopie, ou d'atrophies péri-papillaires [140].

Récemment, des études ont montré que le champ visuel commence à être affecté, quand environ 40% des axones rétiniens ne sont plus fonctionnels [141]. Cependant, les pertes de vision causées par le glaucome n'apparaissent qu'après la perturbation des fibres nerveuses, et des cellules ganglionnaires rétiniennes [142].

D'autres études ont évalué l'importance du complexe des cellules ganglionnaires (GCC), pour le diagnostic précoce du glaucome [140][143][144]. Ces études ont révélé que le complexe GCC était le plus épais chez les sujets sains, et que l'épaisseur diminuait à mesure que la sévérité du glaucome augmentait. En outre, une inter-relation entre l'épaisseur de la RNFL, et du GCC a été trouvée par **D. Dascalescu et al. (2018)** [140], ce qui a renforcé l'idée d'intégrer l'analyse de l'épaisseur du GCC, dans le diagnostic précoce du glaucome.

Dans la première partie de ce chapitre, nous présentons une nouvelle méthode de détection du glaucome, qui combine les indicateurs extraits dans le chapitre précédent (le

rapport CDR, la vérification de la loi ISNT et l'échelle DDLS), avec les caractéristiques structurelles du complexe GCC, extraites à partir des images OCT maculaires. La figure 4.1 montre le synoptique général de la méthode proposée.

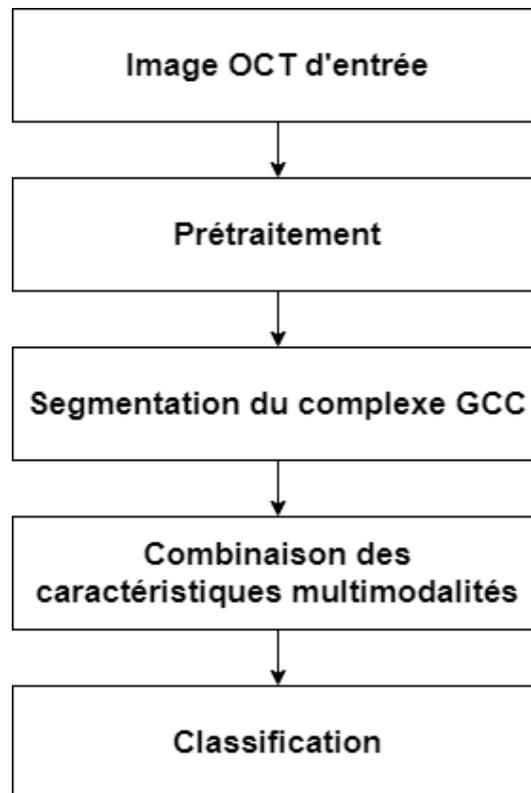


FIGURE 4.1: Organigramme général de la méthode proposée.

D'autre part, l'évaluation de l'angle irido-cornéen est une partie essentielle pour le diagnostic, et le traitement du glaucome, permettant une visualisation directe des principales structures responsables du drainage de l'humeur aqueuse (l'iris et la cornée), ce qui permet une identification précise de la forme du glaucome : Glaucome à Angle Ouvert (GAO) ou Glaucome à Angle Fermé (GAF) [145].

Un réseau de neurones convolutionnel, qui sera présenté dans la deuxième partie du chapitre, aura pour but de classifier les images AS-OCT des patients identifiés comme glaucomateux, par l'algorithme mentionné précédemment, en une des deux catégories de glaucome.

4.1 Prétraitement de l'image OCT

La tomographie par cohérence optique produit une énorme quantité de bruit de type speckle, lors de l'acquisition de l'image OCT. Cela réduit le contraste de l'image, de sorte que les frontières des différentes couches rétiniennes deviennent floues. Le débruitage des images corrompues par ce type de bruit, à l'aide des techniques de filtrage par ondelettes est très efficace, en raison de sa capacité à enlever les parasites, tout en préservant les informations jugées pertinentes (contours, texture, formes... ect.).

4.1.1 Filtrage des images OCT par ondelettes

Comme il est montré dans l'Algorithme 2, le filtrage par ondelettes discrètes inclut trois étapes principales : la transformation de l'image vers le domaine des ondelettes, le seuillage des coefficients liés au bruit speckle, et finalement, la transformation inverse des coefficients seuillés vers le domaine original. La Transformée en Ondelettes Discrète (Discrete Wavelet Transform : DWT), ainsi que les techniques de seuillage des coefficients sont décrites ci-dessous.

Algorithm 2: Débruitage des images par les techniques d'ondelettes.

Entrée: Image I bruitée;

Résultat: Image I_{finale} filtrée;

Début;

$I \Rightarrow$ Image bruitée ;

Décomposition DWT de l'image I ;

DWT (I) \Rightarrow [LL, LH, HL, HH];

Seuillage des coefficients ;

Définir un seuil pour les composantes : LH, HL, HH ;

Mettre à zéro les coefficients supérieurs au seuil \Rightarrow [LH₁, HL₁, HH₁];

Reconstruction;

DWTI \Rightarrow Transformée Inverse en Ondelettes Discrète ;

$I_{finale} \Rightarrow$ DWTI [LL, LH₁,HL₁,HH₁];

Fin.

a. Transformée en Ondelettes Discrète

La Transformée en ondelettes discrète (DWT) d'une image, produit une représentation non-redondante de cette image, qui fournit une meilleure description des caractéristiques spatiales, et spectrales de cette dernière, par rapport à d'autres représentations multi-échelles, telles que la transformée de Fourier.

La DWT peut être interprétée comme une décomposition du signal, en un ensemble de composantes de fréquences indépendantes. Le signal S passe à travers deux filtres complémentaires, et émerge sous la forme de deux composantes [146]. C'est ce qu'on appelle la décomposition. Ces composantes peuvent être rassemblées dans le signal original sans pertes d'informations; ce processus est appelé reconstruction. La figure 4.2 illustre le processus de décomposition de DWT.

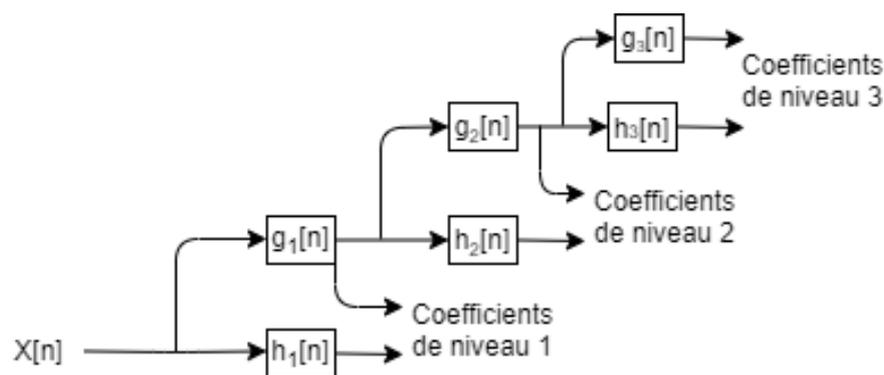


FIGURE 4.2: Processus de décomposition en ondelettes discrète (DWT) d'un signal 1D.

Comme présenté ci-dessus (Figure 4.2), le signal d'entrée $X(n)$ est décomposé en deux composantes: $h_1(n)$ et $g_1(n)$, où h_1 est la composante de haute fréquence et g_1 la composante de basse fréquence du signal original $X(n)$. Ces deux termes sont appelés les coefficients de décomposition de niveau 1. Les composantes de basse fréquence sont décomposées en donnant des coefficients de niveau 2 $g_2(n)$ et $h_2(n)$. Ainsi, le signal est décomposé en plusieurs niveaux.

Une image peut être décomposée en séquences d'images à des résolutions spatiales différentes, à l'aide de la DWT. Dans le cas d'une image 2D, une décomposition à N

niveaux peut être effectuée, il en résulte $3N + 1$ sous-bandes de fréquence, comme le montre la figure 4.3, où les sous-bandes LH, HL, et HH incluent les informations de contours dans les directions horizontales, verticales et diagonales, respectivement, tandis que la sous-bande LL ne contient aucune information de contour, puisqu'il s'agit de la composante de la basse fréquence de l'image d'entrée. Le niveau de décomposition suivant est appliqué sur cette sous-bande.

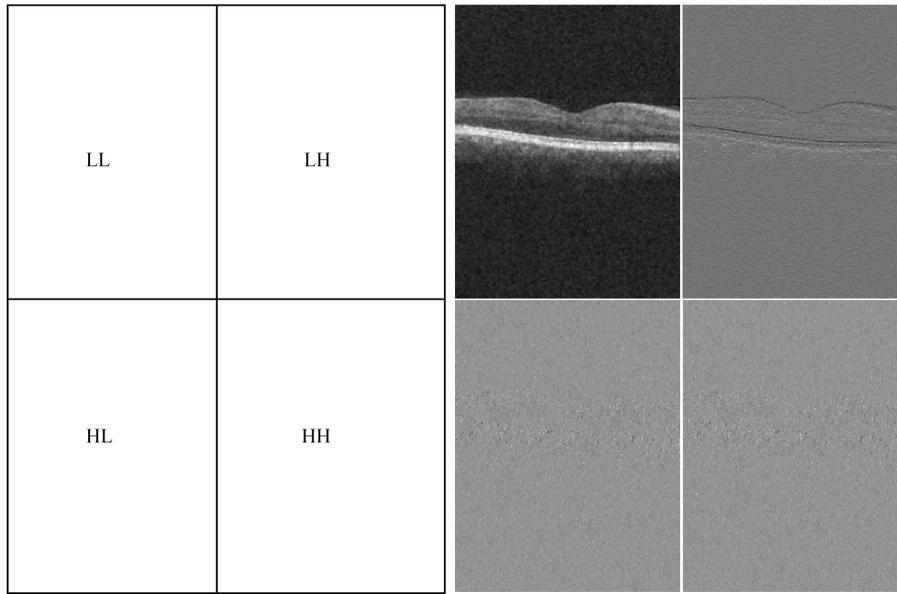


FIGURE 4.3: Décomposition en DWT d'une image OCT.

b. Seuillage des composantes DWT

Sachant que le type de bruit présent dans les images OCT (Speckle), est représenté par des grandes valeurs dans le domaine d'ondelettes, plusieurs algorithmes sont rapportés dans la littérature pour le seuillage des composantes DWT. Ce processus joue un rôle important dans le filtrage des images OCT maculaires. Un seuil trop petit conservera les coefficients bruités, tandis qu'une grande valeur de seuil conduit à la perte des coefficients portant les informations pertinentes de l'image, ce qui engendre la perte des vraies frontières des couches rétinienne. Dans notre étude, la valeur du seuil est calculée d'après la formule 4.1, proposée par **D. Donoho et al.** [147], où δ est la variance du bruit, et M le nombre de pixels dans l'image :

$$\text{Seuil} = \delta \sqrt{2 \log(M)} \quad (4.1)$$

Après la sélection du seuil, deux techniques majeures de seuillage sont rapportées dans la littérature : Seuillage Dur (Hard Thresholding), et Seuillage Doux (Soft Thresholding) [148] [149].

- **Seuillage Doux (Soft Thresholding)**: Dans cette technique de seuillage, les coefficients inférieurs au seuil S , sont mis à zéro. Par contre, l'amplitude des coefficients supérieurs à S est obtenue en soustrayant à ces derniers la valeur de S , afin de s'assurer d'avoir enlevé l'effet du bruit (Equation 4.2). Dans cette équation, θ est la fonction de seuillage, x les coefficients des composantes DWT, et S la valeur de seuil.

$$\theta(x) = \begin{cases} 0 & si |x| < S \\ x - S & si |x| \geq S \end{cases} \quad (4.2)$$

- **Seuillage Dur (Hard Thresholding)**: Dans ce type de seuillage, les coefficients supérieurs au seuil S sont conservés, et les coefficients inférieurs à S sont mis à zéro (Equation 4.3).

$$\theta(x) = \begin{cases} 0 & si |x| < S \\ x & si |x| \geq S \end{cases} \quad (4.3)$$

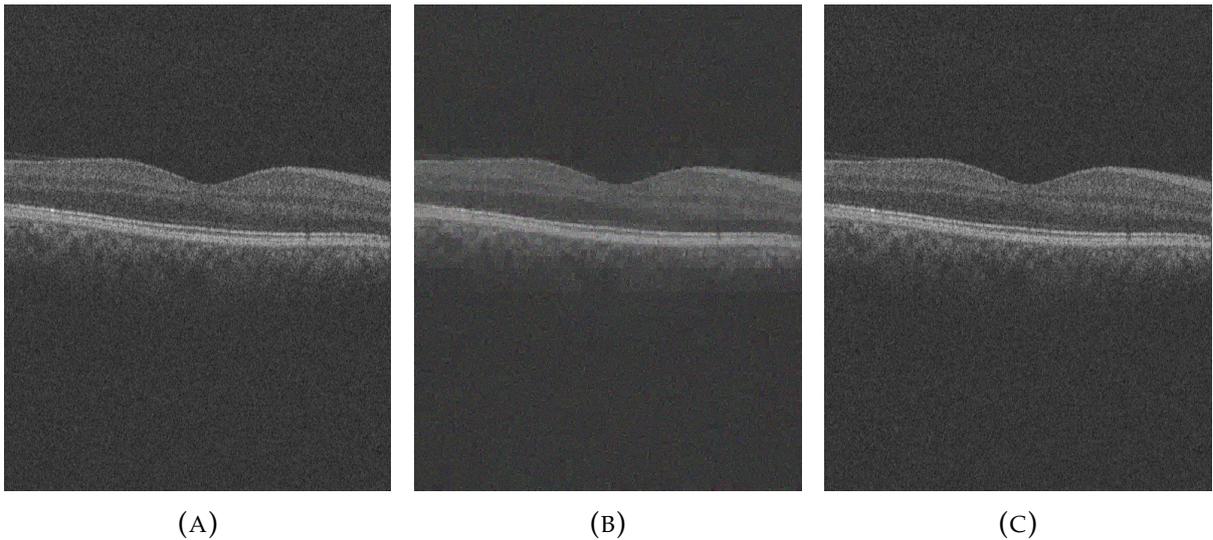


FIGURE 4.4: Débruitage des images OCT maculaires par seuillage des coefficients DWT. (A) image bruitée, (B) seuillage doux, (C) seuillage dur.

Un exemple de débruitage par les deux méthodes de seuillage est illustré dans la Figure 4.4. On remarque que le débruitage basé sur le seuillage doux a présenté une meilleure efficacité, par rapport au débruitage basé sur le seuillage dur, en termes d'atténuation du bruit Speckle dans les images OCT maculaires, et de conservation des frontières des différentes couches rétinienne.

Après le filtrage de l'image OCT maculaire, un lissage par ouverture morphologique est appliqué sur l'image filtrée, ainsi qu'une égalisation adaptative de son histogramme, afin d'améliorer le contraste entre la rétine et le fond, ainsi que le contraste entre les différentes couches rétinienne. Des exemples de prétraitement des images OCT maculaires sont montrés dans la Figure 4.5.

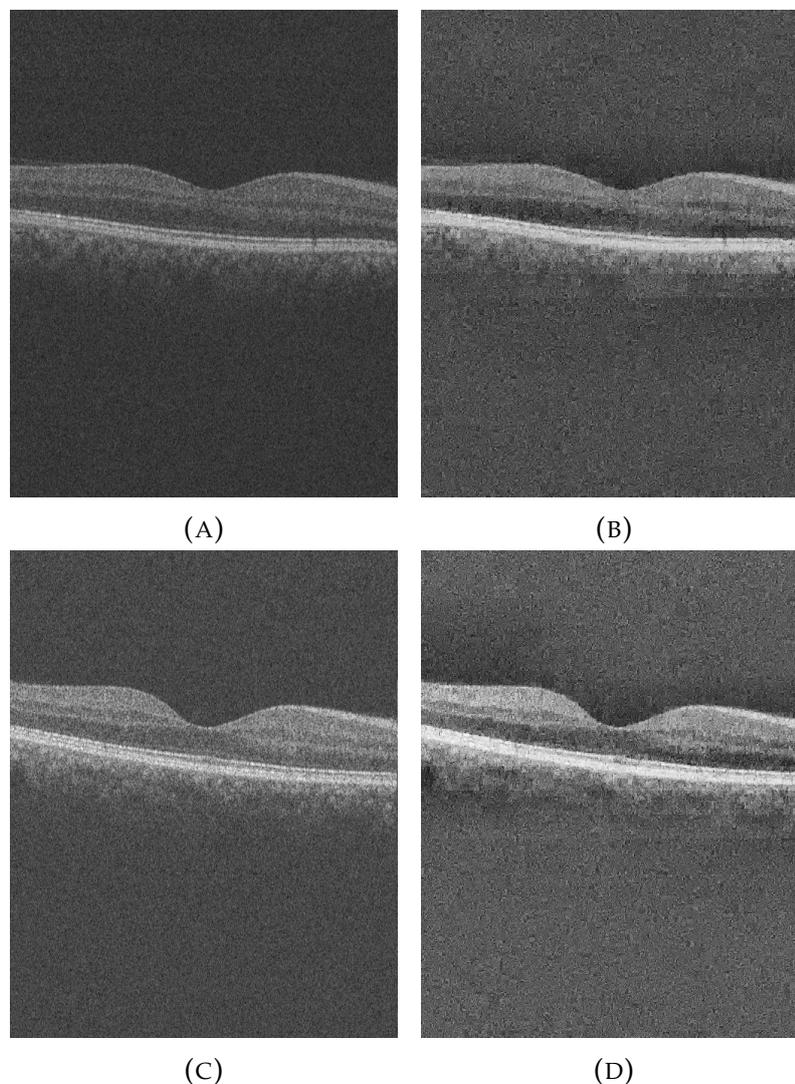


FIGURE 4.5: Exemples de pré-traitement des images OCT maculaires. (A) et (C) images initiales, (B) et (D) résultats de prétraitement.

4.2 Segmentation et évaluation du complexe GCC

L'analyse du Complexe des Cellules Ganglionnaires (GCC) est essentielle pour le diagnostic, et l'évaluation de la progression du glaucome, puisqu'en réalité, les fibres nerveuses forment le tissu le plus endommagé par cette pathologie. Dans cette section, nous présentons un nouvel algorithme pour la segmentation, et la quantification du GCC, afin de faciliter la détection de toute perte liée au glaucome, avant l'atténuation du champ visuel. La procédure proposée pour la segmentation du complexe ganglionnaire est divisée en deux parties :

- La segmentation de la Membrane Limitante Interne (ILM), qui représente la frontière interne du complexe, par l'algorithme de Grab-Cut [150];
- La segmentation de la frontière externe du complexe à l'aide de l'algorithme Random Walker [151].

4.2.1 Segmentation de l'ILM

La limite interne de la rétine, et de la tête du nerf optique est appelée Membrane Limitante Interne (ILM). Elle représente la frontière entre le vitré et la rétine, et est utilisée pour mesurer plusieurs paramètres structurels tels que : l'épaisseur totale de la rétine, les épaisseurs des couches rétiniennes internes (RNFL et GCC), les déformations maculaires, et la détection de la fovéa.

Il est bien connu que la couche RNFL présente une réflectivité élevée dans les images OCT (Figure 4.6), conduisant à un haut contraste entre la rétine et le vitré [152] [153]. Prenant en compte cette réflectivité, nous segmentons l'ILM à l'aide de l'algorithme Grab-Cut, en séparant l'avant-plan (rétine), de l'arrière-plan (vitré et choroïde), et en ne prenant en considération que le contour supérieur.

L'approche de Grab-Cut [150] est basée sur la recherche d'une segmentation binaire de l'image, en formulant une fonction de minimisation d'énergie, et en la résolvant à l'aide

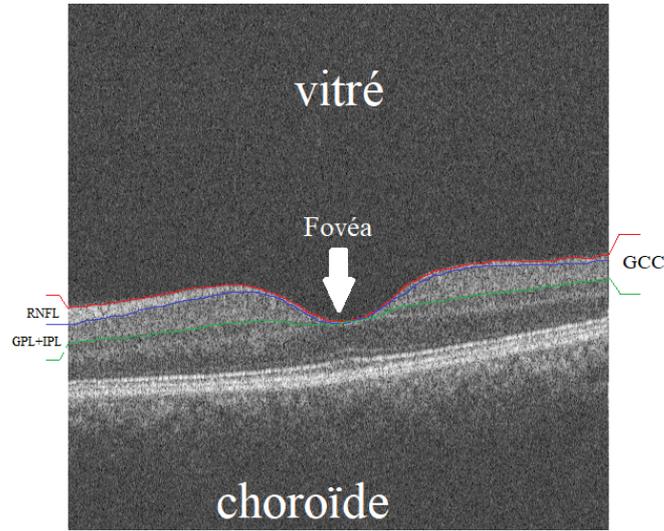


FIGURE 4.6: Couches constitutives du complexe GCC.

des techniques de graph-cut.

Étant donné une image I , considérons le vecteur $Z = \{z_1, z_2, \dots, z_N\}$ des N pixels, où $z_i = \{x_i, y_i, R_i, G_i, B_i\}$ contient les données spatiales (x_i, y_i) , et les valeurs RGB, R_i, G_i, B_i de chaque pixel de l'image. La segmentation de l'image I est définie comme le vecteur $f = \{f_1, f_2, \dots, f_N\}$, $f_i \in \{0, 1\}$ attribuant une étiquette à chaque pixel de l'image, en indiquant s'il appartient à l'arrière-plan (fond), ou le premier-plan (objet :rétine).

Une initialisation T (pour toute l'image) est définie par l'utilisateur, et est constituée de trois régions : T_B, T_F , et T_U , contenant les pixels de l'arrière-plan initial, le premier-plan, et les pixels incertains, respectivement. Les pixels appartenant à T_B et T_F sont fixés en arrière-plan, et en premier-plan, respectivement, ce qui signifie que l'algorithme Grab-Cut ne pourra pas modifier leurs étiquettes. Alors que les pixels appartenant à T_U sont en fait les pixels étiquetés par l'algorithme.

