



HAL
open science

Segmentation de l'arbre vasculaire rétinien : étude de la performance en fonction de l'approche de segmentation

Henda Boudegga, Rahma Boukaddida, Yaroub Elloumi, Rostom Kachouri,
Asma Ben Abdallah, Mohamed Hedi Bedoui

► To cite this version:

Henda Boudegga, Rahma Boukaddida, Yaroub Elloumi, Rostom Kachouri, Asma Ben Abdallah, et al.. Segmentation de l'arbre vasculaire rétinien : étude de la performance en fonction de l'approche de segmentation. Applications Médicales de l'informatique : Nouvelles Approches (AMINA'2020), Dec 2020, Monastir, Tunisie. hal-03363238

HAL Id: hal-03363238

<https://hal.science/hal-03363238>

Submitted on 3 Oct 2021

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Segmentation de l'arbre vasculaire rétinien : étude de la performance en fonction de l'approche de segmentation

Henda Boudegga^{1,2,3}, Rahma Boukaddida^{1,2}, Yaroub Elloumi^{1,2,3}, Rostom Kachouri², Asma Ben Abdallah¹ and Mohamed Hedi Bedoui¹

¹*Medical Technology and Image Processing Laboratory, Faculty of medicine, University of Monastir, Tunisia.*

²*LIGM, Univ Gustave Eiffel, CNRS, ESIEE Paris, F-77454 Marne-la-Vallée.*

³*ISITCom Hamman-Sousse, University of Sousse, Tunisia*

Abstract

La segmentation des vaisseaux rétiniens est une étape cruciale pour la détection de plusieurs pathologies oculaires aussi qu'à la détection des autres structures anatomiques rétiniennes. Ce travail présente un état de l'art sur les méthodes de segmentation des vaisseaux rétiniens. De ce fait, une analyse explicite des méthodes est proposée. Ces méthodes sont catégorisées selon les outils mise en pratique. Cette étude a permis de proposer un workflow général des méthodes de segmentation. Par la suite, les démarches d'évaluation des méthodes ont été étudiées et les performances ont été comparées. En outre, les performances ont été synthétisées en fonction de l'utilisation des outils mise en pratique.

I. Introduction

La rétine est la couche sensorielle de l'œil contenant plusieurs structures anatomiques telles que le disque optique, la macula, les vaisseaux sanguins, etc [1]. La segmentation de l'arbre vasculaire rétinien dans l'image du fond d'œil est une tâche primordiale pour le diagnostic et la thérapie de plusieurs pathologies oculaires telles que la dégénérescence maculaire liée à l'âge, la rétinopathie diabétique, l'hypertension et le glaucome[2]. En outre, la segmentation des vaisseaux rétiniens présente une étape principale dans les méthodes de localisation d'autres composantes rétiniennes telles que le disque optique qui représente la zone de convergence des vaisseaux et la macula dont la texture ne contient pas des vaisseaux. De plus, la configuration des vaisseaux sanguins rétiniens représente une structure d'identification : chaque personne possède sa propre carte vasculaire. De ce faite, la localisation de l'arbre vasculaire rétinien est susceptible d'être employée dans des systèmes biométriques.

L'arbre vasculaire dispose de plusieurs caractéristiques morphologiques telles que la variation de l'épaisseur des vaisseaux (épais, minces), leur convergence du centre du disque optique, la réduction de l'épaisseur en s'éloignant du disque optique, etc. En outre, certaine maladie évoque l'apparition de nouveaux vaisseaux anormaux dans la rétine. Par exemple, le stade prolifératif de la rétinopathie diabétique engendre l'apparition des nouveaux vaisseaux minces dans la rétine où au niveau du disque optique. De même, le stade avancé de la DMLA humide engendre des nouveaux vaisseaux au niveau de la macula. De plus, dans le cas de l'affectation par la rétinopathie diabétique non prolifératif au stade précoce, les « micro-aneurisme » s'apparaissent à côté des vaisseaux qui peuvent engendrer une mauvaise segmentation des vaisseaux. En conséquent, le challenge est de garantir une bonne segmentation des vaisseaux indépendamment des pathologies et la divergence de la qualité et la résolution de l'image.

