

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة أبي بكر بلقايد - تلمسان

Université Aboubakr Belkaïd – Tlemcen –

Faculté de TECHNOLOGIE



THESE

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

En : Génie Biomédical

Spécialité : Génie Biomédical

Option : Signaux et Images en Médecine

Par : BENSMAIL Epse KARA SLIMANE ILHAM

Sujet

Systeme Automatique d'Aide au Diagnostic pour le Dépistage de la Rétinopathie Diabétique

Soutenue publiquement, le 20 / 02 / 2020, devant le jury composé de :

Mr BEREKSI REGUIG Fethi	Professeur	Univ. Tlemcen	Président
Mr BESSAID Abdelhafid	Professeur	Univ. Tlemcen	Directeur de thèse
Mr KADDOUR Abdelhafid	Professeur	USTO Oran	Examineur 1
Mr BOUKLI HACENE Ismail	MCA	Univ. Tlemcen	Examineur 2
Mr MESSADI Mohamed	MCA	Univ. Tlemcen	Invité

MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR
ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITÉ ABOU BEKR BELKAID
FACULTÉ DE TECHNOLOGIE
DÉPARTEMENT DE GÉNIE BIOMÉDICAL

THESE DE DOCTORAT

pour obtenir le grade de

DOCTORAT 3ÈME CYCLE

Spécialité : **Imagerie Médicale**

présentée et soutenue publiquement
par

BENSMAIL Epse KARA SLIMANE Ilham

le

Titre:

Système automatique d'aide au diagnostic pour le dépistage de la Rétinopathie Diabétique

Jury

Président du jury. Pr. BEREKSI REGUIG FETHI,	Université de Tlemcen
Examineur. Pr. KADDOUR ABDELHAFID,	Université USTO
Examineur. Dr. BOUKLI HACENE ISMAIL,	Université de Tlemcen
Invité. Dr. MESSADI MAHAMMED,	Université de Tlemcen

Résumé

Parmi les maladies qui ravagent le monde entier et qui n'arrêtent malheureusement pas de croître, nous retrouvons la Rétinopathie Diabétique (RD). Elle est classée par l'organisation mondiale de la santé comme étant la première maladie pouvant causer une forte déficience visuelle menant jusqu'à la cécité des populations âgées entre 20 et 74 ans. Une très bonne prise en charge, une bonne hygiène de vie, ainsi qu'un dépistage précoce sont la clé de la prévention de la vision des patients diabétiques. Le travail de recherche effectué au cours de cette thèse, consiste en un système d'aide au diagnostic pour le dépistage précoce de la Rétinopathie Diabétique Non Proliférante (RDNP). Un tel système permet aux Ophthalmologistes un gain de temps et d'efforts inestimables. Nous faisons appel au traitement d'images et à la classification supervisée pour détecter et classer le degré de la RDNP. Trois lésions typiques de cette maladie, (les Microanévrismes, les Hémorragies, et les exsudats), ont été détectées avec succès par nos algorithmes, en utilisant des méthodes hybrides différentes pour chaque pathologie. Il s'agit des toutes premières lésions apparentes au cours de l'évolution de la maladie ; en effet les microanévrismes sont les signes précoces de son apparition, ils n'ont aucune influence sur la vision du malade et peuvent parfois ne pas être détectés par les experts car ils se présentent sous forme de toute petite taille. Notre système a été validé sur un ensemble de base de données rétinienne (MESSIDOR, ImageRET, DRIVE), comprenant différentes images de différentes classes de la RD. Il a pu offrir une grande précision de détection des pathologies rétinienne, ainsi qu'une bonne détection des différents stades de la RDNP, basée sur la sélection de caractéristiques pertinentes. Les résultats sont très prometteurs.

Mots clés : Rétinopathie Diabétique ; Rétinopathie Diabétique Non Proliférante ; Sélection de paramètres pertinents ; Détection des lésions rétinienne ; Classification du degré de la RD.

Remerciements

Par ou par quoi et par qui commencer ???

Avant toute chose, je remercie Dieu le tout puissant de m'avoir armée de bonne volonté, de beaucoup de courage, et d'une grande force pour terminer ce modeste travail de recherche.

Pendant ces longues et dures années de labeur, j'ai eu le privilège et la chance de travailler avec des personnes formidables, qui sont devenues petit à petit, ma seconde petite famille de travail. Elles ont toujours été là pour m'écouter, m'encourager, me reconforter et me conseiller dans les moments les plus difficiles. Ceci a été la clé de la réussite de cette thèse.

Mes remerciements vont en premier lieu à mon directeur de thèse Pr BESSAID Abdelhafid, qui m'a laissé la liberté de réaliser mes travaux à ma guise, en veillant bien sur à ce que je ne m'écarte jamais du droit chemin. Dans notre équipe d'imagerie médicale, il est bien plus qu'un encadreur, c'est notre deuxième père sur qui nous pouvons toujours compter.

Je tiens à exprimer ma profonde reconnaissance à quatre personnes extraordinaires rencontrées lors de mon parcours, MESSADI Mohamed, FEROUJ Amel, EL HABIB DAHO Mostafa, LAZOUNI Mohamed El Amine, et Meziani Sarah, je ne vous remercierai jamais assez pour avoir toujours été là pour moi, dans les bons comme dans les mauvais moments. Vous avez partagé avec moi vos connaissances, vous avez fait preuve de bravoure en me relevant à chaque fois que je fléchissais, vous êtes et vous serez toujours ma seconde petite famille.

Je remercie également, tous les membres du Jury de cette thèse pour leur temps si précieux à me consacrer pour la lecture et la synthèse de mon document.

Mes plus profonds remerciements vont à mes très chers parents, vous êtes mon repère dans ce monde, vous m'avez donné la vie et m'avez mené jusqu'ici, vous avez toujours cru en moi, vous avez tout fait pour que je réussisse et si je suis là en ce moment entrain d'écrire ces mots, c'est pour vous voir fiers de moi et vous rendre heureux en vous récompensant par ce modeste travail. Voilà maman

chérie je suis arrivée grâce à toi, et ce travail je te le dédie. Je vous aime plus que tout au monde mes parents adorés.

Je ne te remercierai sans doute jamais assez mon très cher mari Moustafa, je remercie Dieu de m'avoir mise sur ton chemin, tu es bien plus qu'un mari pour moi, tu es mon meilleur ami, mon compagnon, mon âme sœur, mon rayon de soleil, mon bras droit, ma joie de vivre, tu es mon tout. Merci mille fois pour tous les sacrifices que tu as faits pour moi et d'avoir toujours cru en moi. Tu ne m'as jamais laissé baisser les bras, je t'ai toujours trouvé quand j'ai eu besoin de toi. Merci d'être le père fantastique que tu es de nos très chères et adorables petites princesses Lydia et Lila ; oh mes poupées, maman est tellement fière et heureuse de vous avoir, je vois en vous la vie et le bonheur, vous êtes ma raison d'exister et mon oxygène, je vous aime plus que tout dans ce monde.

Je tiens à remercier aussi, ma chère grand-mère qui m'a plus qu'aidé dans mon travail. Ta porte m'a toujours été ouverte. Que Dieu te garde pour nous.

Je tiens à remercier également ma chère belle mère, pour sa gentillesse et ses encouragements. La vie n'a pas été facile pour toi Ma Lila, j'espère pouvoir te rendre heureuse par ce travail.

Je remercie profondément ma petite sœur Farah, tu es et resteras à jamais mon premier petit bébé, je te souhaite ce succès à toi aussi incha'Allah. Je t'aime mon trésor.

Mes remerciements vont aussi à mon grand frère Malik et son épouse Téma.

Je remercie également ma chère tante Téma Korso pour toute l'aide qu'elle m'a apportée.

Un grand merci à ma grande belle sœur Sihem Berrahmon, son mari Kader et leurs petits anges Mordjène, Malek et Arslane, merci d'avoir cru en moi.

Ma gratitude va également à ma seconde belle sœur Manel Bekhchi, son mari Ghouti, et leurs adorables enfants, Hind, Farouk et Racim.

Et finalement mes remerciements vont à la cadette, ma petite sœur de cœur Imi Merabet, son mari Karim, et leur beau gosse Yassine.

Une pensée spéciale à tous les membres du Laboratoire de recherche de Génie Biomédical.

Voilà, j'espère n'avoir oublié personne et ne pas avoir été trop longue. Merci à tout ceux qui ont contribué de près ou de loin au bon déroulement de cette thèse....

Dédicaces

Ce modeste travail est dédié :

Aux prunelles de mes yeux **Lydia** et **Lila**

A mon cher et tendre époux

A mes exemples de la vie "Papa et Maman adorés"

A ma seconde mère "Ma Lila"

A mes très chers sœur et frère

A ma douce grand-mère

A toute ma belle famille

Ainsi qu'à toute ma famille et tous mes amis.

Liste des Abréviations

RD	Rétinopathie Diabétique
RDNP	Rétinopathie Diabétique Non Proliférante
RDP	Rétinopathie Diabétique Proliférante
MAs	Microanévrismes
HEs	Hémorragies
EXs	Exsudats
KNN	K-plus proches voisins
SVM	Séparateur à Vaste Marge
ADL	Analyse Discriminante Linéaire
RN	Réseaux de Neurones
MLP	Perceptron Multicouches
AMIR	Anomalies Microvasculaires Intra Rétiniennes
OCT	Tomographie par Cohérence Optique
RVB	Rouge Vert Bleu
OMD	œdème maculaire diabétique
HSV	Hue Saturation Value
FID	Fédération Internationale de Diabète

Table des matières

Résumé	i
Remerciements	iii
Dédicaces	iv
Liste des Abréviations	v
Table des matières	viii
Table des figures	xii
Liste des tableaux	
Introduction générale	1
Introduction générale	1
1 La Rétinopathie Diabétique : Une complication du diabète	6
1 La rétine	7
2 Le diabète	8
3 La Rétinopathie Diabétique (RD)	10
4 Classification des stades de la Rétinopathie Diabétique	12
4.1 Les complications associées à la RD	14
5 Description des lésions caractéristiques de la RDNP et de la RDP	15
6 Les dispositifs d'acquisition des images rétiniennes	18
6.1 Histoire de l'imagerie	18
6.2 Les différentes techniques d'imagerie médicale	19
7 Traitement de la RD	23
8 Dépistage de la rétinopathie diabétique	24
9 La Rétinopathie Diabétique et le Traitement des images	25
10 Avantages du diagnostic et de la détection précoce de la RD	25
11 Conclusion	26
2 Revues de la littérature	27
1 Introduction	28
2 Les Machines Learning (L'apprentissage Automatique)	28
3 L'apprentissage supervisé	29
3.1 Algorithmes	30
4 L'apprentissage non supervisé	38
5 L'apprentissage semi supervisé	39
6 Sélection des caractéristiques	39
7 Phase d'apprentissage	40
8 Phase de test	40
9 La validation croisée (CROSS VALIDATION de l'anglais)	41

9.1	Le sous-apprentissage	42
9.2	Le sur-apprentissage	43
10	La matrice de confusion	43
11	Recherche bibliographique et travaux connexes	44
12	Conclusion	48
3	Méthodologie du système d'aide au diagnostic pour le dépistage de la RD	49
1	Introduction	50
2	Détection des différentes lésions diabétiques	51
2.1	Détection et classification des Microanévrismes (MAs) . . .	51
2.2	Détection des Hémorragies (HEs)	65
2.3	Détection des Exsudats (EXs)	78
3	Extraction des caractéristiques pertinentes	85
4	Classification de la Rétinopathie Diabétique Non Proliférante . . .	88
5	Conclusion	89
4	Evaluation des Résultats et Discussions	90
1	Introduction	91
2	Les bases de données utilisées pour la validation des résultats . . .	91
2.1	Base de données DRIVE	91
2.2	Base de données Messidor	92
2.3	Base de données ImageRet	93
3	Evaluation des performances des algorithmes de détection des pathologies rétiniennes	93
3.1	Evaluation des performances de détection des Hémorragies rétiniennes	93
3.2	Evaluation des performances de détection des microanévrismes	101
3.3	Evaluation des performances de détection des Exsudats . . .	106
4	Résultats de la classification du degré de la RDNP	111
4.1	Résultats et discussions des performances de la première expérience avec la base de données MESSIDOR	113
4.2	Résultats et discussions des performances de la deuxième expérience avec la base de données DiaretDB0	116
4.3	Résultats et discussions des performances de la troisième expérience avec la base de données DiaretDB1	117
4.4	Résultats et discussions des performances de la quatrième expérience avec la base de données DRIVE	119
4.5	Résultats et discussions des performances de la cinquième expérience avec la nouvelle base de données	120
5	Évaluation des performances de la classification des différents stades de la RDNP	125
6	Le vote majoritaire	128
7	Comparaison de nos résultats de classification avec les travaux de la littérature	130
8	Conclusions	130

Conclusion générale	132
Bibliographie	135

Table des figures

1.1	Photographie d'un fond d'œil rétinien avec ses principales composantes	8
1.2	Anatomie de l'œil humain et ses couches rétiniennes	8
1.3	Vision d'un diabétique en phase proliférative [1]	11
1.4	Deux fonds d'œil rétiniens. (a) Patient sain ; (b) Patient présentant une RD.	12
1.5	Pathologies de la RD ; (a) Fond d'œil rétinien contenant les quatre lésion de la RDNP, (b) Microanévrismes, (c) Hémorragies, (d) Exsudats durs, (e) Nodules cotonneux.	16
1.6	Anomalies Veineuses	17
1.7	Présence des AMIR sur un fond d'œil diabétique	17
1.8	Néovaisseaux prépapillaire et prérétinien	18
1.9	(a) œdème maculaire ; (b) Décollement de la rétine	18
1.10	Rétinographe non mydriatique	21
1.11	Réalisation d'un examen angiographique.	22
1.12	OCT	23
2.1	Séparation optimale de deux classes	29
2.2	Les étapes d'un modèle d'apprentissage supervisé	30
2.3	Le choix du voisinage	32
2.4	Arbre de décision	34
2.5	Architecture d'un MLP	37
2.6	Phase d'apprentissage	40
2.7	Vue d'ensemble du flux de travail de l'apprentissage automatique .	41
2.8	Un exemple du principe de la validation croisée avec $K=5$	42
2.9	Courbe représentative d'un sous-apprentissage	43
2.10	Courbe représentative d'un sur-apprentissage	43
2.11	La matrice de confusion	44
3.1	Organigramme de la représentation d'un système CAD pour le dépistage de la RD	50
3.2	Images rétiniennes contenant des MAs.	54
3.3	Organigramme de détection des microanévrismes	54
3.4	(a) : Image originale ; (b) : Canal vert de l'image originale ; (c) : Canal vert inversé.	55
3.5	Transformation CLAHE appliquée sur le canal vert inversé de l'image originale.	57
3.6	(a) Filtre Médian ; (b) Filtre de Gauss	58

3.7	Détection de tous les maximums locaux présents sur l'image. . . .	59
3.8	Représentation des MAs et des Non-MAs dans différentes directions	61
3.9	(a) Zoom sur une partie de l'image avec la localisation des MAs ; (b) Localisation des MAs en binaire.	61
3.10	Résultat de la croissance de région	62
3.11	Résultat final de détection des MAs.	65
3.12	Organigramme de la méthode développée pour la détection des Hémorragies	68
3.13	Images obtenues après les étapes de prétraitement ; (a) L'image Originale, (b) Le canal vert de l'image originale, (c) L'égalisation Adaptative d'Histogramme, (d) L'ouverture morphologique, (e) Fil- trage Gaussien.	69
3.14	Résultats de l'application de l'algorithme FCM	71
3.15	Résultats de suppression du réseau vasculaire ; (a) Transformation Top-Hat, (b) Résultat du Supremum d'ouverture, (c) Seuillage de l'image b, (d) Dilatation de l'image c, (e) Résultat de la soustraction de l'image (d) avec le résultat de seuillage de la figure (a)	72
3.16	Etapes de prétraitement pour l'élimination de la macula ; (a) Le can- nal de luminance (V) de l'image originale, (b) L'égalisation d'histo- gramme du canal V, (c) Filtrage Gaussien de l'image b, (d) Ferme- ture morphologique de l'image "c", (e) Fermeture par diamètre de l'image "d", (f) Le résultat de la soustraction entre les deux images "d" et "e" (TOP-HAT).	73
3.17	(a) Image binaire, (b) Extraction de la Macula, (c) Résultat de l'opé- ration de soustraction	74
3.18	L'organigramme du processus de classification	74
3.19	(a) Illustration du concept des vecteurs de support et de la marge dans un exemple de discrimination linéaire séparable en deux di- mensions ; b) Exemple de marge souple d'un SVM permettant des erreurs.	77
3.20	Illustration de l'utilisation d'un noyau ϕ dans la méthode SVM. À gauche se trouve l'espace d'origine des attributs et à droite, la projection à travers une fonction du noyau	77
3.21	Résultats de détection des HEs et leur superposition sur l'image originale	78
3.22	Exemples d'exsudats durs (en vert), et d'exsudats mous (en rouge) sur des images du fond d'œil	78
3.23	Organigramme de détection des Exsudats durs	81
3.24	Résultats de prétraitement ; (a) : Image couleur de la rétine, (b) : le canal de luminance de l'image d'origine, (c) : Le filtrage de l'image améliorée	82
3.25	Résultats d'élimination du disque optique et du réseau vasculaire , (a) Elimination du réseau rétinien ; (b) Seuillage de l'image "a" ; (c) Superposition du résultat sur l'image originale.	83

3.26	Résultats d'extraction des exsudats à partir d'une image couleur de la rétine. (a) Image couleur de la rétine ; (b) Canal vert de l'image rétinienne ; (c) Elimination du réseau vasculaire ; (d) Variation de niveaux de gris dans les régions exsudatives ; (e) Résultat de seuillage de l'image "d" ; (f) Dilatation de l'image "e" ; (g) Elimination du disque optique ; (h) Image marqueur ; (i) Résultat de la reconstruction par dilatation ; (j) Résultat de la différence entre l'image du canal vert et l'image reconstruite ; (k) Résultat de seuillage de l'image "j" ; (l) Résultat final de détection des EXs superposé sur l'image originale.	85
3.27	Modèle de classification	88
4.1	Représentation graphique des différents paramètres d'évaluation de l'algorithme de détection des HEs.	98
4.2	Trois exemples d'images saines ou aucune fausse détection n'est obtenue	98
4.3	Détection des hémorragies dans les images rétinienne. (a) : Détection des HEs en présence de nodule cotonneux ; (b) et (c) : Détection des HEs en présence des exsudats, de microanévrismes, et des cicatrices de la chirurgie au laser.	99
4.4	Exemples de la bonne détection des HEs sur des images de qualité médiocre, ainsi qu'en présence d'autres lésions rétinienne.	100
4.5	Exemples de mauvaise détection des HEs rétinienne	100
4.6	Représentation graphique des trois paramètres d'évaluation de la méthode de détection des MAs	103
4.7	Exemples de détection des MAs dans différents types d'images. (a) : Image non pathologique, (b) : Image de mauvaise qualité, (c) : Présence de nodules cotonneux, (d) : Présence de toutes petites hémorragies ainsi que de quelques nodules cotonneux.	104
4.8	Exemple d'une fausse détection de deux MAs alors que ces des points de bifurcation en réalité.	105
4.9	Graphes représentatifs des paramètres d'évaluation des performances de l'algorithme de détection des exsudats durs	107
4.10	Efficacité de l'algorithme sur des images ne contenant pas des Exsudats. (a) : image saine, (b,c) : Images contenant des nodules cotonneux.	108
4.11	Bonne détection des Exsudats sur des images de mauvaise qualité.	109
4.12	Détection des exsudats seulement en présence de nodules cotonneux et des hémorragies rétinienne.	109
4.13	Limites de notre algorithme de détection des exsudats.	110
4.14	Graphes représentatifs des matrices de confusion pour chaque classificateurs de la base de données MESSIDOR.	114
4.15	Graphes représentatifs des matrices de confusion pour chaque classificateurs de la base de données DiaretDB0	116
4.16	Graphes représentatifs des matrices de confusion pour chaque classificateurs de la base de données DiaretDB1	118
4.17	Graphes représentatifs des matrices de confusion pour chaque classificateurs de la base de données DRIVE	119

4.18	Représentation graphique de la matrice de confusion du classifieur ADL de la cinquième expérience.	121
4.19	Représentation graphique de la matrice de confusion du classifieur KNN de la cinquième expérience.	122
4.20	Représentation graphique de la matrice de confusion du classifieur SVM de la cinquième expérience.	123
4.21	Représentation graphique de la matrice de confusion de l'arbre de décision CART de la cinquième expérience.	124
4.22	Représentation graphique de la matrice de confusion des réseaux de neurones de la cinquième expérience.	125
4.23	Principe du vote majoritaire	129

Liste des tableaux

3.1	Les caractéristiques de profil utilisées	64
3.2	Tableau descriptif du choix des différentes caractéristiques utilisées pour classer les HEs	75
3.3	Principe suivi pour le comptage du nombre des MAs et des HEs	86
3.4	Caractéristiques choisies pour la classification	87
4.1	Résultats de comparaison entre la segmentation manuelle et la segmentation automatique des HEs	96
4.2	Comparaison des résultats de détection des hémorragies avec les travaux de la littérature	101
4.3	Résultats de comparaison entre la segmentation manuelle et la segmentation automatique des MAs	102
4.4	Comparaison des résultats de détection des microanévrismes avec les travaux de la littérature	105
4.5	Résultats de comparaison entre la segmentation manuelle et la segmentation automatique des Exsudats	106
4.6	Comparaison des résultats de détection des exsudats avec les travaux de la littérature	111
4.7	Nombre d'images de chaque grade dans les différentes bases de données	113
4.8	Performances atteintes par les cinq classifieurs pour la base de données MESSIDOR	115
4.9	Performances atteintes par les cinq classifieurs pour la base de données DiaretDB0	117
4.10	Performances atteintes par les cinq classifieurs pour la base de données DiaretDB1	118
4.11	Performances atteintes par les cinq classifieurs pour la base de données DRIVE	120
4.12	Matrice de confusion du classifieur ADL de la cinquième expérience	121
4.13	Matrice de confusion du classifieur KNN de la cinquième expérience	122
4.14	Matrice de confusion du classifieur SVM de la cinquième expérience	123
4.15	Matrice de confusion de l'arbre de décision CART de la cinquième expérience	123
4.16	Matrice de confusion des réseaux de neurones de la cinquième expérience	124
4.17	Performances atteintes par les cinq classifieurs pour la nouvelle base de données	126
4.18	Résultats de classification des cinq expériences	127

4.19	Tableau comparatif de la classification du degré de la RDNP avec d'autres travaux de la littérature	130
------	--	-----

Introduction générale

« Choose a job you love, and you will never have to work a day in your life »

Les yeux humains sont constitués de composants structurels pouvant donner des indications sur l'état du corps humain. La rétinopathie diabétique est l'une des maladies touchant les yeux et qui cause des dommages à la rétine. Cette pathologie a un impact majeur sur la vision humaine. Elle est causée par une souffrance prolongée du diabète sucré pouvant entraîner la cécité. Le nombre croissant de personnes atteintes de diabète dans le monde suggère que la RD continuera d'être un facteur majeur de perte de vision. Le dépistage et la détection précoce de la rétinopathie diabétique est donc très importante. Par conséquent, un système automatisé capable de détecter des anomalies dans une image du fond d'œil rétinien est très utile pour fournir des informations rapides afin d'éviter tout dommage supplémentaire à la rétine. Un dépistage annuel est proposé à tous les diabétiques âgés de plus de 12 ans. Cependant, l'augmentation globale du nombre de patients diagnostiqués avec le diabète sucré, associée aux coûts et exigences croissants sur ce système de dépistage signifie que les méthodes pour semi-automatiser ou aider les cliniciens sont très demandées.

De nombreux tests physiques, tels que la mesure de l'acuité visuelle, la dilatation des pupilles, la rétinographie rétinienne, l'angiographie rétinienne, ou encore la tomographie par cohérence optique, peuvent être utilisés pour détecter la rétinopathie diabétique, il s'agit de tests très efficaces pour le diagnostic et le dépistage de la RD. La RD est classée en deux grandes catégories : la RD non proliférante (RDNP) représentant le stade précoce de la RD, elle est classée à son tour sous trois formes : légère, modérée et sévère. Et la RD proliférante (RDP).

Motivations et challenges

La médecine moderne a besoin d'une assistance informatique pour la détection, le diagnostic et la classification de certaines maladies en très peu de temps,

d'où la nécessité d'un système de classification. Ces dernières années, plusieurs études ont été menées pour développer des outils de diagnostic et de classification de la Rétinopathie Diabétique. L'utilisation de méthodes intelligentes pour effectuer cette classification devient de plus en plus fréquente. Bien que la décision du médecin soit le facteur le plus critique dans le diagnostic, les systèmes d'assistance médicale sont même considérés comme essentiels dans de nombreuses disciplines médicales. En pratique, de nombreuses applications résultent d'un apprentissage automatique et permettent d'assister les cliniciens dans leurs procédures de diagnostic, car ils peuvent fournir un diagnostic plus précis et réduire les erreurs dues à la fatigue et aux doutes du médecin. L'apprentissage automatique a pour but de concevoir des modèles efficaces d'un système à partir d'un ensemble d'exemples représentatifs d'une population de données. Parmi les types d'apprentissage automatique, l'apprentissage supervisé déduit automatiquement des règles d'un ensemble d'apprentissage étiqueté. Cette technique consiste à prédire la classe de nouvelles données observées à l'aide de modèles de classification (classificateurs) tels que les arbres de décision, les réseaux de neurones, les k-plus proches voisins, les séparateurs à vaste marge, etc.

La recherche sur la détection précoce de la rétinopathie diabétique s'inspire du désir de sauver la vision du patient. Elle a également été inspirée par la nécessité d'aider les médecins à prendre de meilleures décisions pendant le processus de diagnostic. Cependant, plusieurs facteurs affectent les résultats de la détection. Par exemple, les hémorragies et les exsudats sont deux signes différents de la RD qui doivent être détectés séparément. En outre, les hémorragies et les exsudats ont une couleur similaire à celle des vaisseaux sanguins et du disque optique de la rétine, respectivement. Ainsi, un algorithme efficace devrait pouvoir distinguer les indicateurs de la maladie des caractéristiques normales des images du fond d'œil. Par exemple, les vaisseaux sanguins ont une forme différente de celle des hémorragies et le disque optique possède une taille plus importante que les exsudats. En outre, la recherche porte également sur la classification des images rétinienne sous différentes classes. Ici, un certain nombre de caractéristiques doivent être définies pour que l'algorithme puisse différencier les classes de la RD.

La RD est considérée comme étant un trouble médical grave favorisée par trois principaux facteurs qui sont, la durée de la maladie, le type de diabète sucré et l'âge du patient. Par exemple, la probabilité de développer une RD est de 50 % pour une personne atteinte de diabète depuis 10 ans. Cependant, le risque augmente jusqu'à 90% pour une durée de diabète de trente années. La probabilité de développer une RD chez les personnes atteintes de diabète de type 2 est de 5 %. En outre, selon l'organisation mondiale de la santé, après 15 ans de diabète, 2 % des patients ayant une RD sont aveugles et 10 % souffrent de graves problèmes de vision.

Dans cette thèse, nous proposons une nouvelle approche pour la détection et la classification automatiques des degrés de la RD à partir des images du fond d'œil rétinien est proposée. Différents algorithmes sont développés et utilisés

pour extraire les microanévrismes, les hémorragies, les exsudats, les vaisseaux sanguins, la macula et le disque optique. Les vaisseaux sanguins, la macula et le disque optique sont supprimés des images. En appliquant ces algorithmes, la RD est détectée. Dans la partie de la classification, douze caractéristiques sont définies. Ensuite, la méthodologie est testée en termes de sensibilité et de précision pour évaluer les performances de nos algorithmes.

La détection et la classification de la RD dépendent de plusieurs facteurs :

1. Sélection de la base de données : Il existe plusieurs bases de données publiques pour les images du fond d'œil rétinien. Par conséquent, le premier défi consiste à choisir la base de données appropriée.

2. Suppression des objets compromettant la détection et extraction de lésions candidates : pour bien détecter la RD, les objets similaires aux lésions doivent être supprimés de l'image. Par exemple, les vaisseaux sanguins et les hémorragies ont une intensité sombre, les exsudats et le disque optique ont une intensité lumineuse. Le défi consiste ici à extraire uniquement les exsudats et les hémorragies, et à retirer les autres objets.

3. Algorithmes : comme les lésions de la RD ressemblent à certains objets dans les images rétiniennes, plusieurs algorithmes ont été recherchés et modifiés afin d'en extraire les lésions et de filtrer les autres objets de l'image.

4. Définitions des caractéristiques : Un certain nombre de fonctionnalités peut être définies à partir des images considérées et du processus de détection de la RD. Cependant, le défi consiste à sélectionner les fonctionnalités appropriées afin de réduire le temps de détection. Pour ce faire, diverses caractéristiques expliquant les différences entre les images normales et anormales ont été définies et les plus appropriées ont été sélectionnées. De plus un autre objectif auquel nous nous intéressons tout particulièrement est celui de former le classifieur à partir des fonctionnalités sélectionnées.

5. Sélection des classifieurs pour réaliser la classification : Comme il existe plusieurs types de classificateurs, le défi est de choisir un ou plusieurs capables de réaliser la fastidieuse tâche de la classification et de pouvoir reconnaître efficacement chaque degré de la RD.

Buts et Objectifs

Cette thèse porte principalement sur la détection et la prédiction de la rétinopathie diabétique non proliférante, ainsi que sur l'analyse de différents algorithmes de prédiction. Des algorithmes d'apprentissage automatique tels que le KNN, les réseaux de neurones, le SVM, les arbres de décision, et l'analyse discriminante linéaire, peuvent être formés en leur fournissant des jeux de données d'apprentissage. Ces algorithmes peuvent ensuite prédire le degré de la RD en comparant les données fournies aux jeux de données d'apprentissage. Notre ob-

jectif est de former nos algorithmes en leur fournissant des jeux de données d'apprentissage dans le but de détecter la rétinopathie diabétique non proliférante à l'aide de différents types d'algorithmes de classification.

L'objectif de cette thèse est de pouvoir dépister les maladies de la rétine liées au diabète (la rétinopathie diabétique). Un système capable de diriger correctement les patients vers un expert si un problème de rétine est détecté serait d'une grande aide pour les patients diabétiques, qui peuvent être dépistés à distance et à moindre coût et pour les ophtalmologistes qui ne seraient pas en mesure de répondre aux demandes de santé d'une population croissante de diabétiques. Les algorithmes de traitement d'image, de reconnaissance des formes et d'apprentissage automatique de pointe ont été étudiés et une série de nouvelles techniques ont été développées et testées pour atteindre cet objectif.

Contributions

La plupart des travaux de recherche orientés vers la détection et la classification automatiques de la Rétinopathie Diabétique suivent des étapes similaires de traitement des images. La performance des algorithmes affecte très fortement le résultat final de la détection à chaque étape. En effet, les résultats de l'étape de segmentation des lésions rétinienne reposent principalement sur l'étape de prétraitement. Plus l'image est claire et lumineuse, meilleurs seront les résultats de la détection des pathologies secondaires au diabète. Et plus la détection des lésions est précise, meilleure sera la classification de la Rétinopathie Diabétique Non Proliférante. Par conséquent, afin de mener à bien ce travail de thèse, il est primordial de prêter une très grande attention à chaque phase de notre algorithme. Cette thèse contribue alors à différentes échelles du traitement de l'image. En fait, chaque contribution est un outil distinct qui peut être utilisé par les chercheurs et / ou les médecins.

Dans ce travail, nous avons d'abord automatisé la détection des trois pathologies rétinienne typiques de la RDNP, à savoir : Les Microanévrismes, les Hémorragies, et les Exsudats, à partir des images de fond d'œil. L'utilisation de toutes ces informations dans le processus d'apprentissage et de reconnaissance de la RD est l'une des contributions majeures de la méthode proposée.

La seconde contribution réside dans nos algorithmes de détection, qui grâce à un bon prétraitement et à une bonne segmentation, ont pu améliorer les résultats de performance des chercheurs précédents dans ce domaine.

Et la dernière contribution de cette thèse consiste à sélectionner des fonctionnalités pertinentes permettant de former un classificateur afin de trier les images du fond d'œil en quatre classes de la RDNP. Pour ce faire, une série de machine learning a été implémentée, couronnée d'un vote majoritaire. Ce dernier va augmenter la précision de nos algorithmes et offrir une bonne initiative à l'aide au diagnostic en Ophtalmologie.

Orientation de la Thèse

Le chapitre 1 traite de la problématique de la thèse qui est la Rétinopathie Diabétique due au diabète. Dans ce chapitre tous les détails de cette pathologie seront décrits.

Le chapitre 2 est consacré aux revues de la littérature. Ce chapitre se compose de notre référentiel de collecte d'informations. Il comprend les travaux et les recherches effectués par d'autres chercheurs, qui sont liés à notre travail de thèse de nombreuses façons. Dans ce chapitre une connaissance sur les algorithmes d'apprentissage automatique est également donnée.

Le chapitre 3 est le cœur de la thèse. Il comprend toute la méthodologie développée d'un système d'aide au diagnostic pour le dépistage de la RD. Tous les algorithmes de prétraitement, de détection, et de classification seront traités dans ce chapitre.

Le chapitre 4 est l'évaluation expérimentale de nos résultats, où nous avons montré les algorithmes d'apprentissage automatique, dont le modèle offre une précision maximale et une meilleure prédiction. Pour l'analyse, nous avons utilisé des performances pertinentes pour juger de la fiabilité de notre système.

Ce travail est terminé avec une conclusion récapitulant les différents travaux réalisés dans le cadre de cette thèse, et propose également les perspectives des futurs travaux de recherche dans le domaine.

Chapitre 1

La Rétinopathie Diabétique : Une complication du diabète

" The only thing worse than being blind is having sight but no vision "
Helen Keller

Ce chapitre va initier le lecteur à bien comprendre la problématique traitée dans cette thèse, qui est la Rétinopathie Diabétique. Nous allons révéler la gravité de cette maladie classée parmi les plus graves du fait qu'elle peut mener le diabétique à la cécité si son dépistage ne s'est pas fait précocement.

1 La rétine

La rétine est une feuille multicouche composée de neurones, de photorécepteurs et de cellules de soutien. Les photorécepteurs (les bâtonnets et les cônes), convertissent la lumière en ondes électromagnétiques, qui sont ensuite transmises au cortex visuel du cerveau par le nerf optique. C'est un organe métaboliquement actif ; par conséquent, il est très sensible aux échanges et à la diffusion des nutriments et des gaz. Lorsque des rayons de lumière pénètrent dans l'œil en se concentrant sur la rétine, celle-ci réagit en les envoyant au cerveau. Ensuite, le cerveau les interprète comme une image.

La surface de la rétine humaine est de 1094 mm², calculée à partir de l'hypothèse que la longueur moyenne de l'œil humain est de 22 mm des pôles antérieur et postérieur et que la rétine occupe 72 % de la surface à l'intérieur du globe. [2]

La (Figure 1.2) montre les caractéristiques les plus pertinentes de la rétine, qui sont les artères, les veines, le disque optique et la fovéa. Les dimensions du disque optique sont en moyenne de 1,86 mm verticalement et de 1,75 mm horizontalement. Agurto et al. [3], ont mesuré la variation du diamètre de la taille du disque sur plusieurs individus. Ils ont trouvé une plage de 0,96 à 2,91 mm pour l'axe vertical et de 0,91 à 2,61 mm pour l'axe horizontal.

La fovéa est un repère extrêmement critique de la rétine, car elle contient la plus grande concentration de photorécepteurs dans la rétine. La fovéa est située au centre de la macula, à 1,5 mm de la rétine centrale. Elle représente le centre ou le pic de la résolution visuelle la plus élevée et le site de la vision couleur la plus détaillée. La macula normale apparaît plus sombre que le reste de la rétine en raison d'une augmentation de la quantité de mélanine à cet endroit, qui est un pigment qui aide à absorber la lumière. Toute maladie affectant la macula affectera certainement l'acuité visuelle. La dégénérescence maculaire liée à l'âge, connue sous le nom de la DMLA, est une cause relativement fréquente de la perte visuelle centrale acquise chez les plus de 60 ans. Dans ce trouble, la macula est touchée par la dégénérescence de l'une des couches postérieures de la rétine ou par de nouveaux vaisseaux sanguins aberrants qui se développent et saignent dans la rétine, entraînant une destruction de la vision centrale.

La rétine reçoit son approvisionnement en sang de deux sources : la choriocapillaire et les branches de l'artère centrale de la rétine. La choriocapillaire fournit le tiers externe de la rétine, tandis que les branches de l'artère centrale de la rétine fournissent les deux tiers internes de la rétine [4]. La figure suivante, illustre l'anatomie de l'œil humain ainsi que les différentes couches de la rétine.

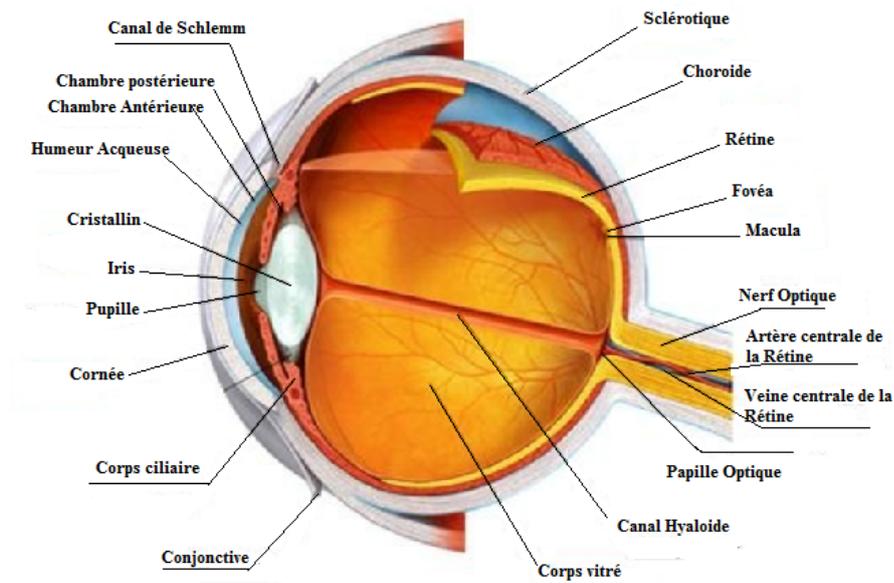


FIGURE 1.1 – Photographie d’un fond d’œil rétinien avec ses principales composantes




FIGURE 1.2 – Anatomie de l’œil humain et ses couches rétiniennes

2 Le diabète

Le diabète est une maladie chronique du métabolisme caractérisé par une hyperglycémie (glycémie élevée), résultant d’une anomalie de la sécrétion d’insuline. L’insuline est une hormone fabriquée par les cellules du pancréas et elle

est essentielle pour aider le glucose à pénétrer dans les cellules du corps afin de maintenir l'énergie et le fonctionnement du cerveau. Il s'agit de la principale hormone régulatrice du carburant dans le corps et la survie de l'homme en dépend. Il existe trois types de diabète différents ; le diabète de type 1, le diabète de type 2 et le diabète gestationnel. Le diabète de type 1 est associé à un manque absolu de production d'insuline et représente 5 à 10 % des diabétiques. Il était auparavant connu sous le nom de diabète juvénile. Il est observé suite à une destruction auto-immune des cellules bêta du pancréas par médiation cellulaire. Les patients diagnostiqués du type 1, ont besoin d'injections d'insuline pour le reste de leur vie. Ce type de diabète est diagnostiqué le plus souvent chez les enfants âgés de 9 à 16 ans. Le diabète de type 2, également appelé diabète de l'adulte, représente environ 90 à 95 % des diabétiques. Cette grande catégorie de diabétiques comprend les personnes qui ont une résistance à l'insuline et qui peuvent avoir un déficit relatif en insuline. L'un des principaux facteurs déclencheurs de ce type de diabète est l'obésité qui provoque un certain degré de résistance à l'insuline. En outre, il est souvent associé à une forte prédisposition génétique, plus que le type 1. Cependant, la génétique est complexe et n'est pas clairement définie. Quant au diabète gestationnel, il est observé pendant la grossesse, il est défini comme tout degré d'intolérance au glucose. Une personne non diabétique et enceinte peut enregistrer une augmentation de sa glycémie. Dans certains cas, les femmes qui contractent ce type de diabète développent un diabète de type 2 déclaré après la grossesse. Environ 7 % de toutes les grossesses sont compliquées par le diabète gestationnel, entraînant plus de 200 000 cas par an [5].

La présence de diabète dans le monde augmente rapidement. De mauvaises habitudes alimentaires et le manque d'exercice, sont les facteurs majeurs contribuant au diabète de type 2 [6]. Selon la Fédération internationale du diabète (FID), il y aurait 425 millions de cas de diabète dans le monde en 2017, ce nombre devrait passer à 622 millions d'ici 2040 [7]. Les patients diabétiques qui ne contrôlent pas leur taux de sucre dans le sang sont plus vulnérables aux autres maladies associées à la co-morbidité. Un risque potentiel auquel les diabétiques peuvent faire face est que l'excès de glucose puisse adhérer aux protéines dans les vaisseaux sanguins, modifiant ainsi leur structure régulière et leur fonctionnement normal. En fait, le diabète peut rendre les vaisseaux plus épais et plus rigides, ce qui peut réduire le flux sanguin. Dans la néphropathie diabétique, les vaisseaux sanguins du rein peuvent également présenter des fuites, ce qui permet aux protéines d'être excrétées avec l'urine. À la fin, certains vaisseaux éclatent et mettent davantage de pression sur les vaisseaux restants. L'augmentation de la charge dans ces vaisseaux peut également les endommager et, à son tour, le rein peut faire défaut, nécessitant une dialyse ou une greffe de rein.

Les nerfs peuvent également être endommagés à la suite du diabète. Les nerfs nous permettent de détecter la température, la pression, la texture ou la douleur. Chez la plupart des personnes atteintes de diabète, les lésions nerveuses (neuropathie diabétique) affectent les pieds et le bas des jambes, provoquant des engourdissements ou des picotements. Les personnes atteintes de neuropathie diabétique peuvent contracter des blessures au pied, telles que des plaies ouvertes, mais ne réalisent pas qu'elles en souffrent en raison de la perte de sensation due à des lésions nerveuses. De telles blessures peuvent entraîner des infections graves

et des ulcérations qui peuvent progresser rapidement. La conséquence extrême d'une infection non traitée chez un diabétique est une amputation du pied ou de la jambe due à la progression de la gangrène qui peut mettre la vie du malade en danger. Enfin, les dommages oculaires et la perception visuelle du monde peuvent avoir le plus d'incidence sur la qualité de vie des diabétiques. La maladie oculaire présente dans la rétine est appelée rétinopathie, par conséquent, les lésions et les changements tissulaires de la rétine qui résultent du diabète sont appelés Rétinopathie Diabétique. Dans ce chapitre, nous allons nous concentrer sur cette maladie et ses différents stades de gravité.

3 La Rétinopathie Diabétique (RD)

La RD est une complication du diabète qui affecte l'œil, plus précisément la rétine. Elle est causée par des lésions des vaisseaux sanguins du tissu photosensible situé à l'arrière de l'œil (rétine). Elle est considérée comme une complication vasculaire très spécifique du diabète de types 1 et 2, avec une prévalence fortement liée à la durée du diabète.