Après l'étiquetage initial, les informations de couleurs sont introduites par l'algorithme GMM (Gaussian Mixture Model) sur les composantes RGB de l'image. Il crée K composantes de distribution gaussienne, paramétrées comme suit :

$$\theta_k = \{\pi(f, k), \mu(f, k), \Sigma(f, k), f \in \{0, 1\}, k \in \{1, 2, \dots, K\}\} \quad (4.4)$$

Où π est le poids de mixture, μ et Σ sont les moyennes, et les matrices de covariance du modèle GMM, respectivement. Nous considérons aussi $K = \{k_1, k_2, \dots, k_N\}$, $i \in \{1, 2, \dots, N\}$, indiquant la composante du GMM (selon f_i) à laquelle appartient le pixel z_i . La fonction d'énergie est définie par la suite comme le montre l'équation 4.5.

$$E(f, k, \theta, z) = U(f, k, \theta, z) + V(f, z) \quad (4.5)$$

Où le terme de données (data term) U évalue l'appartenance de chaque élément de Z au premier-plan, ou l'arrière-plan, en fonction de leur ajustement dans le GMM correspondant. Le terme de données est défini par :

$$U(f, k, \theta, z) = \sum_i D_i(f_i, k_i, \theta, z_i) \quad (4.6)$$

Où:

$$D_i(f_i, k_i, \theta, z_i) = -\log P(z_i | f_i, k_i, \theta) - \log \pi(f_i, k_i) \quad (4.7)$$

Où D_i est le potentiel de vraisemblance du pixel i , basé sur la probabilité du GMM (Equation 4.5), et V est le potentiel de régularisation, calculé en utilisant la distance euclidienne (Equation 4.8), en supposant que les régions segmentées doivent être cohérentes en termes de couleurs. Avec la fonction de minimisation de l'énergie, et l'initialisation initiale définie par l'utilisateur, la segmentation Grab-Cut finale est effectuée à l'aide de l'algorithme min-Cut [154]. La procédure de segmentation par Grab-Cut est résumée dans l'algorithme 3, et un exemple de son application sur les images OCT maculaires pour l'extraction de l'ILM est montré dans la figure 4.7.

$$V(f, z) = \gamma \sum_{(m,n) \in C} dis(m,n)^{-1} [f_n \neq [f_m] \exp(-\beta) \|z_m - z_n\|^2 \quad (4.8)$$

Où C est l'ensemble des paires des pixels adjoints de l'image, dis est la distance euclidienne entre ces pixels, γ est une constante fixé à 50, et la constante β est définie par:

$$\beta = (2(z_m - z_n)^2)^{-1} \quad (4.9)$$

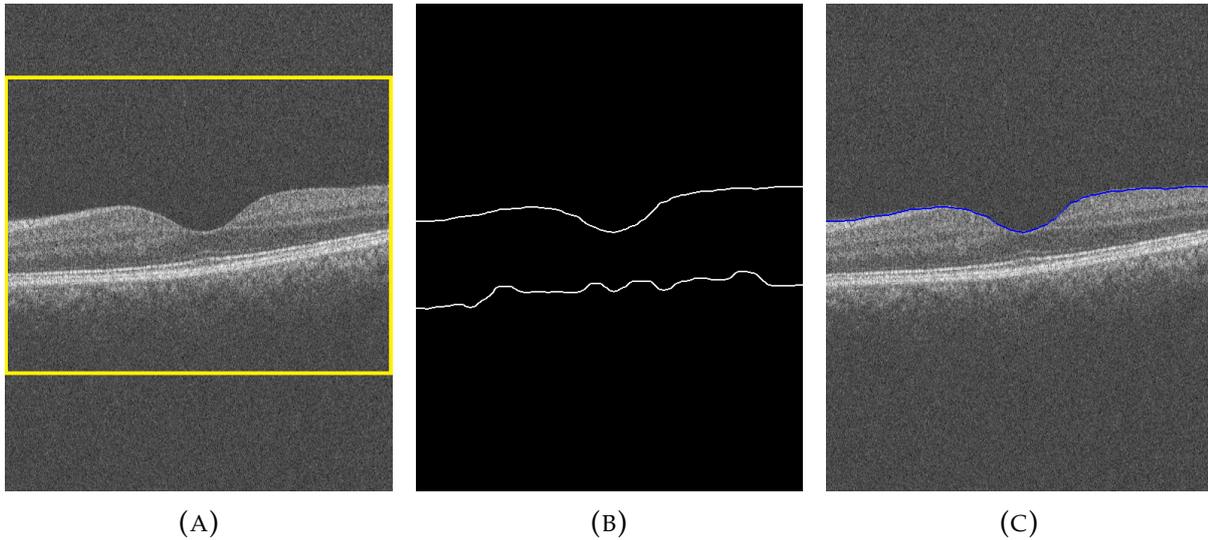


FIGURE 4.7: Segmentation de l'ILM. (A) image d'entrée avec l'initialisation T (rectangle jaune), (B) contours segmentés, (C) extraction finale de l'ILM.

Algorithm 3: Segmentation des images par Grab-Cut.

Entrée: Image I;

Résultat: Segmentation binaire de I;

Début;

Y => Initialisation avec annotation manuelle ;

$f_i \Rightarrow 0, i \in T_B$; $f_i \Rightarrow 1, \forall i \in T_F \cup T_U$ $\theta \Rightarrow$ Initialisez les GMM d'arrière-plan et de premier-plan, en utilisant f;

K => Attribuez des composants GMM aux pixels;

$\theta \Rightarrow$ Apprentissage des paramètres GMM à partir des données z;

f => Estimation de la segmentation: algorithme min-cut ;

Répétez à partir de l'étape 5, jusqu'à la convergence;

Fin.

4.2.2 Segmentation du GCC

Après la segmentation de la membrane ILM, le complexe GCC est segmenté en appliquant l'algorithme de Random Walker [151], sur l'image OCT maculaire filtrée. Le choix de cet algorithme pour la tâche d'extraction du GCC est motivé par le fait de sa :

- Rapidité de calcul;
- Modification rapide de ces variables;
- Robustesse contre le bruit;
- Segmentation précise avec peu d'itérations.

L'algorithme Random Walker est une technique de segmentation multi-classes, basée sur des germes prédéfinis (ou définis par l'utilisateur), indiquant l'appartenance de plusieurs régions aux K classes en sortie [155]. Son principe est d'étiqueter chaque pixel non-sélectionné (non-étiqueté) de l'image, en se basant sur la probabilité qu'un marcheur aléatoire quitte le pixel, et arrive à chacun des germes prédéfinis (pixels étiquetés). Ainsi, les pixels non-étiquetés sont affectés à la classe présentant la plus grande probabilité (la première classe à recevoir le marcheur aléatoire).

Cet algorithme effectue une segmentation sur un graphe pondéré représenté par une paire $G = (V, E)$, contenant des sommets (nœuds) $v \in V$, et des arêtes $e \in E$, où $e_{i,j}$ est l'arête étendue entre les deux nœuds v_i et v_j . Un poids $w_{i,j}$ est affecté à chaque arête du graphe G suivant l'équation 4.10, où I_i et I_j indiquent les intensités de l'image au niveau des pixels i et j , respectivement, et β est un paramètre défini par l'utilisateur. Ce poids montre la similitude entre deux pixels voisins; une grande valeur de $w_{i,j}$ indique une grande probabilité que le marcheur aléatoire passe du nœud v_i au nœud v_j . De même, un degré est calculé pour chaque arête comme le montre l'équation 4.11.

$$w_{i,j} = \exp^{-\beta(I_i - I_j)^2} \quad (4.10)$$

$$d_j = \sum_i w_{i,j} \quad (4.11)$$

Il a été montré dans [151] que la probabilité, pour chaque pixel, qu'un marcheur aléatoire arrive à un des germes étiquetés à une des classes définies, peut être calculée numériquement en résolvant le système d'équations montré dans l'équation 4.12.

$$L_{i,j} = \begin{cases} d_i & \text{si } i = j \\ -w_{i,j} & \text{si } v_i \text{ et } v_j \text{ sont adjacents} \\ 0 & \text{sinon} \end{cases} \quad (4.12)$$

Étant donné un graphe pondéré V , un ensemble de nœuds étiquetés V_M , et un ensemble de nœuds non-étiquetés V_U , tels que $V_M \cup V_U = V$ et $V_M \cap V_U = \emptyset$. Nous étiquetons

chaque nœud $V_i \in V_U$ avec une étiquette $s = i$, où i est l'indexe de la classe. Dans notre application, deux classes sont considérées : la classe du complexe GCC ($s = 1$), et la classe de l'arrière-plan. En supposant que chaque nœud $v_j \in V_M$ est affecté à une étiquette s , nous calculons les probabilités X_i^s pour qu'un marcheur aléatoire quittant le nœud v_i arrive au nœud v_j , en résolvant l'équation 4.13, où X_i^s représente l'ensemble des probabilités d'appartenance à chaque classe S , pour chaque nœud v_j , L_M est la relation entre les pixels étiquetés, B la relation entre les pixels étiquetés et non-étiquetés, et L_U la relation entre les pixels non-étiquetés.

$$L_U X_i^S = -B^T L_M \quad (4.13)$$

Pour la segmentation du GCC proposée, l'image OCT maculaire est divisée en deux classes, classe GCC : $s=1$ (initialisée par les germes blancs dans la figure 4.8 (B)), et la classe de l'arrière-plan : $s=0$ (Initialisée par les germes rouges dans la figure 4.8 (B)). Les pixels du contour ILM segmenté sont utilisés pour définir les germes de la première classe, tandis que tout pixel présentant une intensité inférieure à 160 est utilisé pour définir les germes de la deuxième classe. Un exemple de la segmentation du complexe GCC est illustré dans la figure 4.8.

4.2.3 Mesure et analyse de l'épaisseur de la couche GCC

Après la segmentation du complexe GCC, l'épaisseur de ce dernier est mesurée et analysée, afin de détecter les amincissements pathologiques dus au glaucome. D'après **H. Hou et al. (2020)** [156], l'épaisseur moyenne du complexe des cellules ganglionnaires saines est comprise entre 85 et 100 μm , tandis que, celle des cas glaucomateux présentent des épaisseurs au-dessous de cette moyenne, à cause de la mort des cellules ganglionnaires, et des fibres nerveuses de la couche RNFL.

Dans notre travail, l'épaisseur du complexe GCC, segmenté dans la section précédente, est mesurée par la distance entre chaque pixel de la membrane ILM (Figure 4.9 contour bleu) avec son équivalent du contour externe du GCC (Figure 4.9 contour rouge).

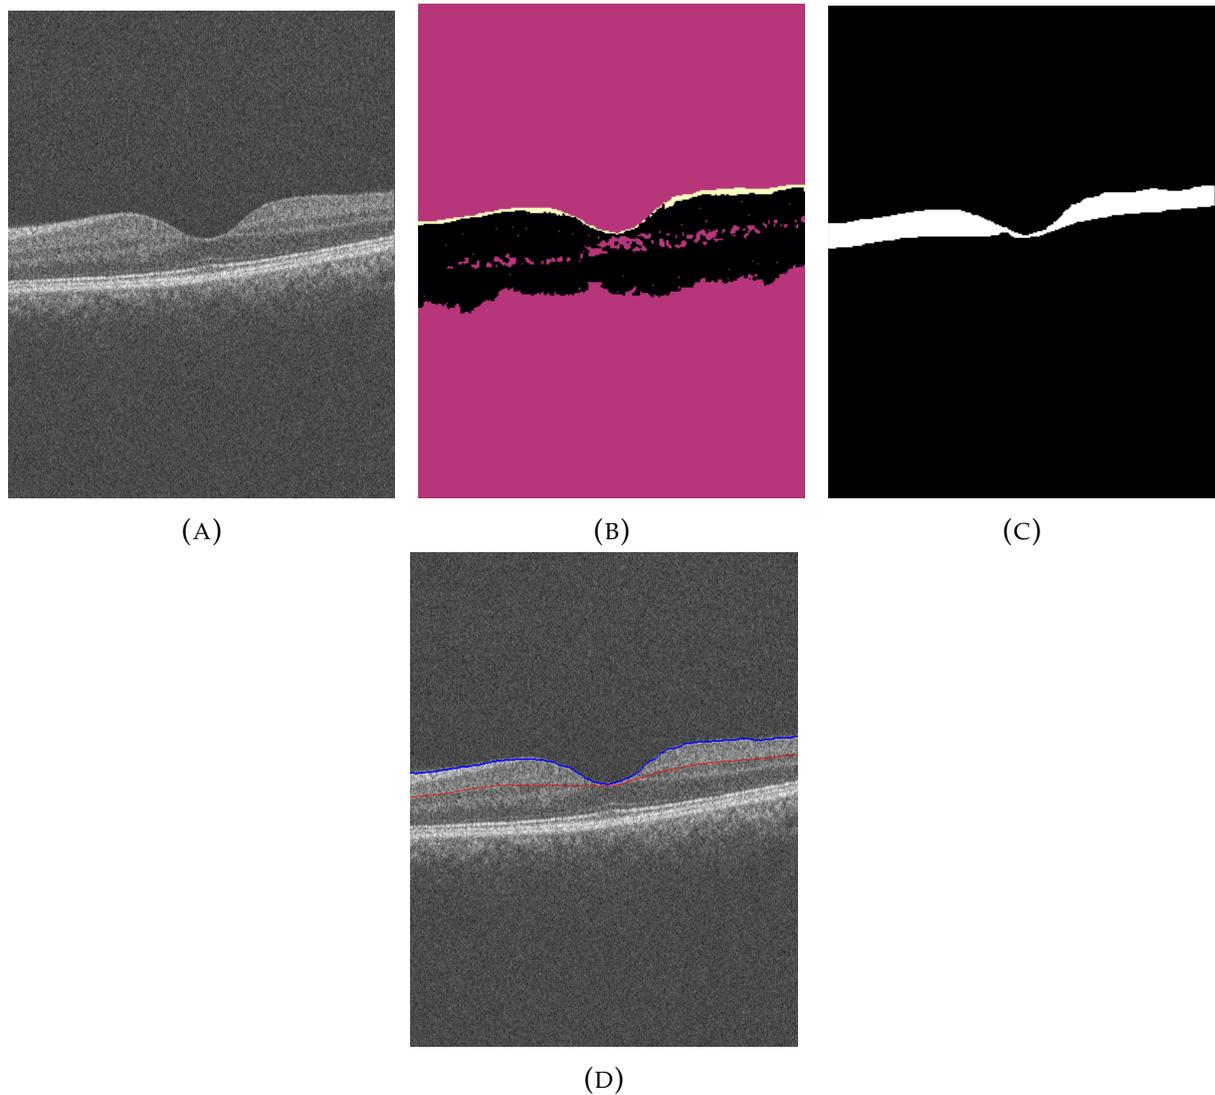


FIGURE 4.8: Segmentation du complexe GCC. (A) image OCT maculaire d'entrée, (B) initialisation des germes du marcheur aléatoire (rouge pour le fond et blanc pour l'objet), (C) extraction du GCC, (D) Segmentation finale du GCC.

Enfin, sachant que la fovéa est la dernière structure rétinienne affectée par le glaucome, elle a été éliminée manuellement du graphe de l'épaisseur (Figure 4.9), ce qui a donné lieu à deux sous-graphes représentant l'épaisseur nasale et temporale du complexe GCC.

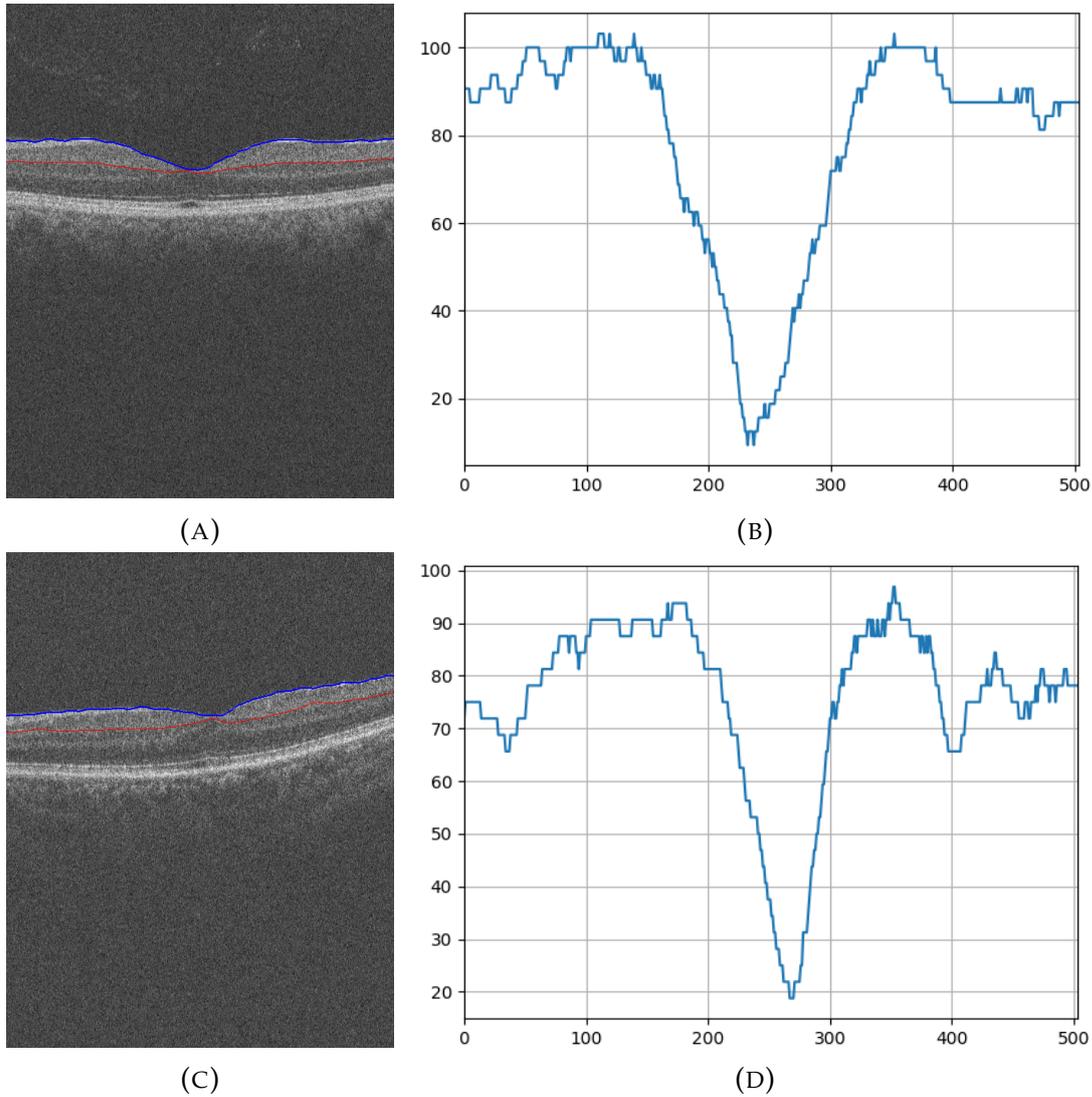


FIGURE 4.9: Mesure de l'épaisseur (en μm) du GCC. Premier ligne: cas sain. Deuxième ligne: cas glaucomateux.

4.3 Détection du glaucome basée sur des caractéristiques hybrides

À notre connaissance, notre étude est la première à combiner les caractéristiques structurales, extraites à partir des images OCT maculaires, avec les indicateurs cliniques, extraits des images fond d'œil pour le dépistage précoce du glaucome. L'intérêt principal de cette combinaison est d'améliorer la précision du diagnostic, en corrigeant les erreurs de classifications observées par le classificateur précédent.

4.3.1 Bases de données utilisées

La méthodologie de la fusion multimodalités proposée pour le diagnostic du glaucome, a été validée expérimentalement sur deux bases de données, contenant des images fond d'œil et OCT maculaires, saines et glaucomateuses. La première est une base de données locale, contenant 60 paires d'images : fond d'œil et OCT maculaire, acquises à l'hôpital Frantz Fanon de Blida, avec un rétinographe Topcon 3DOCT1 Maestro. La résolution des images fond d'œil, et OCT de cette base de données sont 2124×2056 , et 516×516 , respectivement.

La deuxième, est la base de données publique fournie par **T. Mahmudi et al.** [31], contenant des volumes OCT ($650 \times 512 \times 128$), et des images fond d'œil (1612×1536) des yeux droits et gauches, des 50 sujets sains. La figure 4.10 montre des exemples des deux bases de données.

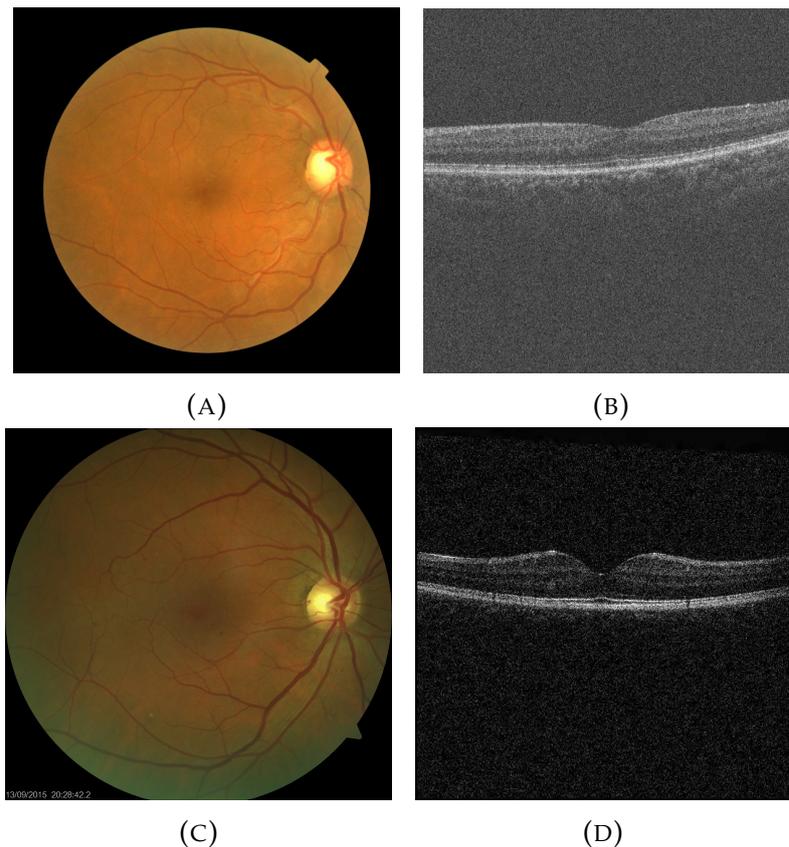


FIGURE 4.10: Exemples des deux bases de données utilisées pour la classification multimodalité. Première ligne : la base de données publique [31], deuxième ligne : la base de données locale.

Afin de caractériser les complexes GCC sains et glaucomateux, les caractéristiques suivantes sont mesurées à partir de chaque graphe d'épaisseur : la valeur moyenne, maximale, et minimale, la moyenne des valeurs de 80% les plus élevées, et la moyenne des valeurs de 20% les plus basses. Ces caractéristiques structurelles sont combinées avec les indicateurs cliniques du glaucome : le CDR vertical, horizontal et régional, vérification de la loi ISNT, et l'échelle DDLS, et sont transmises à un classificateur forêt aléatoire, contenant 1000 arbres de décision (identiques au classificateur précédent), pour l'identification des cas sains des cas pathologiques.

La figure 4.11 montre la description de l'un des arbres de décision du classificateur forêt aléatoire, obtenu par les caractéristiques hybrides. Au niveau du nœud racine, les cas présentant un rapport CDR régional inférieur à 0.185, sont classifiés directement comme cas sains. Sinon il divise les cas restant en fonction de leur épaisseur maximale du graphe nasal. Les cas présentant une valeur supérieure à $92.188 \mu\text{m}$ sont classés comme sujets sains. Sinon les cas restants sont divisés en fonction de leurs épaisseurs minimales du graphe temporal, où les cas présentant une valeur supérieure à $87.5 \mu\text{m}$ sont classés comme sujets sains, tandis que ceux présentant une valeur inférieure sont classés comme cas de glaucome.