Dans ce contexte, plusieurs méthodes de segmentation ont été proposées. Ces méthodes se diversifient selon plusieurs critères. On distingue que les méthodes divergent point de vue

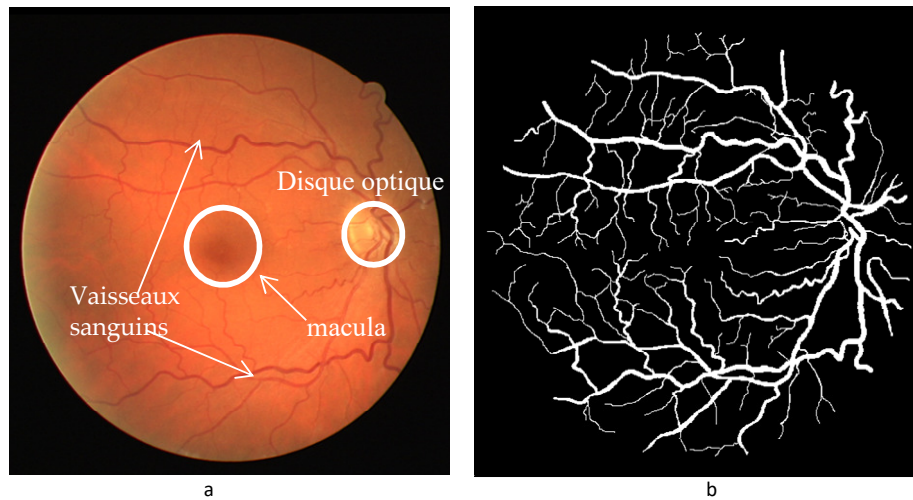


Figure1. Anatomie de la rétine : (a) image rétinienne, (b) image segmentée

outils de segmentation : Certains sont basés sur des Machine Learning à base d'extraction de caractéristique ou à base des architecture d'apprentissage profond, alors que d'autres sont formulés sans classificateurs. En outre, les travaux se différencient point de vue évaluation expérimentale : Certains méthodes utilisent des images des bases de données publiques, autres utilisent des images de bases des données privées. De même, les métriques d'évaluations utilisées par les méthodes de segmentation sont diversifiées. Certains travaux calculent ces performances en se basant sur les métriques telles que « l'Accuracy, Sensitivity, Specificity, Area Under Curve » [3, 2, 4]. D'autres, ont utilisé plus d'autres métriques telles que « Matthews's Correlation Coefficient (MCC) ; Kappa » [5, 6].

Un premier travail qui propose un état de l'art sur les approches de segmentation des vaisseaux sanguins de l'image de fond d'œil a été proposé par [7]. Ce travail répartit les approches de segmentation des vaisseaux rétiens selon les techniques de traitement utilisés: machine Learning supervisée et non supervisée, les filtres, les opérateurs morphologiques, etc. De plus, [7] a proposé une classification des approches qui implémentent la segmentation des vaisseaux rétinienne en utilisant des architectures parallèles. En outre, [7] a décrit les bases des données utilisés pour l'évaluation des méthodes, ainsi que leurs caractéristiques pathologiques.

Un autre travail est proposé par [8] décrivent les approches de segmentation des vaisseaux pour différents organes tel que le cerveau, le cœur, le poumon, le foie, la rétine, etc. L'étude évoquent des méthodes de segmentations des vaisseaux pour différents types d'images tel que: ARM (magnetic resonance angiography), images tridimensionnelles, image de fond d'œil, etc. De plus, [8] a proposé un workflow qui décrit les étapes principales de traitement de segmentation des vaisseaux sanguins, en proposant des répartitions des travaux en fonction des techniques de traitement d'images employées par les méthodes de segmentation : « Vessel enhancement ; Machine learning ; Deformable models ; Tracking ». Les deux travaux [8 ,7] ont critiqué l'utilisation des images de grande résolution en donnant comme raisons la possibilité d'augmenter le taux de faux positif et le temps de calcul.