Au début de cette maladie, le patient diabétique peut ne ressentir aucun symptôme car elle est asymptomatique, elle évolue dans la plus grande discrétion dans la plupart des cas, cependant la personne atteinte peut avoir de légers problèmes de vision, par conséquent, les diabétiques n'envisagent pas d'être examinés régulièrement. Au fur et à mesure que la maladie progresse, les symptômes de la rétinopathie diabétique peuvent inclure des tâches sombres flottant dans la vision, une vision floue ou fluctuante, une diminution de la vision des couleurs, des zones sombres ou des vides dans la vision, ou encore une perte de la vision. Au fil du temps, une trop grande quantité de sucre dans le sang peut entraîner le blocage des minuscules vaisseaux sanguins qui nourrissent la rétine, coupant ainsi l'apport en sang. En conséquence, l'œil tente de développer de nouveaux vaisseaux sanguins, qui ne peuvent pas se développer correctement, et donc ils sont susceptibles de fuir très facilement. Cependant, une fois que la RD est déclarée, les examens oculaires effectués par un ophtalmologiste nécessiteront une surveillance et des visites plus fréquentes. Un diagnostic et une prise en charge précoce peuvent sauver la vision des patients, car la RD est la cause la plus fréquente de nouveaux cas de cécité dans le monde. Outre la durée du diabète, l'hyperglycémie chronique, la néphropathie et l'hypertension sont d'autres facteurs qui augmentent le risque de développer une rétinopathie [8].

La RD affecte malheureusement près de la moitié de la population atteinte de diabète [1]. La prévalence mondiale du diabète est en augmentation constante.



FIGURE 1.3 – Vision d'un diabétique en phase proliférative [1]

En résumé, la RD commence lorsque le diabète sucré endommage les petits vaisseaux sanguins de la rétine, provoquant des microanévrismes (MAs), correspondant à de petites enflures se formant du côté des petits vaisseaux sanguins. L'évolution de la maladie est caractérisée par l'apparition des hémorragies profondes dans la rétine. Les hémorragies rétinienne peuvent causer de graves problèmes de vision. À mesure que la maladie progresse, la rétine réagit en développant des vaisseaux sanguins anormalement faibles, présentant des fuites, ces nouveaux vaisseaux sont très fragiles et mal dirigés. Plus ces vaisseaux sanguins anormaux se développent, et plus ils saignent dans la rétine. En outre, le fluide qui a fuit dans la rétine va produire des sédiments composés de sous-produits lipidiques appelés exsudats. Ils sont jaunes et apparaissent sous différentes tailles et différents emplacements dans la rétine.

Il n'y a pas de symptômes précoces pour la rétinopathie diabétique, car les patients ne souffrent pas de problèmes de vision jusqu'aux stades avancés de la maladie, lorsque les traitements pourraient être inefficaces malheureusement. Par conséquent, un diagnostic précoce de la RD est essentiel afin d'empêcher l'évolution de la maladie. La figure suivante montre un exemple de deux fonds d'œil rétinien, le premier est sain et le second atteint d'une RD.




FIGURE 1.4 – Deux fonds d’œil rétiniens. (a) Patient sain ; (b) Patient présentant une RD.

4 Classification des stades de la Rétinopathie Diabétique

La rétinopathie diabétique est classée par les ophtalmologues sous deux types :

- **Rétinopathie Diabétique Non Proliférante (RDNP)** - On parle d’une rétinopathie précoce où les nouveaux vaisseaux sanguins ne se développent pas (prolifèrent). Les parois des vaisseaux sanguins de la rétine s’affaiblissent. De minuscules bombements correspondants aux microanévrismes surgissent des parois vasculaires des plus petits vaisseaux, laissant parfois échapper du liquide et du sang dans la rétine. Les vaisseaux rétiniens plus grands peuvent commencer à se dilater et à avoir un diamètre irrégulier. La RDNP peut progresser du stade minime au stade sévère, à mesure que davantage de vaisseaux sanguins sont obstrués. Les fibres nerveuses de la rétine peuvent commencer à gonfler. Parfois, la partie centrale de la rétine (macula) commence à gonfler (œdème maculaire), une maladie qui nécessite un traitement.
- **Rétinopathie Diabétique Proliférante (RDP)** - On parle alors d’une rétinopathie avancée. Dans ce type, les vaisseaux sanguins endommagés se ferment, ce qui provoque la croissance de nouveaux vaisseaux sanguins anormaux (néovascularisation) dans la rétine qui peuvent s’infiltrer dans la substance transparente de type gelée qui remplit le centre de l’œil (vitré), pour combler le manque d’oxygène auquel elle est confrontée. Ces nouveaux vaisseaux sont une tentative avortée de la rétine de regagner ses besoins en oxygène, mais ces vaisseaux sont compromis et fragile. Ils se brisent facilement, provoquant des saignements importants dans le gel vitreux de

l'œil et une perte de vision en est la conséquence. De plus, ces nouveaux vaisseaux peuvent s'attacher au gel vitreux et provoquer une traction sur le plan rétinien, entraînant un décollement de la rétine. Si les nouveaux vaisseaux sanguins gênent l'écoulement normal du liquide hors de l'œil, une pression peut s'accumuler dans le globe oculaire. Cela peut endommager le nerf qui transporte les images de l'œil vers le cerveau via le nerf optique, entraînant un glaucome.

La RDNP est quand à elle classée par l'Institut International du Diabète [9], sous quatre stades allant du moins grave au plus sévère.

- Absence de Rétinopathie Diabétique : A ce stade aucun signe clinique apparent n'est observé chez les patients diabétiques, néanmoins ils doivent conserver un mode de vie et une hygiène très contrôlés, et continuer les visites systématiques des diabétiques pour le dépistage précoce et la prévention de la cécité.
- Rétinopathie Diabétique non Proliférative légère : ici, quelques microanévrismes, définis comme de petites contusions dans les parois des petits vaisseaux sanguins (appelés capillaires), apparaissent dans la rétine.
- Rétinopathie Diabétique non proliférative modérée : on observe dans ce cas plus de lésions rétiniennes comparativement au stade précédent. La rétine présente un manque de circulation sanguine, et donc un manque d'oxygène menant à une ischémie résultante de l'endommagement des capillaires qui nourrissent le tissu rétinien.
- Rétinopathie Diabétique non proliférante sévère ou Pré-proliférative : À ce niveau de la RD, de nombreux vaisseaux sanguins sont affectés. L'approvisionnement en oxygène de la rétine par les vaisseaux sanguins est gravement compromis par l'accumulation des dommages. Lorsque cela se produit, certaines zones de la rétine commencent à envoyer des signaux biochimiques au corps indiquant qu'il a besoin d'oxygène.

Les différents stades de la RD	Appellations	Signes cliniques
0	Absence de RD	Absence de tout signe clinique
1	RDNP minime	Apparition de quelques Microanérismes sur les images du fond d'œil.
2	RDNP modérée	<ul style="list-style-type: none"> • Plus de MAs • Hémorragies rétinienne punctiformes • Exsudats secs et mous
3	RDNP sévère ou RD Pré-proliférante	En plus de tous les signes cités précédemment, on peut avoir aussi des modifications veineuses ainsi que des hémorragies intra-rétiniennes étendues.
4	Rétinopathie Diabétique Proliférante	<ul style="list-style-type: none"> ❖ Néovaisseaux pré-rétiniens ❖ Néovaisseaux prépapillaires

La RD peut progresser de deux manières, comme illustré sur la Figure 1.5, soit vers la rétinopathie proliférative décrite précédemment, ou bien vers une maculopathie, que l'on appelle œdème maculaire diabétique (OMD). Comme son nom l'indique, la maculopathie est une maladie qui touche la macula, la partie de la rétine la plus sensible à la lumière. Cette condition survient lorsque du liquide pénètre dans la macula, ce qui la fait gonfler et provoquer ainsi une vision floue. Cette maladie est très fréquente chez les patients atteints de rétinopathie proliférative, touchant jusqu'à 50 % des cas.

- Contrôle de la glycémie : des études démontrent que le contrôle de la glycémie aide à retarder la progression de la RD chez les deux types de diabète [10], [11].

- Pression artérielle : L'hypertension artérielle chez les diabétiques est caractérisée par l'apparition de microanévrismes, d'hémorragies, de nodules cotonneux, et d'un gonflement du nerf optique, qui est liée au niveau de la pression artérielle systolique.

- Maladie rénale : cette maladie peut être associée à la présence de RD et vice versa [12].

Les autres facteurs associés à la progression croissante de la RD sont : le tabagisme, l'anémie, la grossesse et les lipides sériques [12].

4.1 Les complications associées à la RD

La rétinopathie diabétique implique une croissance anormale des vaisseaux sanguins dans la rétine. Les complications peuvent entraîner de graves problèmes de la vision :

- **Hémorragie vitréenne** - Les nouveaux vaisseaux sanguins peuvent saigner dans la substance transparente, semblable à une gelée, qui remplit le centre de l'œil. Si la quantité de saignement est faible, il est possible de ne voir que quelques points noirs (corps flottants). Dans les cas plus graves, le sang peut remplir la cavité vitréenne et bloquer complètement la vision. Une hé-

morragie du vitré en soi ne provoque généralement pas de perte de vision permanente. Le sang disparaît souvent en quelques semaines ou quelques mois. À moins que la rétine ne soit endommagée, la vision peut revenir à sa clarté précédente.

- **Décollement de la rétine** - Les vaisseaux sanguins anormaux associés à la rétinopathie diabétique stimulent la croissance du tissu cicatriciel, ce qui peut éloigner la rétine de l'arrière de l'œil. Cela peut provoquer des tâches dans la vision, ou une perte de vision sévère.
- **Glaucome** - De nouveaux vaisseaux sanguins peuvent se développer à l'avant de l'œil et interférer avec l'écoulement normal du liquide hors de l'œil, provoquant une augmentation de la pression dans l'œil (glaucome). Cette pression peut endommager le nerf optique responsable de la transportation des images de l'œil vers le cerveau.
- **Cécité** - Finalement, la rétinopathie diabétique, le glaucome ou les deux peuvent entraîner une perte de vision complète.

5 Description des lésions caractéristiques de la RDNP et de la RDP

La RD est caractérisée par la présence de lésions typiques normalement inexistantes sur une photographie du fond d'œil d'un patient sain. La RDNP présente trois signes cliniques considérés comme des lésions précoces dans l'évolution de la RD. Ces lésions consistent dans l'apparition des Microanévrismes, des hémorragies, et des exsudats sur les images rétinienne. Plus la maladie évolue, et plus le nombre de lésions augmente. C'est pour cela que le dépistage précoce est la clé de la préservation de la vision des diabétiques. La RDP est quant à elle caractérisée par des lésions bien plus graves et bien plus avancées que la RDNP, notamment en l'apparition de nouveaux vaisseaux sanguins pouvant causer la cécité.

Toutes ces lésions seront citées ci-dessous :

- **Les Microanévrismes (MAs)**

Ce sont les premiers signes évocateurs de la RD. Ils apparaissent dans les capillaires rétiniens sous forme de toutes petites tâches rondes et rouges, comme le montre la figure 1. 6.b. Leur diamètre est compris entre 10 et 100 μm [13]. Ils ont des limites claires et bien définies. Les MAs sont réversibles si le contrôle de la glycémie est amélioré. La rupture des MAs et l'augmentation de la perméabilité capillaire donnent lieu à des hémorragies intra-rétiniennes. Les MAs peuvent apparaître et disparaître de façon transitoire au fil du temps. Il s'agit sûrement de la première maladie présente dans la RD, et demeurant tout au long de son évolution.

- **Les Hémorragies en point ou en tâche**

Il s'agit d'une fuite de sang dans la couche nucléaire interne. Elles apparaissent en rouge foncé et ont également une forme circulaire présentes dans les plus profondes couches de la rétine (Figure 1.6.c), disposées verticalement. Leurs bords peuvent être plus irréguliers et moins bien définis que les MAs. Les hémorragies ponctuelles ne dépassent guère les 200 μm [13].

- **Les nodules cotonneux ou exsudats mous**

Ils sont secondaires au manque d'oxygène dans la rétine, appelé ischémie, cela provoque des lésions sur la couche des fibres nerveuses de la rétine. Le résultat de ces dommages consiste en un gonflement de l'axoplasme de cette couche. Dans les images du fond d'œil, ces lésions apparaissent comme des plaques blanches gonflées.

- **Les Exsudats durs (EXs)**

Le système vasculaire est endommagé par la RD et n'assure donc plus la perméabilité, ce qui permet aux lipides (graisses) avec de l'eau de traverser les vaisseaux jusqu'à la couche nucléaire interne. Après un certain temps, l'eau revient mais les lipides restent dans la couche. Ces dépôts lipidiques sont appelés EXs durs. Ils ont généralement une couleur jaune vive avec des limites irrégulières. Dans la plupart des cas ils se trouvent sous forme d'anneau.




FIGURE 1.5 – Pathologies de la RD ; (a) Fond d'œil rétinien contenant les quatre lésions de la RDNP, (b) Microanévrismes, (c) Hémorragies, (d) Exsudats durs, (e) Nodules cotonneux.

- **Perlage veineux**

C'est une anomalie vasculaire, qui se produit lorsque les capillaires se ferment suite à une ischémie. Plutôt que de lisser les parois des vaisseaux, les veines vont apparaître très irrégulières, un peu comme des perles enfilées dans un collier (d'où leur nom). Le perlage veineux est une découverte significative pour la catégorie sévère de la RD.




FIGURE 1.6 – Anomalies Veineuses

- **Anomalies microvasculaires intra-rétiniennes (AMIR)**

Il existe deux théories à propos des AMIR. L'une les définit comme de nouveaux vaisseaux se développant dans les couches de la rétine. Et l'autre les définit comme étant des restes dilatés de capillaires situés dans une vaste zone d'occlusion capillaire. L'angiographie à la fluorescéine tend à favoriser cette dernière théorie puisque les AMIR se trouvent généralement dans les zones d'occlusion capillaire.

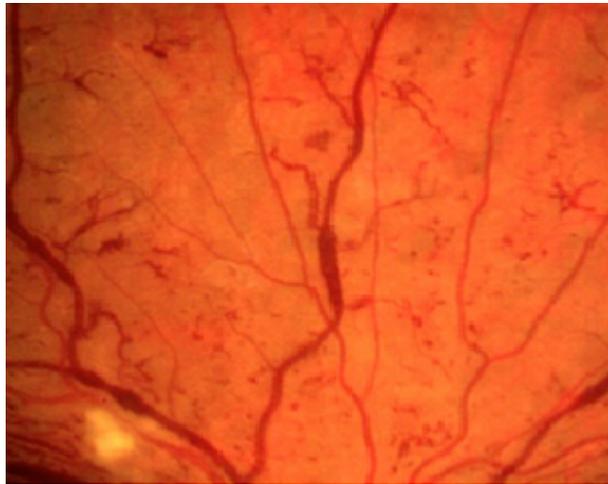


FIGURE 1.7 – Présence des AMIR sur un fond d'œil diabétique

- **La Néovascularisation**

De grandes zones d'ischémie (manque d'oxygène) peuvent être présentes dans la rétine. Lorsque le corps détecte qu'il n'y a pas assez d'oxygène fourni à la rétine, il produit une protéine appelée facteur de croissance de l'endothélium vasculaire responsable de la croissance de nouveaux vaisseaux présents pour compenser l'absence d'oxygène dans la rétine. Le problème est que ces nouveaux vaisseaux sont faibles et saignent facilement, ce qui entraîne des complications telles que

des hémorragies du corps vitré et un glaucome néovasculaire. Lorsque la néovascularisation est présente à proximité du disque optique (dans la limite d'un diamètre de disque centré dans le disque optique), on parle alors d'une néovascularisation du disque (NVD).



FIGURE 1.8 – Néovaisseaux prépapillaire et pré-rétinien

Lorsque la RD est à un stade très avancé, un décollement de la rétine peut survenir. Si cela n'est pas traité immédiatement, une perte de vision permanente se produit.

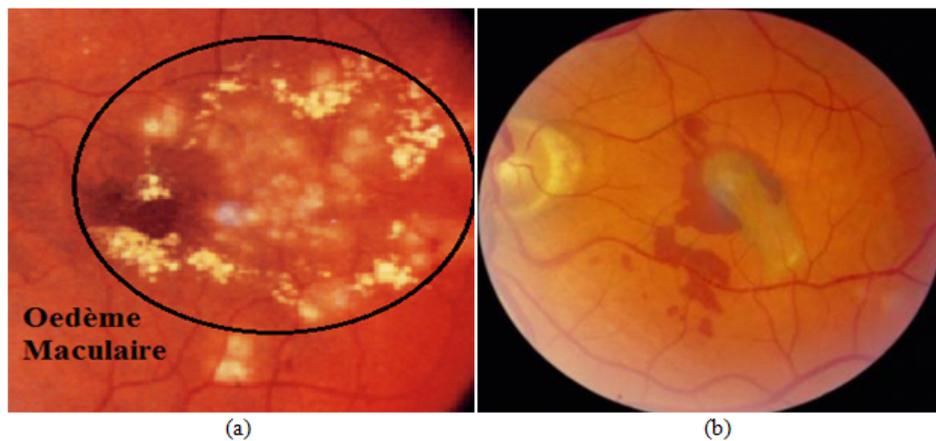


FIGURE 1.9 – (a) œdème maculaire ; (b) Décollement de la rétine

6 Les dispositifs d'acquisition des images rétinienne

6.1 Histoire de l'imagerie

La première tentative d'imagerie de la rétine a été réalisée par le médecin français Jean Mery chez un chat, il a montré que lorsqu'on immerge un chat vivant

dans l'eau, ses vaisseaux rétiniens deviennent visibles de l'extérieur. L'impraticabilité d'une telle approche chez l'homme a conduit à l'invention des principes de l'ophtalmoscope. Il a été inventé par le scientifique tchèque Jan Evangelista Purkinje en 1823, puis amélioré en 1845 par Charles Babbage [14], [15]. Enfin, l'ophtalmoscope a été réinventé et rapporté par Von Helmholtz en 1851 [?]. Ainsi, l'inspection et l'évaluation de la rétine devinrent une routine pour les ophtalmologistes et les premières images de la rétine furent publiées par l'ophtalmologiste néerlandais van Trigt en 1853. Les premières images photographiques utiles de la rétine, montrant des vaisseaux sanguins, ont été obtenues en 1891 par l'ophtalmologiste allemand Gerloff. En 1910 [16], Gullstrand développa la caméra du fond d'œil, un concept encore utilisé aujourd'hui pour imager la rétine. Le développement important suivant a été l'invention de l'imagerie angiographique à la fluorescéine, dans laquelle une caméra de type fond d'œil avec des filtres à bande étroite supplémentaires est utilisée pour imager un colorant fluorescent injecté dans le sang qui se lie aux leucocytes [17]. Il reste largement utilisé car il permet de comprendre l'état fonctionnel de la circulation rétinienne. Les préoccupations concernant la sécurité et la rentabilité conduisent à le remplacer lentement par des méthodes d'imagerie tomographique pour ses applications principales, à savoir le traitement guidé par image de l'œdème maculaire et la «forme humide» de la dégénérescence maculaire.

6.2 Les différentes techniques d'imagerie médicale

Il existe différentes techniques d'imagerie médicale pour capturer les structures internes de l'œil humain, notamment la photographie du fond d'œil et la tomographie par cohérence optique (OCT). Ces deux méthodes sont non invasives. L'OCT fournit des images en coupe transversale des tissus oculaires. Tandis que la photographie rétinienne fournit des images des structures internes de l'œil humain, y compris la rétine, le disque optique, la macula, la fovéa et les vaisseaux sanguins. Les OCT sont utiles lorsque les maladies oculaires sont diagnostiquées au niveau des tissus. En revanche, les images du fond d'œil sont très efficaces lorsque les maladies oculaires sont diagnostiquées au niveau rétinien. De plus, la photographie de fond d'œil est la technique la plus rapide et la plus facile. Elle offre un plus grand champ de rétine et est largement utilisée dans le diagnostic des maladies oculaires. Nous donnerons ci-dessous quelques définitions de ces techniques.

– Imagerie du fond d'œil rétinien

L'imagerie du fond d'œil est définie comme étant le processus par lequel une représentation 2D des tissus semi-transparents rétiniens projetés en 3D sur le plan d'imagerie est obtenue à l'aide de la lumière réfléchie. Ainsi, tout processus qui aboutit à une image en 2D, où les intensités de l'image représentent la quantité de la lumière réfléchie, est une image de fond. Les intensités des images représentent la quantité de lumière réfléchie d'une bande de fréquence spécifique. Comme les lésions de la rétinopathie sont visibles dans le fond de l'œil, l'examen peut être simplement effectué en examinant le fond des yeux du diabétique en utilisant la voie naturelle de la lumière : la

lumière est dirigée à travers la pupille vers la rétine et le fond de l'œil avec ses parties normales et anormales peut être observé de la lumière réfléchie. Une caméra rétinienne non mydriatique est utilisée. Le boîtier de l'appareil photo doit être fixé à l'unité principale et chargé avec un nouveau rouleau de diapositives couleur Kodachrome 64, 24 expositions. Les meilleures photos sont obtenues lorsque l'œil est bien dilaté, la fixation est sur la cible ; et les paupières et les cils sont tenus grands ouverts.

– **Photographie du fond d'œil en couleur**

Les intensités d'image représentent la quantité de bandes d'ondes réfléchies RVB (Rouge, Vert, Bleu), déterminée par la sensibilité spectrale du capteur. L'enregistrement de la lumière réfléchie par le fond d'œil consiste à utiliser une caméra couleur du fond d'œil. Différents filtres et une caméra à niveaux de gris peuvent également être utilisés pour capturer les longueurs d'onde intéressantes. Une méthode très courante consiste à utiliser un filtre vert pour obtenir les longueurs d'onde de la couleur verte et à enregistrer la lumière filtrée à l'aide d'une caméra à niveaux de gris. La photographie du fond d'œil est réalisée par une caméra d'aperçu, qui consiste essentiellement en un microscope spécialisé à faible consommation associé. La conception optique des caméras fond d'œil repose sur le principe de l'ophtalmoscopie indirecte monoculaire. Une caméra de fond fournit une vue verticale et agrandie du fond. Elle visualise de 30 à 50 degrés de la région rétinienne, avec un grossissement de 2,5, et permet une certaine modification de cette relation au moyen d'objectifs zoom ou auxiliaires de 15 degrés, qui fournit un grossissement de 5 à 140 degrés avec un objectif d'avoir un grand angle, qui réduit l'image de moitié.

– **La Rétinographie**

La rétinographie est un test de diagnostic utilisé par les ophtalmologistes pour obtenir une image détaillée du fond de l'œil et de la rétine. Ce type de photographie du globe oculaire permet d'examiner d'importants points de la vision tels que la macula et le disque optique.

Il existe deux types de rétinographe : Le non mydriatique, ce type de test n'a pas besoin d'une dilatation de la pupille. Et le Mydriatique, qui consiste à dilater la pupille du patient pour obtenir une image détaillée des parties les plus profondes de l'œil. Le test vise à étudier la circulation sanguine de la rétine et du nerf optique et permet à une photographie couleur de l'intérieur de l'œil de pouvoir observer la rétine en détail. Il peut arriver que les résultats de la rétinographie présentent une image opaque qui permettra au médecin d'obtenir des informations précieuses sur l'œil du patient. La rétinographie permet de diagnostiquer la rétinopathie diabétique, l'œdème maculaire diabétique, ainsi que les blessures de la rétine. Son but est de prévenir et de diagnostiquer rapidement et efficacement les lésions de la rétine et du nerf optique afin de les traiter le plus vite possible.



FIGURE 1.10 – Rétinographe non mydriatique

– **Angiographie à la fluorescéine et angiographie à l'indocyane**

Les intensités d'image représentent les quantités de photons émis par la fluorophorèse fluorescente ou l'indocyane verte injectée dans la circulation du sujet. Dans cette méthode, une injection de liquide fluorescent est administrée au patient avant la prise de l'angiogramme. Dans les angiogrammes à la fluorescéine, les parties de la rétine où circule le sang sont principalement visibles, tandis que les autres parties de la rétine apparaissent en noir. Ainsi, les vaisseaux sanguins et les microanévrismes peuvent être facilement vus du fait qu'ils apparaissent plus brillants que les autres parties de la rétine. Les lésions hémorragiques contiennent du sang qui ne coule pas et sont donc visibles sous forme de régions sombres dans les angiogrammes à la fluorescéine. Cette technique peut détecter la rétinopathie diabétique (néovascularisation), les occlusions veineuses, les occlusions de l'artère rétinienne, l'œdème du disque optique et les tumeurs.



FIGURE 1.11 – Réalisation d'un examen angiographique.

– **La tomographie par Cohérence Optique (OCT)**

L'OCT permet la visualisation et l'individualisation microscopique des différentes couches de la rétine humaine. Elle consiste en l'estimation de la profondeur à laquelle une rétrodiffusion spécifique a pris naissance en mesurant son temps de vol. Les rétrodiffusions sont généralement causées par des différences d'indice de réfraction dans les transitions d'un tissu à un autre. Les tissus les plus profonds peuvent être différenciés des tissus superficiels car il faut plus de temps à la lumière pour arriver au capteur. L'épaisseur totale de la rétine étant comprise entre 300 et 500 μm , les différences de temps de vol sont très petites et ne peuvent être mesurées que par interférométrie [18]. Il existe une grande similitude entre l'ultra-échographie et la tomographie par cohérence optique, dans le sens qu'elles se reflètent toutes les deux en réfléchissant une impulsion d'énergie sur le sujet étudié et en analysant l'énergie réfléchi. La différence réside dans le fait que l'échographie utilise des ondes sonores pouvant pénétrer une matière opaque, tandis que l'OCT utilise des ondes lumineuses ne pénétrant qu'une matière translucide. Étant donné que les ondes lumineuses ont une longueur d'onde beaucoup plus courte que les ondes sonores, il existe une résolution beaucoup plus grande et de meilleure qualité dans la présentation des images. L'OCT est actuellement le plus souvent utilisé pour examiner la macula dans la DMLA (dégénérescence maculaire liée à l'âge). Dans cette condition, les anomalies du tissu rétinien peuvent être identifiées et mesurées. En raison de sa haute résolution, les couches individuelles de la rétine peuvent être identifiées, ce qui facilite le diagnostic de l'état maculaire et rétinien.



FIGURE 1.12 – OCT

7 Traitement de la RD

Si le patient présente un RD entre les stades 1 à 3 mais ne présente pas d'œdème maculaire, aucun traitement n'est nécessaire. Il est recommandé aux patients de contrôler leur taux de sucre dans le sang et d'autres facteurs de risque tels que la pression artérielle et les lipides, car il a été prouvé que cela ralentissait la progression de la RD. Si le patient développe une rétinopathie proliférante, un traitement au laser sera recommandé, afin de réduire les nouveaux vaisseaux. Cette procédure est appelée photocoagulation pan-rétinienne. Dans cette procédure, le chirurgien fait 1000 à 2000 brûlures au laser dans la rétine en évitant la zone de la macula. En théorie, on pense que le laser cause des dommages à certaines parties de la rétine périphérique en bonne santé et provoque la régression de ces nouveaux vaisseaux fragiles. Ce traitement s'applique idéalement dans les cas où les nouveaux vaisseaux sanguins ont peu ou pas de saignements, pour une meilleure visualisation de la rétine. Une vitrectomie est nécessaire si le saignement semble être grave. Lors de cette intervention chirurgicale, le gel vitreux mélangé au sang est extrait de l'œil et rempli d'une solution saline spéciale. En cas de décollement de la rétine, la chirurgie est la seule solution. Le médecin pourrait utiliser un laser pour tenter de fixer la partie de la rétine déchirée ou une autre procédure appelée cryopexie, qui gèle la rétine autour de la déchirure, laissant une délicate cicatrice qui sécurise la rétine contre la paroi oculaire. La chirurgie ne réussit pas toujours à remettre la rétine en place. L'amélioration de la vue après une chirurgie dépend en partie du point de savoir si le détachement a affecté la partie centrale de la rétine (macula) avant la chirurgie et, le cas échéant, pendant combien de temps. La vision peut prendre plusieurs mois à s'améliorer après une chirurgie de décollement de la rétine. Certaines personnes n'améliorent pas leur vision du tout.

8 Dépistage de la rétinopathie diabétique

Le dépistage est défini comme étant le test d'une population afin d'identifier les individus présentant des attributs qui pourraient être des symptômes précoces ou des indicateurs d'une prédisposition associée à une condition particulière. Le dépistage de la rétinopathie diabétique a pour objectif principal de déterminer si les personnes doivent être référées pour un traitement ultérieur, afin de prévenir la cécité. En plus de cet objectif principal et primordial, le dépistage de la rétinopathie diabétique a d'autres objectifs. Notamment, l'identification de la maladie à un stade précoce, la détection éventuelle d'un besoin de traitement de la pression artérielle et de la glycémie, la sensibilisation des populations aux causes de la rétinopathie diabétique et aux moyens de réduire les risques ; et, potentiellement, l'identification des conditions non diabétiques à travers le processus de dépistage. Cependant, on retrouve un problème majeur qui réside dans le fait que la maladie oculaire diabétique n'interfère pas avec la vue tant qu'elle n'a pas atteint un stade avancé. Le traitement au laser peut sauver la vue, mais seulement s'il est utilisé à un stade précoce. Cela montre l'importance d'un dépistage régulier indispensable, qui peut aider à détecter les patients diabétiques à un stade précoce de la rétinopathie diabétique. De plus, l'identification précoce de tout signe de rétinopathie peut permettre des modifications de la pression artérielle ou de la gestion de la glycémie afin de ralentir la vitesse de la progression. L'imagerie rétinienne numérique est généralement utilisée comme technique de dépistage. La méthode proposée est recommandée au Royaume-Uni et par le groupe de projet national sur le dépistage de la rétine. Cependant, certains défis, tels que des mesures efficaces et rentables, doivent être prise en compte pour établir les systèmes de dépistage. Le dépistage repose sur certains principes, à savoir : la réalisation d'un dépistage rétinien régulier pour les patients diabétiques, la disponibilité d'un système de dépistage efficace, la pratique du dépistage oculaire faisant partie des soins du diabète, la participation de l'ophtalmologiste à la planification et au fonctionnement du système de dépistage et, enfin, le contrôle de la qualité du processus de dépistage. Les auteurs de l'étude [19] ont recommandé quatre étapes dans les programmes de dépistage systématique mis au point pour la rétinopathie diabétique à visée visuelle. Premièrement, un traitement efficace, un dépistage opportuniste et systématique, et enfin un contrôle complet de l'assurance qualité et de la couverture. Pendant ce temps, le travail [20] a présenté une étude sur le dépistage de la rétinopathie diabétique en Nouvelle-Zélande. Ils ont conclu que l'amélioration de la qualité du dépistage rétinien devrait inclure des données sur la qualité des plateformes d'assurance. En règle générale, dans la pratique actuelle, tous les patients diabétiques inscrits subiront d'abord le test d'acuité visuelle. Ensuite, une session de photographie du fond d'œil sera organisée à l'aide de la caméra de fond d'œil et une évaluation sera ensuite effectuée. Un expert paramédical qualifié jouera un rôle important dans la classification des images du fond d'œil capturées sous l'un des différents stades de la rétinopathie diabétique, en fonction des changements ou des anomalies montrés sur les images du fond d'œil. La gestion de la maladie, ainsi qu'un calendrier de suivi ou une référence à un ophtalmologiste pour un diagnostic plus approfondi, sera décidée en fonction du stade de la maladie.

9 La Rétinopathie Diabétique et le Traitement des images

Actuellement, les techniques de traitement des images sont largement utilisées pour diagnostiquer les maladies, notamment les maladies des yeux. Des outils d'imagerie informatiques sont nécessaires pour détecter efficacement les signes de la RD. Une détection précoce permettrait à l'ophtalmologiste de traiter les patients avant que des dommages importants ne se produisent et offrirait les meilleures chances de protéger la vision du patient. Le système de classification automatique de la rétinopathie diabétique permettrait un diagnostic plus rapide et plus efficace. Des actions préventives pourraient être entreprises tôt pour protéger la vision et éviter la cécité.

Le dépistage de la rétinopathie diabétique est actuellement un domaine de recherche courant dans lequel certains chercheurs se concentrent sur la proposition de plusieurs techniques ou méthodes de détection de certaines caractéristiques de la rétinopathie diabétique (à savoir, microanévrismes, hémorragies, exsudats et néovascularisation).

Néanmoins, certains chercheurs proposent de développer des systèmes automatisés de détection et de classification de la rétinopathie diabétique normale ou anormale.

Les systèmes de traitement d'images numériques comportent généralement trois parties principales : le prétraitement, l'extraction de caractéristiques et la classification.

10 Avantages du diagnostic et de la détection précoce de la RD

Les personnes atteintes de RD dont la vue est en danger peuvent être traitées, généralement par injection de drogues au laser ou intra-vitré. Comme les effets du diabète sur les yeux sont généralement asymptomatiques, de nombreuses personnes atteintes de diabète ne sont conscientes d'aucun changement. Si elle n'est pas gérée, la RD peut sérieusement affecter leur vision et conduire éventuellement à la cécité. La grande majorité des patients diabétiques développent une RD sans aucun symptôme, ils jugent qu'il est inutile de faire des dépistages jusqu'à ce qu'ils atteignent les derniers stades, quand leur vision centrale est affectée. Il est alors peut-être trop tard pour un traitement préventif efficace. Le dépistage de la RD est conçu pour détecter les changements précoces (asymptomatiques) menaçant la vue afin d'optimiser le moment du traitement préventif. Une réduction d'un tiers ou plus des nouvelles cécités dues au diabète a été adoptée comme l'un des objectifs clés de la recherche sur le diabète et les recherches en Europe : déclaration de Saint-Vincent, 1990, ils ont décrété que «Des examens de la vue annuels sont recommandés pour les patients diabétiques (et tous les deux ans pour les personnes ayant un excellent contrôle glycémique et aucune rétinopathie lors de l'examen précédent dans certains contextes».

Les membres de ce consortium ont dirigé la transition vers le dépistage bisannuel des patients diabétiques sans rétinopathie et ceci est maintenant recommandé par le Conseil international pour l'ophtalmologie. Cependant, le programme de dé-

pistage de la RD au Royaume-Uni continue de tester tous les patients diabétiques chaque année. Un dépistage régulier de la rétinopathie menaçant la vue des patients diabétiques pourrait optimiser le moment du traitement au laser. S'assurer que les patients sont traités à un stade optimal de la maladie peut améliorer la préservation de la vue à environ 75 %. En Islande, la prévalence de la cécité diabétique a été réduite de 4 à 5 fois après l'avènement du dépistage systématique du diabète chez les diabétiques et un succès similaire a été observé au Danemark.

11 Conclusion

La rétinopathie diabétique ne peut malheureusement pas être guérie. Pour prévenir la perte de vision, l'analyse au laser (photocoagulation) est généralement très efficace pour stopper l'évolution de la maladie, mais bien évidemment, il faudrait que cela se fasse avant que la rétine ne soit endommagée complètement. La rétinopathie diabétique non proliférative contient des indications précoces de la maladie et il est extrêmement essentiel de reconnaître et d'analyser la RD à ses débuts. Si une personne atteinte de diabète effectue régulièrement ses dépistages et réalise tous les traitements recommandés par son médecin, elle aura de fortes chances de préserver sa vision, dans le cas contraire la RD pourra l'entraîner vers la cécité. Dans cette étude sur la RD, une grande partie du travail est faite pour découvrir les microanévrismes, les hémorragies, et les exsudats, car ils indiquent la présence et l'évolution de la rétinopathie dans les images du fond d'œil. Cette étude aide à détecter la rétinopathie à un stade précoce ; le traitement opportun de cette maladie préviendra la perte de vision permanente.

Ce chapitre résume la description générale de la rétine humaine, ainsi que la prévalence du diabète, y compris l'incidence de la rétinopathie diabétique ainsi que ses signes et les principales caractéristiques de la RDNP et de la RDP. La classification et le dépistage de la RD, ainsi que le traitement de la rétinopathie diabétique et les avantages du dépistage précoce de cette maladie ont également été discutés dans ce premier chapitre de la thèse. Les dispositifs d'acquisition des images rétiniennes ont été présentés comme un outil permettant de diagnostiquer la rétinopathie diabétique de manière plus précise et plus efficace.

Chapitre 2

Revue de la littérature

" La foi est une vision des choses qui ne se voient pas "
Jean Calvin

Ce chapitre contient une revue de la littérature relative au modèle d'apprentissage supervisé, à des algorithmes de classification tels que le KNN, les réseaux de neurones, les arbres de décision, l'analyse discriminante linéaire ou encore le SVM. Ce chapitre se réfère également aux travaux de recherches connexes.

1 Introduction

L'application du traitement des images et des techniques de vision par ordinateur dans différents domaines des sciences et de l'ingénierie se développent très rapidement. Dans le domaine médical, les développements existants de telles techniques visent principalement le diagnostic précoce des troubles médicaux en réduisant le temps nécessaire au dépistage de la maladie pour en prévenir les progrès. Des développements fructueux ont été réalisés dans le traitement d'images, tels que les systèmes de diagnostic automatisés, qui reposent sur une multitude d'algorithmes permettant de diagnostiquer des maladies de manière invasive sur une courte période. Par exemple, différents systèmes automatiques ont été proposés pour détecter la rétinopathie diabétique à partir des images rétiniennes du fond d'œil.

2 Les Machines Learning (L'apprentissage Automatique)

L'apprentissage automatique est une branche de l'intelligence artificielle, il concerne la construction et l'étude de systèmes permettant à une machine d'apprendre à partir d'un jeu de données [21]. Les algorithmes d'apprentissage automatique utilisent des méthodes de calcul pour «apprendre» des informations directement à partir de données sans utiliser une équation prédéterminée comme modèle. Les algorithmes améliorent de manière adaptative leurs performances lorsque le nombre d'échantillons disponibles pour l'apprentissage augmente.

Le noyau de l'apprentissage automatique traite de la représentation et de la généralisation. La représentation des instances de données et des fonctions évaluées sur ces instances fait partie de tous les systèmes d'apprentissage automatique. La généralisation est la capacité d'un système d'apprentissage automatique à fonctionner avec précision sur de nouvelles instances de données invisibles après avoir expérimenté une instance de données d'apprentissage. Les exemples de formation proviennent d'une distribution de probabilité généralement inconnue et l'apprenant doit créer un modèle général de cet espace lui permettant de produire des prédictions suffisamment précises dans les nouveaux cas. Les performances de la généralisation sont généralement évaluées en fonction de la capacité à reproduire des connaissances connues à partir d'exemples plus récents. Si une base de données n'est pas étiquetée, on parle alors d'apprentissage non supervisé, qui comprend la classification et l'estimation de la densité.

Plusieurs types d'apprentissage automatique existent, cependant, leurs objectifs diffèrent, les trois principaux sont :

- L'apprentissage supervisé
- L'apprentissage semi-supervisé
- L'apprentissage non supervisé

3 L'apprentissage supervisé

L'apprentissage supervisé est la tâche d'apprentissage automatique consistant à déduire une fonction à partir des données d'apprentissage supervisées [22]. Les données de formation pour l'apprentissage supervisé comprennent un ensemble d'exemples avec des données d'entrée appariées et le résultat de sortie souhaité. Un algorithme d'apprentissage supervisé analyse les données d'apprentissage et produit une fonction inférée appelée classificateur ou fonction de régression. La fonction doit prédire la valeur de sortie correcte pour toutes les données d'entrée valide. Cela nécessite que l'algorithme d'apprentissage soit généralisé à partir des données d'apprentissage à des situations invisibles de manière raisonnable.

La figure 2.1 illustre la résolution d'un problème d'une classification médicale bidimensionnelle. Le système va apprendre à partir des données fournies qui contiennent également les caractéristiques et la sortie (patient malade ou non malade). L'objectif est de trouver une fonction adéquate de séparation entre les deux sorties (classes) présumées, donc une fois que l'apprentissage est terminé, les nouvelles données sont fournies sans sorties et le système génère les sorties en utilisant les connaissances acquises à partir des données sur lesquelles il a été formé.




FIGURE 2.1 – Séparation optimale de deux classes

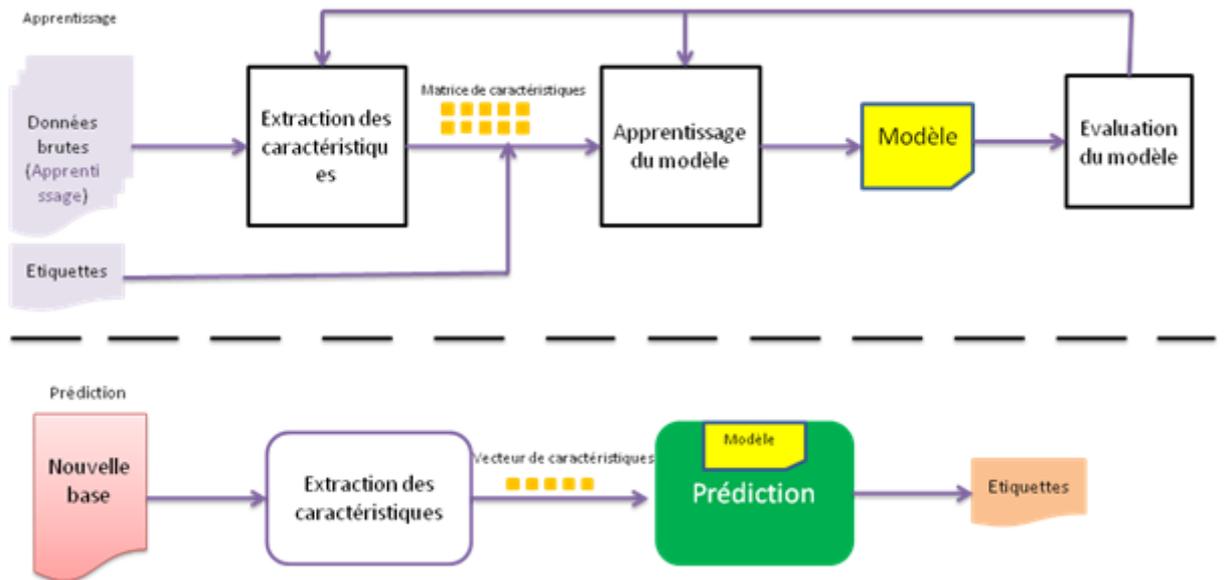


FIGURE 2.2 – Les étapes d’un modèle d’apprentissage supervisé

Dans cette thèse, nous utilisons l’apprentissage supervisé pour réaliser la tâche de la classification des différents stades de la RDNP. Pour cela, nous ne détaillerons que les techniques et algorithmes utilisés dans l’apprentissage supervisé.

3.1 Algorithmes

Comme il existe de nombreux algorithmes d’apprentissage automatique, il n’est pas possible de tous les utiliser pour les analyser. Pour ce document de recherche, nous utiliserons cinq classifieurs pour tester notre base d’images, à avoir : les réseaux de neurones (RN), l’arbre de décision CART, K-Nearest Neighbor (KNN), les Séparateurs à Vaste Marge (SVM), et l’analyse discriminante linéaire (ADL).

3.1.1 Les Séparateurs à Vaste Marge (SVM)

La machine à vecteurs de support (SVM) est une méthode de classification de pointe introduite en 1992 par Boser, Guyon et Vapnik [23].