4.3.2 Comparaison des deux classificateurs

Comme il a été montré dans [140], la couche du complexe des cellules ganglionnaires, s'est avérée avoir un pouvoir de diagnostic plus élevé que la couche des fibres nerveuses (RNFL), surtout pour identifier les cas de glaucome précoce, et les cas sains. Évidemment, la fusion des indicateurs cliniques de glaucome, mesurés dans le chapitre précédent, avec les caractéristiques structurelles de la couche GCC, a fourni un diagnostic plus profond (en analysant deux structures rétiniennes différentes), et a présenté une meilleure précision de classification par rapport au classificateur précédent.

Cette amélioration est traduite par la capacité du deuxième classificateur à rectifier les erreurs de classifications, obtenues par le premier classificateur basé uniquement sur

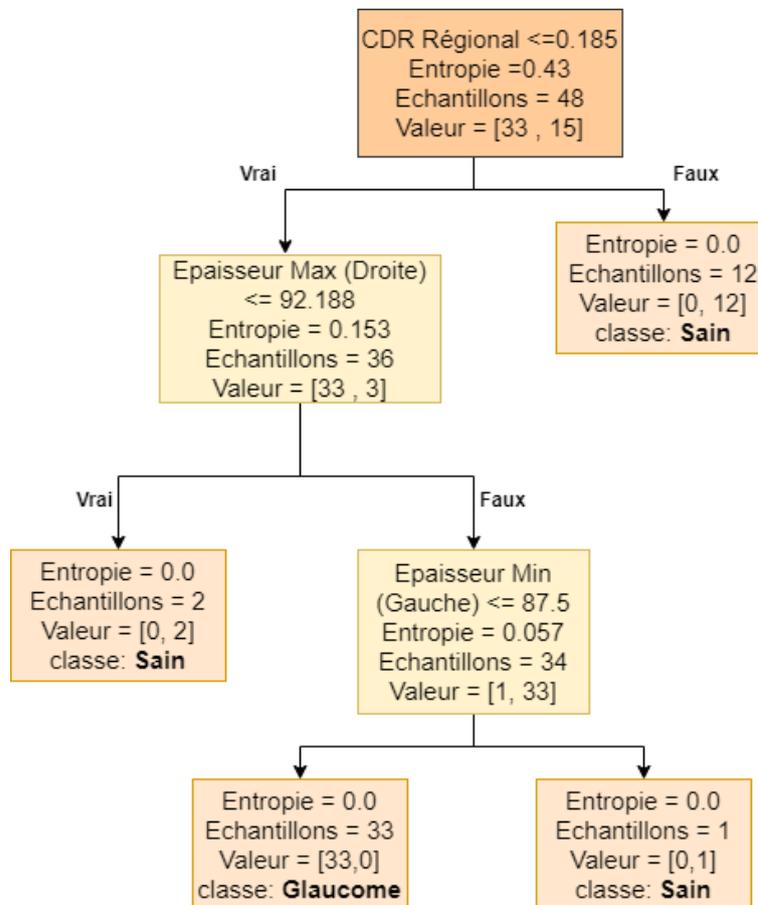


FIGURE 4.11: Exemple des arbres de décision utilisés pour la classification multimodalité.

les caractéristiques liées aux fonds d'œil. Dans le chapitre précédent, nous avons observé que bien que les cas C_1 et C_2 présentaient des indicateurs extrêmement proches, ils appartenaient à des classes différentes : $C_1 \in$ classe 'Sain' et $C_2 \in$ classe 'Glaucome'. La figure 4.12 illustre les caractéristiques structurelles de C_1 et C_2 . Il est à noter que, C_2 présente un amincissement considérable par rapport à C_1 , dont l'épaisseur du complexe GCC est toujours dans les normes. Cette observation veut dire que la classification basée sur la fusion des caractéristiques extraites des images fond d'œil, et OCT maculaires, a efficacement séparé les cas sains, des cas présentant un glaucome précoce. L'évaluation de la performances du classificateur sont présentées dans la section 5.2.

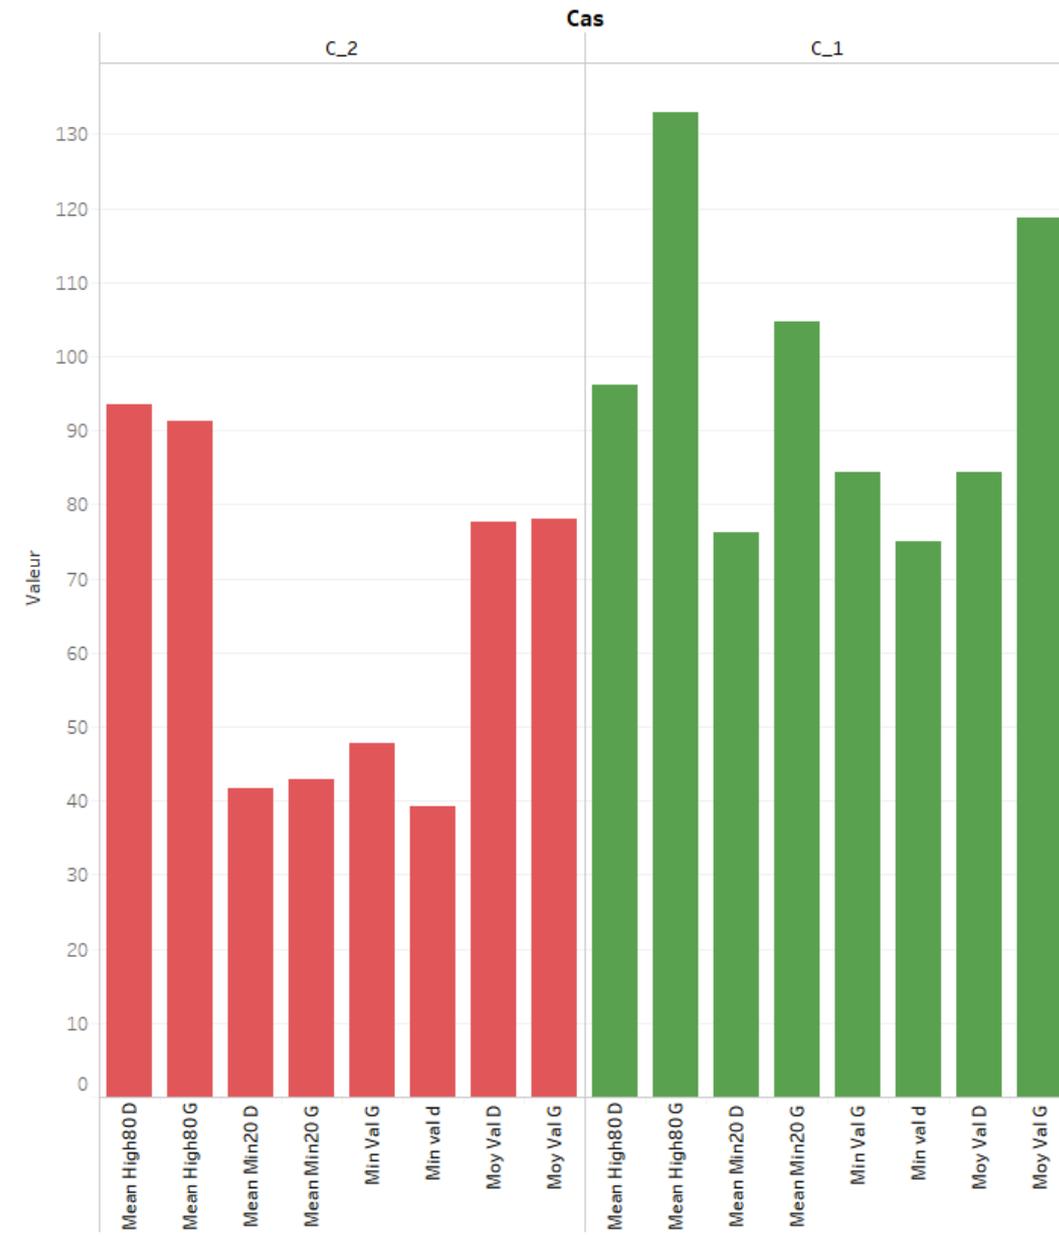


FIGURE 4.12: Caractéristiques structurales maculaires des cas C₁ et C₂.

4.4 Classification de l'angle irido-cornéen

Comme il a été mentionné dans le premier chapitre, il existe principalement deux types de glaucome : Glaucome à Angle Ouvert (GAO), et Glaucome à Angle fermé (GAF). Ce dernier est une forme spécifique de la maladie, dans laquelle une augmentation soudaine de la PIO (Pression Intra-Oculaire) se produit à la suite d'un mauvais

drainage de l'humeur aqueuse, causé par un rétrécissement pathologique de l'angle entre l'iris et la cornée [157].

L'imagerie de la chambre antérieure oculaire est une modalité très importante pour le diagnostic, la prise en charge, et le suivi du GAF. La principale zone pathologique de cette forme de glaucome est le Trabéculum [158], qui est le site de drainage de l'humeur aqueuse dans l'œil [159]. Récemment, l'évaluation qualitative et quantitative des différentes caractéristiques du segment antérieur oculaire, est réalisée à l'aide de l'OCT de la chambre antérieure (AS-OCT).

D'après la littérature, l'identification des deux formes de glaucome est généralement binaire ; soit l'angle est ouvert, soit fermé, et la mesure de la valeur exacte de l'angle irido-cornéen n'est pas obligatoire pour cette tâche. Dans cette section, nous proposons une approche de classification directe des images AS-OCT, présentant un glaucome à angle ouvert ou fermé, basée sur l'apprentissage approfondi, dans lequel plusieurs architectures sont implémentées : AlexNet[160], VggNet[161] et une architecture CNN séquentielle.

4.4.1 Base de données utilisée

La méthodologie proposée pour la classification directe des images AS-OCT, pour l'identification des deux types de glaucome, a été validée expérimentalement avec la base de données publique AGE (Angle closure Glaucoma Evaluation challenge) [162]. Cette base de données contient 4800 images AS-OCT, répartie de manière égale pour l'apprentissage, le test, et la validation. Chaque image a été acquise au niveau du centre d'ophtalmologie Zhongshon (Japon), avec l'OCT CASIA SS-1000 et a une taille de 2130x998 pixels. Des exemples d'images présentant un angle ouvert et fermé sont illustrés dans la figure 4.13.

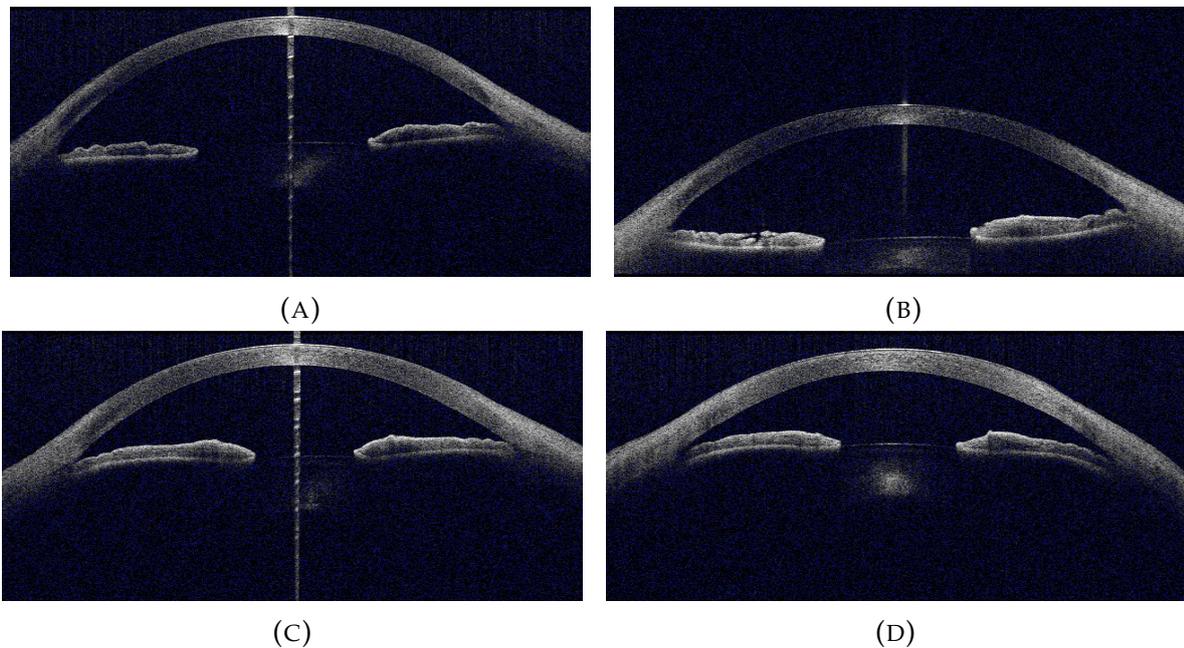


FIGURE 4.13: Exemples de la base de données AGE. Première ligne : images présentant un angle ouvert. Deuxième ligne : images présentant un angle fermé.

4.4.2 Classification des images AS-OCT par AlexNet

Le modèle AlexNet est le modèle le plus représentatif de CNN, qui présente trois avantages, à savoir, une performance supérieure, moins de paramètres d'apprentissage, et une forte robustesse [163]. Ce modèle s'inspire de la vision humaine, tout en imitant le mode de transmission visuel à deux canaux, en apprennent les caractéristiques pertinentes de l'image et en utilisant deux canaux, comme illustré dans la figure 4.14.

AlexNet est un modèle de réseaux de neurones convolutionnels profonds, comprenant plusieurs couches cachées (C1...C5) (Figure 4.14). La première couche convolutive effectue une convolution, avec un max-pooling et une normalisation de réponse locale (Local Response Normalization : LRN), où 96 filtres récepteurs de taille 11x11 pixels sont utilisés pour la convolution, tandis que l'opération de max-pooling (P1), est effectuée avec un filtre de taille 3x3 pixels. Les mêmes opérations sont effectuées dans la deuxième couche de convolution avec des filtres de taille 5x5 pixels. Des filtres de taille 3x3 sont utilisés dans la troisième, quatrième et cinquième couches convolutives, avec 384, 384, et 296 filtres récepteurs, respectivement. Les couches cachées, sont suivies de 2 couches entièrement connectées (FC), de la couche de dropout, puis de la couche de sortie activée

par la fonction Softmax [164].

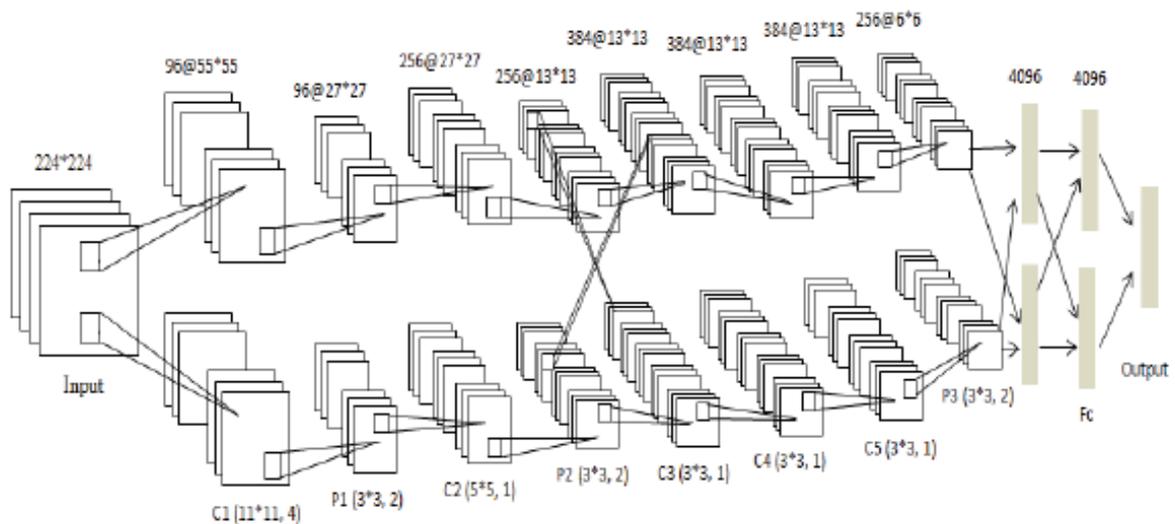


FIGURE 4.14: L'architecture du modèle AlexNet.

Deux nouveaux concepts, la normalisation de la réponse locale (LRN), et le Dropout, sont introduits par ce réseau. La LRN est introduite dans l'architecture AlexNet, où la fonction d'activation utilisée est ReLU. La raison d'introduire cette couche supplémentaire est d'encourager l'inhibition latérale. Cette dernière est un concept en neurobiologie qui fait référence à la capacité d'un neurone à réduire l'activité de ses neurones voisins [165]. Dans l'apprentissage profond, le but de cette inhibition est d'améliorer le contraste local des couches pendant l'apprentissage, de sorte que les minimas-locaux obtenus après la convolution, soient utilisés pour l'excitation des neurones de la couche suivante.

Le Dropout est une technique de régularisation des réseaux de neurones pendant la phase d'apprentissage, qui supprime des neurones (avec leur connections), avec une probabilité spécifique [166]. Dans notre application, la probabilité est fixée à 0.5, ce qui veut dire que 50% des neurones sont désactivés, après chaque opération de Dropout. L'idée est d'éviter la coadaptation, où le réseau devient trop dépendant de connexions particulières, conduisant ainsi à un sur-apprentissage. La figure 4.15 montre un exemple d'application du Dropout sur un réseau de neurones contenant deux couches cachées.

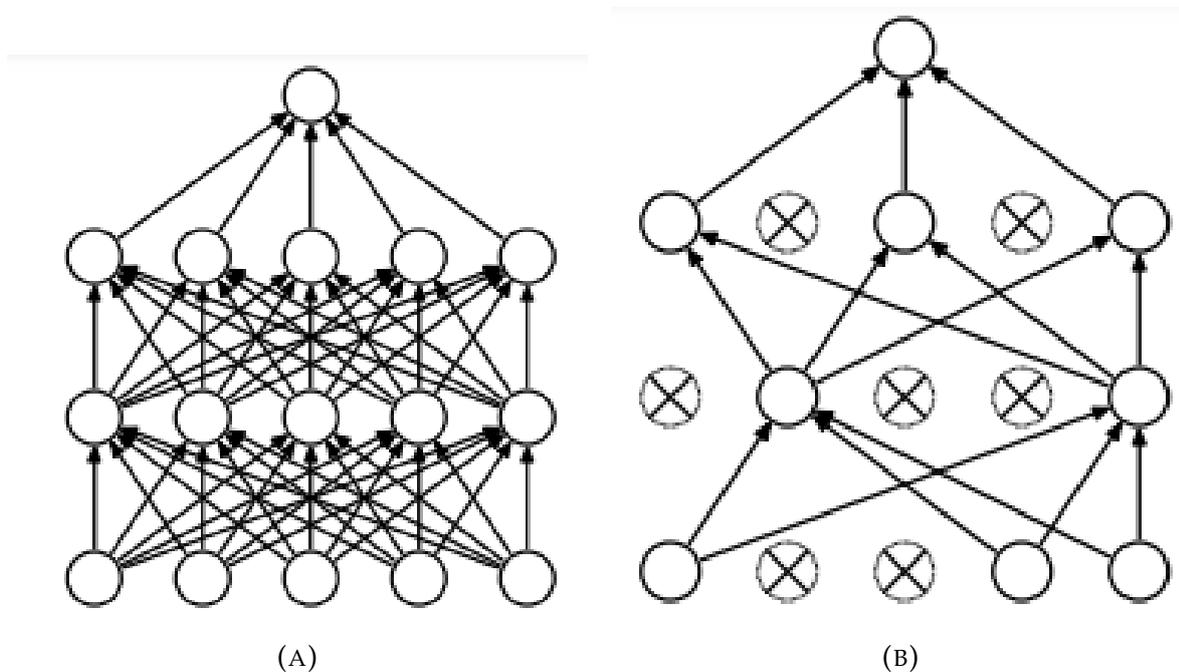


FIGURE 4.15: Exemple de l'application du Dropout. (A) un réseau de neurones avec deux couches cachées avant le Dropout, (B) le réseau après l'application du Dropout.

La base de données d'apprentissage issue de la base de données AGE, contient 3200 images AS-OCT, que nous avons divisées en deux parties : 2560 images (80%), sélectionnées au hasard ont été utilisées pour l'apprentissage, et les 640 images restantes (20%), pour tester le réseau. Le processus de l'apprentissage a été répété à travers 50 epochs (itérations), avec un batch de taille 60 (nombre d'images apprises avant la mise à jour des poids des neurones).

Au début de la phase d'apprentissage, tous les paramètres (poids des neurones) sont initialisés aléatoirement à l'aide d'une distribution gaussienne aléatoire, et les images sélectionnées sont redimensionnées à la taille 300x300, pixels et utilisées comme entrées pour le réseau AlexNet. Les paramètres fixés sont :

- **Nombre d'epochs** : C'est le nombre d'itérations que l'algorithme exécutera sur l'ensemble de données d'apprentissage. Le nombre d'epoch optimal est fixé à 50;
- **Taux d'apprentissage** : C'est le paramètre qui contrôle la modification du modèle en fonction des erreurs estimées, à chaque fois que les poids sont mis à jour. Si ce paramètre est trop petit, le modèle prendra beaucoup de temps pour l'apprentissage,

tandis que si sa valeur est trop élevée, le modèle convergera à un résultat sous-optimal. Dans notre étude, les valeurs de taux d'apprentissage suivantes sont testées: 0.0001, 0.001, 0.01, et 0.1.

Après l'apprentissage, les paramètres de performance suivants sont mesurés pour l'évaluation du modèle AlexNet: précision, sensibilité et spécificité. La meilleure performance a été obtenue en utilisant un taux d'apprentissage de 0.001 (Tableau 4.1). Le modèle AlexNet pouvait identifier les deux formes de glaucome avec une précision de 94.25%, une sensibilité de 90.31%, et une spécificité de 98.20%.

TABLE 4.1: Performance du modèle AlexNet en fonction du taux d'apprentissage.

Taux d'apprentissage	Précision (%)	Sensibilité (%)	Spécificité(%)
0.1	87.07	75.00	99.14
0.01	91.52	85.31	97.73
0.001	94.25	90.31	98.20
0.0001	90.42	82.18	98.71

Les graphes de précision et des pertes obtenues après l'apprentissage du modèle AlexNet, avec un taux d'apprentissage de 0.001, sont illustrés dans la figure 4.16. Après la 30^{ième} epoch, la précision a atteint sa valeur maximale (0.974), sans aucune augmentation considérable par la suite, alors que, la fonction des pertes atteint sa valeur minimale (0.084) après la 40^{ième}, avec deux pics autour de la 9^{ième}, et 17^{ième} epochs. La raison de ces pics est que le réseau a extrait de nouvelles caractéristiques, qui ont provoqué des discontinuités, au niveau des matrices des poids, entraînant une augmentation soudaine de la fonction des poids.