L'objectif de ce travail est de proposer un état de l'art sur les méthodes de segmentation des vaisseaux sanguins rétiens. Ce travail se distingue par la prise en considération des caractéristiques utilisées par les méthodes à base de ML ainsi que les performances proposées par les méthodes de segmentation. Dans ce contexte, on procède à :

- Proposer une classification des méthodes de segmentation en se basant sur les techniques de traitement mise en pratique : un classement des méthodes qui sont basées sur ML à base d'extraction de caractéristiques ou à base des architectures d'apprentissage profond et un autre classement des méthodes qui génère la segmentation sans classificateur.
- Proposer un workflow qui décrit les étapes principales de traitement évoquées par les méthodes de segmentation.
- Evaluer les performances des méthodes de segmentation en fonction des classifications.

Ce papier est structuré en deux sections. La deuxième section consiste à définir le principe des méthodes de segmentation en proposant un workflow. De plus, on procède de classer les méthodes de segmentation en décrivant leur contribution. Dans la section suivante, on procède d'évaluer les méthodes de segmentation en fonction de catégories.

II. méthodes de segmentation automatique de l'AV:

1. Principe de segmentation :

Les méthodes de segmentation sont généralement composées de trois phases principales : prétraitement, segmentation et post-traitement. Les étapes de prétraitement correspondent généralement à l'amélioration de la qualité de l'image, l'élimination du bruit et la transformation de l'image à la forme adéquate. Les principaux traitements fréquemment utilisés sont : La conversion de RGB en niveau de gris [9,11], la correction de la luminosité [12,13], l'égalisation du contraste [4,9,14, 1,2,5,15,18] et l'élimination du bruit [1,5,12,19]. Les phases de segmentations durant lesquelles des techniques et des outils sont utilisées. Certaines méthodes ont utilisé la machine Learning et d'autres ont effectué la segmentation sans recours au machine Learning (sous la forme d'une chaîne de traitement à base des filtres et des opérateurs morphologiques), telles que indiquées dans la figure 3. Le post-traitement consiste généralement à une amélioration du résultat de segmentation des vaisseaux.