Une définition plus formelle est qu’une machine à vecteurs de support construit un hyperplan ou un ensemble d’hyper plans dans un espace de dimension élevée ou infinie, qui peut être utilisé pour la classification, la régression ou d’autres tâches. Intuitivement, une bonne séparation est obtenue par l’hyperplan qui a la plus grande distance jusqu’au point de données d’entraînement le plus proche de toute classe (dite marge fonctionnelle), car en général, plus la marge est grande, plus l’erreur de généralisation du classifieur est faible ([24]).

Les SVM appartiennent à la catégorie générale des méthodes du noyau. Une méthode du noyau est un algorithme qui dépend des données uniquement via des produits point. Dans ce cas, le produit scalaire peut être remplacé par une fonction du noyau qui calcule un produit scalaire dans un espace de fonctions

éventuellement très volumineux. Cela présente deux avantages : premièrement, la possibilité de générer des limites de décision non linéaires à l'aide de méthodes conçues pour les classificateurs linéaires. Deuxièmement, l'utilisation des fonctions du noyau permet à l'utilisateur d'appliquer une classe plus élégante aux données qui n'ont pas de représentation évidente d'espace vectoriel à dimension fixe [25].

3.1.2 Les K-plus proches voisins (De l'anglais K-Nearest Neighbors ou en abrégé KNN)

Le KNN est un algorithme simple qui stocke tous les cas disponibles et classe les nouveaux cas en fonction d'une mesure de similarité [26]. Le KNN a été utilisé dans l'estimation statistique et la reconnaissance de formes. C'est un type d'apprentissage basé sur une instance, ou apprentissage paresseux, il permet de prédire une nouvelle instance (x) en recherchant dans l'ensemble de la formation pour les k instances les plus similaires et en résumant la variable de sortie de ces k instances. Pour la régression, il peut s'agir de la variable de sortie moyenne, tandis que dans la classification, la classe de mode détermine laquelle des k instances du jeu de données d'apprentissage est la plus similaire à la nouvelle entrée, de nombreuses mesures de distance sont utilisées, telles que la distance euclidienne, la distance de Manhattan et la distance de Minkowski. Leurs formules sont données par :

$$D_{Euclidienne} = \sqrt{\sum_{i=1}^k (x_i - y_i)^2}$$

$$D_{Manhattan} = \sum_{i=1}^k |x_i - y_i|$$

$$D_{Minkowski} = (\sum_{i=1}^k (|x_i - y_i|^q)^{1/q}$$

Le KNN recherche les distances entre une requête et tous les exemples dans les données [27], il sélectionne ensuite le nombre spécifié des exemples (K) les plus proches de la requête, puis vote pour l'étiquette la plus fréquente (dans le cas de la classification) ou pour la moyenne des étiquettes (en cas de la régression).

Nous pouvons implémenter un modèle KNN en suivant les étapes ci-dessous :

1. Charger les données
2. Initialiser la valeur de k
3. Pour obtenir la classe prévue, effectuer une itération de 1 au nombre total de points de données d'apprentissage.
 - Calculer la distance entre les données de test et chaque ligne de données d'apprentissage. Dans cette thèse, nous utiliserons la distance euclidienne comme métrique de distance car c'est la méthode la plus populaire.
 - Trier les distances calculées en ordre croissant en fonction des valeurs de distance
 - Obtenir les k premières lignes du tableau trié
4. Obtenir la classe la plus fréquente de ces lignes

5. Retourner la classe prédite

La phase d'apprentissage de l'algorithme consiste à stocker uniquement les vecteurs de caractéristiques et les étiquettes de classe des échantillons d'apprentissage [28]. Dans la phase de classification, k est une constante définie par l'utilisateur, et un vecteur non étiqueté est classifié en attribuant l'étiquette qui est la plus fréquente parmi les k échantillons d'apprentissage les plus proches de ce point d'interrogation. Souvent, l'exactitude de la classification de k -NN peut être améliorée de manière significative si la métrique de distance est apprise à l'aide d'algorithmes spécialisés. Le choix d'une valeur de K appropriée est important pour la performance du classifieur K -NN. Si la valeur de K est trop grande, le classifieur peut classer de manière erronée l'instance de test car sa liste des voisins les plus proches peut inclure des points de données situés loin de son voisinage. D'autre part, si la valeur de K est trop petite, le KNN peut être surchargé en raison du bruit dans le jeu de données d'apprentissage. Un exemple concrets est donné par la figure suivante.

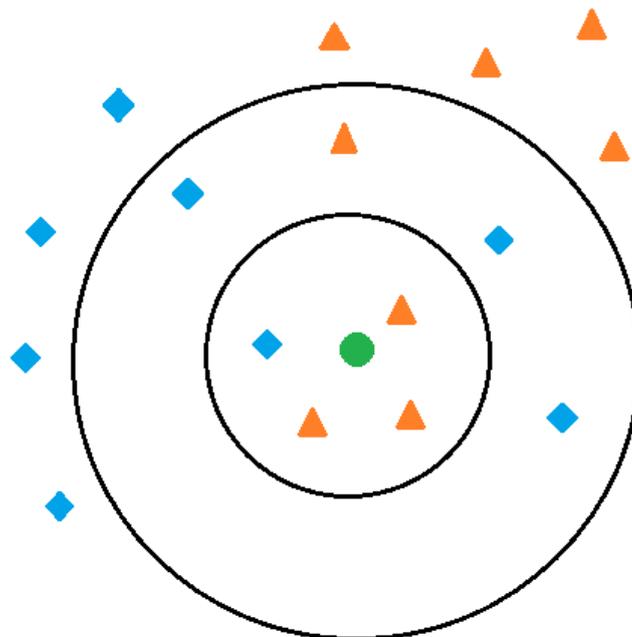


FIGURE 2.3 – Le choix du voisinage

3.1.3 Analyse Discriminante Linéaire ADL (de l'anglais Linear Discriminant Analysis LDA)

L'analyse discriminante linéaire [29] est une technique très courante utilisée pour les problèmes de la classification supervisée utilisant les étiquettes. C'est une technique de réduction de la dimensionnalité utilisée comme étape de pré-traitement dans les applications d'apprentissage automatique et de classification

de modèles. L'objectif principal de ces technologies est la réduction des dimensions en supprimant les entités redondantes et dépendantes en les transformant d'un espace de dimensions supérieures en un espace de dimensions inférieures. Ceci utilise trois étapes :

- La première étape consiste à calculer la séparabilité entre les différentes classes (c'est-à-dire la distance entre la moyenne des différentes classes), également appelée variance inter-classe.

$$S_c = \sum_{i=1}^k M_i (\bar{x}_i - \bar{x})(\bar{x}_i - \bar{x})^L$$

- La deuxième étape consiste à calculer la distance entre la moyenne et l'échantillon de chaque classe, appelée variance intra-classe.

$$S_m = \sum_{i=1}^k (M_i - 1) S_i = \sum_{i=1}^k \sum_{j=1}^{M_i} (x_{i,j} - \bar{x}_i)(x_{i,j} - \bar{x}_i)^L$$

- La troisième étape consiste à construire l'espace de dimension inférieure qui maximise la variance entre les classes et minimise la variance au sein de la classe. Soit D la projection dans l'espace de dimension inférieure, appelée critère de Fisher.

$$D_{ADL} = \operatorname{argmax}_D \frac{|D^L S_c D|}{|D^L S_m D|}$$

L'analyse discriminante linéaire est une méthode simple et efficace de classification. Il existe de nombreuses extensions et variantes de la méthode. Certaines extensions populaires incluent :

- Analyse discriminante quadratique (ADQ) : Dans ce cas, chaque classe utilise sa propre estimation de la variance (ou la covariance lorsqu'il existe plusieurs variables d'entrée).
- Analyse discriminante flexible (ADF) : On fait appel à cette technique, lorsque des combinaisons d'entrées non linéaires sont utilisées, telles que des splines.
- Analyse discriminante régularisée (ADR) : Elle introduit la régularisation dans l'estimation de la covariance, en modérant l'influence de différentes variables de l'ADL.

Le développement initial s'appelait Analyse discriminante linéaire ou Analyse discriminante de Fisher. La version multi-classes a été référée à l'analyse discriminante multiple. Celles-ci sont maintenant simplement appelées analyse discriminante linéaire.

3.1.4 L'arbre de décision CART

Un arbre de décision est une technique de modélisation d'apprentissage automatique efficace non paramétrique largement utilisée pour les problèmes de régression et de classification. Pour trouver des solutions, un arbre de décision

prend une décision séquentielle et hiérarchique concernant la variable de résultats en fonction des données du prédicteur.

L'arbre de décision construit des modèles de régression ou de classification sous la forme d'une arborescence (Figure 2.4). Il décompose un ensemble de données en sous-ensembles de plus en plus petits tout en développant de manière incrémentielle un arbre de décision associé. Le résultat final est un arbre avec des nœuds de décision et des nœuds feuille.

Le niveau de compréhension de l'algorithme de l'arbre de décision est très simple par rapport à l'algorithme de classification. Dans l'algorithme de l'arbre de décision, nous résolvons le problème en représentant l'arbre. Chaque nœud interne de l'arbre correspond à un attribut. Chaque nœud feuille correspond à une étiquette de classe qui concerne la décision prise après le calcul de tous les attributs, et chaque branche représente le résultat du test. Un chemin d'accès de la racine à la feuille représente les règles de la classification.

Afin de prédire une étiquette de classe dans un arbre de décision pour un enregistrement, nous partons de la racine de l'arbre, puis nous comparons la valeur de l'attribut racine avec l'attribut de l'enregistrement sur la base de la comparaison. Nous suivons la branche correspondante à ces valeurs et passons au nœud suivant. Nous continuons à comparer la valeur de l'attribut de notre enregistrement avec d'autres nœuds internes de l'arbre jusqu'à atteindre un nœud feuille.

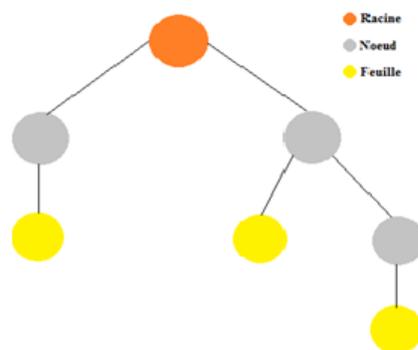


FIGURE 2.4 – Arbre de décision

Dans l'analyse de décision, un arbre de décision et le diagramme d'influence étroitement lié sont utilisés comme un outil d'aide à la décision visuel et analytique, permettant de calculer les valeurs attendues de différentes solutions. Un arbre de décision est une méthode utilisée pour faire les bons choix, en particulier ceux qui impliquent des coûts et des risques élevés. Ils utilisent une approche graphique pour comparer les alternatives concurrentes et leur attribuer des valeurs en combinant les incertitudes, et les coûts en valeurs numériques spécifiques. L'apprentissage par arbre décisionnel est l'une des techniques les plus efficaces pour l'apprentissage supervisé en classification. Les arbres de décision utilisés dans l'exploration des données sont de deux types principaux :

- Les arbres de classification, qui désignent le résultat attendu de la classe à laquelle appartiennent les données.
- Les arbres de régression. Ils correspondent au moment où le résultat prévu peut être considéré comme un nombre réel.

Les arbres de classification et de régression ou CART en abrégé, est un terme introduit par Leo Breiman [30], pour désigner les algorithmes d'arbre de décision pouvant être utilisés pour des problèmes de modélisation ou de modélisation prédictive par régression. L'algorithme CART fournit une base pour des algorithmes importants tels que des arbres de décision renforcés, ou une forêt aléatoire. La création d'un modèle CART implique la sélection de variables d'entrée et de points de scission sur ces variables jusqu'à la construction d'une arborescence appropriée. La sélection de la variable d'entrée à utiliser et du point de division ou de coupure spécifique est choisie à l'aide d'un algorithme glouton afin de minimiser une fonction de coût. La construction de l'arborescence se termine par un critère d'arrêt prédéfini, tel qu'un nombre minimal d'instances de formation attribuées à chaque nœud feuille de l'arborescence.

La création d'un arbre de décision binaire est en réalité un processus de division de l'espace d'entrée. Il s'agit d'une procédure numérique dans laquelle toutes les valeurs sont alignées et différents points de partage sont essayés et testés à l'aide d'une fonction de coût. La division avec le meilleur coût est sélectionnée.

Pour la classification, on utilise la fonction d'index de Gini, qui fournit une indication de la "pureté" des nœuds feuille (degré de mixité des données d'apprentissage attribuées à chaque nœud). Sa fonction est donnée par :

$$G = \sum P_k * (1 - P_k)$$

Où G est l'indice de Gini pour toutes les classes, P_k est la proportion d'instances de formation avec la classe k dans le rectangle considéré. Un nœud qui a toutes les classes du même type (pureté de classe parfaite) aura un $G = 0$, sinon l'index de Gini est positif.

Le critère d'arrêt est important car il influence fortement les performances de l'arbre. Pour améliorer les performances de la classification, on fait appel à la méthode d'élagage. La complexité d'un arbre de décision est définie par le nombre de divisions dans l'arbre. Les arbres les plus simples sont préférés. Ils sont faciles à comprendre, et ils sont moins susceptibles de surcharger les données.

La méthode d'élagage la plus rapide et la plus simple consiste à examiner chaque nœud feuille de l'arborescence et à évaluer les effets de sa suppression à l'aide d'un ensemble de tests de rétention. Les nœuds feuille ne sont supprimés que s'il en résulte une chute de la fonction de coût global sur l'ensemble du test. Vous arrêtez de supprimer des nœuds lorsqu'aucune amélioration supplémen-

taire ne peut être apportée. Des méthodes d'élagage plus sophistiquées peuvent être utilisées, telles que l'élagage en complexité des coûts (également appelé élagage du lien le plus faible) dans lequel un paramètre d'apprentissage (α) est utilisé pour déterminer si les nœuds peuvent être supprimés en fonction de la taille du sous-arbre.

3.1.5 Les Réseaux de Neurones (RN)

Dans le domaine de l'apprentissage automatique, les réseaux de neurones sont un sous-ensemble d'algorithmes construits autour d'un modèle de neurones artificiels répartis sur trois couches ou plus. La conception d'un réseau neuronal est inspirée du fonctionnement des neurones biologiques. Il existe de nombreux autres modèles d'apprentissage automatique qui se distinguent par leur nature adaptative. Chaque nœud de réseau de neurones possède son propre domaine de connaissances sur les règles et les fonctionnalités permettant de se développer à travers des expériences tirées de techniques antérieures qui ne reposent pas sur des réseaux de neurones. Les réseaux de neurones sont bien adaptés à l'identification de modèles non linéaires, comme dans les modèles où il n'existe pas de relation directe un-à-un entre l'entrée et la sortie [8]. Ceci est une formation d'apprentissage. Les réseaux de neurones sont caractérisés en contenant des poids adaptatifs le long des chemins entre les neurones qui peuvent être ajustés par un algorithme d'apprentissage qui tire des enseignements des données observées afin d'améliorer le modèle. Il faut choisir une fonction de coût appropriée. La fonction de coût est ce qui est utilisé pour apprendre la solution optimale du problème à résoudre. En résumé, il peut s'adapter à l'évolution de l'environnement au fur et à mesure de son apprentissage lors de la formation initiale et de ses analyses ultérieures pour fournir davantage d'informations sur le monde.

Un perceptron est un algorithme de classification binaire simple, proposé par Frank Rosenblatt. Il est utile de diviser un ensemble de signaux d'entrée en deux parties : «oui» et «non». Mais contrairement à de nombreux autres algorithmes de classification, le perceptron a été modélisé d'après l'unité essentielle du cerveau humain - le neurone - et possède une incroyable capacité à apprendre et à résoudre des problèmes complexes.

Un perceptron est une machine d'apprentissage très simple. Il peut prendre quelques entrées, chacune ayant un poids pour indiquer son importance, et générer une décision de sortie de «0» ou «1». Cependant, lorsqu'il est combiné à de nombreux autres perceptrons, il forme un réseau neuronal artificiel. Théoriquement, un réseau de neurones peut répondre à toutes les questions, avec suffisamment de données de formation et de puissance de calcul.

Un perceptron multicouche (MLP) est un perceptron qui s'associe à des perceptrons supplémentaires, empilés en plusieurs couches, pour résoudre des problèmes complexes. Le diagramme ci-dessous montre un MLP avec trois couches. Chaque perceptron de la première couche à gauche envoie des sorties à tous les perceptrons de la seconde couche, ces perceptrons envoient à leur tour des sorties

à la dernière couche de droite.

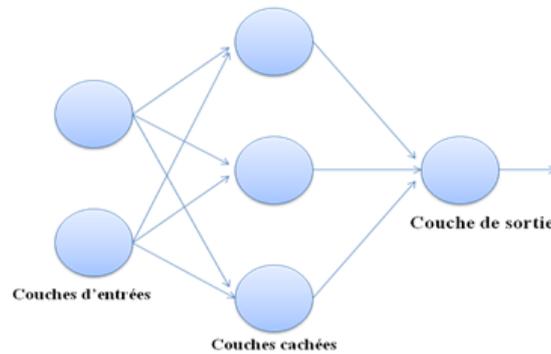


FIGURE 2.5 – Architecture d'un MLP

Chaque perceptron envoie plusieurs signaux, un signal est envoyé à chaque perceptron de la couche suivante. Pour chaque signal, le perceptron utilise des poids différents. Dans le diagramme ci-dessus, chaque ligne allant d'un perceptron d'une couche à la couche suivante représente une sortie différente. Chaque couche peut avoir un grand nombre de perceptrons et plusieurs couches, de sorte que le perceptron multicouche peut rapidement devenir un système très complexe. La figure 2. représente un perceptron à trois couches, il est appelé réseau neuronal non profond ou peu profond. Un MLP avec quatre couches ou plus s'appelle un réseau de neurones profonds. Une différence entre un réseau MLP et un réseau de neurones réside dans le fait que, dans le perceptron classique, la fonction de décision est une fonction échelonnée et la sortie est binaire. Dans les réseaux de neurones qui ont évolué à partir du MLP, d'autres fonctions d'activation peuvent être utilisées pour générer des sorties de valeurs réelles, généralement comprises entre 0 et 1. Cela permet des prédictions basées sur les probabilités ou la classification d'éléments sous plusieurs libellés.

Les différentes étapes suivies par un perceptron sont les suivantes :

1. Prendre les entrées, les multiplier par leurs poids et calculer leur somme. Les poids permettent au perceptron d'évaluer l'importance relative de chacun des résultats. Les algorithmes de réseau neuronal apprennent en découvrant des poids de plus en plus performants qui permettent une prédiction plus précise. Plusieurs algorithmes sont utilisés pour ajuster les poids, le plus commun s'appelle la rétropropagation.
2. Ajouter un facteur de biais, le nombre 1 multiplié par un poids. C'est une étape technique qui permet de déplacer la courbe de la fonction d'activation de haut en bas ou de gauche à droite sur le graphique à chiffres. Il permet d'affiner la sortie numérique du perceptron.
3. Donner la somme par la fonction d'activation. La fonction d'activation mappe les valeurs d'entrée sur les valeurs de sortie requises. Par exemple, les valeurs d'entrée peuvent être comprises entre 1 et 100, et les sorties peuvent être 0 ou 1. La fonction d'activation aide également le perceptron à apprendre lorsqu'il fait

partie d'un perceptron multicouche (MLP). Certaines propriétés de la fonction d'activation, notamment son caractère non linéaire, permettent de former des réseaux de neurones complexes.

4. Le résultat est la sortie du perceptron. La sortie du perceptron est une décision de classification. Dans un perceptron multicouche, la sortie des perceptrons d'une couche correspond à l'entrée de la couche suivante. La sortie des perceptrons finaux, dans la «couche de sortie», constitue la prédiction finale du modèle d'apprentissage du perceptron.

Bien que les perceptrons multicouches (MLP) et les réseaux de neurones soient essentiellement la même chose, ils ne sont pourtant pas identiques, il conviendrait de réaliser les deux tâches suivantes afin de les rendre identiques :

- **Backpropagation** : l'algorithme de backpropagation permet d'effectuer une «passe arrière», ce qui permet d'affiner le poids des entrées. Il effectue des passes en arrière itératives qui tentent de minimiser la «perte», ou la différence entre la prédiction correcte connue et la prédiction réelle du modèle. À chaque passage en arrière, les poids se déplacent vers un optimum qui minimise la fonction de perte et donne la prévision la plus précise.

- **Hyperparamètres** : dans un réseau neuronal moderne, des aspects de la structure multicouche, tels que le nombre de couches, les poids initiaux, le type de fonction d'activation et les détails du processus d'apprentissage, sont traités en tant que paramètres et adaptés pour améliorer les performances du réseau neuronal. Le réglage des hyperparamètres est un art et peut avoir un impact considérable sur les performances d'un réseau de neurones.

- **Structures avancées** : de nombreux réseaux de neurones utilisent une structure complexe qui repose sur le perceptron multicouche. Par exemple, un réseau de neurones récurrents utilise deux réseaux de neurones en parallèle : l'un gère les données d'apprentissage du début à la fin, l'autre de la fin au début, ce qui facilite le traitement du langage. Un réseau de neurones de convolution (CNN) utilise un MLP en trois dimensions, essentiellement trois structures de perceptron multicouches qui apprennent le même point de données. Ceci est utile pour les images couleur comportant trois couches de «profondeur» : rouge, vert et bleu.

4 L'apprentissage non supervisé

L'apprentissage non supervisé aussi appelé apprentissage par corrélation est une technique d'apprentissage automatique, dans laquelle nous n'avons pas besoin de superviser le modèle. Au lieu de cela, on doit permettre au modèle de fonctionner seul pour découvrir des informations. Il traite principalement des données non étiquetées. Les algorithmes d'apprentissage non supervisé permettent d'effectuer des tâches de traitement plus complexes que l'apprentissage supervisé. Cependant, l'apprentissage non supervisé peut être plus imprévisible que d'autres méthodes d'apprentissage naturelles. Cette approche nécessite néanmoins,

une bonne estimation du nombre de classes.

5 L'apprentissage semi supervisé

Les techniques d'apprentissage semi-supervisées [31] se situent entre l'apprentissage non supervisé et l'apprentissage supervisé, au moyen de petites données étiquetées avec une grande donnée non étiquetée au cours de l'étape d'apprentissage. De nombreux chercheurs en apprentissage automatique ont constaté que les données non étiquetées, lorsqu'elles sont utilisées avec une petite quantité de données étiquetées, peuvent produire une amélioration considérable de la précision de l'apprentissage.

6 Sélection des caractéristiques

La sélection des fonctionnalités est l'un des concepts fondamentaux de l'apprentissage automatique qui influe grandement sur les performances d'un modèle. Les fonctions de données utilisées pour former des modèles d'apprentissage automatique ont une influence considérable sur les performances souhaitées. Des caractéristiques non pertinentes ou partiellement pertinentes peuvent avoir un impact négatif sur les performances du modèle.

La sélection des caractéristiques et le nettoyage des données doivent constituer la première et la plus importante étape de la conception d'un modèle. Son principe est de sélectionner automatiquement ou manuellement les fonctionnalités qui contribuent le plus à la variable de prédiction ou à la sortie désirée.

Le fait de disposer de fonctionnalités non pertinentes peut réduire la précision des modèles, pour cela, la sélection des caractéristiques avant la modélisation des données permet de :

- Réduire les sur-ajustements : en effet, moins on dispose de données redondantes, on aura moins d'opportunités pour prendre des décisions basées sur le bruit.
- Améliorer la précision : la minimisation des données trompeuses permet d'améliorer la précision de la modélisation.
- Réduire le temps de formation : lorsqu'on dispose de peu de données, la complexité de l'algorithme sera réduite et l'entraînement des algorithmes sera donc plus rapide.

En résumé, les techniques de sélection des caractéristiques simplifient les modèles d'apprentissage automatique afin de faciliter leur interprétation par les chercheurs. L'informatique élimine principalement les effets de la malédiction de la dimensionnalité. En outre, cette technique réduit le problème de sur-ajustement

en améliorant la généralisation dans le modèle. Cela permet donc de mieux comprendre les données, d'améliorer les performances de prévision, de réduire le temps de calcul ainsi que l'espace requis pour exécuter l'algorithme.

7 Phase d'apprentissage

La formation d'un modèle constitue l'essentiel de l'apprentissage automatique. L'objectif est d'utiliser les données d'entraînement et d'améliorer progressivement les prévisions du modèle. Chaque cycle de mise à jour des poids et des biais constitue une étape de formation. Dans l'apprentissage automatique supervisé, le modèle est construit à l'aide de données d'échantillon étiquetées, tandis que l'apprentissage automatique non supervisé tente de tirer des conclusions à partir de données non étiquetées (sans référence à des résultats connus ou étiquetés).




FIGURE 2.6 – Phase d'apprentissage

Un algorithme d'apprentissage prend en entrée un ensemble de données qui contient les informations nécessaires pour caractériser un problème donné et renvoie un modèle qui représente les concepts caractérisant ces données (Figure 2.6), à la fin il sera capable de prédire l'étiquette de nouveaux objets en fonction de leurs valeurs d'entrée.

8 Phase de test

Elle est utilisée pour fournir une évaluation non biaisée d'un ajustement final du modèle sur l'ensemble de données de formation. Il fournit l'étalon-or utilisé pour évaluer le modèle. Il n'est utilisé qu'une fois qu'un modèle est complètement formé (à l'aide des ensembles d'apprentissage et de validation). L'ensemble de tests est généralement ce qui est utilisé pour évaluer des modèles concurrents. L'ensemble de test est généralement bien organisé. Il contient des données soigneusement échantillonnées couvrant les différentes classes auxquelles le modèle serait confronté, lorsqu'il est utilisé dans le monde réel.




FIGURE 2.7 – Vue d’ensemble du flux de travail de l’apprentissage automatique

9 La validation croisée (CROSS VALIDATION de l’anglais)

Généralement, pour former et tester un modèle, les bases de données utilisées sont conçues en trois parties, la première pour l’apprentissage, la seconde pour la validation et la dernière pour le test. Cependant, nous pouvons également utiliser toute la base de données pour les phases d’apprentissage et de test. Cette technique s’appelle la validation croisée [32]

En apprentissage automatique, un modèle ne peut être conforme aux données de formation et ne pouvons donc pas affirmer que le modèle fonctionnera avec précision pour les données réelles. Pour cela, nous devons nous assurer que le modèle a obtenu les modèles corrects à partir des données et qu’il ne génère pas trop de bruit. Pour ce faire, nous utilisons la technique de validation croisée, dans laquelle nous formons le modèle à l’aide des sous-ensemble de l’ensemble de données, puis nous évaluons à l’aide des sous-ensemble complémentaire de l’ensemble de données. Les trois étapes de la validation croisée sont les suivantes :

1. Réservez une partie de l’échantillon.
2. Utilisez l’ensemble de données restantes pour former le modèle.
3. Testez le modèle en utilisant la partie réservée de l’ensemble de données.

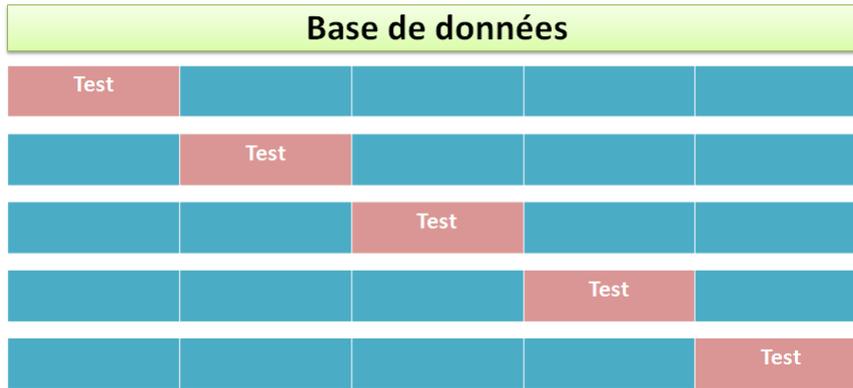


FIGURE 2.8 – Un exemple du principe de la validation croisée avec $K=5$

Dans cette méthode, nous divisons le jeu de données en k nombre de sous-ensembles (appelés plis), puis nous effectuons un apprentissage sur tous les sous-ensembles, mais nous en laissons un $(k-1)$ pour l'évaluation du modèle formé. Dans cette méthode, nous itérons k fois avec un sous-ensemble différent réservé à des fins de test à chaque fois. Cette technique présente les avantages suivants :

- Elle offre une estimation plus précise de la précision hors échantillon.
- Elle utilise les données de manière plus efficace, chaque observation étant utilisée à la fois pour l'apprentissage et les tests.

La validation croisée est l'étape où les meilleurs paramètres pour l'algorithme sont sélectionnés. Le problème de sous-apprentissage et de sur-apprentissage a été découvert en utilisant cette méthode. Normalement, un problème d'apprentissage automatique comporte de nombreuses fonctions d'entrée. Il est donc impossible de visualiser les données ou les problèmes éventuels. En utilisant la validation croisée, ces problèmes peuvent être identifiés via les courbes d'apprentissage.

9.1 Le sous-apprentissage

Il y a sous-ajustement lorsque l'algorithme ne peut pas s'adapter correctement à l'ensemble d'apprentissage. La courbe produite n'est probablement pas assez complexe pour la classification. Pour identifier la présence de ce problème, des courbes d'apprentissage avec les erreurs d'apprentissage et de la validation croisée doivent être tracées. Si les deux erreurs sont élevées et qu'il existe un petit intervalle entre les courbes, on peut en déduire positivement que l'algorithme a sous-alimenté l'ensemble d'apprentissage. La figure suivante illustre une courbe d'apprentissage insuffisante.




FIGURE 2.9 – Courbe représentative d'un sous-apprentissage

9.2 Le sur-apprentissage

Un sur-apprentissage survient lorsque l'algorithme correspond un peu trop bien au jeu d'entraînement et délaisse le jeu de tests. L'algorithme s'adaptant un peu trop à l'apprentissage, il ne peut donc pas généraliser pour des exemples invisibles dans le jeu de tests. Le synonyme d'un sur-apprentissage est une grande variance. La figure suivante montre un exemple de sur-apprentissage.




FIGURE 2.10 – Courbe représentative d'un sur-apprentissage

10 La matrice de confusion

Il s'agit d'une mesure de performance pour un problème de classification d'apprentissage automatique dans lequel le résultat peut être constitué de deux classes ou plus. C'est un tableau avec 4 combinaisons différentes de valeurs prédites et réelles. Elle est extrêmement utile pour mesurer les rappels, la précision,

la spécificité, la sensibilité, le taux de classification et surtout la courbe AUC-ROC. Le nombre de prédictions correctes et incorrectes est résumé avec les valeurs de comptage et ventilé par classe. C'est la clé de la matrice de confusion. Elle montre la confusion d'un modèle de classification lorsqu'il fait des prédictions. Cela donne un aperçu non seulement des erreurs commises par le classificateur, mais surtout des types d'erreurs commises. C'est cette répartition qui permet de surmonter la limitation liée à l'utilisation de la précision de la classification uniquement.




FIGURE 2.11 – La matrice de confusion

Dans un problème à deux classes, nous cherchons souvent à distinguer les observations ayant un résultat spécifique des observations normales. On prend exemple d'un état pathologique et d'un état sain. Dans cette matrice, nous avons affecté la ligne pathologique à «positif» et la ligne d'un état sain à «négatif». Nous avons ensuite attribué la colonne de prédiction d'un état pathologique à «positif» et le cas sain à «négatif».

VP : représente le nombre de personnes malades classées comme telles.

FP : représente le nombre de personnes en bonne santé classées comme étant malades.

FN : représente le nombre de personnes malades classées comme étant en bonne santé.

VN : représente le nombre d'individus en bonne santé classés comme étant sains.

11 Recherche bibliographique et travaux connexes

Le diagnostic assisté par ordinateur a pour objectif de reconnaître les images rétiniennes normales et pathologiques (celles qui présentent des signes de la RD), en exploitant différentes fonctionnalités pour réaliser la fastidieuse tâche de la classification. Plusieurs algorithmes ont été proposés pour classer les images du fond d'œil.

Initialement, les méthodes de détection de la rétinopathie diabétique fonctionnaient en extrayant des caractéristiques d'intérêt dans les images. Les premières approches dans ce domaine visaient à détecter la rétinopathie diabétique en ce qui concerne les caractéristiques texturales des images rétiniennes. Par exemple, Yun et al. [33] ont proposé une méthode basée sur la détection et l'analyse des microanévrismes et des hémorragies. Nayak et al. [34] ont utilisé une combinaison d'exsudats durs et de vaisseaux sanguins selon des techniques morphologiques. Reza et al. [35], ont développé un algorithme basé sur la détection des exsudats durs et des nodules cotonneux. Ces régions pathologiques ont été segmentées à l'aide de techniques de traitement d'images telles que le seuillage, la reconstruction morphologique et le traçage des limites. Enfin, des travaux récents sur ce sujet ont focalisé l'attention sur la localisation des exsudats et sur leur combinaison pour déterminer le stade correct de la maladie. En 2015, grâce à la California Healthcare Foundation [36] qui a créé un défi avec un jeu de données disponible, le développement d'algorithmes automatiques pour classifier et détecter différents degrés de la RD a connu une croissance rapide. Tous les groupes qui ont terminé la compétition par défi ont utilisé l'apprentissage en profondeur et les réseaux de neurones convolutionnels. Les images ont été étiquetées en fonction du degré de la RD présent, de 0 (en bonne santé) à 4 (le plus haut degré de la RD). Ben Graham, l'un des participants du défi, a obtenu la première place [37] sous le nom de «Min Pooling» avec un score de 0,8496. Cette méthode impliquait SparseConvNet, un réseau de neurones à convolution dont l'entrée est l'image entière. Pour former le réseau, il fallait augmenter les données : redimensionner, incliner et faire pivoter les images. Le regroupement a redimensionné les images (300 ou 500 pixels), ils ont ensuite soustrait la couleur moyenne locale et ont découpé l'image à 90 % de sa taille pour supprimer les effets de contour. Le modèle de compétition final combinait trois réseaux différents : deux réseaux convolutionnels, utilisant le pooling maximal fractionnaire [38] impliquant des couches de pooling spatial avec des paramètres fractionnaires, et l'autre utilisant des réseaux de neurones convolutionnels très profonds [39].

Plus récemment, Maria et al. [40] ont proposé une approche informatisée pour la détection de la RD dans des images du fond basée sur l'utilisation des réseaux de neurones à convolution (CNN). Ils ont utilisé des architectures profondes pour classer les photographies rétiniennes en 5 classes de la RD. Cette méthode combine plusieurs images de prétraitement pour obtenir un score de 50,5 %. Ils ont exploré les sous-problèmes en formant un CNN plus important à la tâche principale de la classification.

Aravind et al. [41] ont mis au point une méthode de détection des microanévrismes, premier signe clinique de DR par des opérations morphologiques. Les caractéristiques de surface, entropie, corrélation, énergie, contraste, homogénéité et moyenne ont été extraites. Ensuite, une machine à vecteurs de support (SVM) a été appliquée pour classer chaque image en rétine normale, ou RDNP légère ou grave. La sensibilité et la précision atteintes sont de 92 % et de 90 %, respectivement. Ce travail n'a pas pu détecter le stade de la RDNP modéré.

D'autre part, Sujith Kumar et al. [42] ont présenté un algorithme automatique de détection des candidats potentiels en utilisant l'égalisation adaptative d'histogramme et le seuillage. L'algorithme classe chaque image d'entrée en rétine normale ou en RDNP. Les images RDNP ont été classées en classes d'intensité légère, modérée ou sévère en fonction du nombre des MAs détectés. Contrairement à l'étude [9], ces auteurs ont pu faire la distinction entre la RDNP modérée et sévère. La précision de ce travail était de 94,44 % ; Cependant, l'analyse de la sensibilité n'a pas été prise en compte.

Tjandrasa et al. [43] se sont concentrés sur la classification de la RDNP en classes modérée ou sévère. Les exsudats ont été segmentés en utilisant la classification K-Means. Trois classificateurs différents ont été utilisés. La perception multicouche, qui est l'un des classificateurs de réseaux neuronaux, a montré le meilleur résultat de classification avec une précision de 91,07 %.

De plus, Sundhar et Archana [44] ont proposé un dépistage automatique pour détecter la RD. Leur méthode développée a parfaitement détecté la taille des exsudats et des MAs. Les réseaux de neurones artificiels ont été utilisés pour classer les images du fond d'œil en normales, en RDNP et en RDP. Le test de la classification a atteint une sensibilité de 92,5 %. Bien qu'ils aient pu détecter la RDP, leur étude avait pour inconvénient de n'avoir utilisé qu'un petit nombre d'images, soit 40 images pour être exact, lors du test de la classification.

Jagatheesh et Jenila [45] ont développé une méthode de détection des lésions de la RD à l'aide du modèle Bag of Visual Words (BOVW). Le modèle transforme les descripteurs d'image locaux en représentations d'image prises en compte dans la classification. Ces modèles visent à détecter un grand nombre de vecteurs de caractéristiques autour des points d'intérêt de l'image. Les caractéristiques détectées sont ensuite attribuées à des mots visuels basés sur un dictionnaire visuel. Leur travaux ont atteint une précision de 84,21 % et une sensibilité de 76,62 % pour la détection des exsudats. Pour la détection des hémorragies, ils ont atteint une précision de 75,2 % et une sensibilité de 74,57 %. La détection et la classification de la RD basées sur les modèles BOVW sont encore en développement.

Welikala et al. [46] ont proposé une méthodologie pour détecter et classer la RDP en utilisant une approche de double classification. Le vaisseau sanguin a été segmenté en deux images à l'aide de l'opérateur de ligne standard et d'un opérateur de ligne modifié. Ensuite, 21 caractéristiques ont été extraites de chaque image et ont été utilisées au stade de la classification. La décision finale reposait sur la combinaison des résultats des deux classificateurs en supprimant les réponses des fausses détections des nouveaux vaisseaux sanguins dans chaque classificateur. La RDP est un niveau de la RD très avancé et les traitements actuels peuvent ne pas être efficaces pour la guérir. Cependant, les résultats de cette étude aident les ophtalmologistes à trouver de nouveaux traitements.

L'article [47] a résumé les travaux des chercheurs travaillant sur la détection de la RD à l'aide des système d'aide au diagnostic, comme suit : Les chercheurs

des travaux ([48], [49], [50], [51], [35], [52], [53], [54]), ont utilisé des caractéristiques cliniques, telles que la détection des microanévrismes, des exsudats, des hémorragies, et des veines, pour classer la RD sous deux stades (normal et pathologique). Les lésions sombres ont été segmentées à l'aide d'un opérateur de fossé et les exsudats ont été extraits à l'aide de la croissance de région récursive et du seuillage adaptatif de l'intensité [50].

Quellic et al. [54] ont appliqué des filtres optimaux pour extraire les MAs. Le réseau neuronal artificiel [50], [51], [52] et le travail de contour bayésien [48] ont été utilisés pour la classification. Leurs méthodes ont obtenu une spécificité de 46,3 % et une sensibilité de 95,1 % [50]. Les classificateurs de noyau SVM (Séparateur à Vaste Marge) sont utilisés pour détecter l'absence ou la présence de la RD. Le système CAD anticipé a géré les problèmes de classification dans la RD [55]. Le diagnostic assisté par ordinateur a joué un rôle fondamental dans les industries médicales [56]. Pour reconnaître l'œdème maculaire, la RD et les blessures essentielles, un algorithme permettant d'examiner l'image du fond d'œil mécanisé a été proposé. Lors du dépistage de la RD, cet algorithme est une substitution améliorée de l'examen manuel de la photographie, qui prend beaucoup de temps. Si ce système est exploité par les médecins, il permettra un gain de temps significatif, augmentant ainsi le temps passé dans un programme de dépistage de masse [57]. En imagerie médicale, les informations contextuelles jouent un rôle important. La détection et la discrimination des lésions brillantes ont été réalisées au moyen d'informations contextuelles dans les modalités de l'image du fond d'œil. Le diagnostic des calcifications coronaires et des EXs durs en tomographie est effectué au moyen de cette information contextuelle. Dans la relation spatiale, des caractéristiques contextuelles de haut niveau sont utilisées pour expliquer le contexte. Le système CAD contextuel est un métier à débordement par rapport au système CAD local [58]. Plusieurs auteurs ont suggéré des méthodes de ce système pour la détection des différents stades de la RD (RDNP et RDP).

Handayani et al. [59], ont proposé un système automatisé permettant de classer la rétinopathie diabétique non proliférante sur la base de lésions rouges dans les images rétinienne. Le système se compose de trois parties, la première partie est le processus de segmentation des régions sombres. La deuxième partie concerne le processus de détection des vaisseaux sanguins. Et la troisième partie consiste à obtenir la segmentation des lésions rouge et à classer la gravité de la rétinopathie diabétique non proliférative. La classification utilise les caractéristiques de zones, de périmètres, du nombre de centroïdes et de son écart type. En utilisant le SVM à marge souple, les auteurs ont obtenu une précision de 86,21 % pour 58 données d'apprentissage et 58 données de test.

Al-Jarrah et al. [60], ont proposé un algorithme basé sur la morphologie pour détecter les lésions rétinienne et classifier chaque cas. Tout d'abord, l'algorithme proposé détecte les trois lésions de la RD (les hémorragies, les microanévrismes et les exsudats). Ensuite, ils ont défini et extrait un ensemble de caractéristiques à partir de lésions détectées. L'ensemble des fonctionnalités sélectionnées émule ce que les médecins recherchaient dans la classification des cas de la RDNP. Ils ont conçu un classificateur à réseau de neurones artificiels à trois couches pour

permettre la classification de la RDNP en normal, léger, modéré et grave. Des algorithmes de régularisation bayésienne et de rétropropagation résiliente sont utilisés pour former les réseaux de neurones. La précision des classificateurs proposés basés sur des algorithmes de régularisation bayésienne et de rétropropagation résiliente est de 96,6 % et de 89,9 %, respectivement.

12 Conclusion

Le chapitre 2 a discuté des expériences faites par des auteurs pour la détection de la rétinopathie diabétique. Ce travail sera utile aux techniciens et aux chercheurs qui doivent utiliser les recherches en cours dans ce domaine. Nous avons parlé aussi des différents types d'apprentissage automatiques pour la réalisation de la classification des stades de la RD. Le chapitre suivant donnera les techniques et outils utilisés pour détecter et classer la RDNP.

Chapitre 3

Méthodologie du système d'aide au diagnostic pour le dépistage de la RD

« Logic will get you from A to Z, Imagination will get you everywhere »
Albert Einstein

1 Introduction

De nos jours, l'imagerie médicale constitue un domaine de prédilection dans le cas du traitement d'images. Elle fournit une assistance dans le diagnostic des maladies. Dans l'approche proposée, la détection automatique des microanévrismes, des hémorragies et des exsudats est nécessaire car ils sont considérés comme étant les lésions précoces de la RD. Si ces pathologies ne sont pas détectées à un stade précoce, elles peuvent entraîner une perte de vision permanente du patient diabétique.

Le dépistage périodique et la détection précoce de la RD aident à réduire la progression de cette maladie et à prévenir la cécité. D'où l'énorme importance des systèmes d'aide au diagnostic.