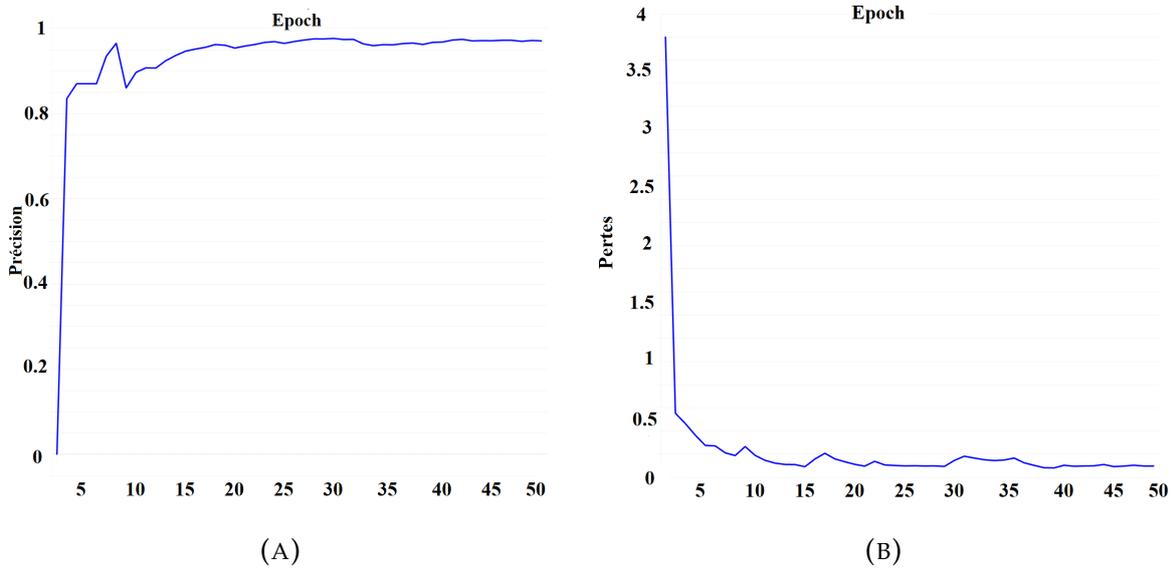


FIGURE 4.16: Fonctions de précision et de pertes du modèle AlexNet. (A) fonction de précision, (B) fonction des pertes.

4.4.3 Classification des images AS-OCT par VGGNet

L'architecture VGG est un modèle classique des réseaux de neurones, proposé par **K. Simonyan et A. Zisserman (2014)** [161]. Son objectif principal est de comprendre comment la profondeur d'un réseau CNN affecte la précision de la classification, et de la reconnaissance des images [167].

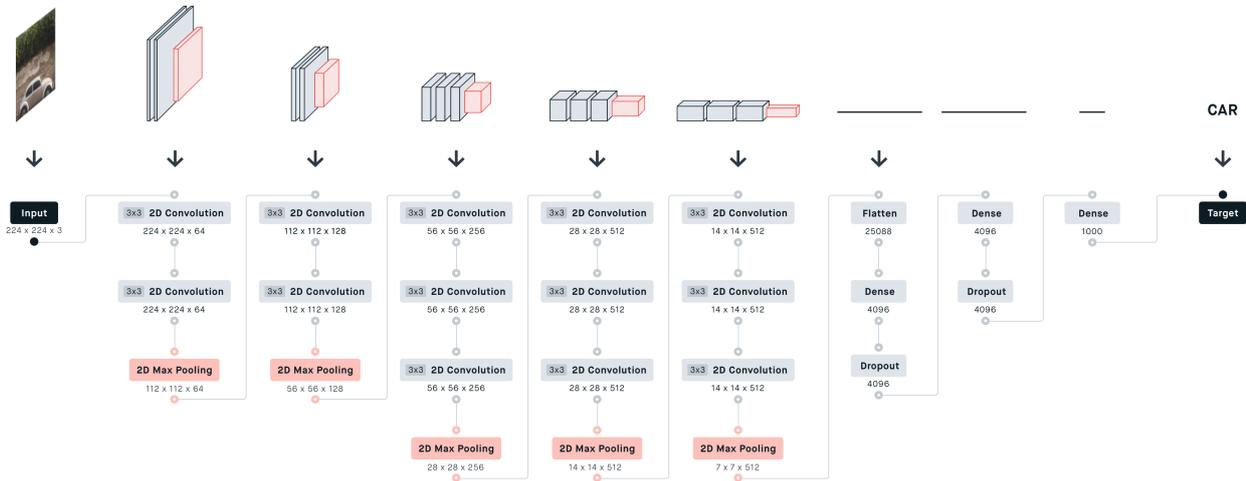


FIGURE 4.17: L'architecture du modèle VGGNet.

La conception du modèle VGG inclus 13, ou 16 couches de convolution, dont la taille des filtres est fixée à 3x3 pixels, suivies par trois couches consécutives entièrement connectées ayant 4096, 4096 et 1000 neurones respectivement, la figure 4.17 donne un exemple d'un réseau VGG à 13 couches de convolution. Contrairement à l'architecture AlexNet, où

chaque couche de convolution contient une seule opération de convolution, et chacune de ces couches est suivie par une couche de max-pooling, dont la taille des kernels est fixée à 2x2 pixels. La combinaison de plusieurs couches de convolution avec des noyaux de petites tailles, au lieu d'une seule couche avec des noyaux plus grand, permet au modèle VGG de réduire le nombre des caractéristiques à extraire afin d'éviter le sur-apprentissage [161]. La table 4.2 montre une description détaillée du modèle VGG utilisé pour la classification des images AS-OCT.

TABLE 4.2: Architecture détaillée du modèle VGG.

Couche	Nom de la couches	Nombre de Filtrés	Neurones	Noyaux	Activation
0	Image d'entrée	1	400x400	-	-
1	2xConvolution	64	400x400	3x3	ReLU
-	Max-Pooling	64	200x200	2x2	ReLU
2	2xConvolution	128	200x200	3x3	ReLU
-	Max-Pooling	128	100x100	2x2	ReLU
3	2xConvolution	256	100x100	3x3	ReLU
-	Max-Pooling	256	50x50	2x2	ReLU
4	3xConvolution	512	50x50	3x3	ReLU
-	Max-Pooling	512	25x25	2x2	ReLU
5	3xConvolution	512	25x25	3x3	ReLU
-	Max-Pooling	512	13x13	2x2	ReLU
6	Entièrement Connectée	4096	-	-	-
7	Entièrement Connectée	4096	-	-	-
8	Entièrement Connectée	1000	-	-	-
10	Couche de sortie	-	2	-	Softmax

Comme pour le modèle AlexNet, la précision, la spécificité et la sensibilité du modèle VGGNet sont mesurées après la phase d'apprentissage, avec plusieurs valeurs de taux d'apprentissage, à savoir, 0.1, 0.01, 0.001 et 0.0001 (Table 4.3). La meilleure performance a été achevée en utilisant un taux d'apprentissage de 0.001. Le modèle VGG pouvait identifier l'ouverture et la fermeture de l'angle irido-cornéen avec une précision de 89.53%, une sensibilité de 80.62% et une spécificité de 98.43%.

Les graphes de précision et de pertes obtenus après l'apprentissage du modèle VGG, avec le meilleur taux d'apprentissage (0.001) sont illustrés dans la figure 4.18. Après la 34^{ième} epoch, la fonction de précision a atteint sa valeur maximale (0.9916), sans aucune

TABLE 4.3: Performance du modèle VGGNet en fonction du taux d'apprentissage.

Taux d'apprentissage	Précision (%)	Sensibilité (%)	Spécificité(%)
0.1	87.07	75.00	99.14
0.01	89.53	80.26	98.43
0.001	94.84	82.18	98.71
0.0001	89.41	79.93	99.45

augmentation considérable par la suite, tandis que la fonction de pertes atteint sa valeur minimale après la 25^{ième} epoch (0.058), avec un seul pic autour du 10^{ième} epoch.

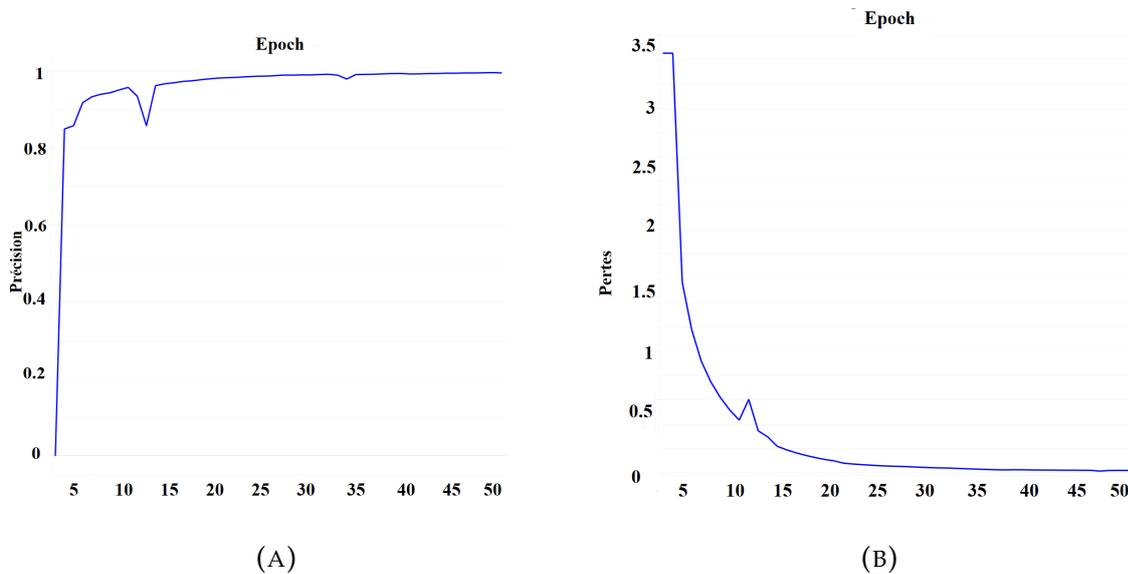


FIGURE 4.18: Fonctions de précision et des pertes du modèle VGGNet. (A) fonction de précision, (B) fonction des pertes.

4.4.4 Classification des images AS-OCT par un réseau CNN séquentiel

En plus des modèles CNN précédents, trois réseaux séquentiels sont implémentés contenant 4, 6, et 8 couches cachées de convolution. La table 4.4 montre une description détaillée des architectures séquentielles implémentées. La même procédure d'apprentissage est appliquée pour les trois modèles séquentiels implémentés. Après avoir divisé la base de données AGE en un ensemble d'images d'apprentissage et un ensemble d'images de test, l'évaluation de chaque modèle est réalisée, avec un taux d'apprentissage de 0.1, 0.01, 0.001, et 0.0001, en mesurant les trois paramètres de performances : précision, spécificité et sensibilité (Table 4.5). Nous remarquons que la meilleure performance est obtenue

à l'aide du modèle contenant 8 couches de convolution, avec un taux d'apprentissage de 0.001. Ce classificateur a pu identifier les deux formes de glaucome, avec une précision de 97.56%, une sensibilité de 99.12, et une spécificité de 96.00%.

TABLE 4.4: Description détaillée des modèles séquentiels implémentés.

Modèle comprenant 4 couches cachées de convolution					Modèle comprenant 6 couches cachées de convolution					Modèle comprenant 8 couches cachées de convolution				
Nom de la couche	Nombre de filtres	Neurone	Kernel	Activation	Nom de la couche	Nombre de filtres	Neurone	Kernel	Activation	Nom de la couche	Nombre de filtres	Neurone	Kernel	Activation
Couche d'entrée	1	400x400	-	-	Couche d'entrée	1	400x400	-	-	Couche d'entrée	1	400x400	-	-
Couche de convolution	32	400x400	3x3	ReLU	Couche de convolution	32	400x400	3x3	ReLU	Couche de convolution	32	400x400	3x3	ReLU
Max-pooling	32	200x200	2x2	-	Max-pooling	32	200x200	2x2	-	Max-pooling	32	200x200	2x2	-
Couche de convolution	64	200x200	3x3	ReLU	Couche de convolution	64	200x200	3x3	ReLU	Couche de convolution	64	200x200	3x3	ReLU
Max-pooling	64	100x100	2x2	-	Max-pooling	64	100x100	2x2	-	Max-pooling	64	100x100	2x2	-
Couche de convolution	32	100x100	3x3	ReLU	Couche de convolution	32	100x100	3x3	ReLU	Couche de convolution	32	100x100	3x3	ReLU
Max-pooling	32	50x50	2x2	-	Max-pooling	32	50x50	2x2	-	Max-pooling	32	50x50	2x2	-
Couche de convolution	64	50x50	3x3	ReLU	Couche de convolution	64	50x50	3x3	ReLU	Couche de convolution	64	50x50	3x3	ReLU
Max-pooling	64	25x25	2x2	-	Max-pooling	64	25x25	2x2	-	Max-pooling	64	25x25	2x2	-
Couche entièrement connectée	-	1024	-	-	Couche de convolution	32	25x25	3x3	ReLU	Couche de convolution	32	25x25	3x3	ReLU
Couche de sortie	-	2	-	Softmax	Max-pooling	32	13x13	2x2	-	Max-pooling	32	13x13	2x2	-
					Couche de convolution	64	13x13	3x3	ReLU	Couche de convolution	64	13x13	3x3	ReLU
					Max-pooling	64	7x7	2x2	-	Max-pooling	64	7x7	2x2	-
					Couche entièrement connectée	-	1024	-	-	Couche de convolution	32	13x13	3x3	ReLU
					Couche de sortie	-	2	-	Softmax	Max-pooling	32	7x7	2x2	-
										Couche de convolution	64	7x7	3x3	ReLU
										Max-pooling	64	4x4	2x2	-
										Couche entièrement connectée	-	1024	-	-
										Couche de sortie	-	2	-	Softmax

TABLE 4.5: Performance du modèle séquentiel à 8 couches de convolution en fonction du taux d'apprentissage.

Taux d'apprentissage	Précision (%)	Sensibilité (%)	Spécificité(%)
0.1	95.38	94.32	92.63
0.01	96.02	95.45	93.23
0.001	97.56	99.12	96.00
0.0001	90.37	92.45	87.89

Les graphes de précision et de pertes obtenus après l'apprentissage du modèle séquentiel ayant 8 couches de convolution, sont illustrés dans la figure 4.19. Après la 27^{ième} epoch, la précision a atteint sa valeur maximale (0.985) sans aucune augmentation considérable par la suite, alors que, la fonction de pertes atteint sa valeur minimale (0.03) après la 33^{ième}, avec deux pics autour de la 8^{ième} et 16^{ième} epochs.

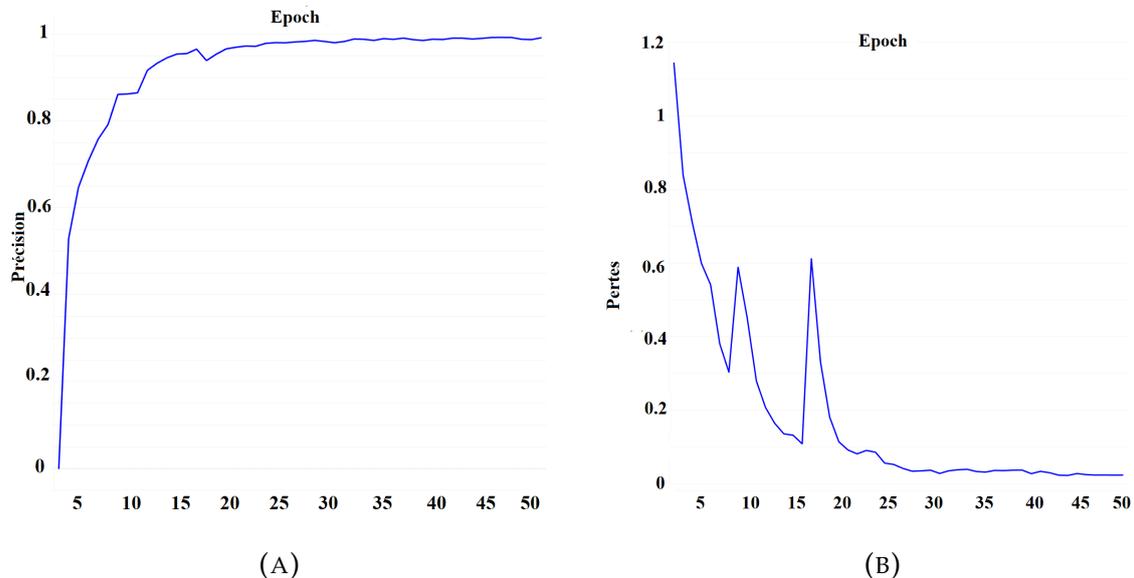


FIGURE 4.19: Fonctions de précision et de pertes du modèle séquentiel. (A) fonction de précision, (B) fonction de pertes.

Discussion

La combinaison des indicateurs de glaucome proposée dans le chapitre précédent, a fourni une analyse profonde de la tête du nerf optique, ce qui a amélioré la précision de l'identification des cas glaucomateux, et des cas sains (voir chapitre 5). Il est à noter que la classification basée uniquement sur ces indicateurs, présentait quelques limitations dans

l'identification des cas sains, et des cas présentant un glaucome précoce.

Dans ce chapitre, les indicateurs précédemment mesurés, ont été combinés avec des caractéristiques structurelles du complexe GCC, extraites des images OCT maculaires. Les résultats ont révélé que cette fusion multi-modalités, a fourni une meilleure détection du glaucome dans son stade précoce, en analysant deux structures rétiniennes différentes (la tête du nerf optique et la macula). L'évaluation de la performance de la classification, basée sur cette fusion, est détaillée dans §5.2.4.

À notre connaissance, notre approche de détection du glaucome basée sur un vecteur de caractéristiques hybrides, extraites des images fond d'œil, et des images OCT maculaires, n'a jamais été tentée auparavant, et s'est avérée très fructueuse.

La principale limitation observée est l'échec de fournir un graphe d'épaisseur précis du complexe GCC, en cas de présence d'une déformation maculaire. Ces déformations peuvent être dues à plusieurs pathologies oculaires, telles que la dégénérescence maculaire liée à l'âge (DMLA), la maculopathie, la néovascularisation de la choroïde ... (Figure 4.20), conduisant à la corruption de l'ordre logique des différentes couches rétiniennes, et de leurs épaisseurs correspondantes. Dans ce cas, la détection du glaucome est faite par le classificateur fond d'œil.

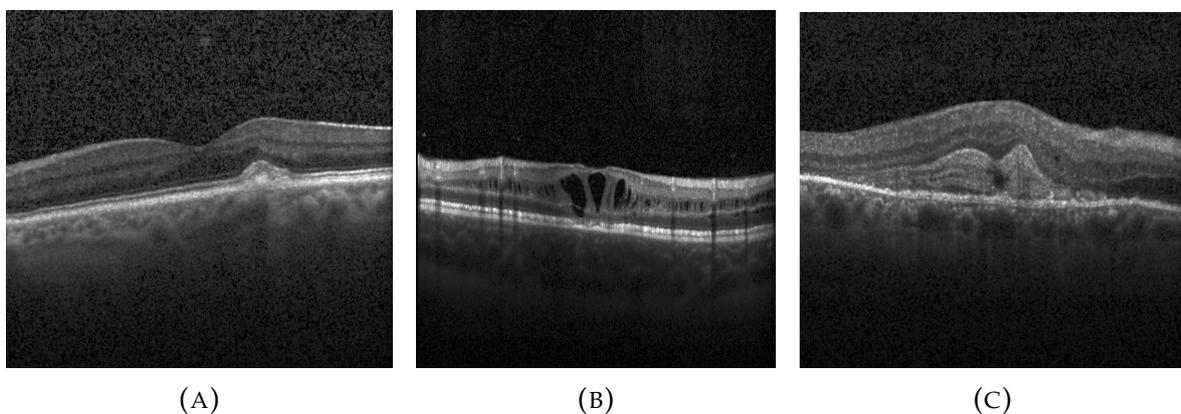


FIGURE 4.20: Exemples de déformations maculaires. (A) dégénérescence maculaire liée à l'âge (DMLA). (B) maculopathie. (C) néovascularisation de la choroïde.

Plusieurs modèles de réseaux de neurones profonds ont été implémentés, pour la classification directe des images AS-OCT, afin d'identifier les deux formes du glaucome : glaucome à angle fermé, et glaucome à angle ouvert. L'évaluation de chaque modèle est détaillée dans §5.3. Cette classification permet l'évaluation automatique des facteurs de risque de la fermeture de l'angle irido-cornéen, et l'amélioration de l'efficacité des interventions de la maladie du glaucome.

Dans le prochain chapitre, nous présentons une évaluation détaillée des différents résultats obtenus, dans les deux derniers chapitres.

CHAPITRE 5
RÉSULTATS ET DISCUSSION

5 Résultats et discussion

Un des moyens les plus efficaces pour lutter contre la cécité causée par la maladie du glaucome, est la détection précoce des fibres nerveuses, par l'analyse des différentes images rétiniennes. Deux techniques de diagnostic assisté par ordinateur ont été présentées dans les deux chapitres précédents. La première est basée sur la détection, et l'analyse de l'élargissement pathologique du cup optique, pour l'identification des cas de glaucome, en mesurant ses différents indicateurs, extraits des images fond d'œil : le rapport CDR, la vérification de la loi ISNT et l'échelle DDLS. Alors que la deuxième technique est basée sur la combinaison de ces indicateurs, avec des caractéristiques structurales du complexe des cellules ganglionnaires, extraites à partir des images OCT maculaires. Dans ce chapitre, nous présentons une évaluation détaillée des différents résultats de segmentation et de classification obtenus dans les deux chapitres précédents.

La meilleure méthode pour valider une segmentation, ou une classification est la comparaison avec la vérité terrain. Cette dernière est un résultat prédéterminé connu pour être 'la bonne réponse', et définit exactement, ce qu'un algorithme informatique est censé produire [168]. En d'autres termes, plus le résultat d'un algorithme est proche de la vérité terrain, plus il est performant. Ci-dessous, nous définissons les paramètres les plus utilisés dans l'évaluation des algorithmes de segmentation, ou de classification des images fond d'œil.