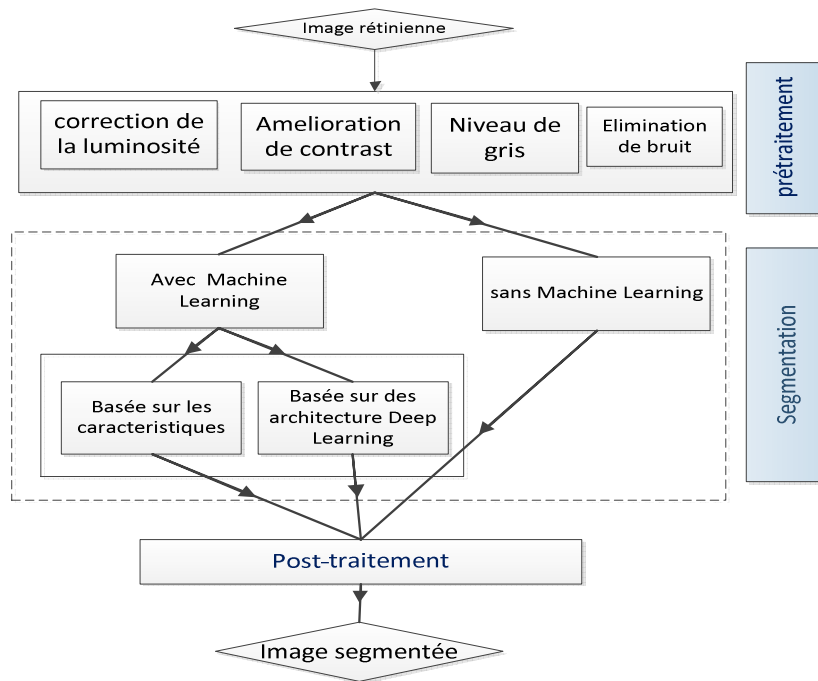


Figure2. Vessels segmentation workflow

2. Méthodes de segmentation sans Machine Learning

La méthode proposée par [15] est initialisée par un prétraitement dans le but rehausser la clarté des vaisseaux. Une première étape consiste à générer une image « IG » après l'extraction de la composante verte et l'élimination du contour noir en dehors de la rétine en utilisant l'algorithme « Otsu thresholding ». Une deuxième étape consiste à générer une image « IB » après l'élimination des régions bruitées en appliquant les opérations morphologiques « opening » et « closing » et l'amélioration de la luminosité de la rétine le filtre médian. Le résultat final du prétraitement est dégagé en soustrayant « IB » de « IG ». Le principe de la segmentation est basé l'épaisseur des vaisseaux et leurs orientations. Dans ce contexte, l'algorithme « Morphological Component Analysis » est appliquée pour séparer les vaisseaux des lésions qui produisent un élargissement des vaisseaux. Cet algorithme prend en compte les caractéristiques des vaisseaux et des lésions pour les représenter respectivement sous une forme linéaire courbée une forme pointillée. Ces caractéristiques des vaisseaux et des lésions sont formulés respectivement par les techniques « Non-Subsampled Shearlet Transform » et « non subsampled contourlet transform ». Par la suite, l'image inversée de « IG » est utilisée par le « Morlet-Wavelet transform » pour l'amélioration de la structure des vaisseaux. Ce dernier est appliqué dans différentes orientations qui varient entre 0 et 180 degrés avec un angle de pas égal à 20°. Cette méthode est achevée par un post-traitement afin de générer un arbre vasculaire binaire en utilisant l'algorithme de seuillage « Adaptive thresholding ».

Pour la méthode proposée par [11], le prétraitement est entamé par l'extraction de l'arrière-plan non uniforme en utilisant l'opération morphologique « top hat » qui est ensuite soustrait

de l'image originale dans l'objectif de d'éliminer le reflet et améliorer la luminosité. En outre, les filtres « black top hat » et « white top hat » sont appliqués respectivement sur l'arrière-plan claire et l'arrière-plan sombre. Par la suite, un traitement d'amélioration de contraste est développée en utilisant la méthode « Independent Component Analysis(ICA) » sur l'image , suivie par conversion de l'image en niveau de gris à l'aide de « Principal Component Analysis (PCA) ». Le principe de la segmentation est basé sur la continuité des vaisseaux. De ce fait, un traitement de vérification des continuités des vaisseaux est appliqué en utilisant le filtre « Second-order Multi-Scale Laplacian of Gaussian detector » qui prend comme paramètre la longueur, l'épaisseur et l'orientation des vaisseaux. Le noyau de ce filtre est pivoté dans des orientations spécifique, que la sortie orienté est multiplié par la longueur et l'épaisseur. De même, le filtre « anisotropic oriented diffusion filtering » est appliquée pour maintenir la formulation des vaisseaux minces. L'arbre vasculaire binaire est obtenu en appliquant la technique « diffusion binarization ». Finalement, un post-traitement est proposé qui consiste à utiliser le « flood-filled morphological reconstruction » afin d'aboutir à un résultat de segmentation sans absence des vaisseaux minces.

La méthode proposée par [10] est débuté par une phase de prétraitement dans le but d'améliorer le contraste des vaisseaux. Cette étape consiste à l'extraction de la composante verte suivie par une correction de la luminosité en utilisant le B-spline et l'égalisation de contraste en utilisant « multiplicative illumination model ». Par la suite, les auteurs procèdent à segmenter les vaisseaux en se basant sur la variation de leurs épaisseurs et leurs orientations dans la rétine en utilisant l'approche « Matched filtering MF ». Cinq filtres ont été utilisés pour extraire les vaisseaux en fonction des cinq largeurs de plus minces aux plus épais. Dans ce contexte, le filtre est appliqué avec cinq noyaux différents dont les tailles sont respectivement 14×14 , 22×22 , 24×24 , 26×26 et 32×32 . Ce traitement a pour objectif d'identifier les vaisseaux ayant des épaisseurs qui varient entre 5 et 22 pixels. Chaque noyau est appliqué à plusieurs reprises après des orientations qui varient entre 0 et 165 degrés avec un angle de pas égal à 15° . Par la suite, les résultats des images filtrées sont fusionnées et seuillée en utilisant la Kittler minimum error thresholding method » afin d'obtenir un arbre vasculaire binaire. Cette méthode est clôturée par un post-traitement pour éliminer les régions non connectée à l'arbre vasculaire rétinien en s'appuyant sur l'opérateur morphologique « morphological cleaning ».