Le but de ce travail de thèse est de développer un système d'aide au diagnostic permettant de détecter et de classifier diverses pathologies liées à la rétinopathie diabétique, à savoir les MAs, les HEs, et les EXs. Cela joue un rôle important dans la détection des différents stades de la RD, en raison de leur nombre, qui est un bon indicateur de la gravité de la maladie. La méthodologie développée dans ce travail est résumée dans la figure 3.1.

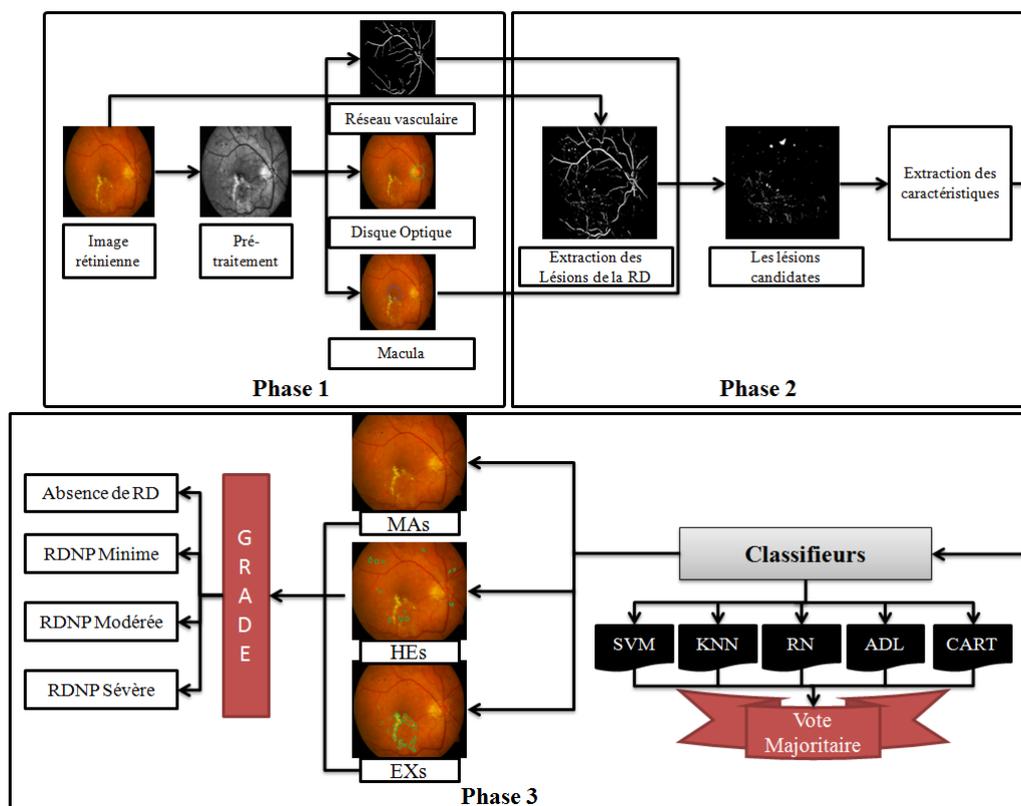


FIGURE 3.1 – Organigramme de la représentation d'un système CAD pour le dépistage de la RD

2 Détection des différentes lésions diabétiques

Dans cette première partie du chapitre, nous allons commencer par extraire les trois lésions rétiniennes typiques de la RDNP, en passant bien évidemment par des techniques de prétraitement des images du fond d'œil.

2.1 Détection et classification des Microanévrismes (MAs)

La plupart des dommages causés par la RD peuvent être réduits ou prévenus s'ils sont diagnostiqués correctement et régulièrement aux stades précoces. Cependant, il est fastidieux pour un ophtalmologiste de diagnostiquer manuellement un patient diabétique, et il s'agit également d'une erreur de prononciation. Par conséquent, une analyse automatique de la rétine des patients diabétiques est nécessaire pour permettre aux ophtalmologistes de dépister de plus grandes populations atteintes de diabète.

Les microanévrismes (MAs) sont considérés comme étant des lésions importantes dans la rétinopathie diabétique. Ils apparaissent sous forme de petits points rouges minuscules arrondis près des vaisseaux sanguins dans les images du fond d'œil. Il s'agit probablement de la seule lésion présente à un stade précoce de la maladie et demeurant tout au long de son évolution. Par conséquent, la détection des MAs est nécessaire et vitale dans un système de dépistage assisté par ordinateur. Cette section de la thèse présente un système préliminaire pour le dépistage et la classification des microanévrismes à l'aide des images du fond d'œil. Il s'agit d'un système de détection qui classe les images sous deux catégories : Présence ou Absence de MAs.

Le système d'aide à la décision ophtalmique proposé consiste en une acquisition, un dépistage et une classification des images rétiniennes.

Le système proposé commence par le processus d'acquisition d'images, au cours duquel les images sont sélectionnées pour un traitement ultérieur. Celles-ci subiront un prétraitement afin d'améliorer le contraste de l'image en plus d'autres améliorations. Les images prétraitées seront ensuite utilisées pour extraire un certain nombre de caractéristiques, telles que la surface, la moyenne et l'écart type de pixels. Enfin, on termine par la phase de classification, où le système pourrait éventuellement être utilisé pour aider le clinicien dans son diagnostic.

A. Etat de l'art

La plupart des méthodes de détection des MAs actuelles se divisent en deux étapes : l'extraction des candidats et la classification des MAs. La première étape consiste généralement en un prétraitement destiné à réduire le bruit et à améliorer le contraste et la luminosité des images. Suivi d'une segmentation spécifique de l'image pour extraire les MAs au mieux. Dans la deuxième étape, les candidats résultants sont étiquetés comme étant vrais ou faux en utilisant une méthode basée

sur l'apprentissage supervisé. La classification nécessite un ensemble de formation pour établir les limites des classes. L'ensemble d'apprentissage est constitué de vecteurs d'entités et d'étiquettes de classe. Les vecteurs de caractéristiques sont des ensembles ordonnés de certaines valeurs de propriété, principalement des descripteurs géométriques ou de couleur permettant de distinguer les véritables MAs des autres candidats susceptibles d'être confondus avec eux.

Gardner et al., [51] ont appliqué un réseau de neurones artificiels pour reconnaître les objets potentiels présents sur les images de fond d'œil diabétique, tels que les MAs, le réseau vasculaire et les exsudats. Le réseau de neurones à convolution (CNN) est une sorte de réseau de neurones artificiel. Il est généralement considéré comme approprié pour la reconnaissance d'images.

Meindert et al., [61] ont proposé une nouvelle méthode de détection des lésions rouges basée sur une approche hybride, qui utilisait les travaux antérieurs de Spencer [62] et Frame [63] avec deux contributions. Cependant, le temps total de la méthode pour traiter une seule image était d'environ 15 minutes, ce qui était long pour les systèmes de dépistage.

Fleming et al. [64], ont utilisé la normalisation du contraste de l'image pour améliorer la capacité de distinction des MAs des autres objets présents sur l'image du fond d'œil. Le temps d'exécution moyen d'une image est passé de 53 à 100 s. Cependant, la sensibilité et la spécificité de la méthode étaient un peu faibles pour un outil de diagnostic efficace. Purwita et al., [65], ont utilisé la conception de la morphologie mathématique. Une étape de prétraitement a été utilisée pour supprimer les objets inutiles. Les MAs candidats ont été extraits en éliminant le réseau vasculaire et de petits objets à l'aide d'un algorithme de détection de bord et de remplissage de région. La détection précise des MAs dépendait de la détection exacte du réseau et du disque optique dans cette méthode.

Antal et al. [66], ont proposé un nouveau système basé sur un ensemble pour la détection des MAs et la classification de la rétinopathie diabétique. Ils ont amélioré la détection des MAs en sélectionnant la combinaison optimale de méthodes de prétraitement et d'extraction de caractéristiques.

Haloi [67] a obtenu par sa méthode de détection des MAs une sensibilité de 97 % et une spécificité de 95 %. L'inconvénient de cette méthode était la nécessité de disposer d'une grande quantité de données de formation et donc perdre du temps.

Istvan et al, [68] ont proposé une méthode de détection automatique des MAs potentiels par analyse du profil de la section transversale rotationnelle. Les pixels maximum locaux ont été sélectionnés comme candidats. Un balayage transversal a été appliqué à chaque candidat pour produire 30 profils. Ensuite, la détection de pic a été appliquée à chaque profil et 7 propriétés de pic ont été calculées. Plusieurs mesures statistiques des propriétés des pics directionnels résultants ont été définies en tant qu'ensemble de caractéristiques d'un classificateur bayésien.

Seoud et al. [69], ont utilisé un nouvel ensemble de fonctions de forme appelé Fonctions dynamiques pour la détection de lésions rouges dans les images du fond d'œil. Le classificateur Random Forest a été utilisé pour la classification.

Une nouvelle méthode de détection automatique des MAs dans les images du fond d'œil est proposée dans Bo Wu et al. [70]. Ils ont utilisé différentes méthodes de prétraitements et une segmentation par croissance de région pour l'extraction des MAs potentiels. Un total de 27 caractéristiques locales et de profil est entraîné par le classifieur KNN afin de classer les images. La méthode proposée a été évaluée sur deux bases de données publiques : ROC et e-optha.

Feroui [71], a proposé une méthode basée sur la morphologie mathématique pour détecter les microanévrismes, elle a fait appel aux opérateurs morphologiques tels que le supremum d'ouverture pour éliminer toutes les structures semblables aux MAs, et a terminé par une classification des pixels. Elle a obtenu des taux de sensibilité, de spécificité et de précision de 89.79 %, 98.96 %, et 99.96 % respectivement.

L'objectif du travail [72], est de mettre en évidence les MAs à l'aide d'un traitement d'image et de classer la gravité de la rétinopathie diabétique. Les lésions ont été extraites à l'aide d'une segmentation en découpage de graphe et la classification de la gravité de la RD est réalisée à l'aide du classifieur SVM avec une ACP. Ils ont obtenu une sensibilité de 94,44 % et une spécificité de 87,5 %.

Dans l'étude de Yehui Yang et al. [73], un algorithme d'analyse automatique de la rétinopathie diabétique basé sur les réseaux de neurones à convolution profonde à deux étapes est utilisé. Cette méthode détermine l'emplacement et le type de lésions dans les images du fond d'œil, et indique les degrés de sévérité de la RD. Les auteurs ont introduit une carte de pondération déséquilibrée, qui apporte plus d'attention aux patchs de lésion pour la classification de la RD, ce qui améliore les performances de leur algorithme. Les résultats expérimentaux ont été comparé à ceux des ophtalmologistes, et le réseau de détection de lésion locale a atteint des performances comparables à celles d'observateurs humains entraînés.

L'article [74], présente les concepts clés de l'apprentissage en profondeur pertinents pour l'analyse d'images de la rétinopathie diabétique et passe en revue les dernières contributions basées sur l'apprentissage en profondeur dans ce domaine.

B. Problématique de la détection des Microanévrismes

La détection des microanévrismes est très importante et très complexe à la fois. En effet, le diamètre des MAs varie généralement entre 10 et $100\mu m$, ce qui est inférieur au diamètre des principales veines optiques. Les images du fond de l'œil contiennent certaines structures semblables aux MAs, en terme de taille et de forme, telles que les petites tâches rondes résultant du croisement des vaisseaux

sanguins minces, cela compromet la reconnaissance des candidats potentiels et rend la tâche de détection des MAs très difficile. Des exemples de présence des Microanévrismes sur les images du fond d’oeil sont illustrés sur la figure suivante :

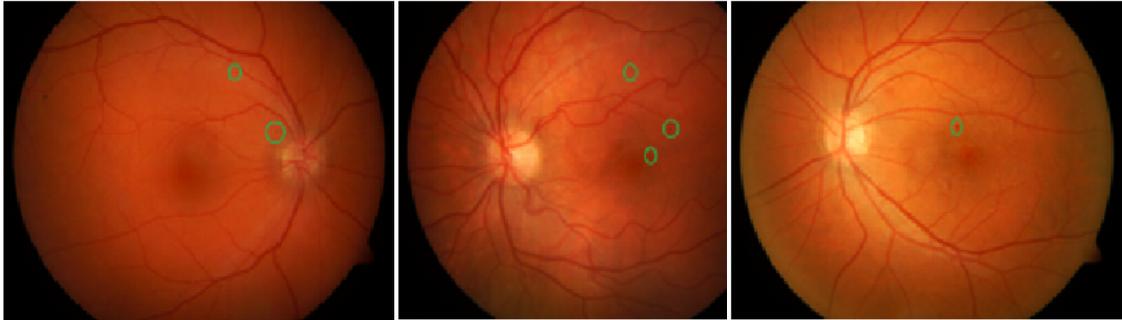


FIGURE 3.2 – Images rétiniennes contenant des MAs.

C. Détection des Microanévrismes (MAs)

La détection automatique des microanévrismes constitue un défi majeur. La figure 3.3 présente le schéma fonctionnel du système proposé pour le dépistage et la classification des MAs.




FIGURE 3.3 – Organigramme de détection des microanévrismes

Dans la méthode proposée, le canal vert inversé des images rétiniennes est utilisé comme entrée principale. Le canal vert fournit le meilleur contraste, tandis que le canal rouge est saturé et le canal bleu est sombre et ne contient aucune information. Dans cette étude nous commençons par certaines étapes nécessaires de prétraitement pour rendre les candidats potentiels plus visibles. Ensuite, les régions candidates à savoir les MAs, sont identifiées dans l’image prétraitée, sur la base de la détection de pic et de la croissance des régions. Finalement, plusieurs caractéristiques sont extraites pour la classification. Le classifieur KNN est

appliqué pour distinguer les véritables MAs de fausses détections. Les différentes étapes de cet organigramme vont être expliquées ci-dessous.

C.1 - Prétraitement des images

Le prétraitement est le processus d'amélioration des données des images, en apportant des corrections et des ajustements de la teinte et du contraste, et en réduisant les bruits dûs aux dispositifs d'acquisition. Les MAs sont à peine visibles dans les zones de faible luminosité et de faible contraste. Afin de réduire ces inconvénients et de créer une image appropriée pour l'extraction des MAs candidats et des caractéristiques, nous avons appliqué ces techniques de prétraitement d'images : l'utilisation du canal vert, la correction d'éclairage, l'égalisation adaptative d'histogramme à contraste limité, le filtrage et le lissage.

– A. Le canal vert

Tout d'abord, on utilise le canal vert de l'image RVB, pour améliorer le contraste. Les caractéristiques rétiniennes peuvent être distinguées les unes des autres en utilisant la couleur comme descripteur. Le canal vert offre un contraste maximal permettant de distinguer les lésions rouges présentes sur les images du fond de l'œil, et il est moins sensible aux éclairages non uniformes, et comme les MAs apparaissent sous la forme de points rouges dans les images rétiniennes alors ce canal est le plus approprié.

Les images d'entrée vont être inversées, ainsi les MAs et le réseau vasculaire apparaîtront sous forme de structures lumineuses. Désormais, lorsque l'on se réfère à une image rétinienne, il s'agit du canal vert inversé de l'image rétinienne d'origine.

La figure suivante présente l'image originale testée, son canal vert et l'inverse de ce canal.




FIGURE 3.4 – (a) : Image originale ; (b) : Canal vert de l'image originale ; (c) : Canal vert inversé.

– B. Correction de la teinte

La deuxième technique est la correction de la teinte, où l'image d'arrière-plan est estimée puis soustraite de l'image originale. L'éclairage non uniforme de l'image doit être corrigé si on veut détecter correctement les microanévrismes présents dans cette zone.

– C. Egalisation adaptative d’histogramme à contraste limité (CLAHE)

L’égaliſation adaptative d’histogrammes est une technique de traitement d’image par ordinateur permettant d’améliorer le contraste de l’image. Son but est de redistribuer la valeur d’intensité dans l’image d’entrée de manière à ce que les valeurs d’intensité des images de sortie soient uniformément réparties. La différence entre l’égaliſation adaptative de l’histogramme et l’égaliſation ordinaire de l’histogramme réside dans le fait que l’égaliſation adaptative calcule plusieurs histogrammes pour différentes sections de l’image, puis distribue les valeurs de la luminosité. Cette technique est utilisée pour améliorer le contraste local et améliorer plus de détails de l’image. Cependant, l’égaliſation adaptative de l’histogramme a ses limites car elle produit une sur-amplification du bruit dans les régions homogènes d’une image. Par conséquent, l’égaliſation adaptative d’histogrammes à contraste limité (CLAHE) est utilisée dans le système proposé afin d’empêcher la sur-amplification du bruit. De nombreux MAs présents sur les images originales du fond d’œil du canal vert inversé ont un contraste insuffisant avec l’arrière-plan environnant, ce qui affecte les futures étapes de détection. Cette technique coupe l’histogramme à la valeur prédéfinie avant de calculer la fonction de distribution cumulative. Elle rend visible de manière plus efficace les parties saillantes intéressantes. La limitation de contraste est appliquée à chaque pixel de voisinage, ce qui évite une amplification excessive du bruit. Une image traitée par égalisation d’histogramme est obtenue en mappant chaque pixel de niveau r_k dans l’image d’entrée en un pixel correspondant de niveau s_k dans l’image de sortie, comme indiqué ci-dessous :

$$s_k = T(r_k) = \sum_{j=0}^k p_r(r_j) = \sum_{j=0}^k \frac{n_j}{n} \quad k=0,1,\dots,L-1$$

La figure suivante présente le résultat de la transformation CLAHE sur le canal vert inversé :




FIGURE 3.5 – Transformation CLAHE appliquée sur le canal vert inversé de l’image originale.

– D. Lissage

La plupart des images rétiniennes sont stockées sous une forme compressée avec perte d’information. Ce qui favorise la déformation des petites structures telles que les MAs. Par conséquent, cela va affecter l’extraction des caractéristiques. De plus, il est important de réduire l’effet du bruit vu que les candidats potentiels sont de petite taille. D’où la nécessité du lissage des images avant les étapes réelles de détection. Un filtre gaussien avec une largeur de 7 et une variance de 1,0 est appliqué, dans notre travail. Il est défini par :

$$I = I_A * G \quad G_{x,y} = \frac{1}{2\pi\theta^2} \exp\left(-\frac{x^2+y^2}{2\theta^2}\right)$$

Où I est l’image résultante d’une convolution entre l’image améliorée I_A et le filtre Gaussien G.

La figure suivante montre le résultat de lissage.




FIGURE 3.6 – (a) Filtre Médian ; (b) Filtre de Gauss

C.2 - Extraction des Microanévrismes

L'étape de l'extraction des candidats potentiels joue un rôle important dans l'ensemble de la détection. L'objectif principal de cette étape est de réduire le nombre d'objets qui ne sont pas similaires aux MAs. Toutefois, les véritables MAs perdus au cours de cette étape ne peuvent pas être récupérés ultérieurement.

– A. Calcul des Maximas locaux

La détection précise des MAs est une tâche très difficile notamment lorsqu'il s'agit de différencier entre les MAs et les fragments des vaisseaux minces. En effet, les segments des vaisseaux sont des structures de l'image rétinienne dont les points sont des maxima locaux dans au moins une direction. D'autre part, les MAs sont des objets circulaires, apparaissant comme des maxima locaux dans toutes les directions. Nous commençons par tester si un pixel dans l'image est un maximum local dans une direction particulière. On considère les lignes de balayage avec des pentes différentes, passant par la position spécifique testée. Les enregistrements des valeurs de pixels le long de ces lignes de balayage donnent un ensemble de profils en coupe transversale. Si nous examinons ces profils, nous constatons que les candidats potentiels montrent un pic défini dans toutes les directions. Dans le cas des points de croisements du réseau rétinien, seuls les profils des lignes de balayage perpendiculaires au vaisseau présentent des pics forts, et à mesure que la direction de la ligne de balayage se rapproche du segment du vaisseau, le pic du profil s'allonge de plus en plus, jusqu'à disparaître presque complètement.

Afin d'exploiter l'observation des profils de section transversale des MAs et des segments du réseau vasculaire, il faut accéder à chaque pixel de l'image dans toutes les directions possibles. Pour cette raison, nous utilisons des lignes de balayage qui traversent l'ensemble de l'image. Considérons l'équation d'interception de la pente de la ligne : $y = p * x + a$. En modifiant le paramètre d'ordonnée à l'origine a avec une pente fixe p , il est possible d'accéder à chaque pixel de l'image pour la direction donnée x , à l'exception du cas vertical qui doit être traité séparément. De cette façon,

nous définissons la ligne de balayage $LB_{\alpha,b}$ comme un vecteur de points dont le k^{me} élément $LB_{\alpha,b}[k]$ est le k^{me} point de la ligne discrète définie par : $y = \tan \alpha * x + a$. L'équation est donnée par :

$$LB_{\alpha,b}[k] = \begin{cases} -90^\circ < \alpha < -45^\circ : \left(\left\lfloor \frac{-k}{\tan \alpha} \right\rfloor, [a] - k \right) \\ -45^\circ \leq \alpha \leq 45^\circ : (i, [\tan \alpha * k + a]) \\ 45^\circ < \alpha < 90^\circ : \left(\left\lfloor \frac{k}{\tan \alpha} \right\rfloor, [a] + k \right) \end{cases}$$

Les directions de balayage doivent être échantillonnées de manière équidistante, c'est à dire :

$$\alpha \in \Phi = \phi_1, \phi_2 \dots : -90 \text{ deg} < \phi_i \leq 90 \text{ deg} \wedge \phi_{i+1} - \phi_i = \Omega$$

où Ω désigne le paramètre d'étape d'analyse. Le choix d'un petit Ω aboutirait à une numérisation plus fine, théoriquement. Cependant, nos expériences ont montré que le choix de Ω inférieur à 3deg n'a pas de différence significative dans les résultats finaux.

La figure suivante montre le résultat de détection de tous les maxima locaux.




FIGURE 3.7 – Détection de tous les maximums locaux présents sur l'image.

– B. Détection des pics

Dans cette étape nous allons considérer que les pics dont la largeur est inférieure ou égale à d_{max} qui peuvent correspondre aux MAs. Outre la position

des pics, la mesure de leur hauteur est également requise, car ces informations décrivent dans quelle mesure l'objet est séparé de son environnement dans une direction donnée. Une telle mesure est nécessaire pour prendre en compte à la fois la hauteur et la largeur du pic. Les pics larges auront une faible valeur, même si leur hauteur suggère le contraire. Cette exigence est remplie en appliquant une ouverture surfacique sur les profils d'intensité. En considérant la différence entre le résultat et le profil d'origine (transformation du chapeau haut de forme), nous pouvons obtenir une mesure de hauteur de pic corrigée appropriée pour chaque position dans le profil.

L'ouverture d'attribut repose sur l'extension successive de tous les maxima régionaux en abaissant progressivement le seuil local, jusqu'à ce qu'un certain critère soit rempli. Dans le cas d'une ouverture surfacique, le critère d'arrêt est atteint lorsque la surface de la région étendue devient plus grande que le paramètre donné. Soit $\Gamma_{\Lambda}^a(v)$, le résultat de l'ouverture surfacique appliquée au vecteur v avec le paramètre Λ . Ainsi, l'opérateur d'ouverture surfacique du chapeau haut de forme est défini par : $\overline{\Gamma}_{\Lambda}^a(v) = v - \Gamma_{\Lambda}^a$ avec $\Lambda = d_{max}$.

Une valeur de hauteur est attribuée à chaque pixel pour une direction donnée, nous définissons la fonction $MHD(x, y, \alpha)$ de mappage de hauteur directionnelle, dont la valeur est calculée en tant que valeur correspondante de l'opérateur d'ouverture surfacique du chapeau haut de forme appliqué au profil d'intensité de la ligne de balayage passant par le point (x, y) selon l'angle α .

$$MHD(x, y, \alpha) = \begin{cases} -90^\circ < \alpha < -45^\circ : \overline{\Gamma}_{d_{max}}^a(IP_{\alpha, b^*})[|b^*| - y] \\ -45^\circ \leq \alpha \leq 45^\circ : \overline{\Gamma}_{d_{max}}^a(IP_{\alpha, b^*})[x] \\ 45^\circ < \alpha < 90^\circ : \overline{\Gamma}_{d_{max}}^a(IP_{\alpha, b^*})[y - |b^*|] \\ \alpha = 90^\circ : \overline{\Gamma}_{d_{max}}^a(VIP_X)[y] \end{cases}$$

où $b^* = y - \tan \alpha * x$. Soit $DHV(x, y)$, désigne le vecteur contenant les valeurs de hauteur pour une position donnée, c'est-à-dire : $DHV(x, y)[i] = MHD(x, y, \phi_i)$. Les MAs atteignent des valeurs de hauteur presque égales pour toutes les directions de balayage, tandis que dans le cas des fragments du réseau, un vide est observé dans certaines directions.

La figure suivante montre la détection et la localisation des MAs.




FIGURE 3.8 – Représentation des MAs et des Non-MAs dans différentes directions

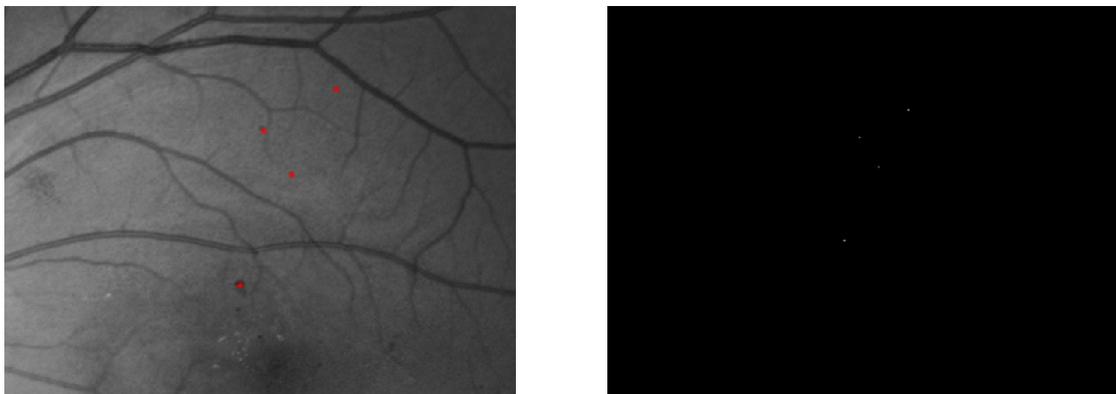


FIGURE 3.9 – (a) Zoom sur une partie de l'image avec la localisation des MAs ; (b) Localisation des MAs en binaire.

– C. La croissance de région

Les candidats potentiels ne peuvent pas représenter les pathologies telles que trouvées dans l'image originale. La croissance de région est utilisée pour rétablir le pixel candidat selon sa forme pathologique d'origine lors de l'extraction. Cependant, il est difficile de déterminer le seuil en raison de l'intensité et de la taille variable des MAs.

La figure suivante représente le résultat de croissance des régions.




FIGURE 3.10 – Résultat de la croissance de région

C.3 - Extraction des caractéristiques

Deux types de caractéristiques ont été extraits pour la caractérisation des MAs : les caractéristiques locales et les caractéristiques de profils.

A. Caractéristiques locales

Pour extraire les caractéristiques d'intensité et de forme, nous avons pris en considération une sous région d'intérêt (ROI) qui sont les MAs candidats. La sous-ROI est beaucoup plus important que la région candidate. La région candidate se situe au centre des sous-ROI et la région restante est dans l'arrière-plan. En outre, la forme des sous-ROI est circulaire car les MAs apparaissent sous la forme d'une structure globale dans les images du fond d'œil. Pour chaque région candidate, les caractéristiques de forme et d'intensité suivantes sont extraites :

Caractéristiques	Noms des caractéristiques	Explications
C1	La surface : $S = \sum_{j \in \Omega} 1$	Ω est l'ensemble des pixels dans la région candidate
C2	La symétrie : $Sym = \sqrt{\frac{1}{N_E} \sum_{j \in E} (d_l - \bar{d})^2}$	où d_l est la distance entre le pixel de bord et le pixel le plus lumineux (pixel central) de la région candidate. \bar{d} est la distance moyenne.
C3	Le rapport d'aspect : $R = \frac{l}{w}$	où l est la plus grande longueur et w est la deuxième plus grande valeur propre de la matrice de covariance de la région candidate.
C4	Le contraste moyen des pixels de bord : $C = \frac{\sum_{j \in A} g_i}{N_A} - \frac{\sum_{j \in B} g_i}{N_B}$	où A est un ensemble de pixels appartenant aux 8 pixels voisins du pixel calculé et dont l'intensité est \geq au pixel calculé. N_A est le nombre de pixels appartenant à A.
C5	Le périmètre	Distance entre chaque paire adjacente de pixels autour du bord de la région
C6	La circularité	$Circularité = \frac{Périmètre^2}{4 * \pi * Surface}$
C7	La déviation standard du contraste des pixels de bord	$\sigma_c = \frac{\sum_{i \in Y} \sqrt{(c_i - \bar{c})^2}}{N_y}$
C8	L'intensité moyenne de la région des MAs candidats	$I_{cand} = \frac{\sum_{i \in \Omega} g_i}{N}$
C9	Déviation standard de l'intensité de la région candidate des MAs	$\sigma_{cand} = \frac{\sum_{i \in \Omega} \sqrt{(g_i - M_{obj})^2}}{N}$
C10	L'intensité moyenne du fond	$I_f = \frac{\sum_{i \in f} g_i}{N_f}$
C11	Déviation standard de l'intensité du fond	$\sigma_f = \frac{\sum_{i \in E} \sqrt{(g_i - I_f)^2}}{N_f}$
C12	Différence entre l'intensité moyenne des MAs candidats et de l'arrière-plan	$I_{diff} = I_{cand} - I_f$
C13	Différence entre l'intensité maximale de la région candidate et un contraste local. Cela donne plus d'informations sur la différence de gris entre les MAs candidats et leurs environs	$D = I_{max} - t \quad \text{avec} \quad t = I_f - \beta \sqrt{\sigma_f}$

B. Caractéristiques de profil

Caractéristiques	Noms des caractéristiques	Explications
C1	La largeur du pic est la différence entre le début et la fin du pic	$W_{pic} = RD_{fin} - RC_{abut}$
C2	Hauteur de la rampe croissante	$H_{RC} = P[RC_{fin}] - P[RD_{abut}]$
C3	Hauteur de la rampe décroissante	$H_{RD} = P[RD_{abut}] - P[RC_{fin}]$
C4	Hauteur moyenne du pic	$\overline{H_{pic}} = \sum_{RC_{abut}}^{RD_{fin}} P[i] / W_{pic}$
C5	Le début de la hauteur de la rampe croissante	$H_{RC_{abut}} = P[RC_{abut}]$
C6	La fin de la hauteur de la rampe décroissante	$H_{RD_{fin}} = P[RD_{fin}]$

TABLE 3.1 – Les caractéristiques de profil utilisées

En résumé, 19 caractéristiques au total (13 caractéristiques locales et 6 caractéristiques de profils) ont été extraites pour chaque candidat.

D. Classification (KNN)

Au stade de l'extraction des caractéristiques, chaque MAs candidat est caractérisé par un vecteur dans un ensemble de 19 caractéristiques, $C=[C1, C2, C3, \dots, C19]$. Cependant, les différentes caractéristiques ont des plages et des valeurs différentes, ce qui n'est pas avantageux pour certains classificateurs. Chacune de ces caractéristiques est normalisée à une variance moyenne et unité nulle en appliquant,

$$\overline{C}_i = \frac{C_i - \mu_i}{\sigma_i}$$

où μ_i est la moyenne de la i^{ieme} fonctionnalité, et σ_i est son écart type. Nous avons sélectionné le classificateur supervisés K plus proche voisin (KNN) pour réaliser la tâche de la classification. Son choix s'est fait par rapport à ce que la littérature utilise le plus souvent, ainsi que pour sa simplicité d'implémentation. Un K=5 a été retenu dans cette partie du travail.

La figure suivante montre le résultat final de détection des MAs.

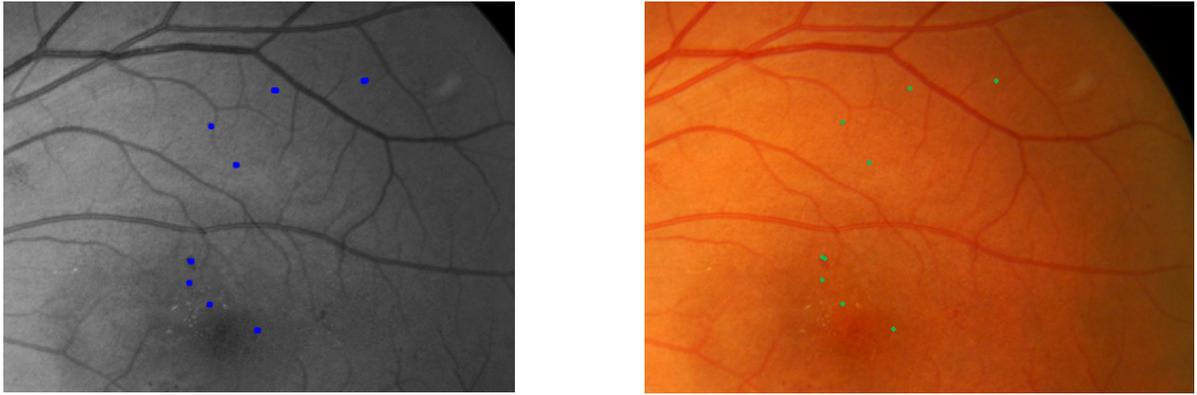


FIGURE 3.11 – Résultat final de détection des MAs.

2.2 Détection des Hémorragies (HEs)

Les hémorragies rétiniennes sont des signes cliniques de maladie ou de blessure de la rétine, observables sous forme de structures sombres indiquant un saignement. Sur une image rétinienne, les hémorragies sont rougeâtres et de différentes tailles, on retrouve les hémorragies punctiformes qui se trouvent sous forme de petites tâches rouges isolées, les hémorragies en tâches sont des structures circulaires irrégulières, texturées en pointillés, tandis que les hémorragies en forme de flammes sont des saignements en éventail orientés vers la tête du nerf optique. Les lignes directrices cliniques précisent que l'emplacement et l'étendue des hémorragies constituent un indicateur direct de la gravité de la maladie. La détection et la segmentation des hémorragies constituent donc un élément important pour le dépistage et la classification assistés par ordinateur.

2.2.1 Etude de la littérature

Dans la plupart des méthodes de détection des hémorragies, une extraction et une classification des candidats appartenant aux lésions rouges sont proposées. Le prétraitement est la première étape du traitement de l'image pour améliorer la qualité de l'image et réduire le bruit. La segmentation des lésions rouges est la seconde étape pour extraire les candidats potentiels. L'analyse et la classification des caractéristiques constituent l'étape finale. Nous allons donner dans ce qui suit un état de l'art sur les différentes approches utilisées dans la littérature pour la détection des HEs.

Neera et al. [75] ont proposé une méthode de détection des exsudats, des hémorragies et des microanévrismes. L'algorithme proposé prend en compte la taille et l'emplacement de l'hémorragie afin que la maladie puisse être diagnostiquée plus tôt et que le patient puisse prendre conseil auprès du médecin.

Kose et al. [76] ont proposé une méthode de séparation de la région saine et non saine en utilisant la méthode de la segmentation inverse. Les textures des régions saines et malsaines sont différentes. Après la segmentation inverse, la partie restante est la lésion sombre, qui est également supprimée en utilisant la valeur d'intensité qui est inférieure à la valeur d'intensité du fond.

Dolly et al. [77], proposent la détection des hémorragies dans les images rétinienne. Leur approche est constituée de trois étapes, en premier ils ont éliminé le bruit de l'image de fond, ensuite ils ont supprimé le réseau et la fovéa, pour finalement détecter les HEs en prenant en compte la forme, la surface, le format, la densité et l'intensité moyenne. Ils ont conclu que cette approche a renforcé la détection des hémorragies.

Garima et al. [78], ont utilisé un traitement morphologique multirésolution en vue de réaliser un regroupement perceptuel des candidats hémorragiques se présentant sous différentes formes, tailles et textures. La méthode proposée est basée sur la suppression des candidats localisés sur les vaisseaux sanguins avec une bonne segmentation des véritables hémorragies. Ce travail a été évalué sur un ensemble de 191 images présentant différents degrés de gravité pathologique, ils ont obtenu une sensibilité de 82 %, cette valeur augmente pour les candidats de plus grande taille.

Smith et al. [79], présentent une synthèse des travaux effectués dans le domaine de la recherche de la détection et la classification des hémorragies issues de la Rétinopathie Diabétique. Ce travail examine, classifie et compare de manière approfondie les algorithmes et les techniques précédemment proposés afin de soutenir et de fournir aux chercheurs actuels et futurs un résumé détaillé de ces algorithmes.

Dans le travail de Godlin et al. [80], toutes les images ont été soumises à des étapes de prétraitement et certaines fonctionnalités ont été extraites des images. Ensuite, le classifieur ANFIS a été utilisé pour classer les images normales et anormales. Des techniques d'optimisation de seuil de Grey Wolf ont été calculées pour obtenir une précision maximale dans le processus de segmentation des hémorragies.

Feroui [71] a suivi trois étapes pour la détection des hémorragies, à savoir : le prétraitement des images, la détection des régions sombres et la classification des pixels. Elle a utilisé la morphologie mathématique. Le test s'est fait sur un ensemble d'images de la base Diaret Db1, elle a atteint une précision de 94.97 %

Jyothi et al. [81], ont présenté une approche avancée basée sur le splat pour la détection des hémorragies. Premièrement, le fond est prétraité via une compensation de couleur moyenne et est segmenté à l'aide de SLIC. La segmentation par les splat se faisait avant ce travail par une sur-segmentation des bassins versants. Cela augmentait le risque de splats non identifiés. Le problème a été résolu en utilisant les SLIC. Les cas de faux positifs et de faux négatifs sont minimisés avec

cette approche. Un ensemble de caractéristiques est extrait de chaque splat pour décrire ses caractéristiques par rapport à son environnement, en utilisant les réponses d'une variété de filtres d'interactions avec des splats voisins et d'informations de forme et de texture. Un classifieur clairsemé est ensuite formé avec des annotations d'experts basées sur les splat et évaluées sur l'ensemble des données disponible au public. Les modèles clairsemés ont beaucoup de force. La parcimonie est un principe de régularisation important pour réduire la complexité du modèle et éviter ainsi un ajustement excessif.

2.2.2 Problématique de la détection des Hémorragies rétiniennes

La segmentation des hémorragies contribue à améliorer l'efficacité de l'analyse d'images assistée par ordinateur de maladies telles que la rétinopathie diabétique et la rétinopathie hypertensive. Cependant on rencontre un problème lors de la délimitation des HEs du fait qu'elles résultent des fuites de sang se trouvant à proximité des vaisseaux sanguins, donc cela va compromettre la détection de leur contours. Une autre difficulté à définir une hémorragie est qu'elle n'a généralement pas de taille ou de forme fixe. Les hémorragies recueillies dans une petite zone sont particulièrement difficiles à dénombrer. L'algorithme utilisé dans cette recherche va tenter de résoudre ces problèmes de détection.

2.2.3 Détection des Hémorragies rétiniennes

Nous proposons pour l'extraction des Hémorragies (HEs), une méthode basée sur la segmentation par la méthode du Fuzzy C-Means (FCM), en passant par des étapes de prétraitement des images d'acquisitions. On fait appel à la morphologie mathématique pour la suppression des candidats non-hémorragiques, et on termine par l'extraction des paramètres pertinents suivie d'une classification pour la réduction des faux positifs. Ces différentes étapes sont illustrées sur la figure suivante :




FIGURE 3.12 – Organigramme de la méthode développée pour la détection des Hémorragies

Les différentes étapes de cet organigramme seront expliquées dans ce qui suit.

2.2.3.1 Prétraitement des images d'acquisition

Les images prises par les caméras du fond d'œil présentent généralement un bruit et une illumination non uniforme, du fait que la luminosité soit centrée sur le disque optique. Cela complique souvent l'extraction des hémorragies, car elles ont une couleur similaire à celle des vaisseaux et du fond. Par conséquent, un prétraitement est nécessaire et très important pour faciliter l'extraction des caractéristiques. Les techniques de prétraitement ont en commun l'ajustement de la

luminosité afin de la rendre uniforme et d'intensifier le contraste entre les zones d'intérêt et l'arrière-plan. Pour détecter une hémorragie dans une image de fond d'œil, nous devons minimiser les détails de l'image. La technique utilisée est effectuée sur le canal vert des images couleur RVB, qui présente la zone d'intérêt la mieux contrastée. La luminosité est le facteur clé pour la détection des lésions rouges. En premier lieu, nous avons appliqué une égalisation d'histogrammes adaptative pour augmenter le contraste des images, suivi par une Ouverture Morphologique qui va lisser les formes et éliminer les composantes plus petites que l'élément structurant. Un filtre Gaussien est utilisé par la fin, pour réduire le bruit présent sur les images. La fonction mathématique réalisant cette tâche est donnée par :

$$I_{amliore} = \gamma^B(I_{corrige} * F_G)$$

Où l'image améliorée finale $I_{amliore}$ est obtenue en effectuant une ouverture morphologique γ^B par un élément structurant sur la convolution de l'image obtenue après l'augmentation de contraste $I_{corrige}$ avec le filtre Gaussien F_G .




FIGURE 3.13 – Images obtenues après les étapes de prétraitement ; (a) L'image Originale, (b) Le canal vert de l'image originale, (c) L'égalisation Adaptative d'Histogramme, (d) L'ouverture morphologique, (e) Filtrage Gaussien.

2.2.3.2 Application de l'algorithme FCM

L'algorithme Fuzzy C-Means est largement utilisé. La procédure de classification floue est introduite par Dunn en 1973 puis améliorée par BezdekIn 1981. Le principal objectif de l'algorithme F-C-Means est de minimiser la fonction objective et la variance intra-classe. L'algorithme Fuzzy C-Means est utilisé dans le domaine du traitement d'image et de la reconnaissance de modèle pour traiter

efficacement les problèmes de mise en cluster.

L'algorithme C-Means flou attribue les niveaux d'appartenance à chaque point de données correspondant à chaque centre de cluster en fonction du point de données et de la distance entre les centres de cluster. La somme des membres de chaque point de données est égale à un. L'algorithme Fuzzy C-Means permet qu'une donnée soit membre de deux classes ou plus. Le FCM donne le meilleur résultat pour les éléments de données superposés et il vaut mieux que l'algorithme de K-Means, mais le principal inconvénient est de spécifier la priorité du nombre de clusters.

Etapes algorithmiques du FCM :

L'algorithme FCM, partitionne la collection de N éléments ($X = X_1, X_2, \dots, X_n$) en cluster flous en fonction de certains critères.

1) Sélectionnez au hasard les centres des clusters « C ».

2) Calculer la composition floue μ_{ij} en utilisant :

$$\mu_{ij} = 1 / \sum_{k=1}^c \frac{d_{ij}^{\frac{2}{m-1}}}{d_{ik}}$$

3) Calculez les centres flous V_j en utilisant :

$$R_j = \frac{\sum_{i=1}^n (\mu_{ij})^m x_i}{\sum_{i=1}^n (\mu_{ij})^m}, \forall j = 1, 2, 3, \dots, c$$

4) Répétez les étapes 2) et 3) jusqu'à atteindre la valeur j minimale où $\|U^{k+1} - U^k\| < B$.