- **Erreur Moyenne:** Ce paramètre mesure l'écart entre les résultats réels (vérité terrain), et les résultats observés par l'algorithme développé. Cette erreur est calculée comme le montre l'équation 5.1, où E_m est l'erreur moyenne, n le nombre d'observations, F_i est l'observation réelle, et O_i est l'observation de l'algorithme.

$$E_m = \frac{1}{n} \sum_{i=1}^n |F_i - O_i| \quad (5.1)$$

• **F-score:** Ce paramètre est une mesure de l'exactitude, avec une valeur comprise entre 0 et 1, et est calculé comme le montre l'équation 5.2, où S_A est la segmentation obtenue par l'algorithme développé, et S_{VT} est la segmentation vérité terrain. Plus la valeur de ce paramètre est proche de 1, meilleure est la performance.

$$F - score = 2 \cdot \frac{S_A \cap S_{VT}}{S_A + S_{VT}} \quad (5.2)$$

• **Sensibilité:** La sensibilité est la capacité d'identifier correctement les cas pathologiques, et est mesurée comme le montre l'équation 5.3, où Se est la sensibilité, TP et FN représentent les vrais positifs, et les faux négatifs, respectivement. Dans notre cas, pour la segmentation, TP représentent les pixels correctement segmentés, et FN les pixels appartenant à l'objet à segmenter, et que l'algorithme développé n'a pas segmenté. Tandis que pour la classification, TP représente l'ensemble de cas de glaucome correctement identifiés, et FN l'ensemble des cas sains identifiés comme cas glaucomateux. Dans les deux cas, plus la valeur de Se est proche de 1, meilleure est la performance.

$$Se = \frac{TP}{TP + FN} \quad (5.3)$$

• **Spécificité:** Contrairement à la sensibilité, la spécificité est la capacité d'identifier correctement les cas sains, et est mesurée comme le montre l'équation 5.4, où Sp est la Spécificité, TN et FP représentent les vrais négatifs, et les faux positifs, respectivement. Dans notre cas, pour la segmentation, TN représentent les pixels correctement segmentés comme n'appartenant pas à la région pathologique, et FP les pixels affectés à tort à l'objet à segmenter. Tandis que pour la classification, TN représentent l'ensemble de cas sains correctement identifiés, et FP l'ensemble des cas glaucomateux identifiés comme cas sains. Comme la sensibilité, plus la valeur de la spécificité est élevée, meilleure est la performance.

$$Sp = \frac{TN}{TN + FP} \quad (5.4)$$

• **Précision:** Ce paramètre représente le degré avec lequel le résultat calculé correspond à la vérité terrain, et est calculé comme le montre l'équation 5.5, où P est la précision.

$$P = \frac{TN + TP}{TN + FN + TP + FP} \quad (5.5)$$

5.1 Evaluation de l'analyse proposée des images fond d'œil

Afin d'évaluer la performance de la segmentation proposée du disque et du cup optiques, dans les images fond d'œil, les algorithmes proposés ont été testés sur différentes bases de données contenant des images fond d'œil de qualités variables. La figure 5.1 montre des exemples d'images segmentées de sujets sains, et pathologiques par l'algorithme proposé, de chaque base de données.

D'après la figure 5.1, on constate que le disque et le cup optiques ont été bien identifiés, et leurs segmentations sont considérablement proches de la vérité terrain. Dans le cas où les disques optiques apparaissent avec un faible contraste, dû au flou de l'ombre qui l'entoure (Figure 5.2), il est à remarquer que la correction (contour blanc obtenu par l'algorithme des contours actifs géodésiques) de la segmentation primaire (contour noir obtenu par l'algorithme de Chan-Vese) peut éliminer les sur-segmentations (Figure 5.2 (A) et 5.2 (B)) et les sous-segmentations (Figure 5.2 (C) et 5.2 (D)) sans la biaiser dans le cas où le disque est bien contrasté. Malgré que la segmentation du cup optique soit considérée comme la tâche la plus délicate dans l'analyse des images fond d'œil, notre algorithme peut extraire les vraies frontières du cup avec exactitude, ceci, dans le cas des petites et grandes excavations. Néanmoins, dans quelques cas, l'arbre vasculaire cachant le cup n'est pas entièrement éliminé dans la phase de prétraitement. Parfois des petits segments des vaisseaux sont segmentés comme région du cup. Cette mauvaise élimination des vaisseaux est due au mauvais contraste entre les vaisseaux sanguins et le cup optiques, à cause d'une mauvaise acquisition. Un exemple de ce cas est montré dans la

figure 5.3.

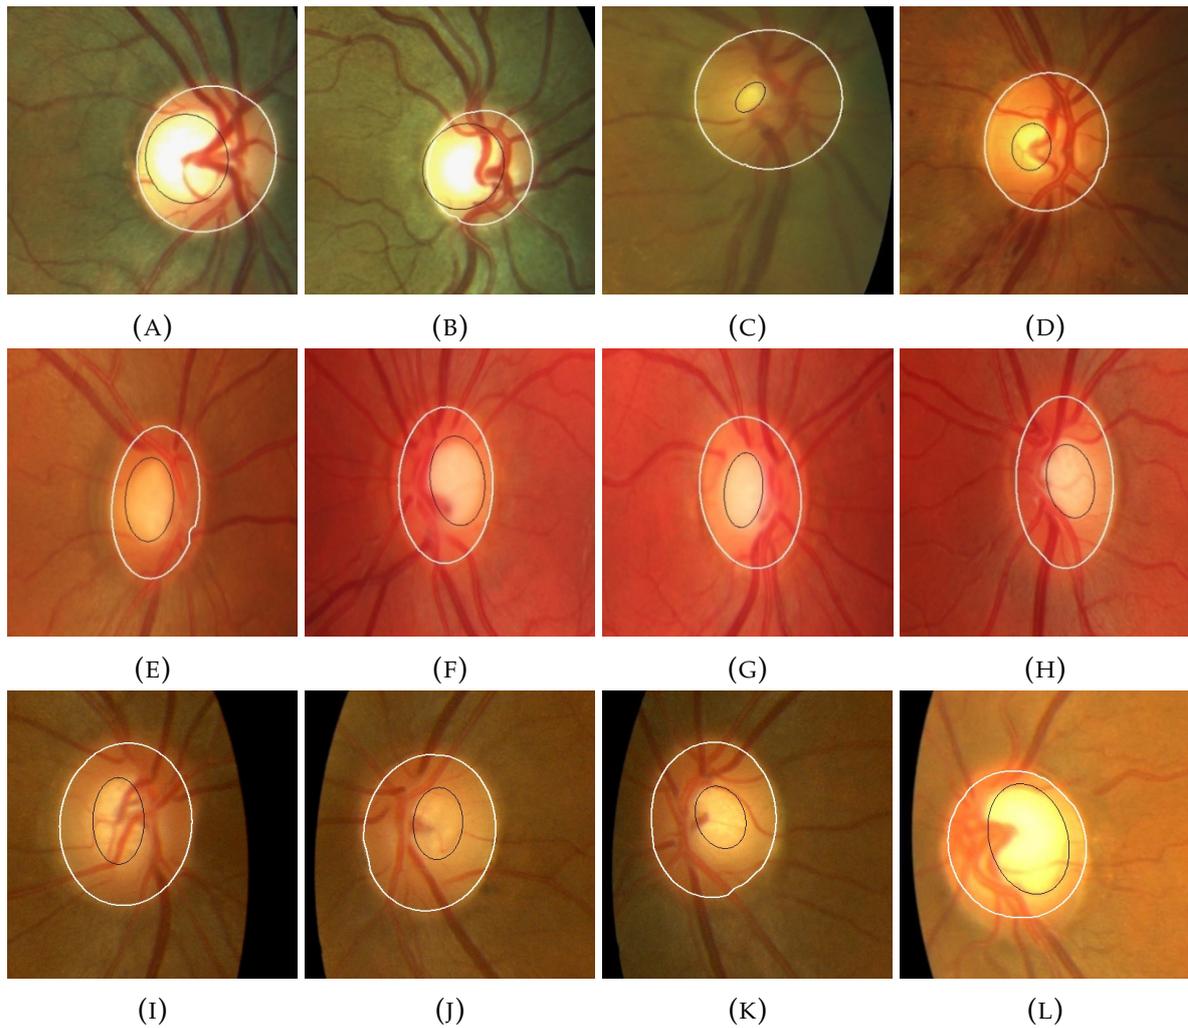


FIGURE 5.1: Exemples de segmentation finale réalisée par le système proposé. Première ligne: exemples de la base de données locale, deuxième ligne: exemples de la base de données HRF, troisième ligne: exemples de la base de données de Mahmudi et al. Contour blanc: segmentation du disque, contour noir : segmentation du cup.

Le système proposé a atteint des valeurs de F-score de 0.9537, et 0.9658 pour la segmentation du disque et du cup optiques, respectivement. Une comparaison des résultats obtenus par rapport aux autres approches étudiées dans le chapitre 2 est montrée dans la table 5.1.

Comme il a été mentionné précédemment, le rapport CDR est le paramètre le plus utilisé pour le diagnostic de la maladie du glaucome. Afin d'évaluer l'exactitude de la mesure de ce paramètre, nous calculons l'erreur moyenne, entre les observations de l'algorithme

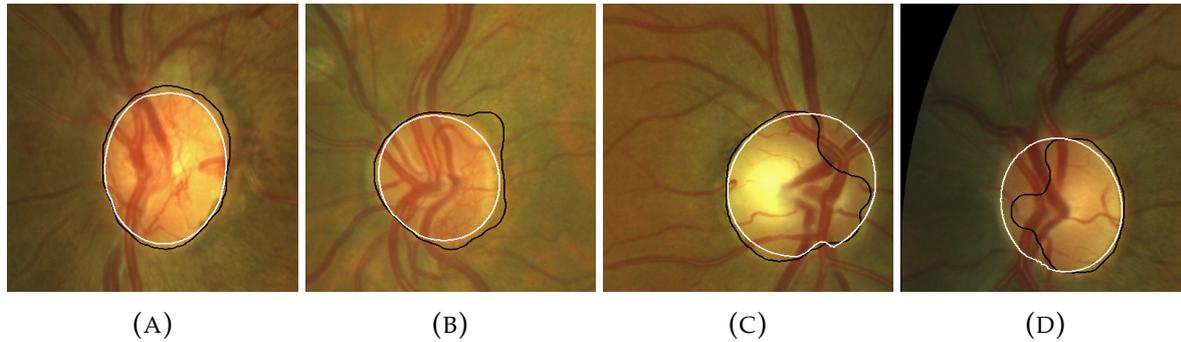


FIGURE 5.2: Exemples des segmentations du disque optique. Contour noir: segmentation primaire du disque optique, contour blanc: segmentation finale du disque optique.

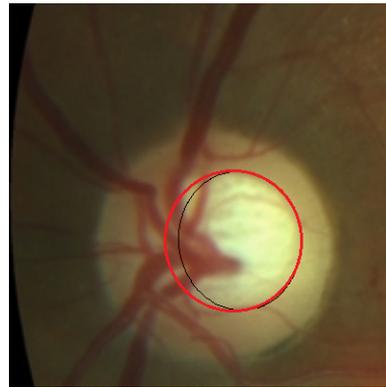


FIGURE 5.3: Mauvaise segmentation du cup à cause des vascularisations dans le disque optique, contour noir est obtenu par l'algorithme, contour rouge est la vérité terrain.

proposé, et la vérité terrain (Equation 5.1). Notre système a permis d'obtenir une erreur moyenne satisfaisante de 0.018, nous pouvons donc dire que les approches utilisées pour la segmentation du disque, et du cup optiques ont prouvé leurs efficacités dans l'aide au diagnostic du glaucome. La table 5.2 donne le résultat de la comparaison de la performance de la mesure du rapport CDR, entre la méthode proposée et les travaux antérieurs.

La combinaison proposée des indicateurs de glaucome, extraits des images fond d'œil, s'est avérée très efficace dans le processus de la détection de la maladie du glaucome. Pour évaluer la performance de la classification effectuée présentée dans la section 3.4, nous avons mesuré trois paramètres : la précision, la sensibilité et la spécificité, qui sont largement utilisés pour quantifier la qualité, et la fiabilité d'un classificateur. La table 5.3 montre une comparaison de performances entre le classificateur proposé, et ceux présentés dans chapitre 2. Il est clair que la combinaison de tous les indicateurs de glaucome

TABLE 5.1: Comparaison des performances de la segmentation entre la méthode proposée et les travaux antérieurs.

Méthode	F-score		Sensibilité		Spécificité		Précision	
	Disque	Cup	Disque	Cup	Disque	Cup	Disque	Cup
Méthode Proposée	0,9537	0,9359	0,8919	0,8733	0,9929	0,9904	0,9771	0,9877
J. Cheng et al.	0.89	0.74	-	-	-	-	-	-
P. S. Mittapali et al.	0,945	0,916	-	-	-	-	-	-
M. S. Haleem et al.	-	-	-	-	-	-	0.91	0.89
G. D. Joshi et al.	0.97	0.84	-	-	-	-	-	-
N. M. Nour et al.	0.59	0.51	0.40	0.30	1.0	0.90	0.70	0.60
Biswal et al.	-	-	-	-	-	-	0.78	-

TABLE 5.2: Comparaison de performance de la mesure du rapport CDR entre la méthode proposée et les travaux antérieurs.

Méthode	Erreur moyenne
Méthode proposée	0.018
G. D. Joshi et al.	0.090
F. Yin et al.	0.106
Tan et al.	0.248
A. M. Jose et al.	0.021

(CDR, Règle ISNT et DDLS), offre une précision de classification élevée de 0.97, et par conséquent, l’algorithme proposé a surpassé les travaux antérieurs de détection du glaucome à partir des images fond d’œil.

TABLE 5.3: Comparaison des mesures de performances du classificateur proposé avec ceux rapportés dans la littérature.

Méthode	Caractéristiques	Classificateurs	Précision	Sensibilité	Spécificité
Méthode Prposée	CDR, ISNT DDLS	Random Forest	0.97	1.00	0.93
I. Qurrshi et al.	CDR	-	0.96	0.90	0.97
D. Agrawal et al.	QB-VMD	LS-SVM	0.86	-	-
J. Nayak et al.	CDR et ISNT	ANN	0.90	1.00	0.80
P. E. Adjei et al.	CDR et ISNT	-	0.90	0.88	0.91
Maheshwari et al.	EWT	LS-SVM	0.96	-	-

De plus, l’importance de chaque paramètre est mesurée au cours de l’apprentissage, en utilisant la méthode de la diminution de précision moyenne. Cette technique est utilisée pour estimer l’erreur de prédiction d’un classificateur, et pour évaluer l’importance

de chaque caractéristique. Pour chaque arbre de décision, l'erreur de prédiction I_P est mesurée avant, et après la permutation des caractéristiques, et les différences entre eux sont moyennées sur tous les arbres du classificateur (Equation 5.6) [169].

$$I_P = \frac{1}{nb_{trees}} \sum_{j=1}^{nb_{trees}} (EP_{tj} - EP_j) \quad (5.6)$$

Où nb_{trees} est le nombre d'arbres dans la forêt aléatoire, EP_{tj} et EP_j représentent l'erreur de prédiction de l'arbre j avant, et après la permutation des caractéristiques, respectivement. La figure 5.4 montre l'importance de chaque indicateur. On peut observer que même si le CDR est cliniquement l'indicateur de glaucome le plus utilisé, le DDLS a été sélectionné comme la caractéristique la plus importante du classificateur, alors que la vérification de la règle ISNT était la caractéristique la moins importante.

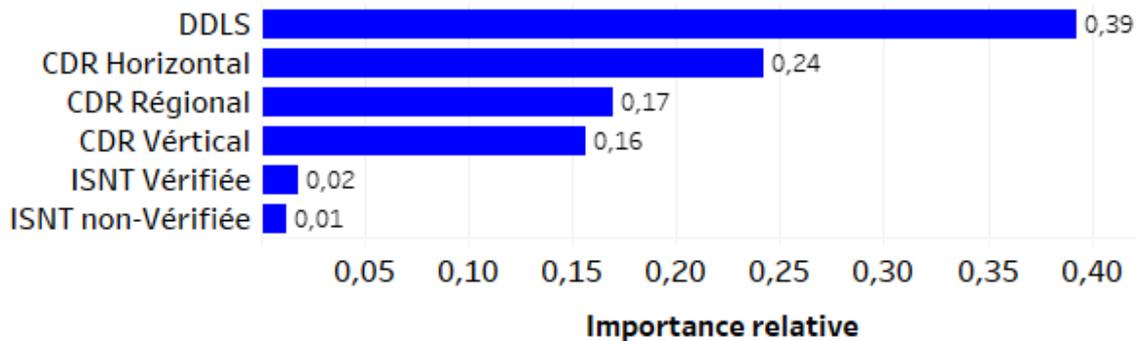


FIGURE 5.4: Importance des indicateurs de glaucome dans le modèle RF proposé.

La table 5.4 montre une comparaison de la capacité de détecter le glaucome en se basant uniquement sur le rapport CDR vertical (l'indicateur le plus utilisé cliniquement pour le diagnostic du glaucome), et sur la combinaison des caractéristiques proposée. Il est à remarquer qu'en se basant seulement sur le CDR vertical, le diagnostic n'était pas adéquat, surtout dans le cas d'un glaucome précoce. La précision du diagnostic de cette caractéristique était de 0.875. L'ajout du CDR horizontal et régional a augmenté le taux de précision jusqu'à 0.938. Cette amélioration considérable est obtenue grâce au fait que la combinaison des trois rapports CDR, permet une analyse plus approfondie de la tête du nerf optique, en détectant les déformations horizontales et verticales du cup optique, ainsi que son élargissement pathologique, ce qui a amélioré la prise de décision du classificateur pour les cas de glaucome précoce et modéré.

TABLE 5.4: Comparaison des capacités de diagnostic du glaucome.

Caractéristiques sélectionnées	Précision
CDR vertical	0.875
CDR vertical, horizontal et régional	0.938
Combinaison proposée des indicateurs de glaucome	0.970

5.2 Evaluation de la combinaison OCT/fond d'œil proposée

Afin d'évaluer la segmentation proposée de la membrane limitante interne (ILM) dans les images OCT maculaires, notre algorithme a été testé sur trois bases de données contenant des images OCT : une base locale de l'hôpital Frantz Fanon de Blida, et celles proposées par **T. Mahmudi et al.**, et **G. Golabbakhsh et al.** La figure 5.6 montre de exemples des résultats obtenus pour la détection de la membrane ILM.

D'après la figure 5.6, il est à noter que même les cas où le contraste est relativement faible, résultant généralement d'une mauvaise acquisition, ou d'une superposition des couches due à la déformation de la rétine, notre algorithme est capable de détecter le contour exact de la membrane ILM. la figure 5.5 montre une comparaison entre le résultat obtenu (contour bleu), et la vérité terrain (contour jaune). Il est clair que les résultats obtenus n'étaient pas influencés par le bruit présent dans les images OCT, mais dans certains cas, des erreurs de quelques micromètres (généralement dans les bords de l'image) sont détectées. Un exemple de ce cas est montré dans la figure 5.5 (coté gauche de l'image).

La performance de la segmentation de l'ILM est évaluée en termes d'erreur moyenne (en micro-mètre), entre la vérité terrain, et les résultats obtenus par l'algorithme proposé. Ce dernier a atteint une erreur moyenne de 1.77 avec un écart type de 0.27. La table 5.5 montre une comparaison de performance avec les travaux étudiés dans le chapitre 2. Notre algorithme a détecté la membrane ILM avec une erreur plus faible que les travaux antérieurs, ce qui permet non seulement d'obtenir une segmentation précise, mais aussi une bonne initialisation pour la segmentation du complexe GCC, et finalement une mesure précise de l'épaisseur de ce dernier.

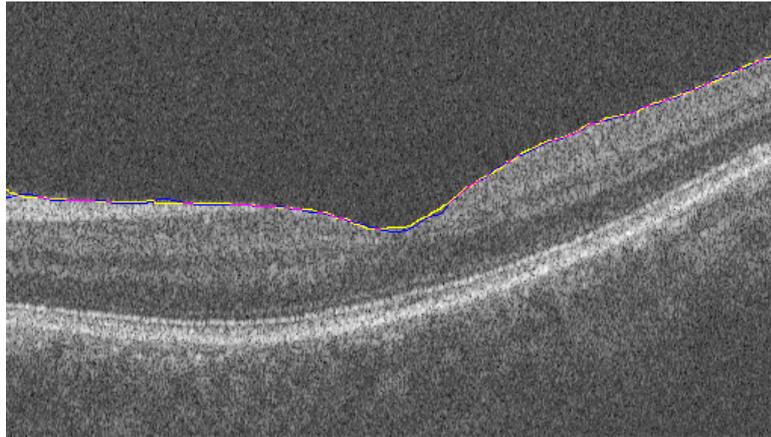


FIGURE 5.5: Comparaison entre la vérité terrain et les résultats obtenus pour la segmentation de l'ILM. Contour bleu: segmentation obtenue, contour jaune: vérité terrain, contour violet: les pixels où la segmentation est superposée sur la vérité terrain.

TABLE 5.5: Comparaison des mesures de performances de la segmentation de l'ILM proposé avec celles reportées dans la littérature.

Méthode	Erreur moyenne (μm)
Méthode proposée	1.77 ± 0.27
M. mayer et al.	2.90 ± 3.80
Q. Yang et al.	3.39 ± 0.96
K. Vermeer et al.	3.90 ± 2.70
J. Duan et al.	0.92 ± 0.26

La segmentation de la frontière du complexe GCC a été évaluée, sur les mêmes bases de données utilisées pour l'évaluation de la segmentation de la membrane ILM. La figure 5.7 montre des exemples de la segmentation finale du complexe GCC, où le contour bleu et le contour rouge représentent la segmentation de l'ILM et la frontière inférieure du GCC, respectivement.

D'après la figure 5.7, il est clair que la technique proposée peut détecter avec exactitude la frontière du complexe GCC, sans aucune influence du bruit présent dans l'image OCT. Mais, il est à noter que la segmentation proposée peut dépendre de la qualité du contraste entre les différentes couches rétinienne. Ceci peut être illustré sur la figure 5.8, où certaines parties du contour ne sont pas correctement identifiées. Une correction manuelle est développée, afin de remédier aux mauvaises segmentations (Figure 5.8 (B)).