La méthode de [5] est initialisée par une étape de prétraitement dans le but d'améliorer le contraste des vaisseaux. Cette étape consiste à l'extraction de la composante verte de l'image RGB, suivie par l'utilisation de l'algorithme CLAHE pour l'égalisation de contraste et le filtre médian pour l'élimination des bruits. La segmentation de l'arbre vasculaire rétinien est effectuée en utilisant le « mean-C thresholding », dont la valeur de threshold est calculée pour chaque pixel de l'image. Finalement, un post-traitement est proposé dans le but d'améliorer le résultat de segmentation par l'élimination des pixels isolés en utilisant l'opération morphologique « morphological cleaning ».

La méthode proposée par [16] est initialisée par un prétraitement pour l'amélioration de contraste des vaisseaux. Ce traitement consiste à la transformation de l'image RGB en niveau de gris en utilisant Principal Component Analysis (PCA) et l'utilisation de

l'algorithme CLAHE pour l'égalisation du contraste. La phase de segmentation consiste à extraire les vaisseaux dans différentes orientations dans la rétine. De ce fait, le filtre « Gumble Probability Distribution Function matched » est appliqué pour détecter les vaisseaux dans différentes directions. En outre, 12 noyaux de ce filtre de taille 15x15 sont appliqués à plusieurs reprises en appliquant à chaque fois une rotation de 15 ° pour la détection des vaisseaux dans différentes orientations. Par la suite, l'algorithme « Entropy based optimal thresholding » est utilisée pour produire un arbre vasculaire binaire. Finalement, un post-traitement est proposé qui consiste à utiliser le « length filtering » pour l'élimination des pixels isolés et non classés.

La méthode proposée par [12] est initialisée par une phase de prétraitement qui est élaborée en trois sous-traitements. Le premier consiste l'enlèvement de la ligne lumineuse centrale du vaisseau provoqué par la capture de l'image, en utilisant l'opération morphologique « Opening » sur la composante verte de l'image RGB. Le sous traitement suivant procède à l'élimination des bruits en utilisant le filtre médian et le filtre Gaussien. Le dernier sous traitement consiste l'amélioration de l'apparence des vaisseaux en utilisant la transformation Top Hat. La phase de segmentation des vaisseaux procède à identifier les segments linéaires des vaisseaux. De ce fait, les lignes des vaisseaux sont identifiées en utilisant l'algorithme « multi-scale line detection ». cet algorithme est appliqué avec différentes dimensions des sous images 3x3, 9x9 et 15x15, et en prenant en compte les lignes des vaisseaux ayant une longueur qui varient entre 3 et 6 pixels. Pour chaque longueur, les lignes identifiées sont soustraites des trois dimensions des sous images. Par la suite, un traitement de seuillage et de combinaison est développé. Dans ce propos, les lignes identifiées sont seuillé en utilisant des valeurs de seuil générés à partir des fonctions « grey thresholding », et ajoutés les uns aux autres en utilisant le « linear combination process ». Un post-traitement est proposé pour produire l'arbre vasculaire binaire. De ce fait, La sortie finale des lignes est ajoutée à l'image produite de la phase de prétraitement. Après le processus de combinaison, l'arbre vasculaire binaire est généré en ajustant la valeur du seuil correspondant.

La méthode proposée par [20] est initialisée par une étape de prétraitement qui correspond à une amélioration de la clarté de l'image et la détection des exudates. Cette étape est entamée par l'extraction de l'arrière-plan en appliquant des filtres médian de taille 69x69 et 139x139 et la soustraction de la composante verte de l'image originale. Le résultat est ensuite converti en niveau de gris suivie par une correction de la luminosité en utilisant le « linearly stretching ». L'image résultante est ensuite améliorée en modifiant l'intensité des pixels suivie par l'application de filtre médian pour la supprimer les bruits et un threshold pour obtenir le masque des exsudats. Suite à ce prétraitement, une phase de segmentation est proposée qui repose sur l'épaisseur des vaisseaux. Cette phase est débutée par l'application de l'algorithme « Neighbourhood Estimator Before Filling (NEBF) » pour la détection des régions des exudates. Cet algorithme procède d'appliquer itérativement le « threshold » et les opérateurs morphologiques « dilation » et « erosion ». Ensuite, l'opérateur « linear-opening-by-reconstruction » est utilisé pour éliminer les petites régions des exudats, en se basant sur leur faible contraste. Le traitement suivant consiste à appliquer l'algorithme « Multi scale Hessian Eigen value Analysis » qui repose sur l'amélioration des vaisseaux, en proposant une seule valeur propre adéquate pour les vaisseaux minces et les vaisseaux épais. Le dernier traitement repose sur l'utilisation de l'algorithme de seuillage « Percentile-Based