Avec :

k l'étape d'itération, B est le critère de terminaison compris entre [0, 1], $U = (\mu_{ij})_{N \times C}$ est la matrice d'appartenance floue, et j est la fonction objective. Dans notre travail, l'algorithme FCM renvoie trois paramètres, tels que les centres, la matrice patricienne et la fonction objective. La matrice de proximité donne la fonction d'appartenance et la fonction objective représente les valeurs de la fonction lors des itérations. Les matrices de proximité maximales sont sélectionnées pour constituer des clusters distincts, puis la moyenne la plus basse est déterminée en tant que premier cluster parmi les trois, ensuite la moyenne la plus élevée est déterminée en tant que troisième cluster, et la valeur moyenne est définie en tant que deuxième cluster.

La figure suivante présente le résultat du FCM.

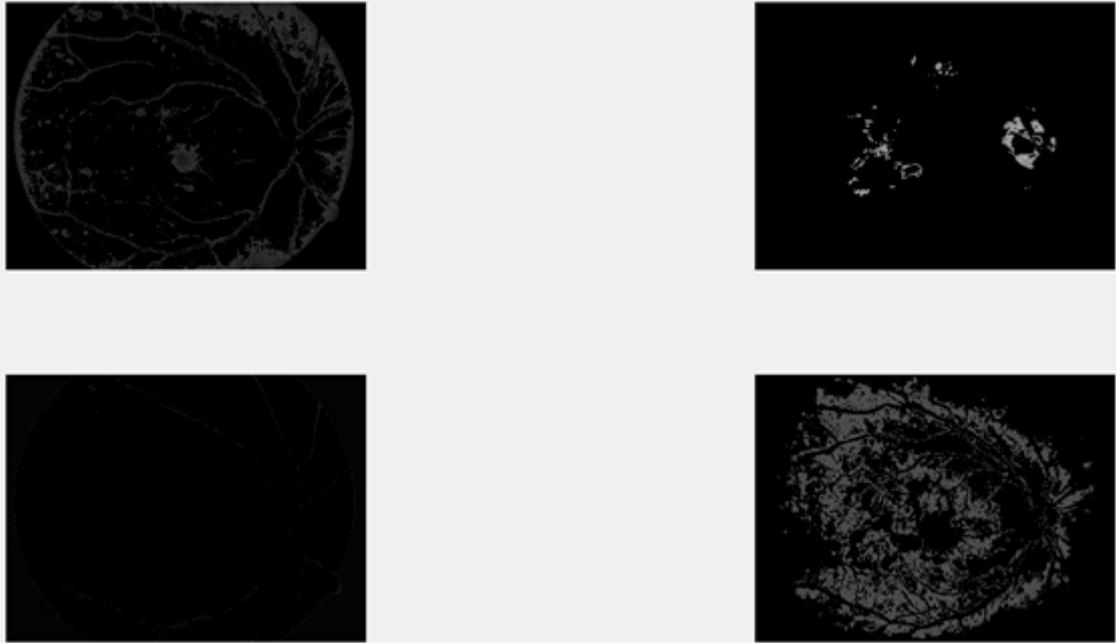


FIGURE 3.14 – Résultats de l’application de l’algorithme FCM

2.2.3.3 Suppression des candidats Non-Hémorragiques (Le réseau vasculaire et la macula)

Étant donné que la couleur de l’hémorragie est presque identique à celle des vaisseaux sanguins, et que la zone fautive détectée est principalement constituée de vaisseaux sanguins, et que la macula apparaît sous forme de tâche foncée sur l’image rétinienne, cela va compromettre la détection des hémorragies. Dans ce cas, il serait judicieux de les détecter pour ensuite de les éliminer.

A. Elimination du réseau vasculaire

On commence par appliquer le chapeau haut de forme avec un élément structurant cercle de taille 10 sur l’image filtrée ultérieurement. On fait appel au chapeau haut-de-forme noir, car il détecte les parties sombres d’une image.

Ensuite on applique l’opération des Supremums d’ouvertures [82]. La particularité de cette opération c’est qu’elle met en évidence les objets connexes qui ont une forme allongée tels que l’arbre vasculaire. Elle consiste à appliquer plusieurs ouvertures successives dans toutes les directions du plan avec un élément structurant linéaire, appliquées sur le chapeau haut de forme, l’image obtenue après ce traitement fait bien apparaître le réseau rétinien. La fonction utilisée pour réaliser cette opération est donnée par :

$$\gamma^{sup}(BTH) = \bigcup_{i=1}^k \gamma^{LB_i}(BTH)$$

Où $\gamma^{sup}(BTH)$ est le supremum d’ouverture par le chapeau haut de forme noir, et $\bigcup_{i=1}^k \gamma^{LB_i}$ est l’union de toutes les ouvertures avec les éléments structu-

rants B_i dans les directions L.

On réalise par la suite un seuillage suivi d'une dilatation afin de bien visualiser le réseau et on termine par soustraire l'image dilatée de l'image obtenue par l'algorithme FCM après le seuillage. Le résultat de ces opérations est montré dans les figures suivantes :




FIGURE 3.15 – Résultats de suppression du réseau vasculaire ; (a) Transformation Top-Hat, (b) Résultat du Supremum d'ouverture, (c) Seuillage de l'image b, (d) Dilatation de l'image c, (e) Résultat de la soustraction de l'image (d) avec le résultat de seuillage de la figure (a)

B. Elimination de la Macula

Un second prétraitement est effectué dans cette étape, car on utilise le canal de luminance qui s'avère être le plus approprié pour la détection de la macula. On travaille sur l'image HSV qui est basé sur la teinte, la saturation et la luminosité.

On s'intéresse au canal de luminance car la macula est bien perçue et cela va nous faciliter la tâche pour les étapes futures. On applique par la suite, une égalisation adaptative d'histogramme afin de corriger le contraste, suivi d'un filtrage Gaussien d'une petite taille (3*3) et d'une variance de 4 afin d'atténuer les bruits.

Une opération de fermeture morphologique avec un élément structurant disque de taille 7 est utilisé pour effacer le réseau vasculaire, secondé par une fermeture par diamètre par un élément structurant disque de taille 80 pour effacer la macula. La soustraction (l'opération du Top-Hat) entre ces deux images de fermeture nous permet de récupérer la macula. Les résultats de ces étapes sont donnés par la figure suivante :

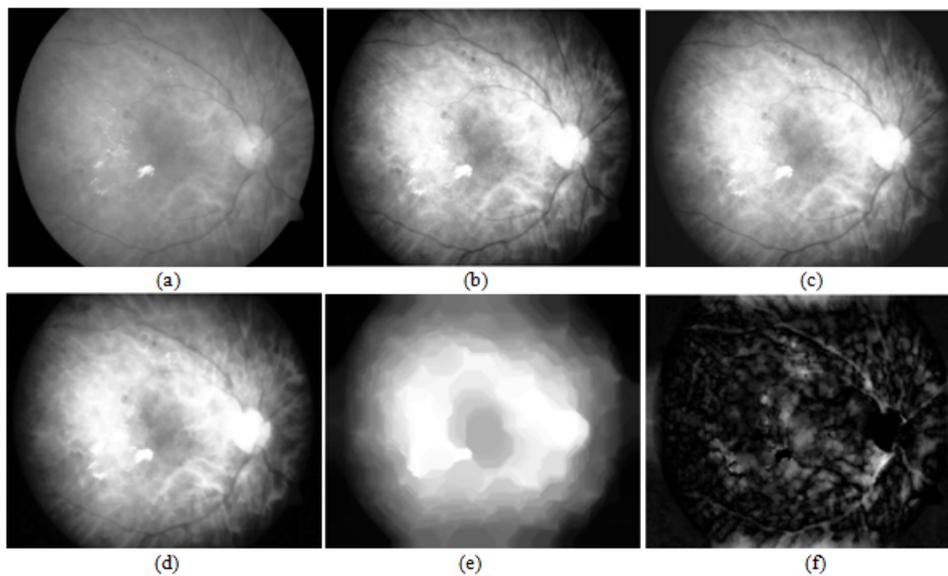


FIGURE 3.16 – Etapes de prétraitement pour l'élimination de la macula ; (a) Le canal de luminance (V) de l'image originale, (b) L'égalisation d'histogramme du canal V, (c) Filtrage Gaussien de l'image b, (d) Fermeture morphologique de l'image "c", (e) Fermeture par diamètre de l'image "d", (f) Le résultat de la soustraction entre les deux images "d" et "e" (TOP-HAT).

Il s'en suit, une binarisation en effectuant un seuillage local ainsi qu'une suite d'ouverture surfacique jusqu'à arriver à une détection précise de la macula. Le résultat des ces opérations d'ouverture sera soustrait par la fin de l'image de la fig 3.15. e, on obtient alors une image ne contenant ni le réseau vasculaire ni la macula, néanmoins cette image présente beaucoup de faux positifs. Les résultats sont donnés par la figure suivante :

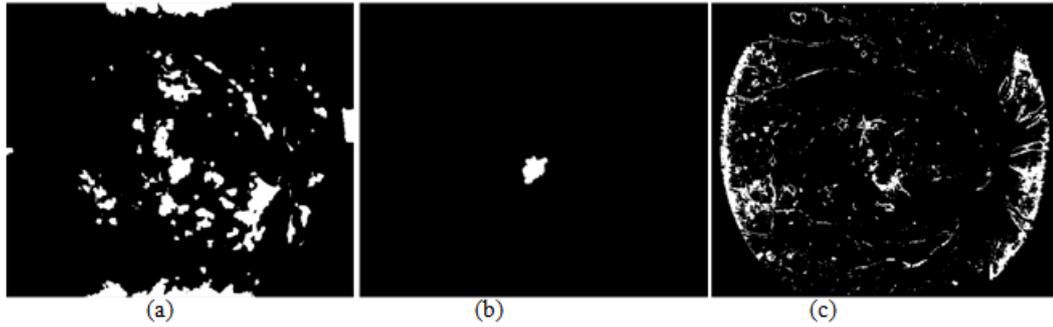


FIGURE 3.17 – (a) Image binaire, (b) Extraction de la Macula, (c) Résultat de l'opération de soustraction

2.2.3.4 Extraction des caractéristiques et classification

L'extraction et la classification des candidats hémorragiques se chevauchent par nature. Ces deux phases sont en fait les composants les plus importants des algorithmes de détection automatisée des hémorragies, car elles contribuent à la détection proprement dite. Le principe suivi est donné par la figure suivante :

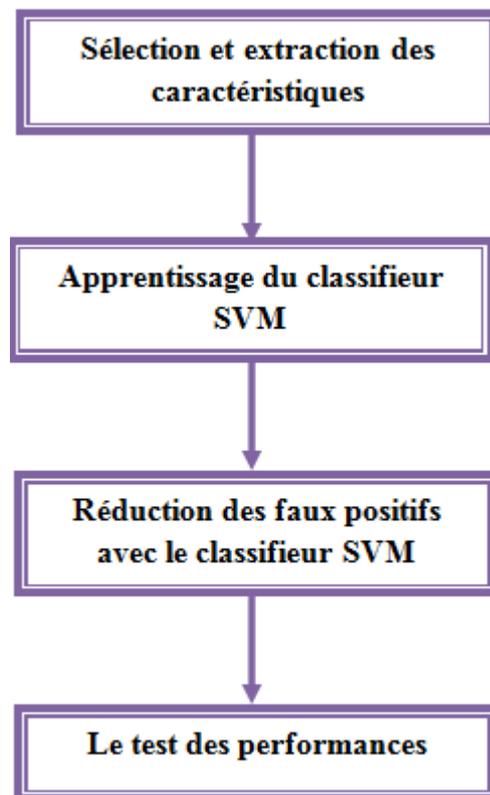


FIGURE 3.18 – L'organigramme du processus de classification

Comme on peut remarquer sur la fig. 3.17. c, l'image contient énormément de faux positifs, un choix correcte et pertinent doit être fait afin de bien caracté-

ser les hémorragies pour pouvoir ensuite classer correctement les images comme étant saines ou diabétiques (Présence d’HEs). Une bonne classification repose principalement sur le vecteur de caractéristique. Pour ce faire, on se base principalement sur la particularité des Hémorragies, à savoir :

Caractéristiques	Noms des caractéristiques	Explications
C1	La surface : $S = \sum_{j \in \Omega} 1$	Elle est caractérisée par l’identification des faux positifs provenant du bruit conséquent des hautes fréquences
C2	L’entropie de Shannon	Présente toute la quantité d’information que contient une image. La valeur de l’entropie diffère considérablement entre les images pathologiques et les images saines
C3	La bifurcation entre deux vaisseaux sanguins	Une division d’un vaisseau sanguin en deux ou plusieurs branches est appelée bifurcation. Une classe d’approches populaires pour la segmentation des navires est basée sur des méthodes de filtrage, qui fonctionnent en maximisant la réponse en tant que structures de navire. La valeur moyenne pour une image de fond d’œil normale est de loin supérieure à celle d’une image de diabétique. Par conséquent, il s’agit d’un bon élément à prendre.
C4	La compacité : $C = \sqrt{(\sum_{i=1}^n d_i - \bar{d})/n_{pixels}}$	Elle est définie comme étant la somme des différences entre la distance des centres de gravité des lésions candidates et la moyenne des distances des centres de gravité avec leurs pixels de bords.
C5	Le périmètre	Distance entre chaque paire adjacente de pixels autour du bord de la région
C6	La circularité	Elle prend en considération les objets de formes circulaires et allongées
C7	Intensité totale 1	Elle est calculée à partir de l’image du canal vert
C8	Intensité totale 2	Elle est calculée à partir de l’image d’amélioration
C9	Intensité normalisée : $I_N = \frac{1}{S} I_{amliore}$	Elle est calculée dans les régions candidates des images d’améliorations
C10	L’intensité moyenne 1	Elle est calculée dans la région candidate de l’image du canal vert
C11	Intensité moyenne 2	Elle est calculée dans la région candidate de l’image d’amélioration
C12	Intensité normalisée du canal vert	Elle est calculée dans chaque région candidate
C13	Ecart type 1	Il est calculé dans la région candidate de l’image du canal vert
C14	Ecart type 2	Il est calculé dans les régions candidates des images d’amélioration

TABLE 3.2 – Tableau descriptif du choix des différentes caractéristiques utilisées pour classer les HEs

Ce choix des caractéristiques a été réalisé sur la base de ce que la littérature utilise le plus souvent, et après discussion et validation de médecins spécialistes

en ophtalmologie. Nous nous sommes appuyés principalement sur les caractéristiques des Hémorragies qui présentent des contours nets et qui se trouvent sous forme de couleur foncée, ce qui rend leur contraste plus important dans une image rétinienne.

Après cette étape décisive, on passe à la dernière phase de notre algorithme qui consiste à classer nos images sous deux catégories : images saines ou images pathologiques (Présence des HEs). Pour réaliser cette tâche, on fait appel à la classification supervisée, qui est largement exploitée par les chercheurs dans ce domaine. Elle utilise la signature spectrale définie dans l'ensemble de formation. Elle détermine chaque classe en fonction de ce à quoi elle ressemble le plus dans le jeu d'entraînement.

La classification supervisée passe par deux phases très importantes afin de réaliser sa fonction : La Phase d'Apprentissage. Elle utilise les données d'apprentissage pour estimer les paramètres de l'algorithme d'un classificateur particulier à utiliser, ces paramètres seront les propriétés du modèle de probabilité utilisé ou seront des équations définissant des partitions dans l'espace multispectral. L'ensemble de paramètres pour une classe donnée est parfois appelé la signature de cette classe.

On a utilisé le Séparateur à Vaste Marge (SVM) pour effectuer la classification de nos images. Les 2/3 de notre base à été utilisé pour l'apprentissage, et le test s'est fait avec le 1/3 restant de la base de donnée.

Le classifieur SVM cherche à séparer deux classes par un hyperplan dont la distance minimale (appelée marge) entre les échantillons d'apprentissage des deux classes est la plus grande possible. Les spectres les plus proches, utilisés pour déterminer l'hyperplan, sont appelés vecteurs de support. La fig. 8. a montre un exemple de classification binaire pour lequel l'hyperplan apparaît en rouge. Parfois, un hyperplan séparateur n'existe pas ou, s'il existe, il ne s'agit pas de la meilleure solution. Une solution consiste à assouplir la contrainte de séparation et à autoriser les erreurs. Dans ce cas, nous utilisons des marges SVM telles que celles illustrées à la (fig. 3.19.b). Bien que les SVM aient été conçus spécialement pour la classification binaire, il ont été étendus vers la classification multi-classes du type «un contre tous» ou «un contre un».




FIGURE 3.19 – (a) Illustration du concept des vecteurs de support et de la marge dans un exemple de discrimination linéaire séparable en deux dimensions ; b) Exemple de marge souple d'un SVM permettant des erreurs.

Les méthodes de noyau sont utilisées lorsque la fonction de décision SVM (l'hyperplan) ne peut pas être séparée par une ligne. Dans ce cas, une fonction (appelée noyau) est utilisée pour transformer les données en un espace plus grand (espace de fonctions) dans lequel les données peuvent être séparées linéairement. La fonction du noyau, peut prendre de nombreuses formes (par exemple, linéaire, polynomiale, gaussienne, etc.), elle calcule un produit scalaire en tant que mesure de la similarité entre deux spectres à traiter. La figure 3.20 illustre l'utilisation d'un noyau pour linéariser l'espace de données afin de définir l'hyperplan SVM. Ensuite, la transformation inverse Φ^{-1} est utilisée pour revenir à l'espace d'origine.

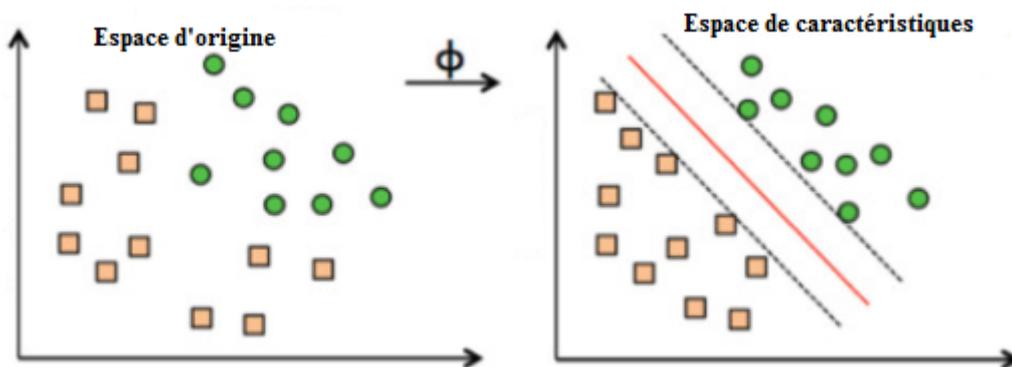


FIGURE 3.20 – Illustration de l'utilisation d'un noyau ϕ dans la méthode SVM. À gauche se trouve l'espace d'origine des attributs et à droite, la projection à travers une fonction du noyau

La figure suivante montre le résultat final de détection des HEs sur l'image binaire et la superposition du résultat sur l'image originale.

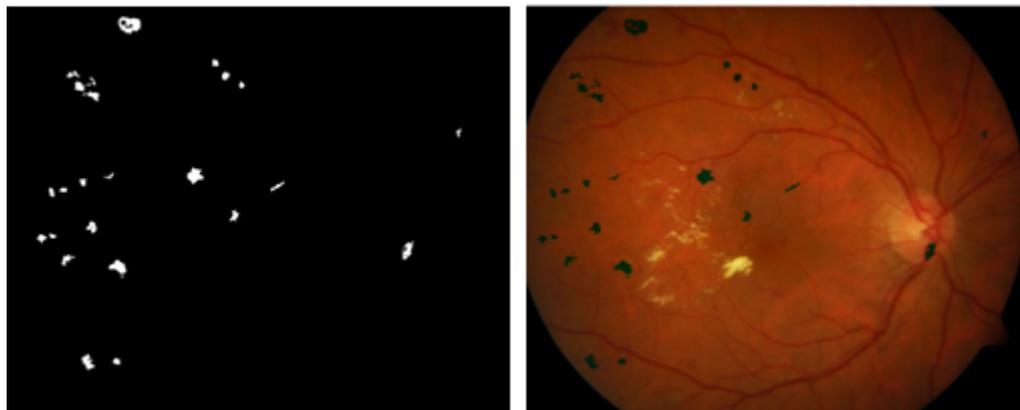


FIGURE 3.21 – Résultats de détection des HEs et leur superposition sur l’image originale

2.3 Détection des Exsudats (EXs)

La présence d’exsudats sur la rétine est le symptôme le plus caractéristique de la rétinopathie diabétique. Les exsudats étant parmi les premiers signes cliniques de RD, leur détection constituerait un atout essentiel pour le dépistage de masse et constituerait une étape importante vers la classification et la surveillance automatiques de la maladie. Une identification et une classification fiables des exsudats présentent un intérêt inhérent dans un système automatisé de dépistage de la rétinopathie diabétique. La figure suivante montre des exemples d’exsudats présents sur les images rétiniennes :



FIGURE 3.22 – Exemples d’exsudats durs (en vert), et d’exsudats mous (en rouge) sur des images du fond d’œil

Les exsudats sont des lipides brillants qui s’échappent d’un vaisseau sanguin. La fuite de liquide a tendance à rester proche de la lésion, donnant un bord généralement bien défini, adapté à l’analyse par ordinateur. La cause principale des exsudats est la fuite de protéines et de lipides du sang dans la rétine par les vaisseaux sanguins endommagés [83]. Dans les images rétiniennes, l’exsudat est présenté sous forme de régions localisées dures, blanches ou jaunâtres, de tailles,

formes et emplacements variables. Généralement, ils se matérialisent près des capillaires qui fuient dans la rétine [84]. Les exsudats durs sont des formations de lipides qui s'échappent de ces vaisseaux sanguins affaiblis. Ce type de rétinopathie est appelé rétinopathie diabétique non proliférante.

2.3.1 Problématique de la détection des exsudats

L'un des principaux obstacles rencontrés lors de la détection des exsudats dans les images du fond d'œil est la grande variabilité de la couleur de l'image rétinienne chez différents patients. Ces variations sont fortement corrélées à la pigmentation de la peau et à la couleur de l'iris. Ainsi, la couleur des exsudats dans certaines régions d'une image peut sembler plus faible que la couleur de fond d'autres régions. En conséquence, les exsudats peuvent être classés à tort. En fait, sans un certain type de normalisation des couleurs, la variation plus importante de la pigmentation rétinienne naturelle dans l'ensemble de données du patient peut empêcher la discrimination des variations relativement faibles entre les différents types de lésions.

2.3.2 Etat de l'art sur les différentes études menées sur la détection des Exsudats

De nombreux travaux de la littérature ont été développés pour la détection automatique de exsudats dans les images rétiniennes en utilisant quatre stratégies principales : le seuillage, la détection des candidats potentiels, la croissance de région et la classification. L'utilisation de la méthode du seuil global et de la détection des contours pour la détection automatique et précise des exsudats est très difficile en raison de l'intensité inégale des exsudats et du faible contraste entre les exsudats et le fond rétinien. Différentes méthodes de classification pour la détection des exsudats ont été proposées pour une détection entièrement automatique. Dans l'étude de Haloï et al. [67], un classifieur SVM associé à une approche spatiale à l'échelle gaussienne a été utilisé pour différencier les exsudats mous, des exsudats durs. D'autres méthodes de classification, notamment les arbres de décision [85], un classificateur Bayésien optimisé par une technique de renforcement adaptatif [86] et une méthode de forêt aléatoire [87], ont également été utilisées.

Malheureusement, les résultats de la classification résultant de l'application des méthodes ci-dessus pour la détection des exsudats ne sont pas suffisamment satisfaisants du point de vue clinique en raison des diverses qualités des images rétiniennes. Cela nécessite une méthode de segmentation d'image plus efficace avant la classification.

Plus récemment, Shengchun et al. [88], ont développé et évalué un algorithme automatique de traitement des images rétiniennes pour la détection des exsudats à l'aide d'un seuil dynamique et de l'application du Fuzzy C-means (FCM)

suivi d'une classification à l'aide du SVM. L'algorithme proposé comprend quatre étapes principales : le prétraitement des images, la localisation du disque optique, la détermination des candidats exsudatifs en utilisant un seuil dynamique en combinaison avec un seuil global basé sur le FCM, et l'extraction de huit caractéristiques de texture de la région exsudat candidate, qui ont ensuite été introduites dans un classifieur SVM pour la classification automatique des exsudats. L'algorithme proposé a été validé sur une base de données publique e-optha (47 images), atteignant une sensibilité moyenne globale, VPP et un F score de 76,5 %, 82,7 % et 76,7 %, respectivement. Il a été testé sur une autre base de données DIA-RETDB1 (89 images) avec une sensibilité, une spécificité et une précision globales moyennes de 97,5 %, 97,8 % et 97,7 %, respectivement.

Feroui [71], a proposé une méthode de détection des exsudats par la combinaison du FCM avec les opérateurs morphologiques. Les résultats de leur étude ont donné une bonne extraction des régions exsudatives.

2.3.3 Détection des Exsudats dans les images rétiniennes

L'identification des exsudats par les ophtalmologistes nécessite normalement une dilatation de l'œil du patient diabétique à l'aide d'une solution chimique qui prend beaucoup de temps et affecte les malades. C'est pour cela qu'un système d'aide à la détection des pathologies rétiniennes est très utile pour les ophtalmologues. Cette partie du chapitre étudie et présente une technique basée sur la morphologie mathématique pour la détection des exsudats à partir des images couleurs du fond d'œil qui inclut l'élimination du disque optique et la classification des exsudats détectés à l'aide de méthodes de traitement d'images en tant que des images normales ou diabétiques. La figure suivante illustre les différentes étapes suivies pour détecter les exsudats.




FIGURE 3.23 – Organigramme de détection des Exsudats durs

Les différentes étapes de cet organigramme seront expliquées dans ce qui suit.

2.3.3.1 Prétraitement des images rétiniennes

La détection des lésions lumineuses dans les images couleur du fond d’œil est une tâche très difficile à accomplir. Les premières complications sont dues à l’étape d’acquisition des images. En effet, elles sont mal contrastées et dégradées par le bruit.

Les images rétiniennes prises lors des examens standard présentent parfois des contrastes insuffisants et contiennent des artefacts. Le contraste de l’image rétinienne diminue à mesure que la distance d’un pixel par rapport au centre de l’image augmente. De plus, la non uniformité d’éclairage augmente les niveaux d’intensité dans certaines régions d’une image, tandis que d’autres régions plus éloignées du disque optique peuvent souffrir d’une réduction de la luminosité. Ainsi, les exsudats ou les lésions similaires dans de telles régions ne se distinguent pas de la couleur de fond près du disque. La qualité d’image rétinienne a un impact important sur les caractéristiques des lésions rétiniennes, en particulier les exsudats. Par conséquent, des techniques de prétraitement sont nécessaires pour améliorer le contraste de ces images. C’est pour cela que l’étape de prétraitement est primordial avant la détection.

En premier lieu on utilise le canal de luminance de l’image rétinienne car il

met en évidence les structures lumineuses telles que les exsudats et le disque optique, aussi il offre un meilleur contraste aux images.

Ensuite, on applique sur les images du canal de luminance une égalisation d'histogramme adaptative pour augmenter le contraste des images. La forme d'une photo est rectangulaire. Cependant, la forme d'un œil est arrondie car l'image rectangulaire contient l'œil rond. Dans l'image du fond d'œil, la région sombre entourant un œil apparaît. Dans l'égalisation générale de l'histogramme, le pixel de la région extérieure sombre est ajouté à l'histogramme, de sorte que les valeurs des pixels proches de cette région extérieure sombre soient inférieures à celles attendues. CLAHE fonctionne sur de petites régions, appelées mosaïques, tandis que l'algorithme général fonctionne sur l'image entière.¹² Comme l'effet des régions extrêmement sombres et claires est limité à la mosaïque locale, une image uniforme peut être obtenue. Les techniques d'amélioration du contraste local sont décrites pour chaque f présent dans l'image initiale et une petite fenêtre $M \times M$ en cours d'exécution w , l'image est filtrée pour produire le nouveau pixel d'image $f(i, j)$ selon l'équation :

$$f(i, j) = 255 \left[\frac{\Psi_w(f) - \Psi_w(f_{min})}{\Psi_w(f_{max}) - \Psi_w(f_{min})} \right] \text{ Avec } \Psi_w(f) [1 + \exp(\frac{\langle f \rangle_w - f(i, j)}{\sigma_w})]^{-1}$$

Et f_{max} et f_{min} sont les valeurs d'intensité maximale et minimale dans l'image entière, tandis que $\langle f \rangle_w$ et σ_w indiquent la moyenne de la fenêtre locale et l'écart type définis par :

$$\langle f \rangle_w = \frac{1}{M^2} \sum f(i, j) \text{ et } \sigma_w = \sqrt{\frac{1}{M^2} \sum (f(i, j) - \langle f \rangle_w)^2}$$

Un filtrage Gaussien est utilisé par la fin pour supprimer les bruits ainsi que certaines variations des niveaux de gris inutiles sur les images. Les résultats de prétraitement sont donnés par la figure suivante :




FIGURE 3.24 – Résultats de prétraitement ; (a) : Image couleur de la rétine, (b) : le canal de luminance de l'image d'origine, (c) : Le filtrage de l'image améliorée

2.3.3.2 Détection et Suppression des candidats non-Exsudatifs (la papille et le réseau vasculaire)

La localisation du disque optique (DO) est une étape essentielle de notre al-

gorithme, car il possède des propriétés similaires à celles des exsudats en termes de couleur et de luminosité. Le DO est un disque jaune vif dans la rétine sous forme arrondie ou en ellipse, où les vaisseaux sanguins de la rétine émergent. Par conséquent, le disque doit être supprimé de l'image du fond d'œil avant une détection ultérieure des exsudats. L'extraction du DO est relativement simple et rapide dans les images rétinienne normales car c'est là où se trouve le plus grand groupe de pixels les plus lumineux ; cependant, cela devient plus difficile dans les images où la zone des lésions brillantes est également grande ou où le DO est obscurcie par les vaisseaux sanguins rétinien, par exemple, lorsque le disque présente une hémorragie importante. Dans notre algorithme proposé, deux étapes sont suivies pour extraire le DO : extraction du réseau vasculaire, et la segmentation du DO. Pour réaliser cette tâche nous devons tout d'abord supprimer le réseau vasculaire pour maximiser nos chances de bien détecter la papille. Une simple fermeture morphologique est appliquée en utilisant un cercle comme élément structurant. Le choix de sa taille se fait par rapport à la largeur des vaisseaux sanguins ($Strel > Vaisseaux$). La formule utilisée pour la réalisation de cette tâche est donnée par :

$$Ferm = \delta^B(I_{Filtre})$$

Où $Ferm$ est la fermeture de l'image filtrée par un élément structurant B . Nous réalisons par la suite un seuillage suivi d'un filtrage afin de différencier la papille de l'arrière plan et d'effacer tous les pixels isolés.

$$Seuillage = [T_s(Ferm)]$$

Les résultats de cette étape sont présentés par la figure suivante :




FIGURE 3.25 – Résultats d'élimination du disque optique et du réseau vasculaire , (a) Elimination du réseau rétinien ; (b) Seuillage de l'image "a" ; (c) Superposition du résultat sur l'image originale.

2.3.3.3 Détection des Exsudats (Exs)

Afin de bien extraire les exsudats, on réalise une seconde étape de prétraitement en utilisant cette fois-ci le canal vert de l'image RVB. Ce choix est fait car il a la particularité de mettre en évidence les lésions jaunes présentes sur les images.

Nous procédons par la suite par une détermination des variations des niveaux de gris dans les régions contenant des Exs, en effectuant une différence entre la valeur de niveau de gris d'un pixel donné et la moyenne de l'image obtenue après une application d'une fermeture morphologique. Le principe de cette opération est donné dans la phase précédente. La taille de la fenêtre retenue lors de cette exécution est de 14. Un seuillage ($T=110$) est réalisé par la suite pour retenir les candidats susceptibles d'appartenir aux exsudats. Lors de cette étape toutes les régions contenant de faibles variations seront supprimées. Néanmoins, suite à l'opération de seuillage on obtient une perte de certains pixels appartenant aux contours des exsudats, pour pallier à ce problème, nous effectuons une dilatation binaire afin de récupérer les pixels échoués. Le résultat obtenu contient le disque optique du fait de sa luminosité, qui doit être supprimés car il appartient aux fausses détections. Sa suppression est réalisée en effectuant une dilatation avec un élément structurant cercle de taille 9, de la papille segmentée. Suivie d'une soustraction de l'image résultante avec l'image contenant le disque optique.

L'opération de la reconstruction morphologique par une dilatation est appliquée sur le canal vert de l'image, ce dernier est considéré comme un masque. La reconstruction est utilisée à des fins de détection des contours exactes des EXs pour réduire au maximum les fausses détections éventuelles. Tous les pixels des régions candidates du canal vert seront mis à zéro pour l'obtention d'une image marqueur, il résulte de cette reconstruction que seules les régions non exudatives soient reconstruites. La détection finale des Exsudats est obtenue en réalisant une soustraction entre l'image du canal vert et l'image obtenue après reconstruction, suivie d'une opération de seuillage de l'image de soustraction. Le résultat de ce travail est illustré sur la figure suivante :

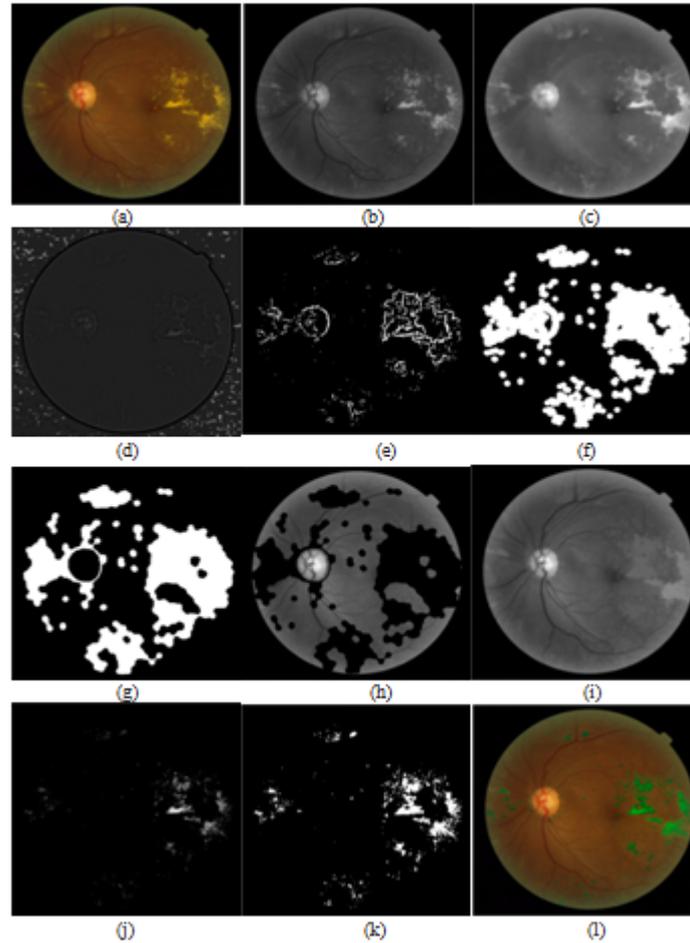


FIGURE 3.26 – Résultats d'extraction des exsudats à partir d'une image couleur de la rétine. (a) Image couleur de la rétine ; (b) Canal vert de l'image rétinienne ; (c) Elimination du réseau vasculaire ; (d) Variation de niveaux de gris dans les régions exsudatives ; (e) Résultat de seuillage de l'image "d" ; (f) Dilatation de l'image "e" ; (g) Elimination du disque optique ; (h) Image marqueur ; (i) Résultat de la reconstruction par dilatation ; (j) Résultat de la différence entre l'image du canal vert et l'image reconstruite ; (k) Résultat de seuillage de l'image "j" ; (l) Résultat final de détection des EXs superposé sur l'image originale.

3 Extraction des caractéristiques pertinentes

L'étape qui suit la détection des lésions rétinienne consiste à extraire de puissants paramètres de nos images afin de les utiliser sous forme de vecteurs d'entrées de nos classificateurs. Le choix des caractéristiques est primordial, plus elles sont bonnes et significatives, meilleure sera la classification. C'est l'étape prédominante dans un système d'aide au diagnostic. Les performances doivent être plus que pertinentes afin de prétendre à une bonne classification du degré de la rétinopathie diabétique.

Dans ce travail de thèse nous avons opté pour le choix de douze caractéristiques.

En premier lieu, nous avons calculé les deux premières valeurs à partir du nombre de MAs et des HEs présents sur chacune de nos images rétinienne. Ensuite, neuf caractéristiques ont été calculées à partir de valeurs statistiques (la surface, le périmètre, la circularité, l'entropie de l'image d'origine, l'entropie du canal vert, l'entropie de la saturation, l'homogénéité de l'image d'origine, l'homogénéité du canal vert, l'homogénéité de la saturation).

Le choix de ces caractéristiques a été retenu après plusieurs test de classification, nous avons décidé de retenir ces performances en raison de : Les MAs sont les premiers signes de la maladie visibles sur les images des patients diabétiques, au fur et à mesure de l'évolution de la RD on se retrouve avec un nombre important de MAs, donc leur nombre est un très bon indicateur du stade de la RD. Les ophtalmologues misent beaucoup sur ce critère d'évaluation. La présence d'hémorragies sur les images du fond d'œil est secondaire aux MAs, plus tôt elles sont détectées et plus la cécité est prévenue et évitée chez les patients diabétiques, car à un stade avancé, les hémorragies rétinienne peuvent être fatales pour la vision du malade. Le principe suivi pour le calcul des nombre de MAs et des HEs est donné par le tableau suivant :

Grades de la RD	Classification de la RD	Nombre de MAs	Nombre des HEs
Grade 0	Absence de RD	MA=0	HE=0
Grade 1	RDNP Minime	$1 \leq MA \leq 5$	HE=0
Grade 2	RDNP Modérée	$5 \leq MA \leq 15$	$0 < HE \leq 5$
Grade 3	RDNP Sévère	MA>15	HE>5

TABLE 3.3 – Principe suivi pour le comptage du nombre des MAs et des HEs

Les valeurs statistiques changent de manière significative d'un patient en bonne santé à un patient malade, leurs valeurs sont très importantes pour déterminer le stade d'évolution de la RD. Les caractéristiques de texture sont dérivées de la matrice de niveaux de gris pour une image. Une petite description des fonctionnalités sélectionnées est donnée dans ce qui suit.

Le contraste est la mesure des variations ou des différences locales de la matrice des niveaux de gris. Il fonctionne en mesurant la manière dont les éléments ne se trouvent pas sur la diagonale principale et renvoie une mesure du contraste d'intensité entre un pixel et les pixels voisins sur toute l'image. Un contraste élevé reflète une différence d'intensité importante dans les niveaux de gris. Il est également appelé deuxième moment de P_d (son moment d'inertie par rapport à l'origine).

$$\text{Contraste} = \sum_{k=0}^{n-1} k^2 P_{\delta}(k)$$

L'homogénéité mesure à quel point la distribution des éléments dans la matrice des niveaux de gris est proche de la diagonale de ce dernier. L'homogénéité pondère les valeurs par l'inverse du poids de contraste, les poids décroissant de façon exponentielle par rapport à la diagonale, comme indiqué dans l'équation. L'ajout de la valeur 1 au dénominateur empêche la valeur 0 lors de la division. À mesure que l'homogénéité augmente, le contraste diminue généralement.

$$\text{Homognite} = \sum_{i=0}^N \sum_{j=0}^M \frac{1}{1+(i-j)^2} P_d(i, j)$$

L'entropie est comprise à partir du concept de thermodynamique. C'est le caractère aléatoire ou le degré de désordre présent dans l'image. La valeur de l'entropie est la plus grande lorsque tous les éléments de la matrice de cooccurrence sont identiques et petits lorsque les éléments sont inégaux.

L'entropie est la plus petite lorsque les valeurs de $P_d(k)$ sont inégales et la plus grande lorsque les valeurs de $P_d(k)$ sont égales. L'entropie est directement proportionnelle à l'imprévisibilité. Les caractéristiques mentionnées ci-dessus ont été calculées pour $d = (0, 1), (1, 1), (1, 0)$ et les valeurs moyennes totales des quatre caractéristiques ont été prises.

$$\text{Entropie} = \sum_{i=0}^N \sum_{j=0}^M -P_d(i, j) \log(P_d(i, j))$$

Ces caractéristiques sont calculées pour diverses images de fond d'œil segmentées, c'est-à-dire des images de fond d'œil normales et des images de fond d'œil anormales (RD). Ces fonctionnalités sont appliquées en entrée à nos cinq classificateurs.

Toutes les caractéristiques de texture utilisées sont résumées dans le tableau suivant :

Caractéristiques	Noms des caractéristiques	Explications
C1	La surface des régions connectées	Nombre de pixels dans chaque région de l'image
C2	Périmètre des régions	Distance entre chaque paire adjacente de pixels autour du bord de la région
C3	Circularité des régions	$\text{Circularite} = \frac{\text{Perimetre}^2}{4\pi * \text{Surface}}$
C4	L'entropie de l'image originale, du canal vert de l'image, et du canal de saturation	$\text{Entropie} = \sum_{i=0}^N \sum_{j=0}^M -P_d(i, j) \log(P_d(i, j))$
C5	L'homogénéité de l'image originale, du canal vert de l'image, et du canal de saturation	$\text{Homogeneite} = \sum_{i=0}^N \sum_{j=0}^M \frac{1}{1+(i-j)^2} P_d(i, j)$
C6	Le contraste	$\text{Contraste} = \sum_{k=0}^{n-1} k^2 P_{\delta}(k)$

TABLE 3.4 – Caractéristiques choisies pour la classification

4 Classification de la Rétinopathie Diabétique Non Proliférante

Nous passons finalement à la dernière étape de notre système d'aide au diagnostic qui consiste en la classification du degré de la RDNP. Durant cette phase, l'algorithme doit pouvoir classer correctement chaque image de la base de données en sa catégorie. La classification en ophtalmologie est un domaine très prisé et très important car il offre à priori des connaissances sur le stade de la rétinopathie diabétique et facilite donc la tâche d'interprétation des images du fond d'œil aux ophtalmologistes et leur permet un gain de temps et d'effort considérables. Ce système prouve son efficacité notamment pour les images d'acquisition qui peuvent être parfois très complexes et de très mauvaise qualité, cela complique alors énormément leur interprétation. Afin de remédier à ces problèmes, nous proposons dans ce travail de thèse une méthode intuitive et utile qui est la classification supervisée, il s'agit d'une technique d'apprentissage automatique, dont le but est de définir des règles permettant de classer un ensemble de données. Nous avons émis le choix de tester cinq différents classificateurs (Perceptron Multi-Couche (MLP) [89], le K plus proche voisin (KNN) [90], les séparateurs à vaste marge (SVM) [91], l'analyse discriminante linéaire ADL [92] et l'arbre de décision CART [93], suivi d'un vote majoritaire, qui est exploité dans les méthodes d'ensemble, il est considéré comme étant un mécanisme de combinaison de prise de décision. Dans le cas d'un problème de classification, le vote majoritaire est l'agrégation d'un ensemble de prédicteurs formés à l'apprentissage. Le principe suivi dans la classification est le suivant :




FIGURE 3.27 – Modèle de classification

Les douze caractéristiques extraites de l'étape précédente sont utilisées dans la phase de classification. Comme le système est axé sur la détection de la RDNP, les classes de l'ensemble de données développé, ont été classées sous quatre catégories : Absence de RD, RDNP Minime, Modérée ou Sévère. Plusieurs algorithmes d'apprentissage automatique, tels que le classifieur KNN, les machines à vecteurs de support (SVM), ont été sélectionnés pour former et classer les images dans leurs classes respectives. Dans le classifieur k-plus proche voisin, l'objet est classé à la majorité des voix de ses voisins, l'objet étant attribué à la classe la plus courante parmi ses k-voisins les plus proches. Les séparateurs à vaste marge effectuent la classification en construisant un hyperplan à N dimensions qui sépare de manière optimale les données. Une définition détaillée de chaque classifieur testé est donnée dans le chapitre 2, Section 2.3.1.