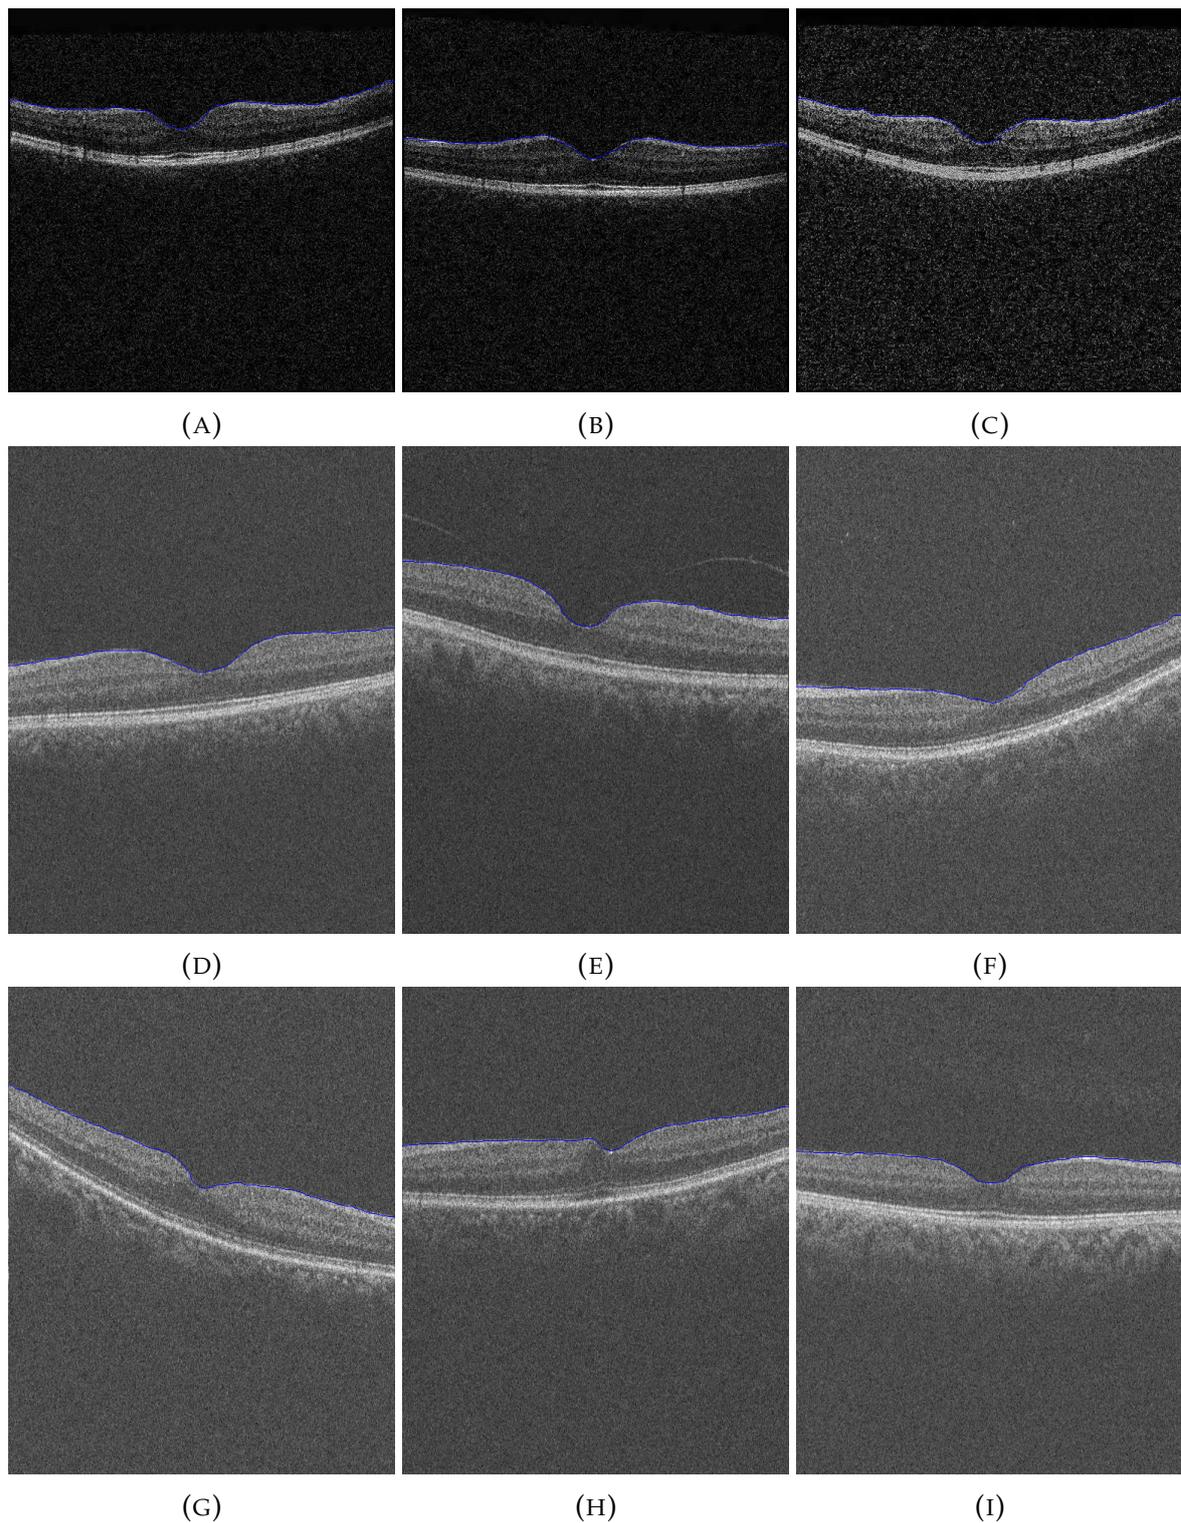


FIGURE 5.6: Exemples de segmentation finale de la membrane ILM. Première ligne: exemples de la base de données locale, deuxième ligne: exemples de la base de données de T. Mahmudi et al., troisième ligne: exemples de la base de données de M. Golabbakhsh et al.

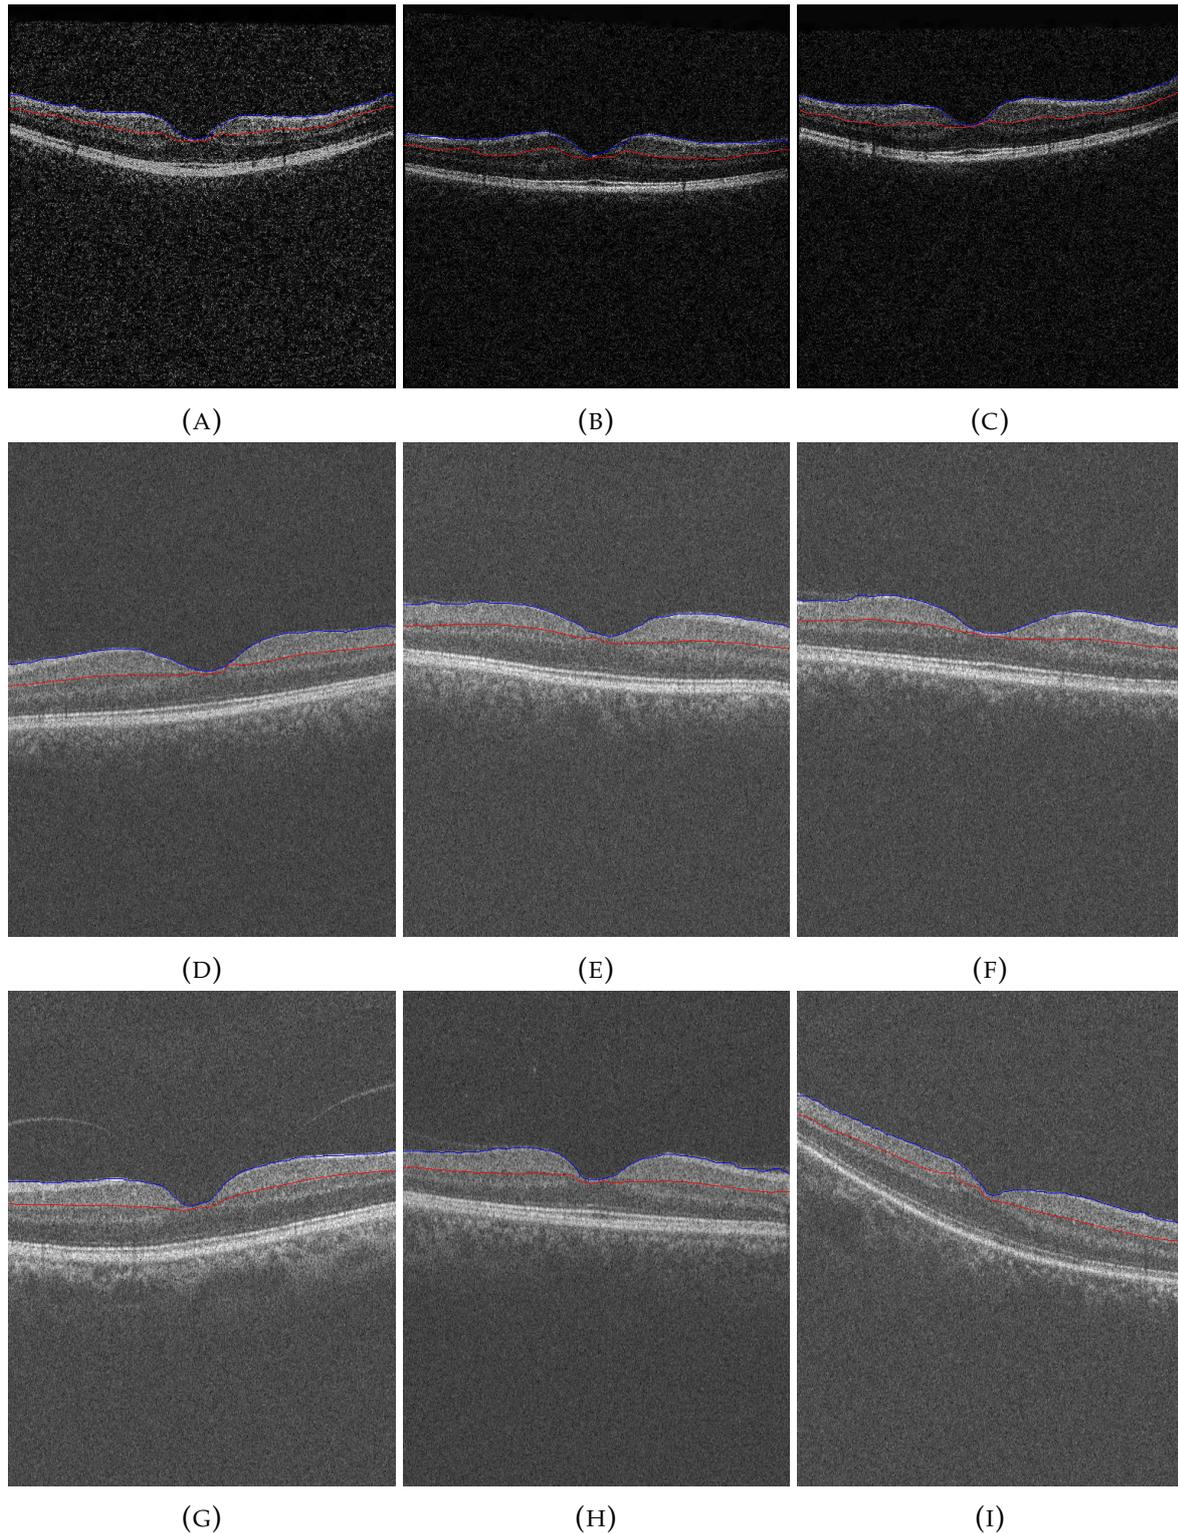


FIGURE 5.7: Exemples de segmentation finale du complexe GCC. Première ligne: exemples de la base de données locale, deuxième ligne: exemples de la base de données de T. Mahmudi et al., troisième ligne: exemples de la base de données de M. Golabbakhsh et al. Contour bleu : segmentation de l'ILM, contour rouge: segmentation du GCC.

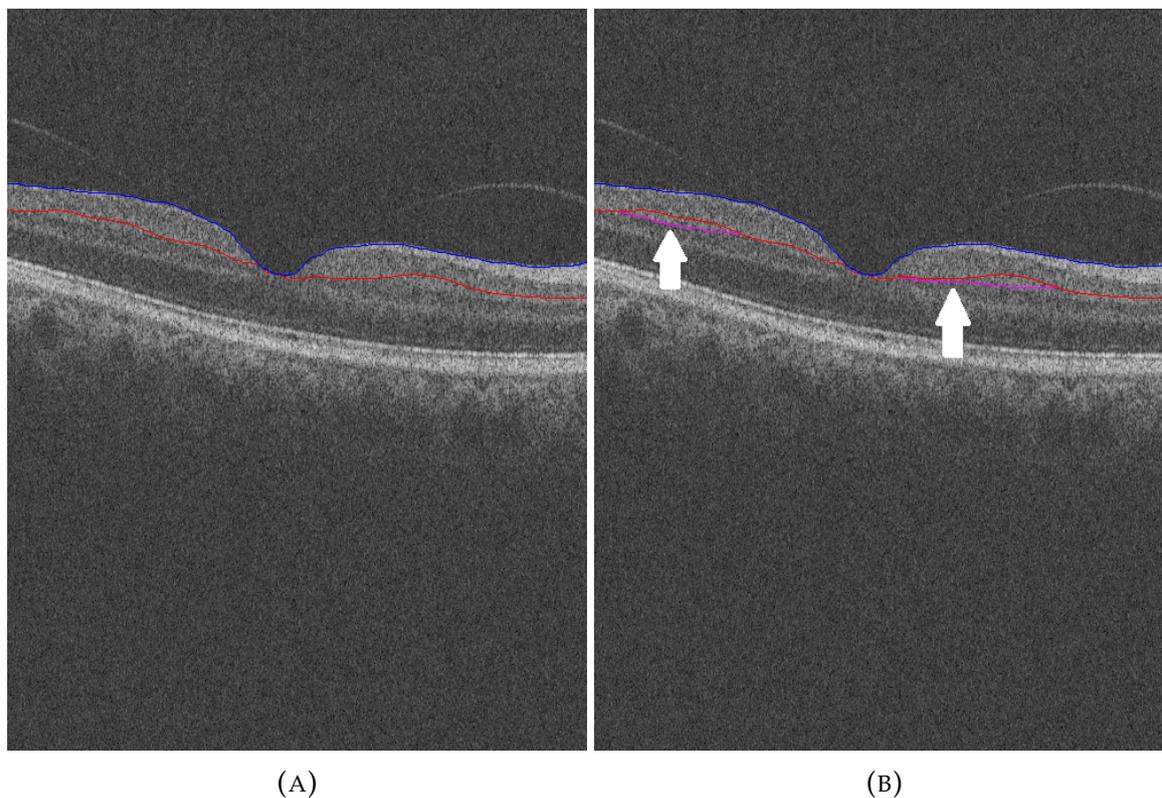


FIGURE 5.8: Exemples de la correction manuelle de la segmentation du complexe GCC. Contour bleu: Segmentation de l'ILM, contour rouge: segmentation du GCC, contour violet: correction des parties mal segmentées du complexe GCC.

Comme pour la segmentation de l'ILM, la segmentation de la frontière inférieure du GCC a été évaluée en termes d'erreur moyenne (en μm), entre la vérité terrain et les résultats obtenus par la technique proposée (sans correction manuelle). Notre technique a atteint une erreur moyenne de 1.25, avec un écart type de 0.47. La table 5.6 montre une comparaison de performances avec les approches étudiées dans le chapitre 2.

D'après la table 5.6, la technique proposée pouvait identifier la limite du complexe des cellules ganglionnaires, avec une erreur inférieure à celles obtenues dans la littérature, ce qui assure une meilleure précision dans la mesure de l'épaisseur du GCC.

TABLE 5.6: Comparaison des mesures de performances de la segmentation de l'ILM proposé avec celles reportées dans la littérature.

Méthode	Erreur moyenne (μm)
Méthode proposée	1.25 ± 0.47
Q. Yang et al	3.78 ± 1.32
J. Duan et al.	1.31 ± 0.32

Au meilleur de nos connaissances, nous avons été les premiers à combiner les caractéristiques structurelles du complexe GCC, extraites des images OCT maculaires, avec les indicateurs du glaucome extraits, des images fond d'œil. Cette fusion multi-modalités s'est avérée plus efficace dans la détection du glaucome précoce, par rapport à sa détection en se basant seulement sur une modalité. La comparaison entre le classificateur multi-modalités et le classificateur fond d'œil est présentée dans table 5.7.

TABLE 5.7: Comapraison de performance des deux classificateurs.

Caractéristiques utilisées	TP	TN	FP	FN	Précision	Sensibilité	Spécificité
Indicateurs de glaucome	43	54	3	2	0.97	1.0	0.93
Indicateur de glaucome + caractéristiques du GCC	44	56	0	2	0.9803	0.9565	1.0

Le classificateur hybride a atteint une précision, une sensibilité, et une spécificité, de 0.98, 0.95 et 1.0, respectivement. Une comparaison des résultats obtenus par rapport aux autres algorithmes de l'état de l'art est effectuée, pour tester les performances de notre système (Table 5.8).

La table 5.8 montre que les résultats obtenus par notre système d'aide au diagnostic hybride, sont plus que satisfaisants. On peut donc noter que la fusion des caractéristiques de la tête du nerf optique (extraites à partir des images fond d'œil), avec les caractéristiques structurelles du complexe des cellules ganglionnaires maculaires (extraites à partir des images OCT maculaires), a prouvé son efficacité dans la détection du glaucome, surtout dans son état précoce.

TABLE 5.8: Performance de la technique proposée pour la détection du glaucome par rapport à la littérature.

Méthode	Caractéristiques	Précision	Sensibilité	Spécificité
Méthode Proposée	Fond d'œil: CDR, ISNT et DDLS OCT: Caractéristiques du GCC	0.98	0.95	1.0
C.Fatima et al.	Fond d'œil: CDR, RDR et ISNT OCT: Epaisseur de RNFL	0.92	-	-
Z. Chang et al.	Fond d'œil: CDR et caractéristiques structurelle OCT: Caractéristiques de la Lamina Cribrosa	0.96	0.95	1.0
T. Shehryar et al.	Fond d'œil: Caractéristiques structurelles et texturales OCT: CDR	0.96	1.0	0.91
I. Qurshi et al.	Fond d'œil: CDR	0.96	0.90	0.97
T. Kausu et al.	Fond d'œil: CDR + EWT	0.97	0.98	-
P. Das et al.	Fond d'œil: CDR et NRR	0.94	0.91	0.95
K. Nirmala et al.	Fond d'œil: WBCT	0.89	-	-
M. Rama et al.	Fond d'œil : HOS et TT	0.91	0.90	0.93
J. Arriga et al.	Fond d'œil: CDR, ISNT et DDLS déplacement des vaisseaux	0.91	0.93	0.91
N. Anantrasirichai et al.	OCT: Caractéristiques de RNFL	0.85	-	-
A. Ramzan et al.	OCT: rapport CDR	0.79	-	-
A. Thompson et al.	OCT: Caractéristiques CNN	0.96	-	-

La figure 5.9 montre L'importance relative de chaque caractéristique incluse dans le classificateur hybride, proposé pour l'indentification des cas de glaucome. Il est à noter que les trois rapports CDR (Régional, Vertical et Horizontal) ont été considérés comme les caractéristiques les plus importantes, pour détecter le glaucome, avec des importances relatives de 0.16, 0.15 et 0.12, respectivement. Ces caractéristiques sont suivies par les caractéristiques structurelles du complexe GCC. Finalement, comme pour le classificateur précédent, la vérification de la loi ISNT est la caractéristique la moins importante.

5.3 Evaluation de la classification des images AS-OCT

La classification des images de la chambre antérieure ont permis à notre système d'identifier la forme du glaucome pour compléter son diagnostic. Plusieurs classificateurs d'apprentissage profond ont été implémentés dans le chapitre 4. La table 5.9 montre une

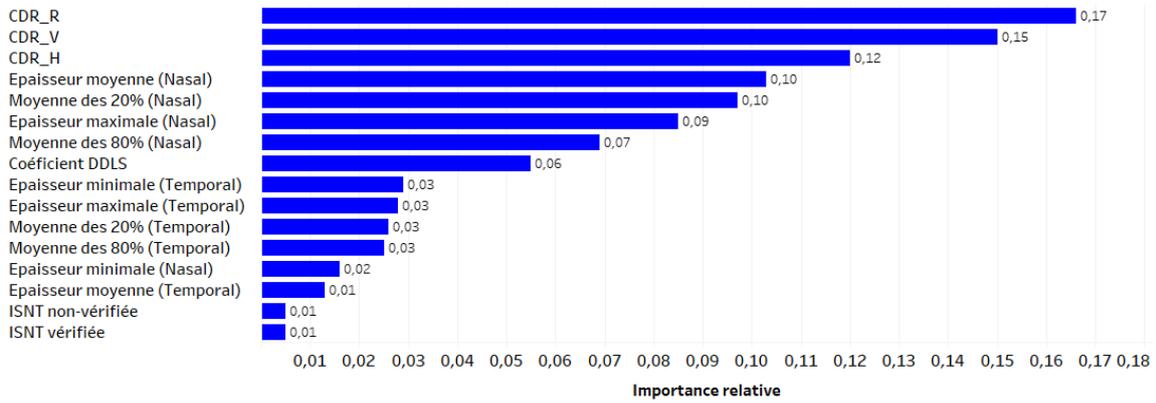


FIGURE 5.9: Importance des indicateurs de glaucome dans le modèle RF hybride proposé.

comparaison entre les modèles implémentés. Il est à noter qu’en termes de précision, et de sensibilité, la meilleure performance a été atteinte par le modèle séquentiel à 8 couches convolutionnelles. Ce modèle, présente donc la meilleure capacité à identifier la fermeture de l’angle irido-cornéen, ce qui est important dans le diagnostic, puisqu’il s’agit de la forme qui nécessite une intervention urgente. D’autre part, le modèle AlexNet présente la meilleure spécificité, donc la meilleure capacité à identifier le glaucome à angle ouvert à partir des images AS-OCT.

TABLE 5.9: Performances des différents modèles implémentés pour la classification des images AS-OCT.

Modèle	Précision	Sensibilité	Spécificité
CNN à 8 couches	0.9756	0.9912	0.96
AlexNet	0.9425	0.9031	0.982
VGGNet	0.9484	0.8218	0.9871

D’après le tableau 5.10, montrant une comparaison de performances entre le modèle implémenté, et les techniques de classification de la chambre antérieure étudiées dans la littérature, nous remarquons que malgré le fait qu’une bonne précision a été atteinte par le modèle séquentiel à 8 couches, et le modèle AlexNet, la performance de ces deux derniers n’était pas suffisante pour surpasser les approches proposées par **H. Hao et al.** et **P. Li et al.** Donc, la classification des images de la chambre antérieure, en une image présentant un angle ouvert, ou fermé doit être améliorée, en implémentant d’autres modèles CNN plus profonds.

TABLE 5.10: Performance de la technique proposée pour la la classification de la chambre antérieure de l'œil par rapport à la littérature.

Méthode	Précision	Sensibilité	Spécificité
Méthode Proposée	0.9756	0.9912	0.96
H. Fu et al. (2017)	0.51	0.75	0.85
H. Fu et al. (2018)	0.89	0.88	0.89
H. Hao et al.	1.0	1.0	1.0
P. Li et al.	1.0	1.0	1.0

Discussion

Dans ce chapitre, nous avons présenté les résultats de la segmentation, et de la classification obtenus dans les différentes étapes du système d'aide au diagnostic du glaucome proposé. Bien que le rapport CDR soit considéré comme l'indicateur le plus utilisé cliniquement pour détecter le glaucome, il est à noter que la classification basée uniquement sur ce rapport, n'était pas adéquate pour l'identification des cas précoces du glaucome (Table 5.4). La même limitation du CDR a été observée par **A. O. Jashua et al. (2020)** [80], où le diagnostic était basé sur le seuillage du CDR vertical.