Thresholding » pour la génération de l'arbre vasculaire rétinien. Cette méthode est clôturée par un post-traitement qui repose sur l'élimination des composants de faible connectivité en appliquant le « Area thresholding ».

La méthode proposée par [15] est initialisée par un prétraitement qui consiste à l'extraction de la composante verte « GCI » de l'image RGB suivie par un traitement qui permet de déterminer la bordure de la rétine. La deuxième phase est la segmentation des vaisseaux selon leurs épaisseurs, dont deux images VEG et VEGW sont produites, que l'une permet d'extraire uniquement les vaisseaux larges et l'autre représente tous les vaisseaux. En premier lieu, le « Gabor Wavlet » est utilisé pour extraire les caractéristiques Gabor à partir de l'image GCI. En deuxième lieu, une chaîne de sous-traitements est appliquée séparément sur l'image caractéristique de Gabor pour l'extraction de tous les vaisseaux et l'image GCI pour l'identification des vaisseaux larges. Le premier sous-traitement consiste à l'égalisation du contraste en appliquant l'algorithme CLAHE. Ensuite, un sous-traitement qui consiste à la normalisation de l'arrière-plan est réalisé en soustrayant l'image moyenne produite par « mean kernel » de l'image à contraste égalisée. Par la suite, le contraste de l'image résultat est amélioré pour une meilleure formulation de la structure des vaisseaux. Les deux images résultantes sont seuillées en appliquant un seuillage automatique « Otsu thresholding ». En outre, les deux images résultats VEG et VE-GW sont différentes. Par la suite, les deux images binaires VEG et VE-GW sont combinées en utilisant l'opération logique « OR » pour produire tout un arbre vasculaire binaire. Cette méthode est finalisée par un post-traitement qui consiste à l'élimination des pixels de faibles connectivités en utilisant des opérations morphologiques et l'utilisation de filtre médian pour le lissage des vaisseaux. .

Pour la méthode proposée par [4], le prétraitement est initialisé par l'inversion de la composante verte de l'image RGB pour que les vaisseaux deviennent plus brillants, suivie par l'élimination de la région en dehors de la rétine en appliquant un masque sur l'image. Par la suite, la transformation morphologique top hat est utilisée pour améliorer l'apparition des vaisseaux dans l'image (T). La segmentation des vaisseaux est basée sur la variation de l'épaisseur des vaisseaux. Cette tâche est formulée par un algorithme itératif, dont chaque itération consiste à appliquer un seuillage sur l'image(T) pour l'extraction des larges vaisseaux et les éliminer de l'image (T). à chaque itération, la valeur de seuillage est réduite pour l'extraction des vaisseaux ayant des épaisseurs plus faibles. A chaque itération, les nouveaux vaisseaux extraits sont combinés avec les vaisseaux de l'itération précédente. Les traitements de cet algorithme s'arrêtent si les nouveaux vaisseaux identifiés sont déjà extraits depuis les itérations précédentes. Le post-traitement repose sur l'élimination des régions des vaisseaux moins que 20 pixels et l'application d'un filtre médian 3*3 sur les autres régions des vaisseaux.