Les différentes étapes de la Figure 3.27, consistent en la division de la base de données sous deux sous bases (la première base va contenir des images utilisées pour l'apprentissage, et la seconde base sera utilisée pour le test des images), selon le principe de la validation croisée (voir chapitre 2, section 2.9), ensuite un vote majoritaire viendra couronner notre classification. Cela est utilisé dans le but de croire au maximum les résultats de nos performances, et finalement on obtiendra des images classées sous leurs différentes catégories.

5 Conclusion

Ce chapitre présente tout le travail effectué dans cette thèse. Le système d'aide au diagnostic proposé pour le dépistage précoce de la rétinopathie diabétique consiste en quatre phases très importantes et dépendantes l'une de l'autre. La première phase de notre algorithme consiste en l'acquisition et l'amélioration des images rétiniennes, un prétraitement efficace est la clé de la réussite d'un tel système. La deuxième phase est la segmentation et la détection des trois caractéristiques de la RDNP, à savoir les microanévrismes, les hémorragies et les exsudats. La troisième phase cruciale de notre algorithme est l'extraction des paramètres performants, c'est là que tout se joue, car mieux on choisit les caractéristiques, et meilleure sera la classification. Et la dernière étape de ce travail réside dans la classification des images sous leur degré de malignité.

Le chapitre suivant va présenter les résultats de ces différentes phases ainsi que des discussions et des limites de nos algorithmes.

Chapitre 4

Evaluation des Résultats et Discussions

« Judge your success by what you had to give up in order to get it »
Dalai Lama

Ce chapitre rapporte tous les résultats des performances obtenues dans ce travail de thèse, des évaluations pertinentes de nos algorithmes de détection et de classification ainsi que des discussions approfondies seront données dans ce dernier chapitre de la thèse.

1 Introduction

Ce chapitre représente le cœur de notre travail de recherche, il est certainement le plus important, car il détaille tous les résultats de détection des lésions de la RDNP, et de la classification du degré de sévérité de la Rétinopathie, en vue du dépistage oculaire précoce de la RD.

Nous allons tout d’abord présenter les bases de données utilisées pour la validation des résultats de nos algorithmes de détection et de classification, une évaluation pertinente sera réalisée pour la validation des méthodes de détection des MAs, des HEs et des EXs. Puis nous donnerons tous les résultats de la classification du degré de la RDNP obtenus dans chaque expérience réalisée au cours de cette recherche. Une évaluation ainsi qu’une comparaison de ces résultats viendra finaliser ce chapitre.

2 Les bases de données utilisées pour la validation des résultats

Dans ce travail de recherche, nous avons utilisé quatre base de données rétinienne publiques pour la validation de nos résultats de détection des lésions de la RDNP, ainsi que pour la classification de ces différents stades. Nous avons ensuite créé une nouvelle base constituée de toutes les images des quatre bases réunies pour augmenter le nombre de nos images et pouvoir réaliser une bonne classification.

2.1 Base de données DRIVE

La base de données DRIVE (Digital Retinal Images for Vessel Extraction) est accessible au public (Staal et al., 2004 ; Isi.uu.nl, 2014). Elle a été créée pour permettre des études comparatives sur la segmentation des vaisseaux sanguins dans les images rétiniennes. La segmentation et la délimitation des attributs morphologiques des vaisseaux sanguins rétiniens, tels que la longueur, la largeur, la tortuosité, les motifs de ramification et les angles, sont utilisées pour le diagnostic, le dépistage, le traitement et l’évaluation de diverses maladies cardiovasculaires et ophtalmologiques telles que le diabète, l’hypertension, l’artériosclérose et néovascularisation choroidale. La détection et l’analyse automatiques du système vasculaire peuvent faciliter la mise en œuvre de programmes de dépistage de la rétinopathie diabétique. De plus, l’arbre vasculaire rétinien est unique pour chaque individu et peut être utilisé pour une identification biométrique. Les photographies de la base de données DRIVE ont été obtenues d’un programme de dépistage de la rétinopathie diabétique aux Pays-Bas. La population de dépistage comprenait 400 sujets diabétiques âgés de 25 à 90 ans. Quarante photographies ont été sélectionnées au hasard, 33 ne montrent aucun signe de rétinopathie diabétique et 7 montrent des signes de rétinopathie diabétique (tels

que des exsudats, des hémorragies et des modifications de l'épithélium pigmentaire) précoce légère.

Chaque image a été compressée au format JPEG 32, ce qui est une pratique courante dans les programmes de dépistage.

Les images ont été acquises à l'aide d'une caméra 3CCD non-mydiatique Canon CR5 avec un champ de vision de 45 degrés. Chaque image a été capturée en utilisant 8 bits par plan de couleur à 768 x 584 pixels. Le champ de vision de chaque image est circulaire avec un diamètre d'environ 540 pixels. Pour cette base de données, les images ont été recadrées autour du FOV. Pour chaque image, une image de masque est fournie, qui délimite le champ de vision.

L'ensemble de 40 images a été divisé en 20 images d'apprentissage et 20 images de test. Pour les images d'apprentissage, une seule segmentation manuelle du système vasculaire est disponible. Pour les cas de test, deux segmentations manuelles sont disponibles ; l'une sert d'étalon-or, l'autre peut être utilisée pour comparer des segmentations générées par ordinateur avec celles d'un observateur humain indépendant. De plus, une image de masque est disponible pour chaque image rétinienne, indiquant la région d'intérêt. Tous les observateurs humains qui segmentaient manuellement le système vasculaire ont été instruits et formés par un ophtalmologiste expérimenté. On leur a demandé de marquer tous les pixels pour lesquels ils étaient au moins à 70 % sûrs d'être un réseau. Ce faisant, les chercheurs ont segmenté manuellement les vaisseaux rétiens à partir du tissu sous-jacent. Ce processus de segmentation, ou extraction de la configuration des vaisseaux sanguins du tissu rétinien, est une tâche que de nombreux groupes de recherche ont tenté d'automatiser car il s'agit d'une procédure laborieuse et fastidieuse.

2.2 Base de données Messidor

La base de données Messidor [94] (qui signifie Méthodes d'Évaluation de Systèmes de Segmentation et d'Indexation Dédiées à l'Ophtalmologie Rétinienne), est la plus grande base de données avec 1200 images rétiniennes, disponibles depuis 2008 sur Internet. Trois services d'ophtalmologie différents ont été utilisés pour collecter des images à l'aide d'une caméra 3CCD non mydiatique adaptée à un Topcon TRC NW6 à 45 degrés FOV. Celles-ci ont été capturées à une résolution de 1440 x 960, 2240 x 1488 ou 2304 x 1536 pixels. Toutes les images sont stockées au format TIFF. 800 de ces images ont été capturées avec une dilatation de la pupille. Le standard de référence fourni avec chaque image contient un stade de dépistage de la rétine diabétique de la progression de la maladie et le risque d'œdème maculaire dans chaque image.

Cette base a pour but d'évaluer automatiquement les images couleur de la rétine en utilisant la segmentation manuelle des lésions de la RD, réalisée par des experts en Ophtalmologie.

2.3 Base de données ImageRet

Mise à la disposition du public en 2008, la base de données ImageRet est subdivisée en deux sous-bases, DIARETDB0 et DIARETDB1 (Valverde et al., 2010; it.lut.fi, 2014). Les images ont été acquises avec un FOV rapporté de 50 degrés en utilisant une caméra Fundus inconnue avec des réglages inconnus, d'une taille de 1500×1152 pixels au format PNG. DIARETDB0 contient 130 images rétiniennes, dont 20 normales et 110 présentant divers signes de rétinopathie diabétique. DIARETDB1 contient 89 images, 5 images représentent une rétine en bonne santé, 84 autres images auraient quelques signes de rétinopathie diabétique proliférante légère. Les images ont été marquées par quatre experts pour la présence de microanévrismes, d'hémorragies et d'exsudats durs et mous.

3 Evaluation des performances des algorithmes de détection des pathologies rétiniennes

Pour ce travail de thèse, l'analyse manuelle effectuée par des spécialistes en Ophtalmologie expérimentés est comparée aux résultats du système semi-automatisé en fonction de la vérité terrain fournie. Le logiciel MATLAB a été utilisé pour la segmentation et la détection des lésions rétiniennes, ainsi que pour la classification.

La sensibilité et la spécificité sont calculées pour tester la capacité du système proposé et son potentiel en tant qu'assurance qualité dans le dépistage rétinien. La sensibilité est le pourcentage d'images de fond d'œil anormales classées comme anormales, alors que la spécificité est le pourcentage d'images de fond d'œil normales classées comme normales par le dépistage. L'exactitude peut également être calculée comme une caractéristique de l'assurance qualité du dépistage. Des études de dépistage bien conçues sont nécessaires pour déterminer si de nouveaux tests de dépistage ou de détection précoce (tels que la photographie rétinienne avec un appareil photo numérique) répondent aux normes de sensibilité et de spécificité.

3.1 Evaluation des performances de détection des Hémorragies rétiniennes

L'évaluation des résultats de notre algorithme de détection des hémorragies, s'est faite sur un ensemble de 76 images obtenues des différentes bases de données citées ci-dessus. Leur choix s'est fait par rapport à la pathologie traitée dans cette partie, à savoir les Hémorragies. Parmi ces 76 images, 15 d'entre elles sont non pathologiques, elles ne présentent aucun signe de la RD, et 61 images présentent des signes de présence de la RD, elles sont caractérisées par la présence des hémorragies seulement, ou bien par d'autres lésions de la RD aussi, telles que les MAs, les exsudats durs et mous. Chaque lésion est différente par rapport à l'autre, que ce soit dans leur taille, dans leur forme, ou bien dans leur contraste,

ce qui explique la difficulté de poser un diagnostic.

Ces images ont été segmentées et annotées par des médecins spécialistes en Ophtalmologie, pour pouvoir les utiliser comme référence pour l'évaluation de la performance de nos résultats de détection des hémorragies rétiniennes, en effectuant une comparaison entre la segmentation manuelle (obtenue à l'aide des experts dans le domaine), et la segmentation automatique (obtenus à l'aide de nos algorithmes cités dans le chapitre 3).

Différentes mesures ont été calculées pour juger de la fiabilité et de la robustesse de notre système. Ces paramètres sont : l'indice de Jaccard, la Valeur Prédictive Positive (VPP), la Sensibilité, la Spécificité, et le taux de classification. Ils déterminent les critères des lésions des images rétiniennes. Nous allons donner quelques informations sur ces paramètres dans ce qui suit.

- L'indice de similarité Jaccard (parfois appelé coefficient de similarité Jaccard) compare les lésions présentes sur les deux images de segmentation (manuelle et automatique), et détermine quelles lésions sont partagées et lesquelles sont distinctes. C'est une mesure de similarité pour les deux ensembles de données, avec une plage allant de 0 % à 100 %. Plus le pourcentage est élevé, plus les deux images sont similaires. Bien que facile à interpréter, il est extrêmement sensible aux échantillons de petite taille et peut donner des résultats erronés, en particulier avec de très petits échantillons ou des ensembles de données avec des observations manquantes, c'est pour cette raison que nous l'avons utilisé que pour les HEs. Il est donné par :

$$\text{Indice Jaccard} = \frac{\text{Nombre de lésions partagées entre les deux images}}{\text{Nombre de lésions dans les deux images}} * 100$$

$$I(x, y) = \frac{|x \cap y|}{|x \cup y|}$$

L'Indice Jaccard suit donc les étapes suivantes :

1. Compte le nombre de lésions partagées entre les deux images.
2. Compte le nombre total de lésions dans les deux images (partagées et non partagées).
3. Divise le nombre de lésions partagées (1) par le nombre total de lésions (2).
4. Multiplie le nombre trouvé dans (3) par 100.

- La valeur prédictive positive (VPP) est la probabilité qu'un résultat positif dans un test d'hypothèse signifie qu'il existe un effet réel. C'est la probabilité que les patients dont le résultat du test est positif soient atteints de la RD. Une valeur prédictive positive est un moyen (avec la spécificité, la sensibilité et des valeurs prédictives négatives) d'évaluer le succès d'un test de dépistage.

Les valeurs prédictives positives dépendent de la fréquence de la maladie dans la population testée. si la maladie est très courante, une personne dont le résultat du test est positif est plus susceptible de souffrir réellement de la maladie que si une personne a un test positif dans une population où la maladie est rare. La

formule pour calculer la valeur prédictive positive est donnée par :

$$VPP = \frac{VraiPositif}{VraiPositif+FauxPositif}$$

Elle est considérée comme la Probabilité que le patient souffre d'une RD lorsque le test est positif.

- **La Valeur Prédictive Négative (VPN)** est le pourcentage de patients avec un test négatif qui ne sont pas atteints de la maladie. La valeur révèle combien de tests négatifs sont de vrais négatifs.

$$VPN = \frac{VraiNegatif}{VraiNegatif+FauxNegatif}$$

Elle est considérée comme étant la Probabilité que le patient est sain lorsque le test est négatif.

- **La sensibilité** (également appelée taux de vrais positifs), est la capacité d'un test à classer correctement un individu en tant que "malade". Elle est définie comme étant la proportion de personnes atteintes de la maladie avec un résultat positif. En d'autres termes, un test très sensible est celui qui identifie correctement les patients atteints d'une maladie. Un test sensible à 100 % identifiera tous les patients atteints de la maladie. Cependant il est rare qu'un test clinique soit sensible à 100 %. Un test avec une sensibilité de 90 % identifiera 90 % des patients atteints de la maladie, mais manquera 10 % d'entre eux. La sensibilité est donnée par :

$$Sensibilite(\%) = \frac{VraiPositif}{VraiPositif+FauxNegatif} * 100$$

Elle est considérée comme étant la Probabilité d'être positive au test en présence de la maladie.

- **La Spécificité** d'un test (également appelé le taux négatif réel), est la capacité d'un test à classer correctement un individu comme étant exempt de maladie (spécificité du test). Elle est la proportion de personnes non atteintes de la maladie qui auront un résultat négatif. En d'autres termes, la spécificité d'un test fait référence à la manière dont un test identifie des patients ne présentant pas de maladie. Un test présentant une spécificité de 100 % identifiera 100 % des patients non atteints de la maladie. Un test spécifique à 90 % identifiera 90 % des patients non atteints de la maladie. Les tests avec une spécificité élevée (un taux négatif réel élevé) sont plus utiles lorsque le résultat est positif. Un test très spécifique peut être utile pour contrôler les patients atteints d'une maladie donnée. Sa formule est donnée par :

$$Specifinite(\%) = \frac{VraiNegatif}{VraiNegatif+FauxPositif} * 100$$

Elle est considérée comme étant la Probabilité de test négatif en l'absence de maladie.

Vrai Positif (VP) : l'image est pathologique (présence d'une rétinopathie dia-

bétique) et le dépisteur a correctement rapporté que le patient souffrait d'une rétinopathie.

Vrai Négatif (VN) : l'image est non pathologique (absence de tout signe clinique indiquant la présence d'une RD), et a été rapportée par le dépisteur comme étant normale.

Faux Positif (FP) : l'image est saine mais le dépisteur a signalé une rétinopathie.

Faux Négatif (FN) : l'image montre une rétinopathie mais a été déclarée comme étant saine par l'analyseur.

Les performances atteintes de 26 images parmi les 76 sont rapportées dans le tableau suivant :

Images	Indice de Jaccard (%)	Valeur prédictive (%)	Sensibilité (%)	Spécificité (%)	Taux de Classification(%)
1	88.82	100	88.82	100	99.96
2	71.74	100	71.74	100	99.9
3	100	100	100	100	100
4	87.81	100	87.81	100	99.63
5	99.7	100	99.7	100	99.99
6	96.52	97.25	96.81	98.89	98.67
7	89.80	89.80	89.62	99.93	99.93
8	81.16	81.16	92.36	99.82	99.82
9	82.78	82.78	94.56	99.91	99.91
10	94.54	94.55	98.65	99.96	99.96
11	85.09	85.09	96.78	99.94	99.94
12	93.42	100	93.41	100	99.65
13	95.62	96.34	91.36	97.58	96.87
14	93.52	100	93.51	100	99.85
15	95.20	100	95.20	100	99.83
16	86.38	100	86.38	100	99.45
17	98.95	100	98.95	100	99.98
18	90.09	90.10	100	99.87	99.87
19	96.79	100	96.79	100	99.78
20	96.78	96.78	100	99.76	99.78
21	95.85	100	95.85	100	99.73
22	95.01	95.01	100	99.94	99.94
23	95.97	100	95.97	100	99.93
24	99.68	100	99.68	100	99.99
25	91.10	91.10	100	99.98	99.98
26	96.81	96.37	93.64	97.53	98.74

TABLE 4.1 – Résultats de comparaison entre la segmentation manuelle et la segmentation automatique des HEs

3.1.1 Discussion et interprétation des résultats

Nous concluons du tableau 4.1, que les performances atteintes pour évaluer notre algorithme de détection des hémorragies sont très élevées. Dans l'ensemble, les résultats sont très satisfaisants. Dans les images 1, 2, 4 et 25, nous remarquons une légère baisse dans les taux des paramètres, cela est causé par la présence de quelques fausses détections (les faux positifs et les faux négatifs) dans les images rétiniennes de qualité médiocre, et perturbées par le bruit, qui à travers même des prétraitements très avancés restent toujours corrompues. Pour une image non pathologique (absence de RD), la spécificité atteinte est de 100 %, mais la sensibilité ne peut être calculée du fait que les valeurs des vrai positifs et des faux négatifs soient égales à zéro car l'image ne contient aucune hémorragie.

Le pourcentage de l'indice Jaccard indique à quel point les deux images sont similaires.

- Deux images partageant toutes les lésions seraient similaires à 100 %. Plus on se rapproche de 100 %, plus il y a de similitude (par exemple 90 % est plus semblable que 89 %).
- Si les images ne partagent aucune lésion, leur indice serait de 0 %.
- Le point médian "50 %" signifie que les deux images partagent la moitié des lésions.

La valeur prédictive est couramment utilisée dans les tests médicaux où un résultat «positif» signifie que le patient est réellement malade. Par exemple, disons qu'un patient a été testé pour une RD et que le test avait une VPP de 26,2 %. Cela signifie que si le test était positif, le patient aurait 26,2 % de chances d'avoir une rétinopathie diabétique. En d'autres termes, un résultat positif au test ne signifie pas nécessairement que le patient est atteint d'une maladie particulière.

La définition de la valeur prédictive positive est similaire à la sensibilité d'un test et les deux sont souvent confondues. Cependant, le VPP est utile pour le patient, alors que la sensibilité est plus utile pour le médecin. Une valeur prédictive positive indique les chances que le patient soit atteint de RD si le résultat est positif. Cela peut être utile pour dire si le malade doit paniquer ou non. D'autre part, la sensibilité d'un test est définie comme la proportion de personnes atteintes de la maladie qui auront un résultat positif. Ce fait est très utile aux médecins pour décider quel test utiliser, mais il n'a que peu d'intérêt pour le patient si son test est positif.

Les paramètres utilisés pour l'évaluation des critères de détection des HEs, sont donnés par les graphiques de la figure suivante :

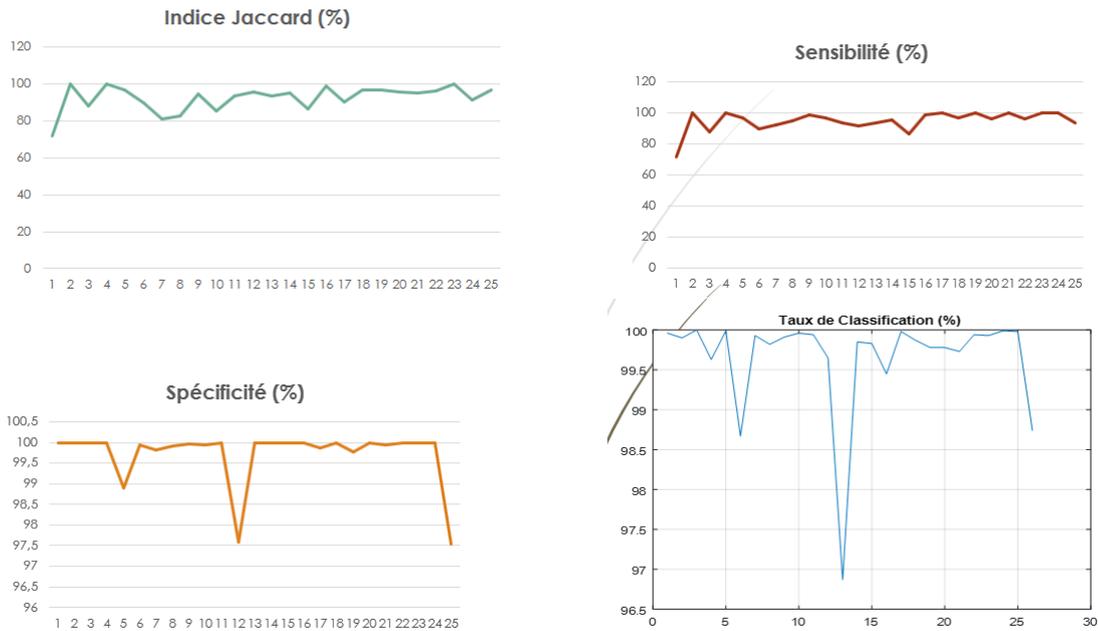


FIGURE 4.1 – Représentation graphique des différents paramètres d'évaluation de l'algorithme de détection des HEs.

3.1.2 Robustesse et limites de l'algorithme de détection des hémorragies rétiennes

tout Cette section du chapitre rapporte quand l'algorithme fonctionne bien et lorsqu'il trouve des difficultés lors de la compilation. Nous avons utilisé différents types d'images pour juger de l'efficacité de notre algorithme.

Nous avons tout d'abord testé des images saines (absence de tout signe clinique), aucune fausse détection n'a été faite sur un ensemble de quinze images. Un exemple de cela est donné par la figure suivante :



FIGURE 4.2 – Trois exemples d'images saines ou aucune fausse détection n'est obtenue

L'algorithme a montré ses preuves même en présence d'autres pathologies de la rétinopathie diabétique, il a été capable de reconnaître et de différencier les

hémorragies des autres lésions. Un exemple concret est donné par la figure suivante :




FIGURE 4.3 – Détection des hémorragies dans les images rétinienne. (a) : Détection des HEs en présence de nodule cotonneux ; (b) et (c) : Détection des HEs en présence des exsudats, de microanévrismes, et des cicatrices de la chirurgie au laser.

La détection des HEs a pu se faire aussi sur des images de très mauvaise qualité (très faiblement contrastées, très bruitées, et mal éclairées). Un exemple est donné par la figure suivante :



FIGURE 4.4 – Exemples de la bonne détection des HEs sur des images de qualité médiocre, ainsi qu'en présence d'autres lésions rétiniennes.

En dépit de cette haute performance de détection, l'algorithme peut toute fois passer à côté de certaines hémorragies qui sont de tout petit calibre et très faiblement contrastées (Fig. 4.5.b), ou bien, des HEs se trouvant au centre de la macula (Fig. 4.5.c), car elle a des caractéristiques très semblables aux HEs. Un exemple de mauvaise détection est donné aussi par la figure 4.5.a, où les HEs qui sont collées au réseau vasculaire ont été éliminées avec ce dernier. Cliniquement parlant, les ophtalmologistes ne s'intéressent pas ou très peu aux petites hémorragies.




FIGURE 4.5 – Exemples de mauvaise détection des HEs rétiniennes

3.1.3 Comparaison de nos résultats avec les travaux connexes

Nous avons effectué une comparaison de nos résultats avec les travaux de la littérature traitant la même problématique que la notre, les résultats sont sommés dans le tableau suivant :

Auteurs	Sensibilité (%)	Spécificité (%)
Marwan et al [95]]	87.53	95.08
Amel Feroui [71]]	93.90	95.69
Dolly et al [77]	87.71	94.64
Godlin et al [80]	85	99.39
Notre méthode	96.30	99.95

TABLE 4.2 – Comparaison des résultats de détection des hémorragies avec les travaux de la littérature

Les performances atteintes par notre algorithme de détection des hémorragies rétinienne sont très bonnes et supérieures comparativement aux travaux cités dans le tableau 4.2. Cela nous permet de dire que notre système peut être utilisé pour l'aide au diagnostic en ophtalmologie.

3.2 Evaluation des performances de détection des microanévrismes

L'évaluation des résultats de détection des Microanévrismes suit la même procédure que pour la pathologie précédemment citée. Un ensemble de 20 images contenant des MAs a été segmenté automatiquement et manuellement par des experts dans le domaine. Les paramètres utilisés dans cette section pour évaluer la méthode de détection des Microanévrismes sont :

Tout d'abord nous avons calculé les valeurs des vrai positif, faux positifs, vrai négatifs, et les faux négatifs.

Ensuite les valeurs prédictives positives ont été calculées pour chacune des 20 images de notre tableau. Et finalement les taux de pourcentage de la sensibilité, de la spécificité, et de la classification ont été donnés sur le tableau ci dessous. Les résultats de comparaison entre les deux segmentations sont reportées sur le tableau suivant :

Images	VP	VN	FP	FN	VPP (%)	Sensibilité (%)	Spécificité (%)	Taux de Classification (%)
1	1022	316927	36	2	96.60	99.80	99.9886	99.9880
2	618	317939	0	73	100	89.4356	100	99.9771
3	103	316393	5	5	95.37	95.3704	99.9984	99.9968
4	92	242536	0	25	100	78.6325	100	99.9897
5	775	317484	8	18	98.97	97.7301	99.9975	99.9918
6	112	316715	9	12	92.56	90.3226	99.9972	99.9934
7	279	314883	0	60	100	82.3009	100	99.9810
8	328	317573	0	84	100	79.6117	100	99.9736
9	439	312295	0	74	100	85.5750	100	99.9763
10	194	316150	12	6	94.17	97	99.9962	99.9962
11	48	316156	0	2	100	96	100	99.9963
12	36	315336	0	6	100	85.71	100	99.9758
13	264	316848	36	2	88	99.25	99.9886	99.9826
14	60	314671	4	3	100	95.24	99.99	99.9977
15	165	315316	8	31	95.37	84.1837	99.9975	99.9876
16	12	315210	26	4	100	75	99.99	99.9998
17	36	317606	0	2	100	94.74	100	99.9994
18	100	314954	4	12	96.15	89.2857	99.9987	99.9949
19	517	317315	0	5	100	99.04	100	99.9996
20	36	316470	11	2	100	94.74	99.9965	99.9995

TABLE 4.3 – Résultats de comparaison entre la segmentation manuelle et la segmentation automatique des MAs

3.2.1 Discussion et interprétation des résultats

Nous remarquons sur le tableau 4.3, que la performance atteinte pour la détection des MAs est très élevée. Cependant, la valeur de la sensibilité peut chuter dans certaines images, nous interprétons cela par la présence de certains faux négatifs. L'algorithme ne peut malheureusement pas détecter les MAs dont la taille ne dépasse guère les 10 μm . C'est très délicat et compromettant de pouvoir les détecter dans ces conditions. D'autre part, le système peut fléchir lorsque les images sont de très mauvaises qualité, car même plusieurs opérations de prétraitement ne suffisent pas à les améliorer, c'est pour ces principales raisons que nous trouvons des difficultés lors de la détection des MAs.

Les VP, VN, FP, FN sont des valeurs qui peuvent prédire les fausses et les bonnes détections, elles sont très significatives pour connaître l'état de la maladie. Ces chiffres classent les images en pathologiques ou saines et offrent une grande précision en disant si les images ont été classées faussement ou correctement par le dépisteur. Par exemple, la valeur d'un vrai positif représente une image pathologique classée comme telle par l'algorithme, quant au faux positif, l'image du patient est saine mais l'algorithme la dépiste comme ayant une rétinopathie. Ces paramètres nous donnent une vue d'ensemble significative des

images rétiniennes testées.

La représentation graphique de ces paramètres est donnée par la figure suivante :

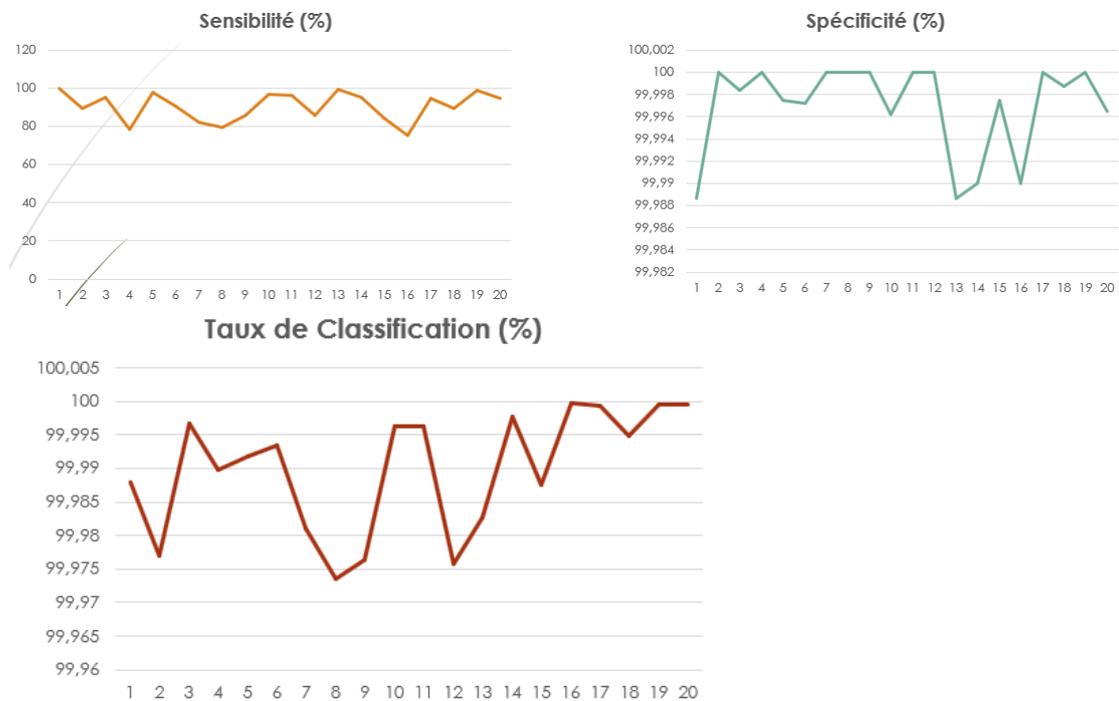


FIGURE 4.6 – Représentation graphique des trois paramètres d'évaluation de la méthode de détection des MAs

3.2.2 Robustesse et limites de l'algorithme de détection des Microanévrismes

Afin de juger de la performance d'un système, nous avons utilisé plusieurs images de différentes qualité. Pour ce faire nous avons opté tout d'abord pour des images non pathologiques, où aucun signe de la RD n'est présent, le test a été effectué avec succès. Un exemple de cette bonne détection est illustré sur la figure 4.7.a. Nous avons poursuivi le test, en utilisant cette fois-ci des images rétiniennes de mauvaises qualité. Leur acquisition s'est accompagnée d'une dégradation considérable qui a rendu leur traitement très difficile et compliqué à la fois. Néanmoins l'algorithme a fait ses preuves en détectant clairement les MAs sur ce type d'images médiocres. Un exemple est donné par la fig. 4.7.b.

Quoique les MAs aient des caractéristiques communes avec le réseau vasculaire et les hémorragies rétiniennes de petite taille, l'algorithme a pu différencier entre ces trois paramètres et a classé efficacement les MAs, un exemple de cela est montré sur la fig 4.7.c.d.

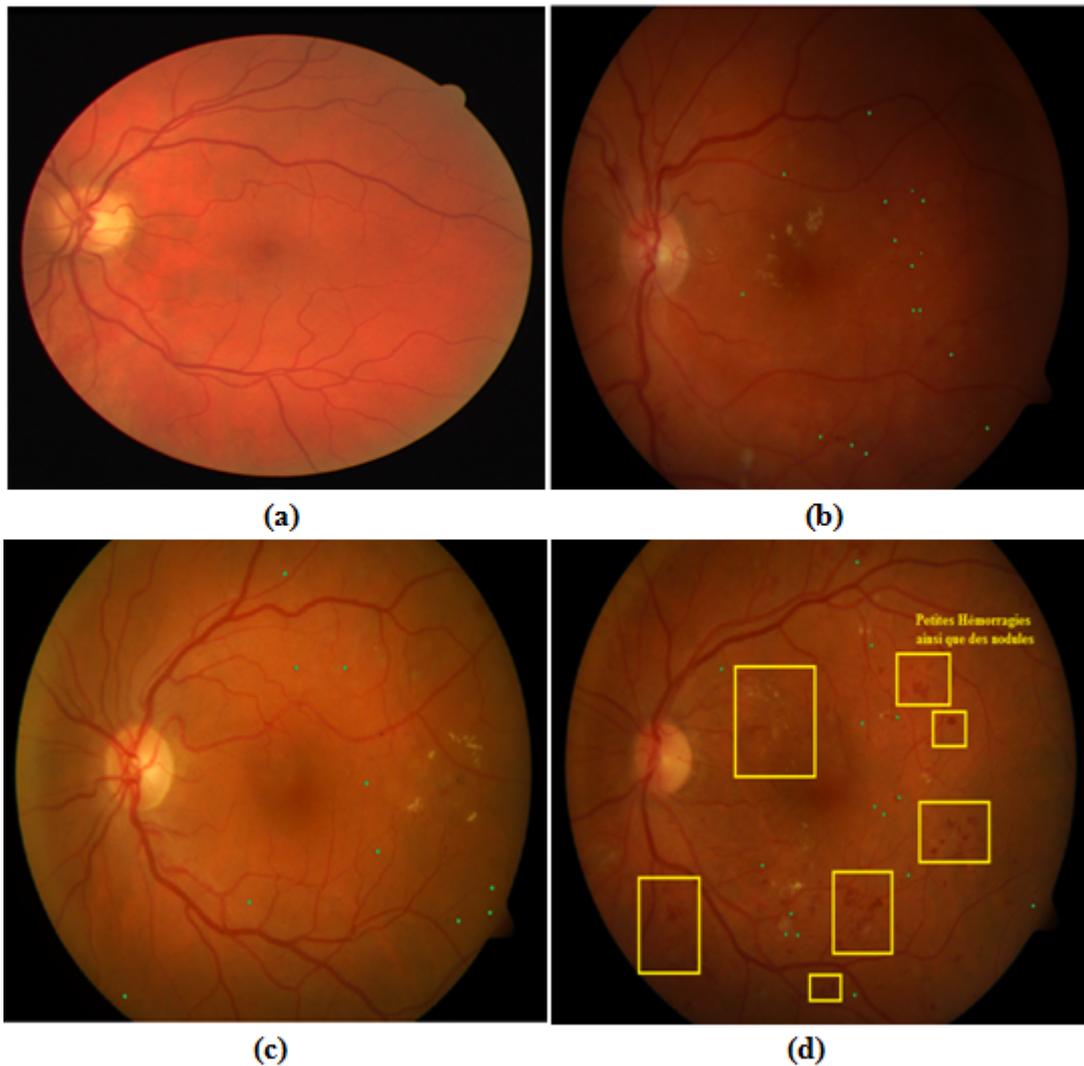


FIGURE 4.7 – Exemples de détection des MAs dans différents types d’images. (a) : Image non pathologique, (b) : Image de mauvaise qualité, (c) : Présence de nodules cotonneux, (d) : Présence de toutes petites hémorragies ainsi que de quelques nodules cotonneux.

La principale contrainte lors de la détection des MAs réside dans le fait de leur toute petite taille, cela va compromettre l’opération de segmentation en rasant principalement les MAs les plus petits et les plus faiblement contrastés.

Sachant que les images rétiniennes contiennent certaines structures semblables aux MAs en terme de taille et de forme, telles que les petites tâches rondes qui résultent du croisement de deux vaisseaux sanguins minces, cela va compromettre leur reconnaissance et rendre leur détection quasi impossible.

La figure 4.8 donne un exemple des limites atteintes par notre système.

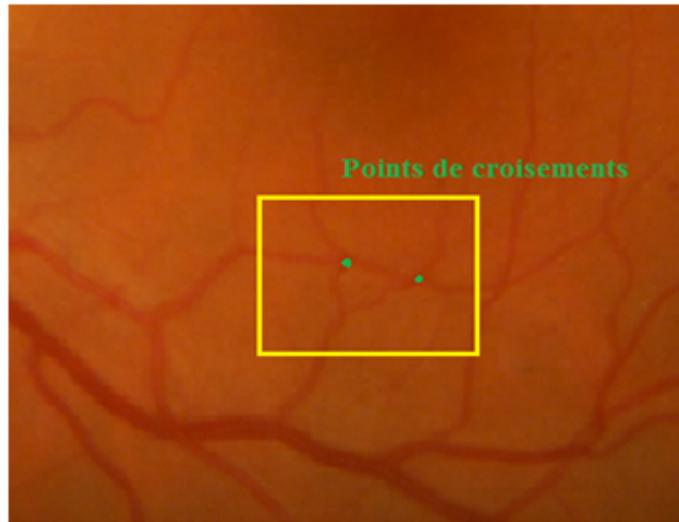


FIGURE 4.8 – Exemple d’une fausse détection de deux MAs alors que ces des points de bifurcation en réalité.

3.2.3 Comparaison des résultats de détection des MAs avec les travaux des chercheurs précédents dans ce domaine

La comparaison des résultats de performance d’évaluation de la détection des MAs s’est faite sur la base de trois paramètres pertinents, à savoir : la sensibilité, la spécificité, et le taux de classification. Les performances atteintes dans cette partie de la thèse ont été comparées avec les travaux de certains chercheurs traitant la même problématique, les résultats sont donnés par le tableau suivant :

Auteurs	Feroui [71]	Sudha et al. [72]	Notre approche
Méthodes utilisées	Ouverture ultime et classification KNN	Segmentation en découpage de graphe et le classification SVM, avec une ACP pour classifier la gravité de la RD	Croissance de région et classification KNN
Bases utilisées	DiaretDB1	Non reportée	DiaretDB1
Sensibilité (%)	89.79	94.44	93.62
Spécificité (%)	98.96	87.5	99.53
Taux de Classification (%)	99.96	Non reporté	99.98

TABLE 4.4 – Comparaison des résultats de détection des microanévrismes avec les travaux de la littérature

Ce tableau montre clairement que les performances atteintes par notre algorithme de détection des MAs sont très satisfaisantes. Cela démontre l'efficacité des algorithmes utilisés dans cette section. Ces bonnes performances seront la clé de la réussite d'une bonne classification du degré de la RDNP qui se base principalement sur la bonne détection des MAs qui sont les premières lésions apparentes lors de la déclaration de la maladie et qui resteront certainement tout au long de son évolution.

3.3 Evaluation des performances de détection des Exsudats

Nous passons finalement à l'évaluation de notre troisième et dernier algorithme de détection des exsudats présents sur les images du fond d'œil rétinien. Trois paramètres ont été calculés pour mesurer le degré de ressemblance entre la segmentation automatique et la segmentation manuelle réalisée par des médecins experts dans le domaine de la rétinopathie diabétique.

Un ensemble de dix-sept images a été utilisé pour réaliser cette tâche. Le tableau suivant résume les performances atteintes.

Images	Sensibilité (%)	Spécificité (%)	Taux de Classification (%)
1	90.98	98.47	98.37
2	92.36	99.62	98.63
3	94.87	94.84	94.94
4	97.58	99.46	99.48
5	95.91	100	99.92
6	98.78	99.36	99.31
7	99.34	99.82	99.77
8	99.53	98.06	98.15
9	95.53	100	99.90
10	99.63	99.83	99.81
11	90.71	99.53	99.30
12	87.32	100	99.59
13	95.76	96.41	97.48
14	98.62	94.54	95.09
15	91.87	100	99.98
16	94.63	100	99.95
17	98.85	99.38	97.37

TABLE 4.5 – Résultats de comparaison entre la segmentation manuelle et la segmentation automatique des Exsudats

3.3.1 Discussion et interprétation des résultats

Nous constatons sur le tableau 4.5 que le taux moyen obtenu de sensibilité est supérieur à 95 %, cela témoigne que seulement quelques fausses détections (FP)

ont été obtenues par l'algorithme dans la majorité des images rétiniennes. Ces fausses détections résident dans les pixels exsudatifs faiblement contrastés et qui sont collés à l'arbre vasculaire.

Ces exsudats vont être automatiquement supprimés avec le réseau rétinien lors de son élimination. Ces pixels ratés par l'algorithme sont présents sur les images segmentées manuellement par les ophtalmologues, c'est pour cette raison que la valeur de sensibilité chute.

Quant au taux moyen de spécificité rapporté sur le tableau 4.5 est proche de la perfection, cela peut être interprété par la capacité de l'algorithme à dépister correctement les images non pathologiques. Notre système détecte clairement les patients en bonne santé.

Les valeurs choisies des différents seuils et des éléments structurants influent certainement sur les mesures de performances.