Cette limitation est illustrée dans la figure 3.25, où un chevauchement entre les deux classes (sain et glaucomateux), lorsque la valeur du CDR vertical est comprise entre 0.3 et 0.5, ce qui montre que la tête du nerf optique n'est pas la seule structure rétinienne touchée par le glaucome.

La technique proposée pour améliorer le diagnostic consiste à introduire les informations de l'épaisseur du complexe des cellules ganglionnaires (GCC). Plusieurs études ont confirmé la relation entre la présence, et la progression du glaucome, avec les amincissements pathologiques au niveau de cette couche au niveau de la macula [19][156][144][19]. Pour cela, des caractéristiques structurelles du GCC ont été extraites à partir des images OCT maculaires, et combinées avec les caractéristiques de la tête du nerf optique, mesurées à partir des images fond d'œil. A notre connaissance, cette fusion de caractéristiques n'a jamais été tentée auparavant, et s'est avérée très efficace. Aussi, nous sommes

convaincus que ce type d'approches peut être appliqué, lorsqu'il y a une confusion entre un glaucome précoce et un cas sain. Nous avons testé notre algorithme sur plusieurs bases de données, où nous avons obtenus une précision de 98.03%, surpassant les approches de détection du glaucome présentées dans l'état de l'art.

Le temps de calcul total pour générer un diagnostic complet, où la tête du nerf optique, le complexe GCC et la chambre antérieure sont analysés, est d'environ 1 minute 50 secondes, avec une implémentation Python dans Visual Studio 2019 (les composants du système sont exécutés de manière séquentielle), avec une machine de 2.2 GHz et 4 GB de RAM.

Afin de tester efficacement la fiabilité de la technique proposée, dans un domaine aussi sensible que le domaine de la santé, une base de données locale fournie par le service d'ophtalmologie de l'hôpital Frantz Fanon de Blida, a été utilisée avec d'autres bases de données publiques, pour l'évaluation des différents résultats obtenus, ce qui représente un point fort, pour l'efficacité de notre système.

La limitation principale du système proposé, est observée dans la classification de la chambre antérieure. Cette classification est très importante pour identifier la forme exacte du glaucome (si présent), en se basant sur l'angle irido-cornéen, puisque le protocole d'intervention se base sur cette classification. L'algorithme proposé a été testé sur la base de données publique associée à la compétition AGE (Angle closure Glaucoma Evaluation challenge), et a atteint une précision de 97.56% (classé parmi les top 50), mais n'a pas surpassé d'autres approches comme **H. Hao et al.** et **P. Li et al.** Comme futur travail, nous proposons d'implémenter des architectures CNN plus profondes, afin d'améliorer la classification de la chambre antérieure.

CONCLUSION

Conclusion

Le glaucome est une maladie neuro-dégénérative oculaire, considérée comme l'une des principales causes de déficience visuelle dans le monde. Puisqu'il peut être asymptomatique, un diagnostic et un traitement précoces sont cruciaux pour prévenir la perte de vision. Cette pathologie oculaire silencieuse est principalement caractérisée par une perte des fibres du nerf optique causée par une augmentation soudaine, et anormale de la pression interne de l'œil (PIO). Cependant, la mesure de la PIO n'est ni suffisamment spécifique, ni suffisamment sensible pour être considérée comme un indicateur efficace du glaucome, car les dommages visuels liés à ce dernier peuvent être présents sans augmentation de la PIO. Pour cela, une examination complète des différentes images rétinienne doit être inclus dans le processus de dépistage du glaucome.

Notre travail de thèse entre dans le cadre du développement d'un système d'aide au diagnostic du glaucome, basé sur l'analyse simultanée des images fond d'œil et des images OCT maculaires, et de la chambre antérieure. Afin de construire un tel système, notre étude s'est articulée autour de trois axes principaux. Le premier consistait à détecter la présence des anomalies glaucomateuse en se basant uniquement sur les caractéristiques suivantes : les rapports CDR, la vérification de la loi ISNT et l'échelle DDLS. Le deuxième consistait à améliorer le premier diagnostic en ajoutant des caractéristiques structurelles de la couche du complexe des cellules ganglionnaires maculaires. Finalement, le dernier axe consistait à compléter le diagnostic du glaucome, en classifiant les images AS-OCT, des patients jugés glaucomateux, pour identifier la forme du glaucome détecté : glaucome à angle ouvert, ou glaucome à angle fermé.

La mesure des indicateurs du glaucome, et l'extraction des caractéristiques structurales du complexe GCC, se basent essentiellement sur la segmentation du disque et du cup optiques, et les deux frontières du complexe GCC maculaire. Ce point nous a amené dans un premier temps, à développer des algorithmes de segmentation efficaces pour ces éléments anatomiques.

Au meilleur de nos connaissances, nous avons été les premiers à combiner les caractéristiques des images fond d'œil avec celles des images OCT maculaires. Cette méthode s'est avérée plus précise (98.03 %) dans la détection du glaucome, que de se fier uniquement aux caractéristiques du fond d'œil (97 %). Cependant, et bien que l'algorithme proposée soit efficace, il est à noter que la présence des pathologies oculaires, résultants de la déformation de la rétine, peut biaiser la mesure de l'épaisseur du GCC. Dans ce cas, nous suggérons de se baser uniquement sur l'analyse des images fond d'œil.

Le travail de notre thèse a montré des résultats encourageants, où le CDR a été mesuré avec une erreur de 0.018, tandis que l'ILM, et la frontière inférieure du GCC ont été segmentées avec une erreur de 1.77 ± 0.27 et $1.25 \pm 0.47 \mu m$, respectivement. En ce qui concerne la segmentation du disque et du cup optiques, des coefficients F-score de 0.95 et 0.93 ont été obtenus pour la segmentation du disque, et du cup respectivement. D'après cette performance, notre système d'aide au diagnostic peut être utilisé pour aider les ophtalmologues dans leurs routines de dépistage du glaucome, afin de leurs fournir une deuxième opinion, et ainsi à les aider dans le dépistage de masse.

Perspectives

Plusieurs perspectives peuvent être envisagées dans le prolongement de ce travail :

1. Notre algorithme peut être amélioré en prenant en considération d'autres caractéristiques, comme la déformation de la Lamina Cribrosa, introduite par Cheng et al. (2020), qui s'est avérée efficace, lorsqu'elle est combinée avec les informations

extraites du fond d'œil. Il est à noter aussi que l'information de l'âge du patient est très importante pour identifier le glaucome précoce et l'absence de la maladie. Il nous semble intéressant de considérer l'introduction de ces caractéristiques, avec celles étudiées dans notre travail.

2. Le second point qui nous semble important, est l'introduction de la classification multi-classes entre le cas sain, et les différents stades de glaucome. Cela peut être réalisée à l'aide d'une grande base de données d'apprentissage, présentant les différents stades de glaucome.
3. La dernière perspective que nous proposons est l'amélioration de la vérification de la loi ISNT, en se basant sur l'épaisseur de la couche RNFL autour de la tête du nerf optique, au lieu de se baser sur l'épaisseur du bord neuro-rétinien dans les images fond d'œil.

Références

- [1] Caroline Crotti. “Chirurgie du segment antérieur de l’oeil et traitement du glaucome par laser femtoseconde et imagerie de tomographie par cohérence optique”. PhD thesis. 2011.
- [2] Naïma Chalour. “La réponse des cellules gliales de Müller à l’amyloïde- β et au stress oxydant dans la dégénérescence rétinienne”. PhD thesis. Paris 5, 2012.
- [3] Raul Martin Herranz and Rosa M Corrales Herran. *Ocular surface: anatomy and physiology, disorders and therapeutic care*. CRC Press, 2012.
- [4] Josef Flammer and Katarzyna Konieczka. “Le glaucome”. In: *Forum Médical Suisse*. Vol. 17. 05. EMH Media. 2017, pp. 105–112.
- [5] Paul N Schacknow and John R Samples. *The glaucoma book: a practical, evidence-based approach to patient care*. Springer Science & Business Media, 2010.
- [6] Yih-Chung Tham et al. “Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis”. In: *Ophthalmology* 121.11 (2014), pp. 2081–2090.
- [7] MSPRH. *Enquete causes de cecite en Algerie*. Tech. rep. Ministere de la Sante, de la Population et de la Reforme Hospitaliere, 2008.
- [8] Paul J Foster et al. “The definition and classification of glaucoma in prevalence surveys”. In: *British journal of ophthalmology* 86.2 (2002), pp. 238–242.
- [9] Canadian Ophthalmological Society Glaucoma Clinical Practice Guideline Expert Committee et al. “Canadian Ophthalmological Society evidence-based clinical practice guidelines for the management of glaucoma in the adult eye”. In: *Canadian Journal of Ophthalmology* 44 (2009), S7–S54.
- [10] M Detry-Morel. “Le glaucome congénital”. In: *BULLETTIN-SOCIETE BELGE D OPH-TALMOLOGIE* (2001), pp. 49–60.
- [11] Nicholas YQ Tan et al. “Glaucoma screening: where are we and where do we need to go?” In: *Current opinion in ophthalmology* 31.2 (2020), pp. 91–100.
- [12] Christophe Baudouin, Alexandre Denoyer, and William Rostène. “Le glaucome aujourd’hui: dépistage et avancées thérapeutiques”. In: *Biologie Aujourd’hui* 207.2 (2013), pp. 87–95.
- [13] Gianmarco Vizzeri et al. “Role of imaging in glaucoma diagnosis and follow-up”. In: *Indian journal of ophthalmology* 59.Supp1 (2011), S59.
- [14] Harry A Quigley. *Glaucoma: what every patient should know*. CreateSpace, 2011.
- [15] Noga Harizman et al. “The ISNT rule and differentiation of normal from glaucomatous eyes”. In: *Archives of ophthalmology* 124.11 (2006), pp. 1579–1583.
- [16] Jeffrey D Henderer et al. “Reliability of the disk damage likelihood scale”. In: *American journal of ophthalmology* 135.1 (2003), pp. 44–48.

- [17] David Huang et al. "Optical coherence tomography". In: *science* 254.5035 (1991), pp. 1178–1181.
- [18] Felipe A Medeiros et al. "Use of progressive glaucomatous optic disk change as the reference standard for evaluation of diagnostic tests in glaucoma". In: *American journal of ophthalmology* 139.6 (2005), pp. 1010–1018.
- [19] Wei-Wei Wang et al. "Diagnostic ability of ganglion cell complex thickness to detect glaucoma in high myopia eyes by Fourier domain optical coherence tomography". In: *International journal of ophthalmology* 11.5 (2018), p. 791.
- [20] Advanced Glaucoma Intervention Study Investigators et al. "Advanced Glaucoma Intervention Study: 2. Visual field test scoring and reliability". In: *Ophthalmology* 101.8 (1994), pp. 1445–1455.
- [21] Enrique J Carmona et al. "Identification of the optic nerve head with genetic algorithms". In: *Artificial Intelligence in Medicine* 43.3 (2008), pp. 243–259.
- [22] Attila Budai et al. "Robust vessel segmentation in fundus images". In: *International journal of biomedical imaging* 2013 (2013).
- [23] Zhuo Zhang et al. "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*. IEEE. 2010, pp. 3065–3068.
- [24] Joes Staal et al. "Ridge-based vessel segmentation in color images of the retina". In: *IEEE transactions on medical imaging* 23.4 (2004), pp. 501–509.
- [25] Etienne Decencière et al. "Feedback on a publicly distributed image database: the Messidor database". In: *Image Analysis & Stereology* 33.3 (2014), pp. 231–234.
- [26] Francisco Fumero et al. "RIM-ONE: An open retinal image database for optic nerve evaluation". In: *2011 24th international symposium on computer-based medical systems (CBMS)*. IEEE. 2011, pp. 1–6.
- [27] Tomi Kauppi et al. "The diaretdb1 diabetic retinopathy database and evaluation protocol." In: *BMVC*. Vol. 1. 2007, pp. 1–10.
- [28] Jayanthi Sivaswamy et al. "Drishti-gs: Retinal image dataset for optic nerve head (onh) segmentation". In: *2014 IEEE 11th international symposium on biomedical imaging (ISBI)*. IEEE. 2014, pp. 53–56.
- [29] Peyman Gholami et al. "OCTID: Optical coherence tomography image database". In: *Computers & Electrical Engineering* 81 (2020), p. 106532.
- [30] Reza Rasti et al. "Macular OCT classification using a multi-scale convolutional neural network ensemble". In: *IEEE transactions on medical imaging* 37.4 (2017), pp. 1024–1034.
- [31] Tahereh Mahmudi et al. "Comparison of macular OCTs in right and left eyes of normal people". In: *Medical Imaging 2014: Biomedical Applications in Molecular, Structural, and Functional Imaging*. Vol. 9038. International Society for Optics and Photonics. 2014, 90381W.
- [32] Marzieh Golabbakhsh and Hossein Rabbani. "Vessel-based registration of fundus and optical coherence tomography projection images of retina using a quadratic registration model". In: *IET Image Processing* 7.8 (2013), pp. 768–776.
- [33] N. Inoue et al. "Development of a simple diagnostic method for the glaucoma using ocular Fundus pictures." In: *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*. 2005, pp. 3355–3358. DOI: [10.1109/IEMBS.2005.1617196](https://doi.org/10.1109/IEMBS.2005.1617196).

- [34] Juan Xu et al. "Optic disk feature extraction via modified deformable model technique for glaucoma analysis". In: *Pattern recognition* 40.7 (2007), pp. 2063–2076.
- [35] D. W. K. Wong et al. "Level-set based automatic cup-to-disc ratio determination using retinal fundus images in ARGALI". In: *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2008, pp. 2266–2269. DOI: [10.1109/IEMBS.2008.4649648](https://doi.org/10.1109/IEMBS.2008.4649648).
- [36] Jagadish Nayak et al. "Automated Diagnosis of Glaucoma Using Digital Fundus Images". In: *Journal of Medical Systems* 33.5 (2008), p. 337. ISSN: 1573-689X. DOI: [10.1007/s10916-008-9195-z](https://doi.org/10.1007/s10916-008-9195-z). URL: <https://doi.org/10.1007/s10916-008-9195-z>.
- [37] S. Kavitha, S. Karthikeyan, and K. Duraiswamy. "Early detection of glaucoma in retinal images using cup to disc ratio". In: *2010 Second International conference on Computing, Communication and Networking Technologies*. 2010, pp. 1–5. DOI: [10.1109/ICCCNT.2010.5591859](https://doi.org/10.1109/ICCCNT.2010.5591859).
- [38] Y. Hatanaka et al. "Automatic measurement of cup to disc ratio based on line profile analysis in retinal images". In: *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2011, pp. 3387–3390. DOI: [10.1109/IEMBS.2011.6090917](https://doi.org/10.1109/IEMBS.2011.6090917).
- [39] C. Ho et al. "An Automatic Fundus Image Analysis System for Clinical Diagnosis of Glaucoma". In: *2011 International Conference on Complex, Intelligent, and Software Intensive Systems*. 2011, pp. 559–564. DOI: [10.1109/CISIS.2011.92](https://doi.org/10.1109/CISIS.2011.92).
- [40] G. D. Joshi, J. Sivaswamy, and S. R. Krishnadas. "Optic Disk and Cup Segmentation From Monocular Color Retinal Images for Glaucoma Assessment". In: *IEEE Transactions on Medical Imaging* 30.6 (2011), pp. 1192–1205. ISSN: 0278-0062. DOI: [10.1109/TMI.2011.2106509](https://doi.org/10.1109/TMI.2011.2106509).
- [41] F. Yin et al. "Automated segmentation of optic disc and optic cup in fundus images for glaucoma diagnosis". In: *2012 25th IEEE International Symposium on Computer-Based Medical Systems (CBMS)*. 2012, pp. 1–6. DOI: [10.1109/CBMS.2012.6266344](https://doi.org/10.1109/CBMS.2012.6266344).
- [42] D. W. K. Wong et al. "An ensembling approach for optic cup detection based on spatial heuristic analysis in retinal fundus images". In: *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2012, pp. 1426–1429. DOI: [10.1109/EMBC.2012.6346207](https://doi.org/10.1109/EMBC.2012.6346207).
- [43] Y. Xu et al. "Efficient optic cup localization based on superpixel classification for glaucoma diagnosis in digital fundus images". In: *Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012)*. 2012, pp. 49–52.
- [44] J. Cheng et al. "Superpixel Classification Based Optic Disc and Optic Cup Segmentation for Glaucoma Screening". In: *IEEE Transactions on Medical Imaging* 32.6 (2013), pp. 1019–1032. ISSN: 0278-0062. DOI: [10.1109/TMI.2013.2247770](https://doi.org/10.1109/TMI.2013.2247770).
- [45] M Muthu Rama Krishnan and Oliver Faust. "Automated glaucoma detection using hybrid feature extraction in retinal fundus images". In: *Journal of Mechanics in Medicine and Biology* 13.01 (2013), p. 1350011.
- [46] Noorhayati Mohamed Noor, Noor Elaiza Abdul Khalid, and Norharyati Md Ariff. "Optic cup and disc color channel multi-thresholding segmentation". In: *2013 IEEE International Conference on Control System, Computing and Engineering*. IEEE. 2013, pp. 530–534.

- [47] José Abel De La Fuente-Arriaga, Edgardo M Felipe-Riverón, and Eduardo Garduño-Calderón. "Application of vascular bundle displacement in the optic disc for glaucoma detection using fundus images". In: *Computers in biology and medicine* 47 (2014), pp. 27–35.
- [48] Ngan-Meng Tan et al. "Multi-scale superpixel classification for optic cup localization". In: *2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI)*. IEEE. 2014, pp. 137–140.
- [49] D. Yadav, M. P. Sarathi, and M. K. Dutta. "Classification of glaucoma based on texture features using neural networks". In: *2014 Seventh International Conference on Contemporary Computing (IC3)*. 2014, pp. 109–112. DOI: [10.1109/IC3.2014.6897157](https://doi.org/10.1109/IC3.2014.6897157).
- [50] A. A. Salam et al. "Autonomous Glaucoma detection from fundus image using cup to disc ratio and hybrid features". In: *2015 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*. 2015, pp. 370–374. DOI: [10.1109/ISSPIT.2015.7394362](https://doi.org/10.1109/ISSPIT.2015.7394362).
- [51] H. Alghmdid et al. "Measurement of optical cup-to-disc ratio in fundus images for glaucoma screening". In: *2015 International Workshop on Computational Intelligence for Multimedia Understanding (IWCIM)*. 2015, pp. 1–5. DOI: [10.1109/IWCIM.2015.7347097](https://doi.org/10.1109/IWCIM.2015.7347097).
- [52] A. Agarwal et al. "Automatic glaucoma detection using adaptive threshold based technique in fundus image". In: *2015 38th International Conference on Telecommunications and Signal Processing (TSP)*. 2015, pp. 416–420. DOI: [10.1109/TSP.2015.7296295](https://doi.org/10.1109/TSP.2015.7296295).
- [53] A. Agarwal et al. "A novel approach to detect glaucoma in retinal fundus images using cup-disk and rim-disk ratio". In: *2015 4th International Work Conference on Bioinspired Intelligence (IWOBI)*. 2015, pp. 139–144. DOI: [10.1109/IWOBI.2015.7160157](https://doi.org/10.1109/IWOBI.2015.7160157).
- [54] A. M. Jose and A. A. Balakrishnan. "A novel method for glaucoma detection using optic disc and cup segmentation in digital retinal fundus images". In: *2015 International Conference on Circuits, Power and Computing Technologies [ICCPCT-2015]*. 2015, pp. 1–5. DOI: [10.1109/ICCPCT.2015.7159441](https://doi.org/10.1109/ICCPCT.2015.7159441).
- [55] W. Ruengkitpinyo et al. "Glaucoma screening using rim width based on ISNT rule". In: *2015 6th International Conference of Information and Communication Technology for Embedded Systems (IC-ICTES)*. 2015, pp. 1–5. DOI: [10.1109/ICTEmSys.2015.7110827](https://doi.org/10.1109/ICTEmSys.2015.7110827).
- [56] Pardha Saradhi Mittapalli and Giri Babu Kande. "Segmentation of optic disk and optic cup from digital fundus images for the assessment of glaucoma". In: *Biomedical Signal Processing and Control* 24 (2016), pp. 34–46. ISSN: 1746-8094. DOI: <https://doi.org/10.1016/j.bspc.2015.09.003>. URL: <http://www.sciencedirect.com/science/article/pii/S1746809415001512>.
- [57] A. Diaz et al. "Glaucoma diagnosis by means of optic cup feature analysis in color fundus images". In: *2016 24th European Signal Processing Conference (EUSIPCO)*. 2016, pp. 2055–2059. DOI: [10.1109/EUSIPCO.2016.7760610](https://doi.org/10.1109/EUSIPCO.2016.7760610).
- [58] P. Das, S. R. Nirmala, and J. P. Medhi. "Detection of glaucoma using Neuroretinal Rim information". In: *2016 International Conference on Accessibility to Digital World (ICADW)*. 2016, pp. 181–186. DOI: [10.1109/ICADW.2016.7942538](https://doi.org/10.1109/ICADW.2016.7942538).