La représentation graphique des paramètres d'évaluation des performances de l'algorithme de détection des exsudats est donnée par la figure suivante :

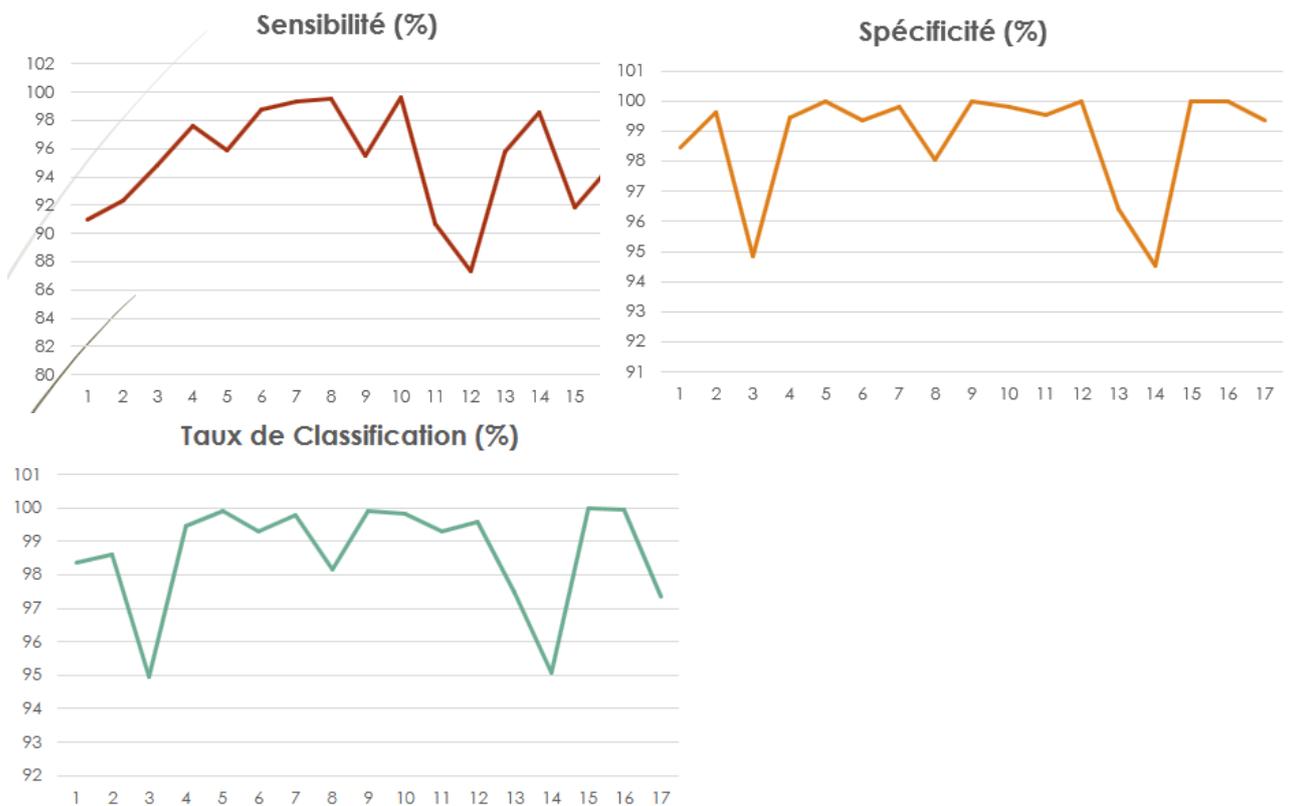


FIGURE 4.9 – Graphes représentatifs des paramètres d'évaluation des performances de l'algorithme de détection des exsudats durs

3.3.2 Robustesse et limite de l'algorithme de détection des exsudats

Nous avons utilisé différentes caractéristiques d'images pour l'appréciation de la performance de détection des exsudats. En premier lieu, le test s'est fait sur une série d'images non pathologiques (ne présentant aucune lésion sur le fond d'œil), les résultats de cette performance a été un succès comme on peut le voir sur la fig. 4.10.a. Ensuite, nous avons testé notre algorithme sur des images ne contenant que des nodules cotonneux et le disque optique, ces deux caractéristiques ont été choisies car elles sont très semblables aux EXs. Aucune détection n'est faite sur ce type d'images, cela nous indique clairement que notre système est capable de différencier les EXs des autres objets qui lui sont similaires, le résultat est montré sur la fig. 4.10.b.c.

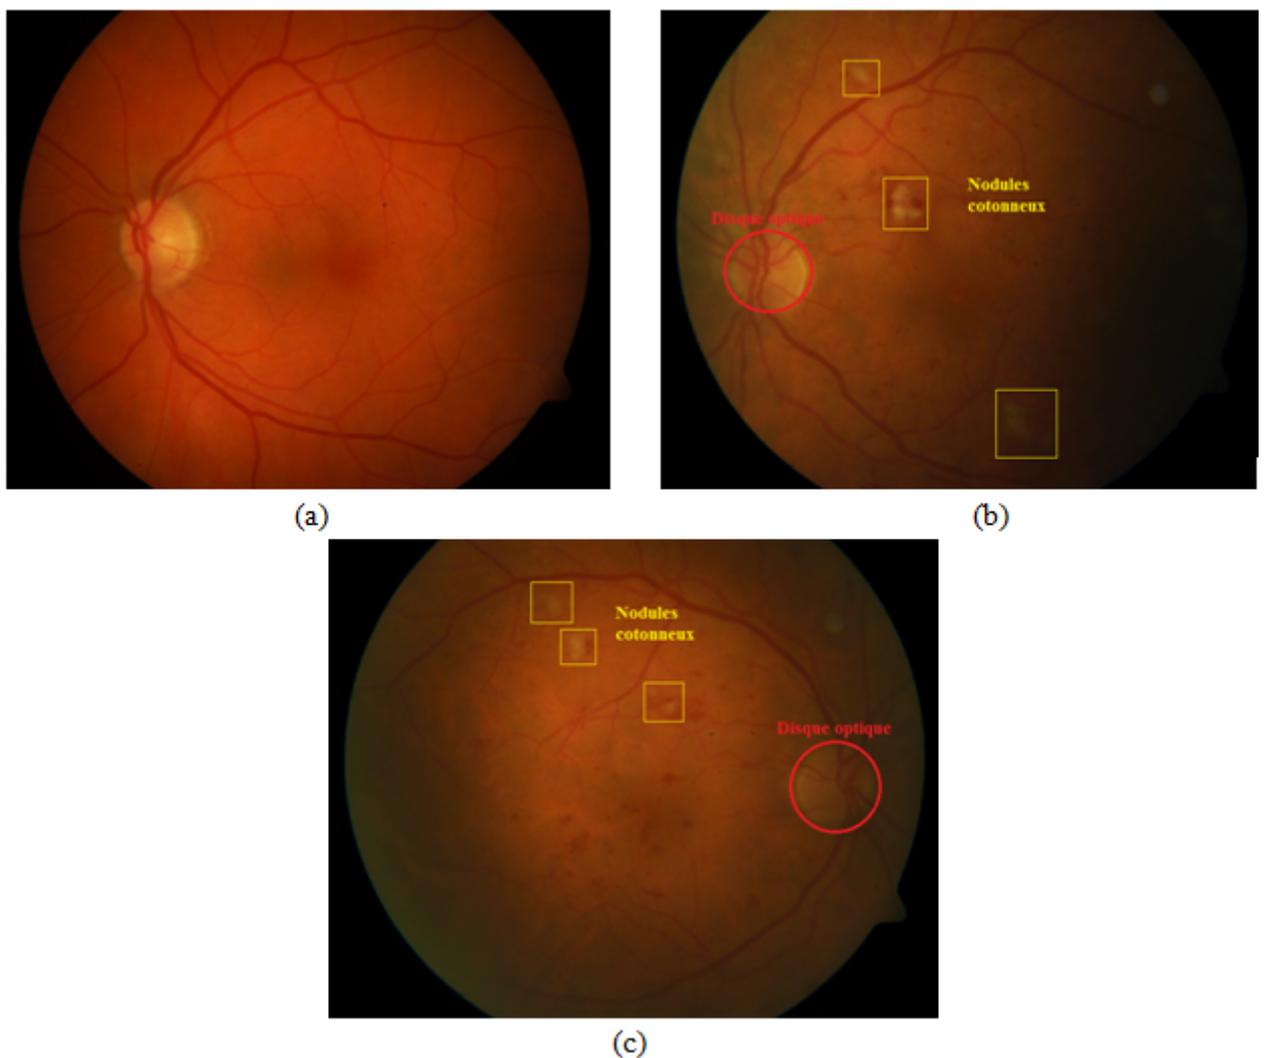


FIGURE 4.10 – Efficacité de l'algorithme sur des images ne contenant pas des Exsudats. (a) : image saine, (b,c) : Images contenant des nodules cotonneux.

Nous avons poursuivi ces test en utilisant cette fois-ci des images de mauvaise qualité, l'algorithme a fait ses preuves en réussissant à détecter les exsudats, et ce

même sur des images de faible contraste, mal éclairées et très bruitées. Les résultats sont reportés sur la fig. 4.11.




FIGURE 4.11 – Bonne détection des Exsudats sur des images de mauvaise qualité.

Et finalement, nous avons testé notre algorithme sur des images de la RD contenant plusieurs lésions et non seulement les exsudats, il a su gérer la situation en ne détectant que la pathologie souhaitée. Un exemple de cette bonne détection est donné par la figure 4.12.




FIGURE 4.12 – Détection des exsudats seulement en présence de nodules cotonneux et des hémorragies rétiniennes.

En dépit de ces bonnes performances, l'algorithme ne peut être parfait. Sur certaines images rétiniennes il n'a pas réussi à détecter certains pixels exsudatifs. La cause la plus probable de cette limite c'est la mauvaise luminosité et le mauvais contraste de ces pixels, en plus de leur tout petit diamètre qui complique certainement la tâche. Cela peut ne pas être très compromettant du fait que les cliniciens s'intéressent principalement aux exsudats étendus qui donnent une

bonne appréciation de l'évolution de la maladie. La bonne détection des exsudats repose essentiellement sur le choix des paramètres de détection (les valeurs des différents éléments structurants utilisés, et des seuils). Plus il est pertinent, meilleure sera la segmentation. La figure 4.13 montre un exemple de quelques fausses détections des exsudats obtenues par notre algorithme.




FIGURE 4.13 – Limites de notre algorithme de détection des exsudats.

3.3.3 Comparaison des résultats de détection des Exsudats avec les travaux de la littérature

Afin de faire une évaluation très approfondie de notre algorithme de détection des exsudats, nous avons décidé de le soumettre à une comparaison avec des travaux récents des chercheurs évoquant le même contexte. Le tableau 4.6 résume ces faits.

Auteurs	Sensibilité (%)	Spécificité (%)	Taux de Classification (%)
Amel Feroui [71]	97.50	97.95	Non reporté
Jahiruzzaman et al. [96]	98.20	89.80	92.30
Lokesh Gowda et al. [97]	98.38	96.36	99.01
Notre approche	97.48	98.78	99.26

TABLE 4.6 – Comparaison des résultats de détection des exsudats avec les travaux de la littérature

Nous concluons de ce tableau, que notre système a atteint d'excellentes performances en comparaison avec les travaux cités ci-dessus. Cela est très encourageant et bénéfique pour l'automatisation absolue de notre algorithme de détection des exsudats, afin de le rendre accessible aux ophtalmologues pour l'exploiter à des fins d'aide au diagnostique pour le dépistage de la Rétinopathie Diabétique Non Proliférante.

La section suivante va traiter les différents résultats de la classification du degré de la rétinopathie diabétique.

4 Résultats de la classification du degré de la RDNP

L'ophtalmologie moderne a connu une croissance spectaculaire des connaissances et une augmentation exponentielle de la technologie. Une bonne partie de cette explosion "hi-tech" implique des tests de diagnostic. Malheureusement, il y a parfois une tendance à utiliser des tests simplement parce qu'ils sont disponibles ; ou parce qu'ils sont hi-tech. L'idée de base d'un test de diagnostic est d'augmenter (ou de diminuer) la suspicion selon laquelle un patient est atteint d'une maladie particulière, dans la mesure où nous pouvons prendre des décisions en matière de gestion.

Le système d'aide au diagnostic développé au cours de ce travail de thèse se termine par la phase cruciale de la classification des différents stades de la RDNP. Notre système doit être apte à la fin de la compilation de dire si l'image d'entrée est non pathologique ou bien atteinte d'une RDNP, et de classer cette dernière en trois catégories différentes (RDNP Minime, RDNP Modérée, ou bien RDNP Sévère). Afin de réaliser cette performance, nous avons adopté le concept des machines learning en entraînant cinq différents classificateurs utilisant l'apprentissage supervisé, couronnés d'un vote majoritaire qui viendra perfectionner la classification. Le premier classificateur testé dans cette thèse est le perceptron multicouches MLP, qui est un réseau de neurone contenant une couche d'entrée,

une couche de sortie et 20 couches cachées. Un pas de 0.1, une époque de 1000, ainsi qu'une erreur de 0.001 ont été utilisés comme paramètres d'apprentissage. Les neurones sont reliés par des liaisons appelées poids synoptiques, et la mise à jour de ces poids se fait en utilisant l'algorithme de rétropropagation du gradient. Ce classifieur est très reconnu pour sa puissance d'apprentissage, il offre une meilleure capacité de généralisation, en particulier sur des données bruitées. Le second classificateur est le Séparateur à Vaste Marge (SVM) multi-classes, il est largement exploité par la littérature et a la capacité d'obtenir d'excellentes performances tout en minimisant l'erreur empirique. Il a aussi la réputation d'offrir une bonne gestion des cas et ce même dans la classification de plusieurs stades. La fonction Polynomiale d'ordre 2 a été retenue pour la séparation entre les différentes classes de la RDNP.

Le troisième classificateur est l'algorithme des K-Plus proches voisins (KNN), il a la particularité d'être très facile à implémenter et offre de très bons résultats. Un voisinage $K=5$ ainsi qu'une distance euclidienne ont été utilisés par ce classifieur. Le quatrième classificateur testé est l'analyse discriminante linéaire (ADL), largement connue et exploitée dans la littérature, elle est simple d'implémentation et offre une très grande précision.

Enfin, le dernier classificateur est l'algorithme de l'arbre de décision CART, qui est bien connu par sa puissance de classification. L'indice de Gini est utilisé pour le choix du meilleur attribut de division.

La classification du degré de la RDNP a été évaluée à l'aide de quatre bases d'images rétiniennes publiques, à savoir : la base de donnée MESSIDOR, la base DRIVE, et les deux bases DiaretDB1 et DiaretDB0 (citées ci-dessus dans la section 4.2), ensuite nous avons sommés ces quatre bases pour obtenir une nouvelle base de donnée constituée de 360 images. Les quatre stades de la rétinopathie diabétique non proliférante ont été déterminés avec succès, grâce à la bonne détection des trois pathologies rétiniennes (MAs, HEs, et EXs), et à la bonne caractérisation des données de classification. Sur les images saines sans signe de RD, les vaisseaux sanguins occupent la plus grande surface de l'image rétinienne. Les lésions de la RD sont absentes. Aux stades où la RDNP est légère ou modérée, la surface de la rétine des images pathologiques est corrompue par la présence des MAs, des HEs et des EXs avec un nombre de lésions plus important dans le stade modéré. Et dans le cas où la RDNP est sévère, leur importance est beaucoup plus grande. Ce stade précède la prolifération de la maladie qui à ce moment là peut entraîner le diabétique à la perte de sa vision s'il ne prend pas en charge sérieusement sa maladie.

Les différentes bases de données utilisées sont composées de quatre grades différents caractérisant la RDNP (grade 0, grade 1, grade 2, et grade 3), comme indiqué dans le tableau 4.7. Sachant que le grade 0 représente les images saines (absence de la RD) ne contenant aucun signe pathologique, le grade 1 définit la rétinopathie diabétique non proliférante légère (NPDR), le grade 2 représente la RDNP modérée et le grade 3 est le stade préproliférant ou bien la RDNP Sévère.

Types des images	Normales (Grade 0)	RDNP Légère (Grade 1)	RDNP Modérée (Grade 2)	RDNP Sévère (Grade 3)	Total
Base de données MESSIDOR	22	23	22	34	101
Base de données DiaretDB1	5	31	34	19	89
Base de données DiaretDB0	20	38	44	28	130
Base de données DRIVE	33	2	5	0	40
Somme des quatre bases	80	94	105	81	360

TABLE 4.7 – Nombre d’images de chaque grade dans les différentes bases de données

Le tableau 4.7 résume le nombre d’images utilisé de chaque grade de la RDNP. Dans la base de donnée MESSIDOR, nous avons testé un ensemble de 101 images : 22 images appartiennent au stade 0, 23 images sont du premier grade, 22 images représentent le grade 2, et enfin 34 images sont de la troisième classe.

Dans la base de données DiaretDB1, nous avons testé 89 images : 5 images appartiennent au grade 0, 31 images sont du grade 1, 34 images représentent le 2ème stade, et enfin 19 images appartiennent à la classe sévère (3). La base d’images DiaretDB0 est constituée d’un ensemble de 130 images, dont 20 images sont non pathologiques, 38 images représentent le stade de la RDNP Légère, 44 images sont du stade modéré, et 28 images constituent le grade sévère de la RDNP.

Dans la base de données DRIVE, nous avons testé 40 images : 33 images sont saines, 2 images appartiennent à la première classe et 5 images appartiennent au deuxième grade.

Ensuite nous avons sommé ces quatre bases de données pour obtenir une nouvelle base plus importante constituée de 360 images, avec 80 images saines, 94 image du grade 1, 105 images de la classe modérée, et 81 images appartenant au stade préproliférant de la RD.

Nous allons donner dans ce qui suit les résultats des performances de la classification du degré de la RDNP pour chaque base de données citées ci-dessus.

4.1 Résultats et discussions des performances de la première expérience avec la base de données MESSIDOR

Les résultats des performances obtenues par les cinq différents classifieurs, pour réaliser la fastidieuse tâche de la classification du degré de la RDNP des

images rétiniennes issues de la base de donnée MESSIDOR, sont donnés par les matrices de confusion et leur représentation graphique (figure 4. 14).




FIGURE 4.14 – Graphes représentatifs des matrices de confusion pour chaque classifieurs de la base de données MESSIDOR.

Les matrices de confusion nous donnent des appréciations et des connaissances approfondies sur la classification réalisée par les différents classifieurs. Nous avons utilisé le principe de la validation croisée (son principe est donné dans le chapitre 2 section 2.9) pour l'apprentissage et le test de notre base de donnée, nous avons retenu un $k=3$.

Si l'on veut interpréter, par exemple, le résultat obtenu par le classifieur LDA, sur la figure 4.14, on dira que le grade 0 se compose de 3 images, 2 d'entre elles ont été bien classées et la troisième a été considérée par l'algorithme comme appartenant au grade 1. Donc le grade 0 a obtenu une sensibilité de 66.66 %, et une spécificité de 96.67 %, car une image du grade 1 a été faussement classée par l'algorithme sous le grade 0.

Le grade 1 se compose de 12 images appartenant à la catégorie de la RDNP Légère. 11 d'entre elles ont été classées comme telle, et 1 image a été faussement attribuée au grade 0. Ce grade obtient alors une sensibilité de 91.67 % du fait qu'il a raté une image, et une spécificité de 85.71 %. La raison pour laquelle la valeur a

chuté est les trois images provenant des grades 0, 2, et 3, qui ont été faussement considérées comme appartenant au grade 1.

Le grade 2 est formé de 13 images de la RDNP Modérée, 11 images ont été bien classées par l’algorithme, 1 image a été attribuée au grade 1, et la dernière image de cette catégorie a été considérée comme appartenant au grade 3. La sensibilité atteinte dans ce grade est de 84.63 % du fait des deux images ratées par l’algorithme, et la spécificité est de 100 % car aucune image des trois autres grades n’a été faussement attribuée à ce stade.

Et finalement le troisième grade est formé de 5 images de la RDNP Sévère. 4 images ont été bien classées et 1 image a été attribuée au grade 1 par erreur. La sensibilité de ce grade est de 80 % (du à l’image ratée), et sa spécificité est de 96.43 % (cela est du à l’image du 2ème grade qui a été considérée comme faisant partie du grade 3).

Cette explication est valable pour toutes les autres performances des classifieurs restants.

Afin d’évaluer les performances de notre système, nous avons calculé, pour chaque classifieurs, la sensibilité, la spécificité, et le taux de classification, à travers la matrice de confusion de chacun, pour pouvoir juger de la fiabilité et de la précision de nos algorithmes. Les résultats obtenus sont sommés dans le tableau suivant :

	Sensibilité (%)	Spécificité (%)	Taux de Classification (%)
CART	90.83	94.56	92.42
SVM	87.72	96.54	95.45
KNN	83.89	93.87	90.91
MLP	89.71	95.34	93.94
ADL	81.31	94.69	92.42

TABLE 4.8 – Performances atteintes par les cinq classifieurs pour la base de données MESSIDOR

On conclut de ce tableau que les performances de classification atteintes sont élevées. Les cinq classifieurs ont été capable de donner le grade de la RDNP pour les images de test utilisées. Le SVM a donné les meilleures prestations de classification en obtenant un taux de 95.45 %, secondé par les réseaux de neurones, et suivi de près par l’arbre de décision et l’analyse discriminante qui ont atteints pratiquement les mêmes performances. Finalement le KNN a donné un taux légèrement inférieur aux autres classifieurs avec un pourcentage de 90.91 %.

4.2 Résultats et discussions des performances de la deuxième expérience avec la base de données DiaretDB0

La méthode proposée est évaluée à l'aide de 130 images rétinienne, dont 20 sont normales et 110 sont pathologiques. Ces images sont obtenues à partir de la base de données DiaretDB0. Nous avons suivi la même procédure employée pour la base de données MESSIDOR, pour l'interprétation des résultats de la classification des différents grades de la RDNP à travers les machines learning. La validation croisée avec un $K=3$ a été retenu pour entrainer et tester notre base. Les matrices de confusion et leur représentation graphique ont été calculées pour chaque classifieur. Les résultats sont donnés par la figure suivante :

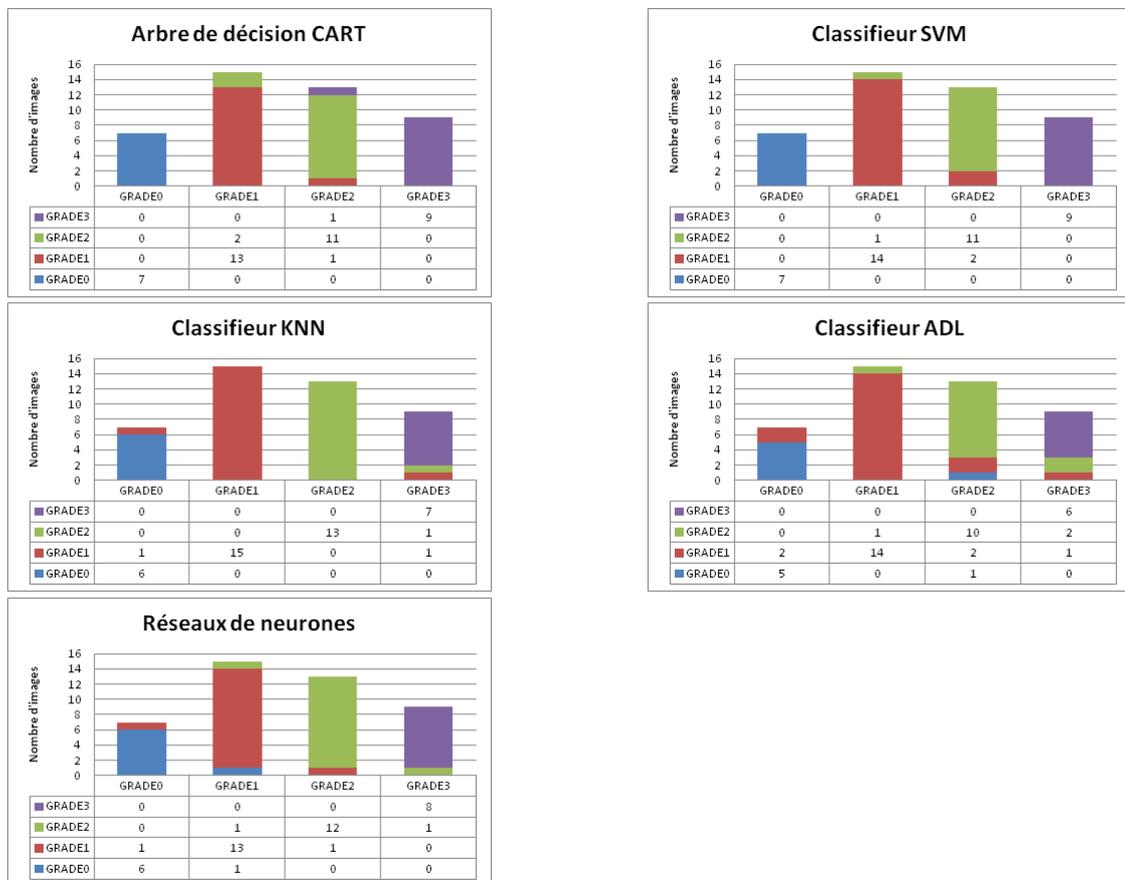


FIGURE 4.15 – Graphes représentatifs des matrices de confusion pour chaque classifieurs de la base de données DiaretDB0

L'algorithme a pu déterminer avec succès les quatre degrés de la rétinopathie diabétique, grâce à la bonne détection des pathologies rétinienne en grande partie ainsi qu'au bon choix des caractéristiques d'entrée des classificateurs. Dans les images saines, aucune anomalie n'est observée et par conséquent les lésions rétinienne sont absentes. Dans la RDNP légère, modérée ou sévère, nous remarquons l'apparition des MAs, des HEs et des EXs sur les images du fond d'œil, avec un nombre, une localisation, et une taille différents et plus conséquent au fur et à mesure de l'évolution de la maladie.

Le tableau suivant résume les résultats obtenus dans cette expérience. Nous avons utilisé tous les descripteurs de notre base de données. Les performances de classification avec les cinq différents classificateurs mis en œuvre ont été évaluées en calculant les pourcentages de sensibilité, de spécificité et de classification. Les résultats sont donnés par le tableau suivant :

	Sensibilité (%)	Spécificité (%)	Taux de Classification (%)
CART	91.87	96.72	95.45
SVM	94.79	97.54	96.59
KNN	89.52	96.07	94.32
MLP	95.27	97.99	96.6
ADL	83.49	93.29	89.77

TABLE 4.9 – Performances atteintes par les cinq classifieurs pour la base de données DiaretDB0

Le tableau 4.9 montre que les cinq classificateurs formés ont donné un bon taux de classification. Les meilleurs résultats sont ceux obtenus par les réseaux de neurones, suivis de près par le classifieur SVM. La plus faible prestation a été obtenue par le classifieur ADL. En ce qui concerne les valeurs de sensibilité et de spécificité, nous remarquons que l'évaluation de la validité intrinsèque de notre système est bonne, sachant que la sensibilité est la probabilité que les tests effectués sur des patients malades (pathologiques) soient positifs, et la spécificité est la probabilité que les tests effectués sur des personnes en bonne santé soient négatifs ; en d'autres termes, le test est négatif sachant que la personne n'est pas malade.

En conclusion de ce tableau, nous pouvons dire que notre algorithme est capable de différencier les quatre stades de la RDNP, il est très important en termes de gain de temps et d'effort pour les ophtalmologistes.

4.3 Résultats et discussions des performances de la troisième expérience avec la base de données DiaretDB1

La méthode utilisée a été validée à l'aide de 89 images rétiniennes issues de la base de données DiaretDB1. Les résultats sont donnés par la figure suivante :




FIGURE 4.16 – Graphes représentatifs des matrices de confusion pour chaque classifieurs de la base de données DiaretDB1

Nous avons validé ces résultats par le calcul de paramètres performant donnant une bonne vision de notre système, le tableau suivant résume ces faits.

	Sensibilité (%)	Spécificité (%)	Taux de Classification (%)
CART	76.55	94.15	91.67
SVM	81.85	95.55	93.33
KNN	75.13	93.37	90
MLP	90	95.57	93.33
ADL	73.1	90.33	86.67

TABLE 4.10 – Performances atteintes par les cinq classifieurs pour la base de données DiaretDB1

Nous remarquons dans ce tableau que les paramètres d'évaluation sont acceptables. Le système d'aide au diagnostic offre une grande précision dans la classification des différents stades de la RDNP.

4.4 Résultats et discussions des performances de la quatrième expérience avec la base de données DRIVE

L'évaluation de cette quatrième expérience s'est faite à l'aide de 40 images rétinienne de la base de données DRIVE. Cette base est très petite, nous avons décidé de l'utiliser pour montrer à quel point il est compromettant de ne pas élargir la base d'images.

Les résultats sont montrés sur la figure suivante :

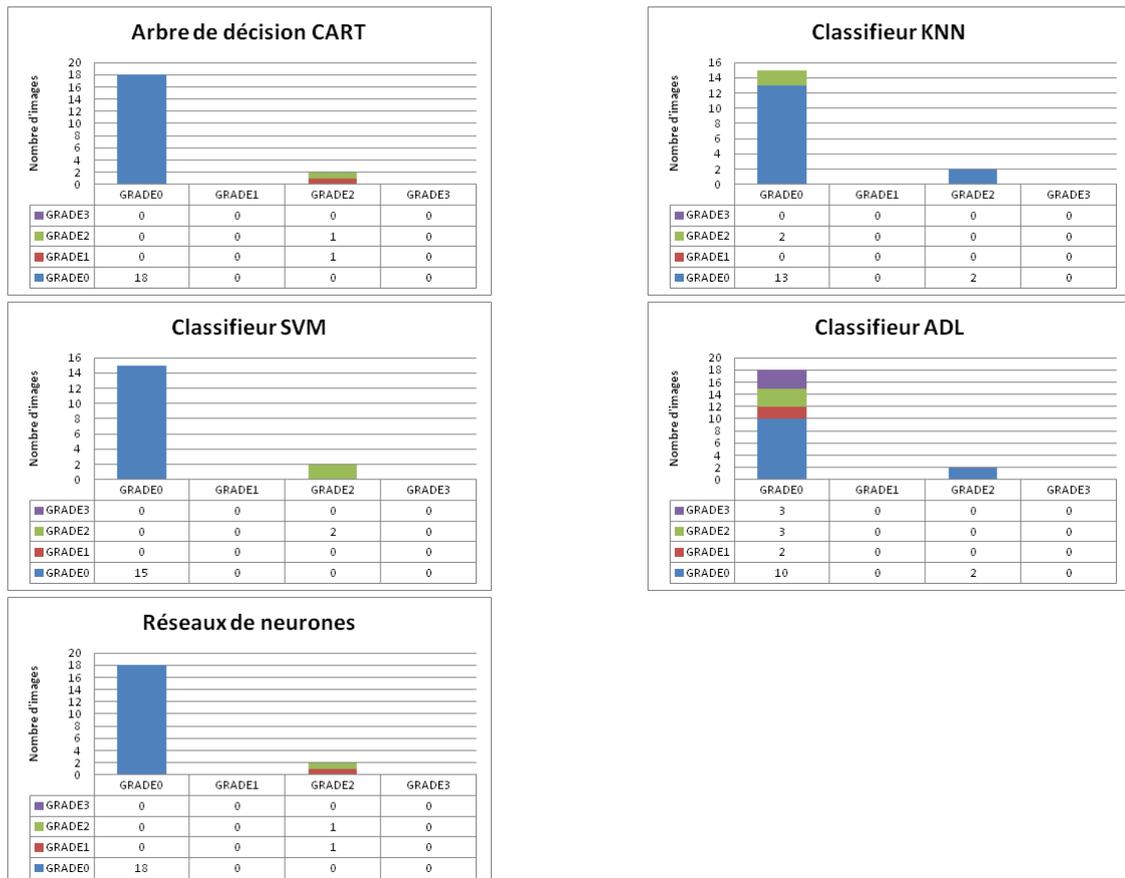


FIGURE 4.17 – Graphes représentatifs des matrices de confusion pour chaque classifieurs de la base de données DRIVE

Les matrices de confusion obtenues par chaque classifieur sont peu significatives du fait que la base ne contient que très peu d'images. En effet, dans cette base l'algorithme a la capacité de reconnaître le grade 0 car 33 images le forment, mais il n'a pas pu reconnaître les autres grades car seulement 2 images composent le grade 1, 5 images constituent le grade 2, et aucune image n'appartient au grade 3. Donc l'apprentissage ne peut pas se faire correctement dans ce cas de figure. Si on prend l'exemple de la matrice de confusion des réseaux de neurones, on constate que les 18 images de test appartenant au grade 1 sont bien classées, car l'algorithme ne connaît en réalité que cette catégorie, les grades 1 et 3 n'ont aucune image, et les 2 dernières images de test appartiennent au grade 2, l'algorithme a reconnu seulement une et l'autre a été classée au hasard.

Nous avons calculé les performances de cette expérience, et les résultats sont donnés par le tableau ci-dessous :

	Sensibilité (%)	Spécificité (%)	Taux de Classification (%)
CART	Ne peut être calculée	98.68	97.5
SVM	Ne peut être calculée	100	100
KNN	Ne peut être calculée	71.67	88.24
MLP	Ne peut être calculée	98.68	97.5
ADL	20.83	72.06	75

TABLE 4.11 – Performances atteintes par les cinq classifieurs pour la base de données DRIVE

Le tableau 4.11 révèle une classification médiocre obtenue avec la base DRIVE. Nous expliquons cela par le nombre insuffisant ou inexistant des images disponibles pour l'apprentissage. Il s'agit d'une base déséquilibrée, car elle souffre de sous-apprentissage.

Afin de remédier à ce genre de base de données, nous avons décidé de créer une nouvelle base constituée du total d'images utilisées par les différentes expériences.

4.5 Résultats et discussions des performances de la cinquième expérience avec la nouvelle base de données

Cette nouvelle base de données est constituée de 360 images, provenant des différentes bases de données utilisées dans les quatre précédentes expériences. Nous avons décidé d'utiliser cette base pour palier au problème des petites bases de données. Car la clé de la réussite d'une excellente performance de classification est l'exploitation d'une large base de données, plus la base est grande et plus l'algorithme pourra apprendre les données souhaitées.

L'apprentissage de la nouvelle base de données s'est fait à l'aide de la validation croisée avec un $k=3$, la base a été divisée en 3 et le test s'est fait avec un total de 120 images. Nous donnerons ci-dessous les différentes matrices de confusion obtenues par chaque classifieur, et nous terminerons cette section par l'évaluation

des critères de la nouvelle base.

Matrice de confusion du classifieur ADL

Grades	Grade 0	Grade 1	Grade 2	Grade 3	Somme
Grade 0	32	0	0	0	32
Grade 1	0	33	0	0	33
Grade 2	0	0	18	0	18
Grade 3	1	0	0	36	37
Somme	33	33	18	36	120

TABLE 4.12 – Matrice de confusion du classifieur ADL de la cinquième expérience

Le test s’est fait avec un ensemble de 32 images appartenant au grade 1, 33 images sont issues du grade 1, 18 images sont du 2ème grade, et finalement 37 images sont attribuées au dernier grade.

Dans cette expérience, l’algorithme a atteint pratiquement la perfection, car il a pu classer 119 images sur 120 correctement. la seule image ratée par l’algorithme provient du grade 3 qui a été attribuée à tort à la classe saine. La représentation graphique de cette matrice est donnée par la figure suivante :

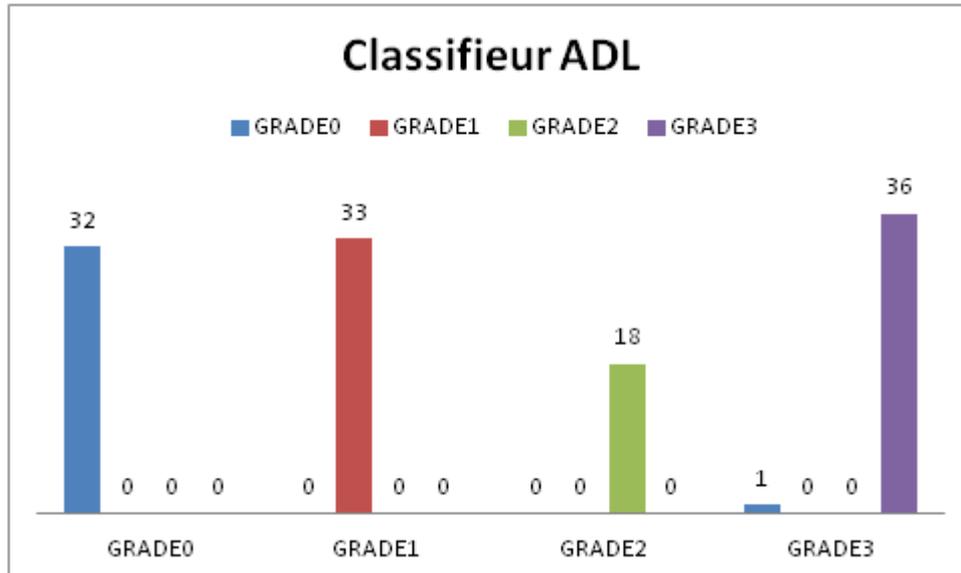


FIGURE 4.18 – Représentation graphique de la matrice de confusion du classifieur ADL de la cinquième expérience.

Matrice de confusion du classifieur K-NN

Les paramètres utilisés par le classificateur KNN sont l’utilisation d’une distance Euclidienne avec un nombre de K=5.

Grades	Grade 0	Grade 1	Grade 2	Grade 3	Somme
Grade 0	25	6	1	0	32
Grade 1	1	32	0	0	33
Grade 2	0	1	15	2	18
Grade 3	1	0	1	35	37
Somme	27	39	17	37	120

TABLE 4.13 – Matrice de confusion du classifieur KNN de la cinquième expérience

Dans cette expérience, l’algorithme des K plus proches voisins a pu classer correctement 25 images sur 32 du grade 0, les sept images restantes ont été mal classées, 6 d’entre elles ont été affectées au grade 1 et la dernière a été considérée par l’algorithme comme étant du 2ème grade. Ensuite, parmi les 33 images composant le grade 1, 32 ont été bien classées, et la seule image ratée par notre système a été faussement attribuée au grade 0. Puis, sur les 18 images du grade 2, 15 ont été bien classées. Deux images ont été faussement considérées comme étant du grade 3, et une image a été attribuée au grade 1. Et finalement, 35 images du grade 3 ont été bien classées sur 37. Une image a été assignée au grade 2, et l’autre au grade 0.

La représentation graphique de la matrice de confusion du classificateur KNN est donnée par la figure suivante :

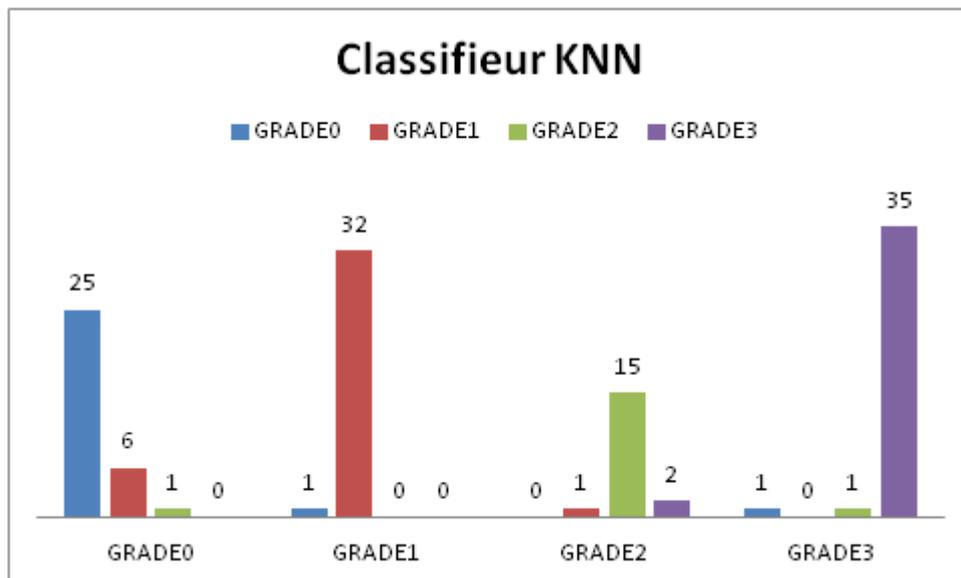


FIGURE 4.19 – Représentation graphique de la matrice de confusion du classifieur KNN de la cinquième expérience.

Matrice de confusion du classifieur SVM

Les paramètres d’ajustement de l’algorithme des séparateurs à vaste marges utilisés sont la fonction Kernel Polynomiale avec le principe du 1 contre tous.

Grades	Grade 0	Grade 1	Grade 2	Grade 3	Somme
Grade 0	31	1	0	0	32
Grade 1	0	33	0	0	33
Grade 2	0	2	16	0	18
Grade 3	0	1	0	36	37
Somme	31	37	16	36	120

TABLE 4.14 – Matrice de confusion du classifieur SVM de la cinquième expérience

Dans cette expérience, le classificateur SVM a très bien classé les images de test. La représentation graphique du tableau 4.14 est illustrée sur la figure suivante.




FIGURE 4.20 – Représentation graphique de la matrice de confusion du classifieur SVM de la cinquième expérience.

Matrice de confusion du classifieur CART

Grades	Grade 0	Grade 1	Grade 2	Grade 3	Somme
Grade 0	32	0	0	0	32
Grade 1	0	33	0	0	33
Grade 2	1	0	17	0	18
Grade 3	0	0	1	36	37
Somme	33	33	18	36	120

TABLE 4.15 – Matrice de confusion de l'arbre de décision CART de la cinquième expérience

L'algorithme de l'arbre de décision CART a très bien géré la classification des images de la RDNP. Il a pu classer les grades 0 et 1 avec précision. La bonne caractérisation, ainsi que le nombre d'échantillons disponible pour l'apprentissage jouent un rôle très important dans la bonne classification.

La figure 4.21, illustre la représentation graphique de la matrice de confusion de l'arbre de décision CART.

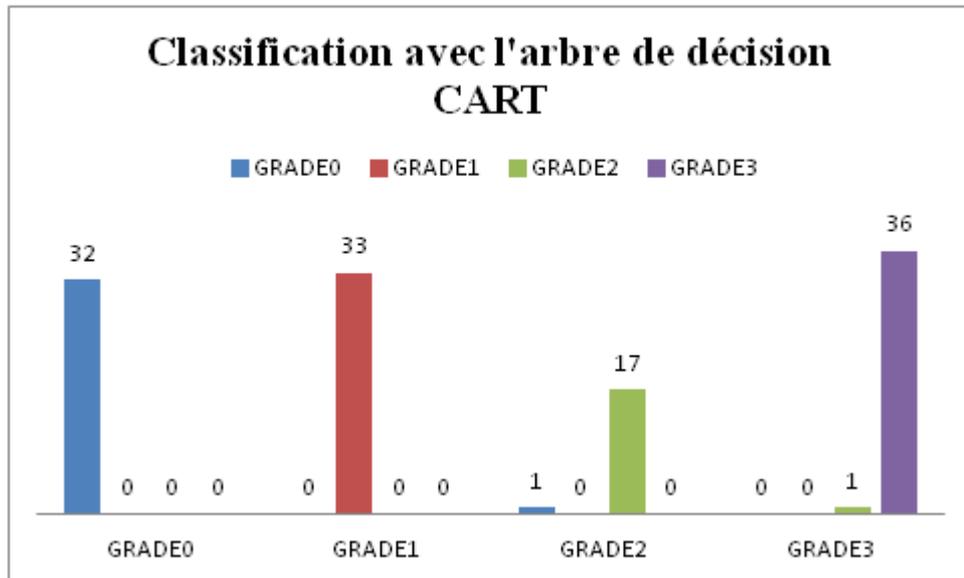


FIGURE 4.21 – Représentation graphique de la matrice de confusion de l'arbre de décision CART de la cinquième expérience.

Matrice de confusion des Réseaux de neurones

Grades	Grade 0	Grade 1	Grade 2	Grade 3	Somme
Grade 0	32	0	0	0	32
Grade 1	1	32	0	0	33
Grade 2	0	0	18	0	18
Grade 3	0	1	0	36	37
Somme	33	33	18	36	120

TABLE 4.16 – Matrice de confusion des réseaux de neurones de la cinquième expérience

Les performances atteintes dans cette dernière expérience relèvent de la perfection de notre système de classification du degré de la RDNP. L'algorithme des réseaux de neurones a pu classer toutes les images du grade 0 et du grade 2 correctement, il a su reconnaître toutes les images saines de notre base de données, ainsi que toutes les images pathologiques appartenant à la catégorie de la RDNP Modérée. Une seule image du grade 1 a été ratée par l'algorithme des réseaux

de neurones, elle a été attribuée à tort au grade 0, sachant que le grade 1 est très similaire au grade 0. Et une image aussi parmi les 37 du grade 3, a été faussement classée sous le grade 1. Ce système est très fiable et très robuste en terme de reconnaissance du stade de nos images rétiniennes.

La représentation du tableau 4.16, est donnée par la figure suivante :




FIGURE 4.22 – Représentation graphique de la matrice de confusion des réseaux de neurones de la cinquième expérience.

5 Évaluation des performances de la classification des différents stades de la RDNP

Afin d'évaluer et de juger les performances de notre système d'aide au diagnostic réalisant la classification des différents stades de la RDNP, nous avons calculé quatre mesures pertinentes, à savoir, la sensibilité, la spécificité, le taux de classification, et l'erreur commise par l'algorithme. Les fonctions de ces paramètres sont données dans ce chapitre dans la section 4.3.1. Il reste à déterminer les fonction du taux de classification et de l'erreur commise. Leurs relations sont données par :

$$TauxdeClassification(\%) = \frac{VraiPositif+VraiNegatif}{VraiPositif+VraiNegatif+FauxPositif+FauxNegatif} * 100$$

$$Erreurcommise = 1 - Tauxdeclassification$$

Les résultats des performances des cinq classifieurs sont donnés par le tableau suivant :

	Sensibilité (%)	Spécificité (%)	Taux de Classification(%)	Erreur commise
CART	97.85	99.46	98.23	0.0177
SVM	95.76	98.85	96.67	0.033
KNN	88.26	96.33	94.58	0.0542
MLP	98.48	99.42	98.06	0.0194
ADL	99.24	99.70	97.78	0.022

TABLE 4.17 – Performances atteintes par les cinq classifieurs pour la nouvelle base de données

Les performances atteintes par nos cinq classifieurs dans cette cinquième expérience sont très élevées. Les arbres de décision ont obtenu les meilleures performances avec un taux de classification de 98.33 %, les réseaux de neurones viennent les seconder avec un taux de classification de 98.06 %. L'analyse discriminante linéaire vient en troisième position avec un taux de 97.78 %, suivi par un taux de 96.67 % obtenu par le SVM. Le KNN a obtenu le plus faible taux dans cette expérience avec un 94.58 %, son algorithme a raté malheureusement quelques images.

Le tableau suivant résume les résultats de nos cinq expériences réalisées au cours de cette étude :

Expérience 1 : Base de données MESSIDOR (101 images)					
	CART	MLP	KNN	SVM	ADL
Sensibilité (%)	90.83	89.71	83.89	87.72	81.31
Spécificité (%)	94.56	95.34	93.87	96.54	94.69
Taux de Classification (%)	92.42	93.94	90.91	95.45	92.42
Expérience 2 : Base de données DiaretDB0 (130 images)					
	CART	MLP	KNN	SVM	ADL
Sensibilité (%)	91.87	95.27	89.52	94.79	83.49
Spécificité (%)	96.72	97.99	96.07	97.54	93.29
Taux de Classification (%)	95.45	96.6	94.32	96.59	89.77
Expérience 3 : Base de données DiaretDB1 (89 images)					
	CART	MLP	KNN	SVM	ADL
Sensibilité (%)	76.55	90	75.13	81.85	73.1
Spécificité (%)	94.15	95.57	93.37	95.55	90.33
Taux de Classification (%)	91.67	93.33	90	93.33	86.67
Expérience 4 : BDD DRIVE (40 images)					
	CART	MLP	KNN	SVM	ADL
Sensibilité (%)	Ne peut être calculée	20.83			
Spécificité (%)	98.68	98.68	71.67	100	72.06
Taux de Classification (%)	97.5	97.5	88.24	100	75
Expérience 5 : Nouvelle Base de données (360 images)					
	CART	MLP	KNN	SVM	ADL
Sensibilité (%)	97.85	98.48	88.26	95.76	99.24
Spécificité (%)	99.46	99.42	96.33	98.85	99.70
Taux de Classification (%)	98.23	98.06	94.58	96.67	97.78

TABLE 4.18 – Résultats de classification des cinq expériences

Ce tableau résume toutes les valeurs des paramètres d'évaluation obtenues par les cinq machines learning, dans les cinq expériences réalisées.

L'expérience 5 rapporte les meilleures performances atteintes dans ce travail de thèse. Le système d'aide au diagnostic élaboré dans cette recherche offre une grande précision de classification. Il est tout a fait capable de reconnaître une image saine d'une image pathologique, et de donner le grade de la pathologie de chaque image de notre base de données.

Cette expérience a réussi à obtenir ces résultats prometteurs grâce à plusieurs facteurs, notamment, le nombre d'images contenu dans notre base. Effectivement, cela va offrir plus de chance à notre algorithme de reconnaître les différents grades de nos images. Dans un système de classification, plus la phase d'apprentissage est bien apprise, et meilleures seront les performances de la classification.

Nous avons décidé d'utiliser cinq classificateurs dans cette recherche car plusieurs études montrent qu'un modèle de classification induisant une seule hypothèse pose des problèmes de dimensionnalité, de biais et de variance. C'est pour cette raison que nous avons proposé de combiner chacun des classificateurs faibles individuels pour former un système de classification unique appelé les machine learning. Le choix des classifieurs utilisé dans ce travail a été retenu après avoir réalisé une multitude de test avec des dizaines de classifieurs différents. Les cinq classifieurs correspondent le mieux à notre base de classification.

6 Le vote majoritaire

Nous avons utilisé à la fin de ce travail de thèse de rajouter le vote majoritaire pour augmenter nos chances d'obtention d'une très grande précision du système élaboré tout au long de ces cinq années de recherches. Son principe est donné par la figure suivante :




FIGURE 4.23 – Principe du vote majoritaire

Le principe du vote est de regrouper les modèles pour prévoir le résultat final. Nous disposons de cinq différents classificateurs composés des arbres de décision (CART), un classificateur SVM, une analyse discriminante linéaire (ADL), des réseaux de neurones, et du classifieur KNN. Les modèles sont opposés les uns aux autres et sélectionnés selon les meilleures performances en votant à l'aide de la classe du vote majoritaire. Le vote souple ne peut être fait lorsque tous les classificateurs peuvent calculer des probabilités pour les résultats. Le vote progressif aboutit au meilleur résultat en calculant la moyenne des probabilités calculées par des algorithmes individuels.

Les méthodes de vote sont basées sur un processus démocratique (pondéré) qui combine les prévisions fournies par les modèles de classification calibrés de manière indépendante sur un certain nombre de sources analytiques disponibles. L'approche la plus simple et intuitive repose sur la règle du vote à la majorité, qui attribue un échantillon sur la base de l'affectation de classe la plus fréquente (méthode «en vrac»), alors que l'échantillon n'est pas classé en cas d'égalité.

Les approches de protection sont dérivées en appliquant des limites spécifiques, ce qui signifie qu'un échantillon est attribué uniquement si la fréquence des assignations à une classe est supérieure à un seuil sélectionné. Par exemple, les critères de vote à la majorité «intermédiaire» et «strict» classent un échantillon si l'accord de prédiction est supérieur ou égal à 75 % et 100 %, respectivement. Le vote à la majorité stricte représente le cas d'un accord de prédiction complet de tous les modèles considérés.

Le taux du vote majoritaire obtenu dans ce travail de thèse est de l'ordre de **98.34 %**, avec une erreur commise de 0.0083.

7 Comparaison de nos résultats de classification avec les travaux de la littérature

Nous avons effectué une comparaison de nos résultats de classification des différents stades de la rétinopathie diabétique non proliférante avec les travaux récents des chercheurs dans ce domaine, pour montrer la contribution de cette thèse. Les résultats de cette comparaison sont illustrés dans le tableau suivant :

	Sensibilité (%)	Spécificité (%)	Taux de Classification (%)
Kanika et al. [98]	98,5	100	92
Hillol et al. [99]	—	—	89,61
Saha et al. [100]	90,11	87,66	97,13
Notre approche	97,85	99,46	98,33

TABLE 4.19 – Tableau comparatif de la classification du degré de la RDNP avec d'autres travaux de la littérature

Nous pouvons conclure de ce tableau, que notre système de dépistage précoce de la RDNP, peut être utilisé pour l'aide au diagnostic en Ophtalmologie. Il serait très intéressant de l'automatiser complètement afin de le rendre exploitable par les médecins spécialistes.

8 Conclusions

Les travaux réalisés dans le cadre de cette thèse, permettent de concevoir avec succès un système CAD dédié au diagnostic des premiers stades de la RD, en particulier de la RDNP. Grâce aux fonctionnalités sélectionnées dans cette technique, nous sommes en mesure de détecter les lésions lumineuses ainsi que les lésions sombres. Par rapport à d'autres travaux de recherche, les aspects importants de l'algorithme proposé sont discutés ci-après.

La nouveauté de cette recherche réside dans la conception d'un système CAD combinant des méthodes de prétraitement et de détections hybrides pour segmenter les lésions candidates, ce qui est très important pour l'extraction efficace de chaque pathologie car elles ont des aspects différents les unes que les autres. Ces méthodes ont été capable d'extraire les lésions sombres les plus difficiles qui existent dans la RDNP, appelées les Microanévrismes. Ils correspondent aux premières manifestations de la maladie. Les hémorragies et les exsudats sont des symptômes associés à l'évolution de la RDNP. La technique proposée est également capable d'identifier de telles lésions. Le système proposé est capable de gérer la détection et l'élimination des régions susceptibles de causer de faux positifs, à savoir les vaisseaux sanguins, la macula et le disque optique, en utilisant des approches simples et efficaces. Ici, la technique de détection du disque optique proposée est capable d'extraire sa forme complète.

Pour l'extraction de caractéristiques, une combinaison de caractéristiques fortes telles que les caractéristiques basées sur la forme géométrique et la texture est extraite pour obtenir des informations détaillées sur les lésions.

Bien que le SVM soit considérée comme une technique de classification efficace en termes de complexité temporelle et de précision, les autres techniques de classification sont appréciées car leur précision pour la détection des classes de lésions sombres et brillantes est bien supérieure à celle du classifieur SVM sur le jeu de fonctionnalités extraites. La précision des performances atteintes par les cinq classifieurs testés pour la classification du degré de la RDNP utilisant douze caractéristiques est très élevée pour chaque expérience réalisée. Par conséquent, nous pouvons conclure que les différents classifieurs exploités dans cette recherche soient comparables en terme de précision de notre système.

Ce système proposé pourra aider les ophtalmologistes et les patients atteints de la rétinopathie diabétique à effectuer un dépistage oculaire périodique. Les avantages sont la facilité et la rapidité du dépistage oculaire et la précision des résultats. Nous avons obtenu une sensibilité de 97,85 % et une spécificité de 99.46 % pour les 360 images testées. Si les MAs sont présents près des vaisseaux sanguins, ils seront probablement éliminés lors de l'extraction des vaisseaux et le succès de la détection des microanévrismes dépend de l'extraction des vaisseaux. Mais avec une bonne segmentation, nous avons réduit le taux de fausse détection. La détection des hémorragies peut également être incluse pour augmenter la précision de la détection du niveau de gravité de la rétinopathie diabétique.

Conclusion générale

La rétinopathie diabétique (RD) est l'une des principales causes de cécité chez les êtres humains âgés de 20 à 74 ans. Une détection précoce de la RD est assez difficile car elle peut ne pas être détectée à ses débuts par les experts. Plusieurs techniques et algorithmes ont été établis pour sa détection. Néanmoins, ils sont confrontés à plusieurs problèmes pour atteindre une sensibilité, une précision et une spécificité effectives. Pour remédier à cela, nous avons proposé dans ce travail de thèse, des algorithmes plus efficaces de traitement des images, et de classification, afin d'accroître l'efficacité et d'identifier facilement les maladies liées à la RD. Actuellement, les techniques de traitement des images sont largement utilisées pour diagnostiquer les maladies, notamment celles des yeux. Des outils d'imagerie informatique sont nécessaires pour détecter efficacement les signes de la rétinopathie diabétique. Une détection précoce permettrait à l'ophtalmologiste de traiter les patients avant que des dommages importants ne se produisent, et offrirait les meilleures chances de protéger la vision du patient. Le système de classification automatique de la rétinopathie diabétique offre un diagnostic plus rapide et plus efficace. Des actions préventives peuvent être entreprises tôt pour protéger la vision et éviter la cécité. Le dépistage de la rétinopathie diabétique est actuellement un domaine prisé par la recherche. Les systèmes de traitement d'images numériques se composent généralement de quatre parties principales : le prétraitement, la détection des différentes pathologies, l'extraction de caractéristiques et la classification.

Ce travail de thèse est basé sur le développement d'un système d'aide au diagnostic en Ophtalmologie, pour le dépistage et la classification des différents stades de la RDNP. Nous avons fait appel à des outils de traitement d'images et à la classification supervisée pour l'élaboration de ce système.

Afin de réaliser cette fastidieuse tâche, nous avons commencé par apporter des corrections à nos images rétiniennes à travers des étapes de prétraitement efficaces, telles que la correction de l'illumination, l'augmentation de contraste, et l'atténuation des bruits. Nous avons poursuivi ce travail, par la détection des trois lésions caractéristiques de la RDNP, à savoir, les microanévrismes, les hémorragies et les exsudats. Il s'agit des premiers signes cliniques évocateurs de la maladie, leur détection permet un diagnostic précoce, et donc la préservation de la vision des patients diabétiques. Cette étape est réalisée à l'aide de la segmentation des éléments principaux de la rétine (le réseau vasculaire, la macula, et le disque optique), et de méthodes hybrides utilisant la combinaison de la morphologie mathématique et de la classification non supervisée. Une sélection de

paramètres pertinents caractérisant convenablement les images du fond d'œil, vient compléter notre système. C'est une phase cruciale, car c'est à travers ces caractéristiques que nous pouvons juger de la fiabilité de la classification. Cette dernière achève ce travail thèse en réalisant la classification du degré de la RDNP. Le principe des machines learning a été adopté dans cette étape. Un total de cinq classifieurs (le SVM, le KNN, les Réseaux de neurones, l'ADL, et l'arbre de décision CART) a été testé sur un ensemble de 360 images du fond d'œil, issues de quatre bases de données rétiniennes (MESSIDOR, DiaretDb0, DiaretDb1, DRIVE). Ces classifieurs correspondent le mieux à nos images, ils ont pu obtenir des taux de validation cohérents et logiques. La sortie de notre système classe les images d'entrée en saines (absence de tout signe clinique de la maladie), ou pathologiques en donnant le stade de gravité de la RDNP.

La technique proposée dépend fortement de la résolution de l'image, de la variation de l'intensité de la couleur rétinienne, ainsi que de la position et de la taille des lésions rétiniennes. Les contributions majeures rapportées dans le cadre de ce travail, reposent essentiellement la haute performance de détection des lésions de la RD, et la bonne classification des différents stades de la RDNP qui a pu améliorer les travaux récents des chercheurs dans ce domaine, tout en minimisant le nombre de faux positifs afin de se rapprocher le plus possible de la perfection.

Néanmoins et en dépit de ces hautes performances, le système peut rencontrer certaines difficultés qui peuvent réduire sa fonction. Ces principales contraintes résident dans la détection des lésions rétiniennes qui sont très difficile à extraire, notamment lorsqu'elles se présentent sur des images de très mauvaise qualité et qui se trouvent collées sur les éléments de la rétine. Elles seront éliminées avec ces dernières. Et comme le système est dépendant de chaque étape, alors la classification sera affectée par cela.

Cependant, les résultats de classification obtenus au cours de cette recherche indiquent clairement que le système réalisé est apte à être utilisé à des fins d'aide au diagnostic en ophtalmologie. On peut mentionner que ce travail propose une méthodologie permettant à la fois d'identifier et de distinguer différents types de lésions sombres et lumineuses, et qu'il est donc capable de mieux fonctionner par rapport à d'autres méthodes et avec une précision plus élevée. Le système proposé présente une approche de diagnostic fiable et rapide pour le stade précoce de la RD, appelée RDNP. Nous pouvons envisager de l'utiliser pour le dépistage de masse de la maladie.

Perspectives et Travaux futurs

Outre ces aspects saillants, il reste encore plusieurs pistes à exploiter pour poursuivre cette recherche. Les facteurs les plus plausibles sont donnés dans ce qui suit :

- Rendre notre système d'aide au diagnostic complètement automatique afin qu'il puisse être exploité par les Ophtalmologues.

- La taille de la base de données utilisée à des fins de formation et de test peut être étendue pour modifier le niveau de précision du système proposé. Et prétendre à l'exploitation d'une base de données réelle.

- Réaliser la classification de la RDP, en détectant davantage de pathologies liées à la RD (Nodules cotonneux, les Néovaisseaux prérétiniens et prépapillaires, et l'œdème maculaire), qui représentent le stade avancé de la maladie.

Bibliographie

- [1] L. Loumé, *Rétinopathie diabétique : comment le diabète peut rendre aveugle*. Sciences et avenir, 2018.
- [2] S. Barriga, V. Murray, C. Agurto, G. Zamora, H. Yu, J. C. Wigdahl, S. C. Nemeth, W. C. Bauman, and P. Soliz, "Statistical validation of an automatic algorithm for diabetic retinopathy screening," *Technique de l'ingénieur*, 2012.
- [3] C. Agurto, H. Yu, V. Murray, M. Pattichis, S. Barriga, and P. Soliz, "Detection of hard exudates and red lesions in the macula using a multiscale approach," *IEEE Southwest Symposium on Image Analysis and Interpretation*, no. 1043, 2012.
- [4] J. Vislisel and T. Oetting, "Diabetic retinopathy : from one medical student to another," *Department of Ophthalmology and Visual Sciences, University of Iowa*, no. 1043, 2010.
- [5] H. Yu, C. Agurto, S. Barriga, S. Nemeth, P. Soliz, , and G. Zamora, "Automated image quality evaluation of retinal fundus photographs in diabetic retinopathy screening," *IEEE Southwest Symposium on Image Analysis and Interpretation*, no. 1037, 2012.
- [6] H. Yu, E. S. Barriga, C. Agurto, S. EcheGARAY, M. S. Pattichis, W. Bauman, and P. Soliz, "Fast localization and segmentation of optic disk in retinal images using directional matched filtering and level sets," *IEEE Transactions on Information Technology in Biomedicine*, vol. 16, no. 4, pp. 644– 657, 2012.
- [7] F. F. des Diabétiques, *Le diabète dans le monde*. Diabetes Atlas IDF 8e Edition, 2017.
- [8] R. Klein, "Hyperglycemia and microvascular and macrovascular diseases in diabetes," *Diabetes Care*, 1995.
- [9] "Atlas du diabète de la fid." International Diabetes Federation. Huitième édition 2017.
- [10] S. Barriga, V. Murray, C. Agurto, G. Zamora, H. Yu, J. C. Wigdahl, S. C. Nemeth, W. C. Bauman, and P. Soliz, "The diabetes control and complications trial research group, the effect of intensive treatment of diabetes on the development and progression of long term complications in insulin-dependent diabetes mellitus," *N Engl J Med*, no. 329,977, 1993.
- [11] U. prospective. diabetes. study. (UKPDS). Group, "Intensive blood-glucose control with sulphonylureas or insulin compared with conventional treatments and risk of complications in patients with type 2 diabetes (ukpds 33)," 1998.

- [12] C. Hasslacher, A. Bosted–Kiesel, and H. P. Kempe, “Effect of metabolic factors and blood pressure on kidney function in proteinuric type ii (non-insulin- dependent) diabetic patients,” *Diabetologia*, vol. 36, no. 1051, 1993.
- [13] F. H. Jelinek and M. J. Cree, “Automated image detection of retinal pathology,” *Boca Raton : CRC Press*, 2010.
- [14] C. R. Keeler, “150 years since babbage’s ophthalmoscope,” *Arch. Ophthalmol.*, vol. 115, 1997.
- [15] D. S. Halacy and C. Babbage, “Father of the computer,” *Crowell-Collier Press*, 1970.
- [16] A. Gullstrand, “Neue methoden der reflexlosen ophthalmoskopie berichte deutsche ophthalmologische gesellschaft,” 1910.
- [17] H. R. Novotny and D. L. Alvis, “A method of photographing fluorescence in circulating blood in the human retina,” *Circulation*, vol. 24, 1961.
- [18] D. Huang, E. A. Swanson, J. S. S. C. P. Lin, W. G. Stinson, M. R. H. W. Chang, T. Flotte, K. Gregory, C. A. Puliafito, and J. Fujimoto, “Optical coherence tomography,” *Science*, vol. 254, no. 5035, p. 1178–1181, 1991.
- [19] P. Massin and S. Feldman-Billard, “Referentiel sfd/sfo pour le depistage et la surveillance des complications oculaires du patient diabetique 2016.” [://www.sfdiabeto.org](http://www.sfdiabeto.org) > www.sfdiabeto.org > files > files > resources, 2016.
- [20] Hutchinson, “Dépistage de la rétinopathie diabétique par lecture différée de photographies du fond d’oeil,” Décembre 2010.
- [21] M. Mohammed, M. B. Khan, and E. B. M. Bashier, *Machine learning : Algorithms and Applications*. Taylor Francis Group, LLC., international standard book number-13 ed., 2017. 978-1-4987-0538-7 (Hardback).
- [22] O. F.Y, A. J.E.T, A. O, H. J. O, O. O, and A. J, “Supervised machine learning algorithms : Classification and comparison,” *International Journal of Computer Trends and Technology (IJCTT)*, vol. 48, no. 3, pp. 2231 – 2803, June 2017.
- [23] B. Boser, I. Guyon, and V. Vapnik, “A training algorithm for optimal margin classifiers,” *Proceedings of the fifth annual workshop on Computational learning theory*, pp. 144 – 152, July 1992.
- [24] A. Rivel, “Support vector machines.” : pageperso.univ-lr.fr > arnaud.revel > MesPolys > SVM.
- [25] “Machines à vecteurs supports.” [://www.math.univ-toulouse.fr](http://www.math.univ-toulouse.fr) > besse > Wikistat > pdf > st-m-app-svm. Institut de Mathématiques de Toulouse.
- [26] D. Cheng, S. Zhang, Z. Deng, Y. Zhu, and M. Zong, “Knn algorithm with data-driven k value,” *Springer Internationla Publishing Switzerland*, pp. 499 – 512, 2018.
- [27] O. Harrison, “Machine learning basics with the k-nearest neighbors algorithm.” [://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761](http://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761). Publié le : 2018-09-10.
- [28] M. Schott, “K-nearest neighbors (knn) algorithm for machine learning.” [://medium.com/capital-one-tech/k-nearest-neighbors-knn-algorithm-for-machine-learning-e883219c8f26](http://medium.com/capital-one-tech/k-nearest-neighbors-knn-algorithm-for-machine-learning-e883219c8f26). Publié le : 2019-04-22.

- [29] A. Tharwat, T. Gaber, A. I. d, and A. E. Hassanien, "Linear discriminant analysis : A detailed tutorial," *researchgate.net*, May 2017.
- [30] L. Breiman, J. Friedman, R. Olshen, and C. Stone, *Classification and regression trees*. Wadsworth Books, 358, 1984.
- [31] E. H. D. Mostafa, *Classification and Recognition of Biomedical Data with Ensemble Methods*. PhD thesis, Université Abou Bake Belkaid de Tlemcen, 2015.
- [32] P. Gupta, "Cross-validation in machine learning." [://towardsdatascience.com > cross-validation-in-machine-learning](http://towardsdatascience.com/cross-validation-in-machine-learning), June, 7 2017.
- [33] W. Yun, L. Acharya, U. R. Venkatesh, Y. Chee, C. Min, L. C, and N. E, "Identification of different stages of diabetic retinopathy using retinal optical images," *International Journal of Computer Trends and Technology (IJCTT)*, no. 178, p. 106–121, 2008.
- [34] J. Nayak, P. Bhat, S. Acharya, R. Lim, and M. Kagathi, "Automated identification of diabetic retinopathy stages using digital fundus images," *Journal of medical systems*, no. 332(2), p. 107–115, 2008.
- [35] A. W. Reza and C. Eswaran, "A decision support system for automatic screening of non-proliferative diabetic retinopathy," *Journal of medical systems*, no. 35(1), pp. 17 – 24, 2011.
- [36] "Diabetic retinopathy detection." Foundation, C. H, September 2015.
- [37] B. Graham, "Kaggle diabetic retinopathy detection competition report," August 6 2015.
- [38] B. Graham, "Fractional max-pooling," *arXiv preprint : 1412.6071*, 2014.
- [39] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv :1409.1556*, 2014.
- [40] M. .A, Bravo, and P. Arbelaez, "Automatic diabetic retinopathy classification," *Biomedical Computer Vision, published in SIPAIM*, 2017.
- [41] C. Aravind, M. PonniBala, and S. Vijayachitra, "Automatic detection of microaneurysms and classifications of diabetic retinopathy images using svm technique," *International Journal of Computer Applications*, 2013.
- [42] S. S. Kumar and S. Vipula, "Automatic detection of diabetic retinopathy in non-detailed rgb retinal fundus images," *International Journal of Computer Applications*, vol. 47, pp. 26–32, June 2012.
- [43] H. Tjandra and I. Anggoro, "Classification of non-proliferative diabetic retinopathy based on segmented exudates using k-means clustering," *International Journal on Image, Graphics and Signal Processing*, pp. 1 – 8, 2015.
- [44] C. Sundhar and D. Archana, "Vautomatic screening of fundus images for detection of diabetic retinopathy," *International Journal of Communication and Computer Technologies*, vol. 2, April 2014.
- [45] C. Jagatheesh and C. Jenila, "Automatic detection and classification of diabetic retinopathy lesion using bags of visual words model," *International Journal of Scientific and Research Publications*, vol. 5, September 2015.

- [46] R. Welikala, M. Fraz, T. Williamson, and S. Barman, "The automated detection of proliferative diabetic retinopathy using dual ensemble classification," *International Journal of Diagnostic Imaging*, vol. 2, 2015.
- [47] J. Amin, M. Sharif, and M. Yasmin, "A review on recent developments for detection of diabetic retinopathy," *Scientifica*, Article ID 6838976, vol. 2016, 2016.
- [48] F. Aptel, P. Denis, F. Rouberol, and C. Thivolet, "Screening of diabetic retinopathy : effect of field number and mydriasis on sensitivity and specificity of digital fundus photography," *Diabetes Metabolism*, vol. 34, no. 3, p. 290 – 293, 2008.
- [49] P. Kahai, K. R. Namuduri, and H. Thompson, "A decision support framework for automated screening of diabetic retinopathy," *International Journal of Biomedical Imaging*, Article ID 45806, vol. 2006, no. 8, 2006.
- [50] D. Usher, M. Dumskyj, M. Himaga, T. H. Williamson, S. Nussey, and J. Boyce, "Automated detection of diabetic retinopathy in digital retinal images : a tool for diabetic retinopathy screening," *Diabetic Medicine*, vol. 21, no. 1, pp. 84 – 90, 2004.
- [51] G. Gardner, D. Keating, T. H. Williamson, and A. T. Elliott, "Automatic detection of diabetic retinopathy using an artificial neural network : a screening tool," *British Journal of Ophthalmology*, vol. 80, no. 11, pp. 940 – 944, 1996.
- [52] C. Sinthanayothin, V. Kongbunkiat, S. Phoojaruenchanachai, and A. Singalavanija, "Automated screening system for diabetic retinopathy," *Proceedings of the 3rd International Symposium on Image and Signal Processing and Analysis (ISPA '03)*, vol. 2, pp. 915 – 920, 2003.
- [53] A. Osareh, M. Mirmehdi, B. Thomas, and R. Markham, "Classification and localisation of diabetic-related eye disease," *Springer Computer Vision ECCV : 7th European Conference on Computer Vision Copenhagen, Denmark*, vol. 2353, pp. 502 – 516, May 28–31, 2002.
- [54] G. Quellec, S. R. Russell, and M. D. Abramoff, "Optimal filter framework for automated, instantaneous detection of lesions in retinal images," *IEEE Transactions on Medical Imaging*, vol. 30, no. 2, pp. 523 – 533, 2011.
- [55] G. S. A. G. Vimala and S. Kajamohideen, "Diagnosis of diabetic retinopathy by extracting blood vessels and exudates using retinal color fundus images," *WSEAS Transactions on Biology Biomedicine*, vol. 11, pp. 20 – 28, 2014.
- [56] H. Fujita, Y. Uchiyama, and T. N. et al., "Computer-aided diagnosis : the emerging of three cad systems induced by japanese health care needs," *Computer Methods and Programs in Biomedicine*, vol. 92, no. 3, pp. 238 – 248, 2008.
- [57] B. Dupas, T. Walter, and A. E. et al., "Evaluation of automated fundus photograph analysis algorithms for detecting microaneurysms, haemorrhages and exudates, and of a computer-assisted diagnostic system for grading diabetic retinopathy," *Diabetes Metabolism*, vol. 36, no. 3, pp. 213 – 220, 2010.

- [58] C. I. Sánchez, M. Niemeijer, and I. I. et al., "Contextual computer-aided detection : improving bright lesion detection in retinal images and coronary calcification identification in ct scans," *Medical Image Analysis*, vol. 16, no. 1, pp. 50 – 62, 2012.
- [59] H. Tjandrasa and P. L. A., "Classification of non-proliferative diabetic retinopathy based on features extracted from red lesion segmentation," *The 3rd International Conference on Computer Engineering and Mathematical Sciences (ICCEMS 2014)*, 2014.
- [60] A.-J. MA and S. H., "Non-proliferative diabetic retinopathy symptoms detection and classification using neural network," *J Med Eng Technol.*, vol. doi : 10.1080/03091902.2017.1358772, no. 41(6), pp. 498 – 505, 2017.
- [61] N. Meindert, V. Bram, and S. J. et al., "Automatic detection of red lesions indigital color fundus photographs," *IEEE Trans. Med. Imaging*, no. 24 (5), p. 584–592, 2005.
- [62] T. Spencer, R. Phillips, and P. Sharp, "Automated detection and quantification of microaneurysms in fluorescein angiograms," *Albrecht Von Graæes Archiv Für Ophthalmologie*, no. 230(1), pp. 36 – 41, 1992.
- [63] A. Frame, P. E. Undrill, and M. J. C. et al., "A comparison of computer based classification methods applied to the detection of microaneurysms in ophthalmic fluorescein angiograms," *Comput. Biol. Med*, no. 28 (3), p. 225–238, 1998.
- [64] A. D. Fleming, P. Sam, and K. A. G. et al., "Automated microaneurysm detection using local contrast normalization and local vessel detection," *IEEE Trans. Med. Imaging*, no. 25(9), p. 1223–1232, 2006.
- [65] P. A, A. K, and D. A. et al., "Automated microaneurysm detection using mathematical morphology," *2nd International Conference on Instrumentation, Communications, Information Technology, and Biomedical Engineering (ICICI-BME). IEEE*, p. 117–120, 2011.
- [66] A. B and H. A., "An ensemble-based system for microaneurysm detection and diabetic retinopathy grading," *IEEE Trans. Biomed. Eng.*, no. 59 (6), p. 1720–1726, 2012.
- [67] H. M., "Improved microaneurysm detection using deep neural networks," *Computer Science*, 2015.
- [68] I. L and A. H., "Retinal microaneurysm detection through local rotating cross-section profile analysis," *IEEE Trans. Med. Imaging*, no. 32 (2), 2013.
- [69] S. L, H. T, and C. J. et al., "Red lesion detection using dynamic shape features for diabetic retinopathy screening," *IEEE Trans. Med. Imaging*, no. 35(4), p. 1116–1126, 2015.
- [70] B. Wu, W. Zhu, F. Shi, S. Zhu, and X. Chen, "Automatic detection of microaneurysms in retinal fundus images," *Computerized Medical Imaging and Graphics*, no. 55, p. 106–112, 2017.
- [71] A. Feroui, *Analyse des images couleur du fond d'œil pour l'aide au diagnostic en ophtalmologie : Application à la détection des pathologies rétiniennees*. PhD thesis, Université Abou Bakr Belkaid de Tlemcen, Mai 2014.

- [72] S.Sudha, A.Srinivasan, and T. Devi, "Automatic detection of microaneurysms in diabetic retinopathy images using graph cut segmentation and svm classifier with pca," *International Journal of Pure and Applied Mathematics*, vol. 119, 2018.
- [73] Y. Yang, T. Li, W. Li, H. Wu, W. Fan, and W. Zhang, "Lesion detection and grading of diabetic retinopathy via two-stages deep convolutional neural networks," *arXiv :1705.00771v1 [cs.CV]*, 2018.
- [74] N. Asiri, M. Hussain, and H. A. Abualsamh, "Deep learning based computer-aided diagnosis systems for diabetic retinopathy : A survey," *arXiv :1811.01238v1 [cs.CV]*, 3 Nov 2018.
- [75] S. Neera and R. Chandra, "Automated early detection of diabetic retinopathy using image analysis techniques," *International Journal of Computer Applications*, vol. 8, no. 2, p. 0975 – 8887, 2010.
- [76] K. C, S. U, I. C, and E. H, "Simple methods for segmentation and measurement of diabetic retinopathy lesions in retinal fundus images," *Computer Methods Programs Biomed*, vol. 107, pp. 274 – 293, 2013.
- [77] D. Sahu and S. Meshram, "Automatic detection of hemorrhages using image processing technique," *International journal of engineering Sciences Research Technology*, pp. 2277–9655, 2016.
- [78] G. Gupta, K. Ram, S. Kulasekaran, N. Joshi, and M. Sivaprakasam, "Detection of retinal hemorrhages in the presence of blood vessels," *Proceedings of the Ophthalmic Medical Image Analysis International Workshop*, 2014.
- [79] S. Gulati, N. Kleawsirikul, and B. Uyyanonvara, "A review on hemorrhage detection methods for diabetic retinopathy using fundus images," *International Journal of Biological, Ecological and Environmental Sciences (IJBEES)*, vol. 1, no. 6, p. 2277 – 4394, 2012.
- [80] G. A. L and K. Parasuraman, "Detection of retinal hemorrhage from fundus images using anfis classifier and mrg segmentation," *Biomedical Research*, vol. 29, no. 7, pp. 1489–1497, 2018.
- [81] J. Krishna and C. .B, "Detection of retinal hemorrhage from fundus images based on splat feature extraction," *International Journal of Advanced Research Trends in Engineering and Technology (IJARTET)*, pp. 2394–3785, 2014.
- [82] I. Bloch, H. Heijmans, and C. Ronse, *Chapter 14 MATHEMATICAL MORPHOLOGY*. Handbook of Spatial Logics, Springer.
- [83] H. Li and O. Chutatape, "Automated feature extraction in color retinal images by a model based approach," *IEEE Trans. on Medical Engineering*, vol. 51, pp. 246–254, 2004.
- [84] M. Foracchia, E. Grisan, and A. Ruggeri, "Detection of optic disk in retinal images by means of a geometrical model of vessel structure," *IEEE Trans. Med. Imag.*, vol. 23, no. 10, p. 1189–1195, 2004.
- [85] M. M. Fraz, W. Jahangir, S. Zahid, M. M. Hamayun, and S. A. Barman, "Multiscale segmentation of exudates in retinal images using contextual cues and ensemble classification," *Biomedical Signal Processing and Control*, vol. 35, no. 7, p. 50–62, 2017.

- [86] B. Harangi and A. Hajdu, "Automatic exudate detection by fusing multiple active contours and regionwise classification," *Computers in Biology and Medicine*, vol. 54, no. 7, p. 156–171, 2014.
- [87] X. Zhang, G. Thibault, and E. D. et al., "Exudate detection in color retinal images for mass screening of diabetic retinopathy," *Medical Image Analysis*, vol. 18, no. 7, p. 1026–1043, 2014.
- [88] S. Long, X. Huang, Z. Chen, S. Pardhan, and D. Zheng, "Automatic detection of hard exudates in color retinal images using dynamic threshold and svm classification : Algorithm development and evaluation," *BioMed Research International*, vol. 2019, no. Article ID 3926930, doi.org/10.1155/2019/3926930,, 23 January 2019.
- [89] S. K. Mohapatra, J. K. Swain, and M. N. Mohanty, "Detection of diabetes using multilayer perceptron," *International Conference on Intelligent Computing and Applications, Advances in Intelligent Systems and Computing 846*, 2019.
- [90] G.-F. Fan, Y.-H. Guo, J.-M. Zheng, and W.-C. Hong, "Application of the weighted k-nearest neighbor algorithm for short-term load forecastingl," *Energies* 2019, 12, 916 ; doi :10.3390/en12050916, 9 March 2019.
- [91] H. K. Febriawan, P. Helmholz, and I. M. Parnum, "Support vector machine and decision tree based classification of side-scan sonar mosaics using textural featuresl," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. XLII-2/W13, 10 - 14 June 2019.
- [92] B. Ghogh and M. Crowley, "Linear and quadratic discriminant analysis : Tutorial," *arXiv :1906.02590v1 [stat.ML]*, June 2019.
- [93] S. Fletcher and M. Z. Islam, "Decision tree classification with differential privacy : A survey," *ACM Computing Surveys, Vol. X, No. Y, Article Z*, May 2019.
- [94] "Description du projet messidor." www.adcis.net > logiciels-tiers > messidor-fr.
- [95] M. DS and Eswaran.C, "An automated decision-support system for non-proliferative diabetic retinopathy disease based on mas and has detection," *Computer Methods Programs Biomedical, electronically published*, 2012.
- [96] M. Jahiruzzaman and A. B. M. A. Hossain, "Detection and classification of diabetic retinopathy using k-means clustering and fuzzy logic," *18th International Conference on Computer and Information Technology (ICCIT)*, 2016.
- [97] L. G. J and K. V. Viswanatha, "Automatic diabetic retinopathy detection using fcm," *International Journal of Engineering Science Invention (IJESI)*, vol. 7, no. 4, pp. 9–24, April 2018.
- [98] K. Verma, P. Deep, and A. G. Ramakrishnan, "Detection and classification of diabetic retinopathy using retinal images," *ResearchGate*, 02 June 2014.
- [99] H. GHOSH, A. BISWAS, and B. RAY, *Medical Image Processing : Classification of Diabetic Retinopathy Using Machine Learning*. PhD thesis, May 2018.
- [100] R. Saha, A. R. Chowdhury, S. Banerjee, and T. Chatterjee, "Detection of retinal abnormalities using machine learning methodologies," *Neural Network World*, August 30, 2018.

Résumé

Parmi les maladies qui ravagent le monde entier et qui n'arrêtent malheureusement pas de croître, nous retrouvons la Rétinopathie Diabétique (RD). Elle est classée par l'organisation mondiale de la santé comme étant la première maladie pouvant causer une forte déficience visuelle menant jusqu'à la cécité des populations âgées entre 20 et 74 ans. Une très bonne prise en charge, une bonne hygiène de vie, ainsi qu'un dépistage précoce sont la clé de la prévention de la vision des patients diabétiques. Le travail de recherche effectué au cours de cette thèse, consiste en un système d'aide au diagnostic pour le dépistage précoce de la Rétinopathie Diabétique Non Proliférante (RDNP). Un tel système permet aux Ophthalmologistes un gain de temps et d'efforts inestimables. Nous faisons appel au traitement d'images et à la classification supervisée pour détecter et classer le degré de la RDNP. Trois lésions typiques de cette maladie, (les Microanévrismes, les Hémorragies, et les exsudats), ont été détectées avec succès par nos algorithmes, en utilisant des méthodes hybrides différentes pour chaque pathologie. Il s'agit des toutes premières lésions apparentes au cours de l'évolution de la maladie ; en effet les microanévrismes sont les signes précoces de son apparition, ils n'ont aucune influence sur la vision du malade et peuvent parfois ne pas être détectés par les experts car ils se présentent sous forme de toute petite taille. Notre système a été validé sur un ensemble de base de données rétinienne (MESSIDOR, ImageRET, DRIVE), comprenant différentes images de différentes classes de la RD. Il a pu offrir une grande précision de détection des pathologies rétinienne, ainsi qu'une bonne détection des différents stades de la RDNP, basée sur la sélection de caractéristiques pertinentes. Les résultats sont très prometteurs.

Mots clés : Rétinopathie Diabétique ; Rétinopathie Diabétique Non Proliférante ; Sélection de paramètres pertinents ; Détection des lésions rétinienne ; Classification du degré de la RD.

Abstract

Among the diseases that ravage the world and which unfortunately do not stop growing, we find the Diabetic Retinopathy (DR). It is ranked by the World Health Organization as the first disease that can cause severe visual impairment leading to blindness in people aged 20 to 74 years. A very good management, a healthy lifestyle, and early detection are the key to preventing the vision of diabetic patients.

The research work done through this thesis consists of a diagnostic aid system for early detection of non-proliferative diabetic retinopathy (NPDR). Such a system allows Ophthalmologists to save valuable time and effort.

We use image processing and supervised classification to detect and classify the degree of DR. Three typical lesions of this disease, (Microaneurysms, Hemorrhages, and exudates), have been successfully detected by our algorithms, using different hybrid methods for each pathology. These are the first visible lesions during the evolution of the disease; Indeed, microaneurysms are early signs of its appearance, they have no influence on the vision of the patient and sometimes can not be detected by experts because they are in the form of any small size.

Our system has been validated on a set of retinal databases (MESSIDOR, ImageRET, DRIVE), including different images of different classes of the disease. He was able to offer a high accuracy of detection of retinal pathologies, as well as a good detection of the different stages of the NPDR, based on the selection of relevant characteristics. The results are very promising.

Key words : Diabetic retinopathy ; Non Proliferative Diabetic Retinopathy ; Selection of relevant parameters ; Detection of retinal lesions ; Classification of the degree of the DR.

ملخص

من بين الأمراض التي تدمر العالم والتي للأسف لا تتوقف عن النمو ، نجد اعتلال الشبكية السكري (RD). صنفته منظمة الصحة العالمية كأول مرض يمكن أن يسبب ضعفاً بصرياً شديداً يؤدي إلى العمى لدى الأشخاص الذين تتراوح أعمارهم ما بين 20 و 74 عاماً. تعد الرعاية الجيدة، نمط الحياة الصحي والكشف المبكر المفتاح الرئيسي لمنع خسارة رؤية مرضى السكري.

يتكون العمل البحثي الذي تم خلال هذه الأطروحة من نظام المساعدة التشخيصية للكشف المبكر عن اعتلال الشبكية السكري غير التكاثري (RDNP). مثل هذا النظام يسمح لأطباء العيون بتوفير وقت وجهد ثمين. نستخدم معالجة الصور والتصنيف الخاص للإشراف لاكتشاف وتصنيف درجة RDNP. تم اكتشاف ثلاث آفات نموذجية لهذا المرض (Microanévrismes، النزيف، exsudats) بنجاح بواسطة خوارزمياتنا ، وذلك باستخدام طرق مختلفة لكل مرض. والتي تعتبر أول مؤشرات مرئية أثناء تطور المرض. في الواقع ، تمثل Microanévrismes علامات مبكرة على ظهور المرض ، وليس لها أي تأثير على رؤية المريض وأحياناً لا يمكن للخبراء اكتشافها لأنها تظهر بحجم صغير جداً.

تم التحقق من صحة نظامنا على مجموعة من قواعد بيانات شبكية العين (MESSIDOR ، ImageRET ، DRIVE)، بما في ذلك صور متعددة لفئات وأصناف المرض. قدم النظام دقة عالية للكشف عن أمراض الشبكية ، بالإضافة إلى اكتشاف جيد للمراحل المختلفة من RDNP ، استناداً إلى اختيار الخصائص المميزة والنتائج كانت واعدة جداً.

الكلمات الرئيسية: اعتلال الشبكية السكري (RD). اعتلال الشبكية السكري غير التكاثري (RDNP). اختيار الخصائص المميزة ؛ الكشف عن آفات الشبكية ؛ تصنيف درجة اعتلال الشبكية السكري.