- [59] J. Ayub et al. "Glaucoma detection through optic disc and cup segmentation using K-mean clustering". In: *2016 International Conference on Computing, Electronic and Electrical Engineering (ICE Cube)*. 2016, pp. 143–147. DOI: [10.1109/ICECUBE.2016.7495212](https://doi.org/10.1109/ICECUBE.2016.7495212).
- [60] D. D. Patil and R. R. Manza. "Design new algorithm for early detection of primary open angle glaucoma using retinal Optic Cup to Disc Ratio". In: *2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*. 2016, pp. 148–151. DOI: [10.1109/ICEEOT.2016.7754905](https://doi.org/10.1109/ICEEOT.2016.7754905).
- [61] S. Maheshwari, R. B. Pachori, and U. R. Acharya. "Automated Diagnosis of Glaucoma Using Empirical Wavelet Transform and Correntropy Features Extracted From Fundus Images". In: *IEEE Journal of Biomedical and Health Informatics* 21.3 (2017), pp. 803–813. ISSN: 2168-2194. DOI: [10.1109/JBHI.2016.2544961](https://doi.org/10.1109/JBHI.2016.2544961).
- [62] K. Nirmala et al. "Glaucoma detection using wavelet based contourlet transform". In: *2017 International Conference on Intelligent Computing and Control (I2C2)*. 2017, pp. 1–5. DOI: [10.1109/I2C2.2017.8321875](https://doi.org/10.1109/I2C2.2017.8321875).
- [63] N. Sengar et al. "Automated detection of suspected glaucoma in digital fundus images". In: *2017 40th International Conference on Telecommunications and Signal Processing (TSP)*. 2017, pp. 749–752. DOI: [10.1109/TSP.2017.8076088](https://doi.org/10.1109/TSP.2017.8076088).
- [64] Kartik Thakkar. "Detection of Glaucoma from Retinal Fundus Images by analysing ISNT Measurement and features of Optic Cup and Blood Vessels". In: *International Journal of Engineering Technology Science and Research*. 2017.
- [65] Anindita Septiarini et al. "Optic disc and cup segmentation by automatic thresholding with morphological operation for glaucoma evaluation". In: *Signal, Image and Video Processing* 11.5 (2017), pp. 945–952. ISSN: 1863-1711. DOI: [10.1007/s11760-016-1043-x](https://doi.org/10.1007/s11760-016-1043-x). URL: <https://doi.org/10.1007/s11760-016-1043-x>.
- [66] P. E. Adjei et al. "Optic cup and optic disc analysis for glaucoma screening using pulse-coupled neural networks and line profile analysis". In: *2018 IEEE 4th Middle East Conference on Biomedical Engineering (MECBME)*. 2018, pp. 204–208. DOI: [10.1109/MECBME.2018.8402434](https://doi.org/10.1109/MECBME.2018.8402434).
- [67] Sharanagouda Nawaldgi, YS Lalitha, and Manjunath Reddy. "A novel adaptive threshold and ISNT rule based automatic glaucoma detection from color fundus images". In: *Data Engineering and Intelligent Computing*. Springer, 2018, pp. 139–147.
- [68] Syedia T Fatima Bokhari et al. "Fundus image segmentation and feature extraction for the detection of glaucoma: A new approach". In: *Current Medical Imaging* 14.1 (2018), pp. 77–87.
- [69] TR Kausu et al. "Combination of clinical and multiresolution features for glaucoma detection and its classification using fundus images". In: *Biocybernetics and Biomedical Engineering* 38.2 (2018), pp. 329–341.
- [70] Muhammad Salman Haleem et al. "A novel adaptive deformable model for automated optic disc and cup segmentation to aid glaucoma diagnosis". In: *Journal of medical systems* 42.1 (2018), p. 20.
- [71] Shwetha C Shetty and Priyanka Gutte. "A Novel Approach for Glaucoma Detection Using Fractal Analysis". In: *2018 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*. IEEE. 2018, pp. 1–4.

- [72] Anindita Septiarini et al. "Automatic detection of peripapillary atrophy in retinal fundus images using statistical features". In: *Biomedical Signal Processing and Control* 45 (2018), pp. 151–159.
- [73] Nur Ayuni Mohamed et al. "An automated glaucoma screening system using cup-to-disc ratio via Simple Linear Iterative Clustering superpixel approach". In: *Biomedical Signal Processing and Control* 53 (2019), p. 101454.
- [74] Zaka Ur Rehman et al. "Multi-parametric optic disc segmentation using superpixel based feature classification". In: *Expert Systems with Applications* 120 (2019), pp. 461–473.
- [75] Dheeraj Kumar Agrawal, Bhupendra Singh Kirar, and Ram Bilas Pachori. "Automated glaucoma detection using quasi-bivariate variational mode decomposition from fundus images". In: *IET Image Processing* 13.13 (2019), pp. 2401–2408.
- [76] Xin Zhao et al. "Glaucoma screening pipeline based on clinical measurements and hidden features". In: *IET Image Processing* 13.12 (2019), pp. 2213–2223.
- [77] Tomaz Ribeiro Viana Bisneto, Antonio Oseas de Carvalho Filho, and Deborah Maria Vieira Magalhães. "Generative adversarial network and texture features applied to automatic glaucoma detection". In: *Applied Soft Computing* 90 (2020), p. 106165.
- [78] Birendra Biswal et al. "Robust retinal optic disc and optic cup segmentation via stationary wavelet transform and maximum vessel pixel sum". In: *IET Image Processing* 14.4 (2019), pp. 592–602.
- [79] Imran Qureshi et al. "Detection of glaucoma based on cup-to-disc ratio using fundus images". In: *International Journal of Intelligent Systems Technologies and Applications* 19.1 (2020), pp. 1–16.
- [80] Afolabi O Joshua, Gugulethu Mabuza-Hocquet, and Fulufhelo V Nelwamondo. "Assessment of the Cup-to-Disc ratio method for Glaucoma detection". In: *2020 International SAUPEC/RobMech/PRASA Conference*. IEEE. 2020, pp. 1–5.
- [81] Poonguzhali Elangovan, Malaya Kumar Nath, and Madhusudan Mishra. "Statistical Parameters for Glaucoma Detection from Color Fundus Images". In: *Procedia Computer Science* 171 (2020), pp. 2675–2683.
- [82] Michael D Abràmoff et al. "Automated segmentation of the cup and rim from spectral domain OCT of the optic nerve head". In: *Investigative ophthalmology & visual science* 50.12 (2009), pp. 5778–5784.
- [83] Markus A. Mayer et al. "Retinal Nerve Fiber Layer Segmentation on FD-OCT Scans of Normal Subjects and Glaucoma Patients". In: *Biomed. Opt. Express* 1.5 (2010), pp. 1358–1383. DOI: [10.1364/BOE.1.001358](https://doi.org/10.1364/BOE.1.001358). URL: <http://www.osapublishing.org/boe/abstract.cfm?URI=boe-1-5-1358>.
- [84] Zhenguo Wang Yasufumi Fukuma Masanori Hangai Nagahisa Yoshimura Atsuo Tomidokoro Makoto Araie Ali S. Raza Donald C. Hood Qi Yang Charles A. Reisman and Kinpui Chan. "Automated layer segmentation of macular OCT images using dual-scale gradient information". In: *Opt Express*. 2010 Sep 27; 18(20): 2129321307. (2010).
- [85] J. Xu et al. "3D optical coherence tomography super pixel with machine classifier analysis for glaucoma detection". In: *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. 2011, pp. 3395–3398. DOI: [10.1109/9/IEMBS.2011.6090919](https://doi.org/10.1109/IEMBS.2011.6090919).

- [86] K. A. Vermeer et al. "Automated segmentation by pixel classification of retinal layers in ophthalmic OCT images". In: *Biomed. Opt. Express* 2.6 (2011), pp. 1743–1756. DOI: [10.1364/BOE.2.001743](https://doi.org/10.1364/BOE.2.001743). URL: <http://www.osapublishing.org/boe/abstract.cfm?URI=boe-2-6-1743>.
- [87] Yu-ping Wang, Qiang Chen, and Sheng-tao Lu. "Quantitative assessments of cup-to-disk ratios in spectral domain optical coherence tomography images for glaucoma diagnosis". In: *2013 6th International Conference on Biomedical Engineering and Informatics*. IEEE. 2013, pp. 160–165.
- [88] Robert Koprowski et al. "Automatic analysis of selected choroidal diseases in OCT images of the eye fundus". In: *Biomedical engineering online* 12.1 (2013), p. 117.
- [89] N. Anantrasirichai et al. "SVM-based texture classification in Optical Coherence Tomography". In: *2013 IEEE 10th International Symposium on Biomedical Imaging*. 2013, pp. 1332–1335. DOI: [10.1109/ISBI.2013.6556778](https://doi.org/10.1109/ISBI.2013.6556778).
- [90] Fabrício R Silva et al. "Sensitivity and specificity of machine learning classifiers for glaucoma diagnosis using Spectral Domain OCT and standard automated perimetry". In: *Arquivos brasileiros de oftalmologia* 76.3 (2013), pp. 170–174.
- [91] P. Agrawal and P. T. Karule. "Measurement of retinal thickness for detection of Glaucoma". In: *2014 International Conference on Green Computing Communication and Electrical Engineering (ICGCCEE)*. 2014, pp. 1–4. DOI: [10.1109/ICGCCEE.2014.6922263](https://doi.org/10.1109/ICGCCEE.2014.6922263).
- [92] Dharmanna Lamani Chandrappa et al. "Segmentation of Retinal Nerve Fiber Layer in Optical Coherence Tomography (OCT) Images using Statistical Region Merging Technique for Glaucoma Screening". In: *International Journal of Computer Applications* 128.10 (2015), pp. 32–35.
- [93] D Kaba et al. "Retina layer segmentation using kernel graph cuts and continuous max-flow". In: *Optics express* 23.6 (2015), pp. 7366–7384.
- [94] Hassan Muhammad et al. "Hybrid deep learning on single wide-field optical coherence tomography scans accurately classifies glaucoma suspects". In: *Journal of glaucoma* 26.12 (2017), p. 1086.
- [95] Jinming Duan et al. "Automated segmentation of retinal layers from optical coherence tomography images using geodesic distance". In: *Pattern Recognition* 72 (2017), pp. 158–175.
- [96] Aneeqa Ramzan et al. "Automated glaucoma detection using retinal layers segmentation and optic cup-to-disc ratio in optical coherence tomography images". In: *IET Image Processing* 13.3 (2018), pp. 409–420.
- [97] Jie Wang et al. "SD Net: joint segmentation and diagnosis revealing the diagnostic significance of using entire RNFL thickness in glaucoma". In: (2018).
- [98] Stefan Maetschke et al. "A feature agnostic approach for glaucoma detection in OCT volumes". In: *PloS one* 14.7 (2019), e0219126.
- [99] Kaveri A Thakoor et al. "Enhancing the Accuracy of Glaucoma Detection from OCT Probability Maps using Convolutional Neural Networks". In: *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE. 2019, pp. 2036–2040.

- [100] Gabriel García, Adrián Colomer, and Valery Naranjo. "Analysis of Hand-Crafted and Automatic-Learned Features for Glaucoma Detection Through Raw Circumpapillary OCT Images". In: *International Conference on Intelligent Data Engineering and Automated Learning*. Springer. 2020, pp. 156–164.
- [101] Ai Ping Yow et al. "Automated circumpapillary retinal nerve fiber layer segmentation in high-resolution swept-source OCT". In: *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. IEEE. 2020, pp. 1832–1835.
- [102] Atalie C Thompson et al. "Assessment of a segmentation-free deep learning algorithm for diagnosing glaucoma from optical coherence tomography scans". In: *Jama Ophthalmology* 138.4 (2020), pp. 333–339.
- [103] Sunita Radhakrishnan, David Huang, and Scott D Smith. "Optical coherence tomography imaging of the anterior chamber angle." In: *Ophthalmology Clinics of North America* 18.3 (2005), pp. 375–81.
- [104] Yanwu Xu et al. "Axial alignment for anterior segment swept source optical coherence tomography via robust low-rank tensor recovery". In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer. 2016, pp. 441–449.
- [105] Jing Tian et al. "Automatic anterior chamber angle assessment for HD-OCT images". In: *IEEE Transactions on Biomedical Engineering* 58.11 (2011), pp. 3242–3249.
- [106] Yanwu Xu et al. "Anterior chamber angle classification using multiscale histograms of oriented gradients for glaucoma subtype identification". In: *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE. 2012, pp. 3167–3170.
- [107] Swamidoss Issac Niwas et al. "Cross-examination for angle-closure glaucoma feature detection". In: *IEEE journal of biomedical and health informatics* 20.1 (2015), pp. 343–354.
- [108] Soe Ni Ni et al. "Anterior chamber angle shape analysis and classification of glaucoma in SS-OCT images". In: *Journal of ophthalmology* 2014 (2014).
- [109] Swamidoss Issac Niwas et al. "Complex wavelet based quality assessment for AS-OCT images with application to Angle Closure Glaucoma diagnosis". In: *Computer methods and programs in biomedicine* 130 (2016), pp. 13–21.
- [110] Huazhu Fu et al. "Segmentation and quantification for angle-closure glaucoma assessment in anterior segment OCT". In: *IEEE transactions on medical imaging* 36.9 (2017), pp. 1930–1938.
- [111] Huazhu Fu et al. "Multi-context deep network for angle-closure glaucoma screening in anterior segment OCT". In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer. 2018, pp. 356–363.
- [112] Qiaoling Shang et al. "Automated iris segmentation from anterior segment oct images with occludable angles via local phase tensor". In: *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE. 2019, pp. 4745–4749.
- [113] Chenglang Yuan et al. "Identification of primary angle-closure on AS-OCT images with Convolutional Neural Networks". In: *arXiv preprint arXiv:1910.10414* (2019).

- [114] Huaying Hao et al. "Open-Narrow-Synechia Anterior Chamber Angle Classification in AS-OCT Sequences". In: *arXiv preprint arXiv:2006.05367* (2020).
- [115] Panming Li et al. "Automatic Angle-Closure Glaucoma Screening Based on the Localization of Scleral Spur in Anterior Segment OCT". In: *2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI)*. IEEE. 2020, pp. 1387–1390.
- [116] Fathima CS. "Glaucoma Detection Using Fundus Images and OCT Images". In: *Government College of Engineering Kannur, International Conference on Systems, Energy & Environment (ICSEE)*. 2019.
- [117] Guangzhou An et al. "Glaucoma diagnosis with machine learning based on optical coherence tomography and color fundus images". In: *Journal of healthcare engineering* 2019 (2019).
- [118] Zailiang Chen et al. "Combination of enhanced depth imaging optical coherence tomography and fundus images for Glaucoma screening". In: *Journal of medical systems* 43.6 (2019), p. 163.
- [119] Tehmina Shehryar et al. "Improved automated detection of glaucoma by correlating fundus and SD-OCT image analysis". In: *International Journal of Imaging Systems and Technology* (2020).
- [120] Rashid Jalal Qureshi et al. "Combining algorithms for automatic detection of optic disc and macula in fundus images". In: *Computer Vision and Image Understanding* 116.1 (2012), pp. 138–145.
- [121] Sumaiya Pathan et al. "Automated detection of optic disc contours in fundus images using decision tree classifier". In: *Biocybernetics and Biomedical Engineering* 40.1 (2020), pp. 52–64.
- [122] M Usman Akram et al. "Retinal images: optic disk localization and detection". In: *International Conference Image Analysis and Recognition*. Springer. 2010, pp. 40–49.
- [123] Geert Litjens et al. "A survey on deep learning in medical image analysis". In: *Medical image analysis* 42 (2017), pp. 60–88.
- [124] Chengyao Shen, Mingli Song, and Qi Zhao. "Learning high-level concepts by training a deep network on eye fixations". In: *NIPS Deep Learning and Unsup Feat Learn Workshop*. Vol. 2. 2012.
- [125] AMEL FEROU. "ANALYSE DES IMAGES COULEUR DU FOND DOEIL POUR LAIDE AU DIAGNOSTIC EN OPHTALMOLOGIE: APPLICATION A LA DETECTION DES PATHOLOGIES RETINIENNES." PhD thesis. 2014.
- [126] Shih-Chia Huang, Fan-Chieh Cheng, and Yi-Sheng Chiu. "Efficient contrast enhancement using adaptive gamma correction with weighting distribution". In: *IEEE transactions on image processing* 22.3 (2012), pp. 1032–1041.
- [127] Thomas Edgar Walter. "Application de la morphologie mathématique au diagnostic de la rétinopathie diabétique à partir d'images couleur". PhD thesis. Paris, ENMP, 2003.
- [128] Tony F Chan and Luminita A Vese. "Active contours without edges". In: *IEEE Transactions on image processing* 10.2 (2001), pp. 266–277.
- [129] Chuang Wang. "Level set segmentation of retinal structures". PhD thesis. Brunel University London, 2016.

- [130] David Bryant Mumford and Jayant Shah. "Optimal approximations by piecewise smooth functions and associated variational problems". In: *Communications on pure and applied mathematics* (1989).
- [131] Pedro F Felzenszwalb and Daniel P Huttenlocher. "Efficient graph-based image segmentation". In: *International journal of computer vision* 59.2 (2004), pp. 167–181.
- [132] CIE. *CIE Colorimetry–Part 4: 1976 L* a* b* Colour Space*. 1976.
- [133] Valery Risson. "Application de la morphologie mathématique à l'analyse des conditions d'éclairage des images couleur". PhD thesis. 2001.
- [134] I Kirati. "la segmentation bayésienne non supervisée d'images". PhD thesis. Thèse de doctorat, 2015.
- [135] Jost B Jonas, Wido M Budde, and Songhomitra Panda-Jonas. "Ophthalmoscopic evaluation of the optic nerve head". In: *Survey of ophthalmology* 43.4 (1999), pp. 293–320.
- [136] Ethem Alpaydin. *Introduction to machine learning*. MIT press, 2020.
- [137] Leo Breiman. "Random Forests". In: *Machine Learning* 45.1 (2001), pp. 5–32. ISSN: 1573-0565. DOI: [10.1023/A:1010933404324](https://doi.org/10.1023/A:1010933404324). URL: <https://doi.org/10.1023/A:1010933404324>.
- [138] Glenn De'ath and Katharina E Fabricius. "Classification and regression trees: a powerful yet simple technique for ecological data analysis". In: *Ecology* 81.11 (2000), pp. 3178–3192.
- [139] Lama Seoud et al. "Red lesion detection using dynamic shape features for diabetic retinopathy screening". In: *IEEE transactions on medical imaging* 35.4 (2015), pp. 1116–1126.
- [140] Dana Dascalescu et al. "The ganglion cell complex as an useful tool in glaucoma assessment". In: *Romanian journal of ophthalmology* 62.4 (2018), p. 300.
- [141] Graham Lakkis. "The ganglion cell complex and glaucoma". In: *Pharma* 3 (2014), pp. 28–32.
- [142] Michael R Banitt et al. "Progressive loss of retinal ganglion cell function precedes structural loss by several years in glaucoma suspects". In: *Investigative ophthalmology & visual science* 54.3 (2013), pp. 2346–2352.
- [143] Purvi Raj Bhagat, Kalyani Vivek Deshpande, and Bhagyashree Natu. "Utility of ganglion cell complex analysis in early diagnosis and monitoring of glaucoma using a different spectral domain optical coherence tomography". In: *Journal of current glaucoma practice* 8.3 (2014), p. 101.
- [144] Gianluca Scuderi et al. "Ganglion cell complex analysis in glaucoma patients: What can it tell us?" In: *Eye and Brain* 12 (2020), p. 33.
- [145] Ivano Riva et al. "Anterior Chamber Angle Assessment Techniques: A Review". In: *Journal of Clinical Medicine* 9.12 (2020), p. 3814.
- [146] S Kother Mohideen, S Arumuga Perumal, and M Mohamed Sathik. "Image denoising using discrete wavelet transform". In: *International Journal of Computer Science and Network Security* 8.1 (2008), pp. 213–216.
- [147] David L Donoho and Iain M Johnstone. "Threshold selection for wavelet shrinkage of noisy data". In: *Proceedings of 16th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Vol. 1. IEEE. 1994, A24–A25.

- [148] Mohsen Ghazel. "Adaptive fractal and wavelet image denoising". In: (2004).
- [149] S Grace Chang, Bin Yu, and Martin Vetterli. "Adaptive wavelet thresholding for image denoising and compression". In: *IEEE transactions on image processing* 9.9 (2000), pp. 1532–1546.
- [150] Carsten Rother, Vladimir Kolmogorov, and Andrew Blake. "' GrabCut" interactive foreground extraction using iterated graph cuts". In: *ACM transactions on graphics (TOG)* 23.3 (2004), pp. 309–314.
- [151] Leo Grady. "Random walks for image segmentation". In: *IEEE transactions on pattern analysis and machine intelligence* 28.11 (2006), pp. 1768–1783.
- [152] Jing Tian et al. "Real-time automatic segmentation of optical coherence tomography volume data of the macular region". In: *PloS one* 10.8 (2015), e0133908.
- [153] Tuomas Heikka, Barry Cense, and Nomdo M Jansonius. "Retinal layer thicknesses retrieved with different segmentation algorithms from optical coherence tomography scans acquired under different signal-to-noise ratio conditions". In: *Biomedical Optics Express* 11.12 (2020), pp. 7079–7095.
- [154] Yuri Boykov and Gareth Funka-Lea. "Graph cuts and efficient ND image segmentation". In: *International journal of computer vision* 70.2 (2006), pp. 109–131.
- [155] Anna Fabijańska. "Segmentation of pulmonary vascular tree from 3D CT thorax scans". In: *Biocybernetics and Biomedical Engineering* 35.2 (2015), pp. 106–119.
- [156] Huiyuan Hou et al. "Ganglion Cell Complex Thickness and Macular Vessel Density Loss in Primary Open-Angle Glaucoma". In: *Ophthalmology* (2020).
- [157] Chelvin CA Sng et al. "Pretreatment anterior segment imaging during acute primary angle closure: insights into angle closure mechanisms in the acute phase". In: *Ophthalmology* 121.1 (2014), pp. 119–125.
- [158] Joshua Z Gasiorowski and Paul Russell. "Biological properties of trabecular meshwork cells". In: *Experimental eye research* 88.4 (2009), pp. 671–675.
- [159] Christopher Kai-shun Leung et al. "Anterior chamber angle measurement with anterior segment optical coherence tomography: a comparison between slit lamp OCT and Visante OCT". In: *Investigative ophthalmology & visual science* 49.8 (2008), pp. 3469–3474.
- [160] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. "Imagenet classification with deep convolutional neural networks". In: *Advances in neural information processing systems* 25 (2012), pp. 1097–1105.
- [161] Karen Simonyan and Andrew Zisserman. "Very deep convolutional networks for large-scale image recognition". In: *arXiv preprint arXiv:1409.1556* (2014).
- [162] Huazhu Fu et al. "Age challenge: Angle closure glaucoma evaluation in anterior segment optical coherence tomography". In: *Medical Image Analysis* 66 (2020), p. 101798.
- [163] Jing Sun et al. "Scene image classification method based on Alex-Net model". In: *2016 3rd International Conference on Informative and Cybernetics for Computational Social Systems (ICCSS)*. IEEE. 2016, pp. 363–367.
- [164] Md Zahangir Alom et al. "The history began from alexnet: A comprehensive survey on deep learning approaches". In: *arXiv preprint arXiv:1803.01164* (2018).

- [165] Sergey Ioffe and Christian Szegedy. "Batch normalization: Accelerating deep network training by reducing internal covariate shift". In: *International conference on machine learning*. PMLR. 2015, pp. 448–456.
- [166] Nitish Srivastava et al. "Dropout: a simple way to prevent neural networks from overfitting". In: *The journal of machine learning research* 15.1 (2014), pp. 1929–1958.
- [167] Xuanqing Liu et al. "Towards robust neural networks via random self-ensemble". In: *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018, pp. 369–385.
- [168] Wiro J Niessen et al. "Error metrics for quantitative evaluation of medical image segmentation". In: *Performance characterization in computer vision*. Springer, 2000, pp. 275–284.
- [169] Hong Han, Xiaoling Guo, and Hua Yu. "Variable selection using mean decrease accuracy and mean decrease gini based on random forest". In: *2016 7th IEEE International Conference on Software Engineering and Service Science (ICSESS)*. IEEE. 2016, pp. 219–224.