La méthode proposée par [9] est initialisée par une phase de prétraitement qui consiste à remplacer le contour de la rétine par une couleur de fond, l'extraction de la composante verte et la transformation de l'image en image niveau de gris. La phase de la segmentation des vaisseaux est basée sur la variation de leurs épaisseurs. En outre, deux traitements sont exécutés simultanément qui correspondent à extraire respectivement les vaisseaux larges et les vaisseaux minces. De ce fait, la transformation top-hat est utilisée, suivie par

l'application de l'algorithme de seuillage « empirical threshold » pour produire une image binaire contenant les larges vaisseaux. Le deuxième traitement consiste à l'inversion de l'image résultante de la phase de prétraitement de prétraité. Par la suite, le « first-order derivative filter » est utilisée pour la détection des vaisseaux dans toutes les directions, dont l'image est pivoté dans 18 directions avec un angle de 10 degrés. Les résultats après chaque rotation sont combinés dans une seule image à fin de produire une couverture complète de toutes les directions des vaisseaux. Par la suite, les pixels de faible connectivité sont éliminés en examinant ses connectivités avec ses voisins. Le résultat de la phase de segmentation est abouti à travers la combinaison des vaisseaux épais et les vaisseaux minces en utilisant l'opération logique « OR ». Ainsi, un post-traitement de suppression des bruits est appliqué en utilisant l'opération morphologique « erosion ».

3. Méthodes à base de machine d'apprentissage

3.1. Méthode à base d'extraction de caractéristiques et apprentissage

La méthode proposée par [2] propose une méthode qui est initialisée par une étape de prétraitement qui consiste à appliquer l'algorithme CLAHE pour l'égalisation du contraste des vaisseaux. Par la suite, le classificateur « Random Forest RF » est appliquée qui intercepte un ensemble des propriétés pour chaque pixel qui représente des caractéristiques morphologiques des vaisseaux à fin de déterminer s'il correspond à un vaisseau ou non. Dès que les pixels sont classés, un seuillage est appliqué pour générer un arbre vasculaire binaire.

La méthode proposée par [21] est initialisée par un prétraitement qui consiste à l'extraction de la composante verte de l'image RGB. L'étape suivante est la segmentation qui, consiste à utiliser le classificateur « Extrem learning Machine ELM » pour classer les pixels en se basant sur un ensemble des caractéristiques qui représente des caractéristiques morphologique des vaisseaux. La méthode est finalisée par une phase de post traitement qui consiste à éliminer les régions isolées.

La méthode proposée par [14] est initialisée par un prétraitement qui consiste à l'extraction de la composante verte et l'application d'un masque dans le but d'égaliser le contraste de l'image I. La deuxième étape est l'extraction des vaisseaux épais en appliquant le filtre passe-haut et un seuillage sur l'image I et sauvegarde le résultat dans une image I'. Entre temps, la reconstruction Top Hat est appliquée sur l'image I et sauvegarde le résultat dans une image I''. Par la suite, Les régions communes entre I' et I'' sont extraites en tant que vaisseaux larges. Les pixels restants dans les deux images binaires sont combinés dans une sous image. Le classificateur « Gaussian Mixture Model GMM » est appliqué pour identifier les vaisseaux de faible dimension en utilisant un ensemble des caractéristiques. Ces derniers qui vont être combiné avec les larges vaisseaux.

[1] a proposé une méthode qui est initialisée par une phase de prétraitement qui commence par l'élimination des régions en dehors de la rétine, la conversion de l'image RGB en « YCbCr color space », « L*a*b color space » et « Gaussian color space ». Par la suite, l'algorithme CLAHE qui est pour l'égalisation du contraste des vaisseaux. Ensuite, le filtre gabor est utilisé pour améliorer l'image et le « half ware rectified » est appliqué pour prendre

en considération tous les vaisseaux dans la rétine. Par la suite, un traitement d'extraction des vaisseaux rétiens est effectué en deux étapes principales « Clustering » et « Classification ». Le « clustering » est effectué avec le classificateur « k-means » en donnant comme résultat deux classes « vaisseaux » et « non vaisseaux ». La « Classification » est développée en utilisant le classificateur « Decision Tree » qui intercepte un ensemble des paramètres. Ce traitement est pour fouiller la classe « non vaisseaux » et dégager les pixels mal classée et qui correspondent aux vaisseaux. Par la suite, les nouveaux vaisseaux classés sont combinée avec les pixels de la classe « vaisseau » pour obtenir un arbre vasculaire binaire. Cette méthode de segmentation se termine par une étape de post traitement qui consiste à appliquer le « mathematical morphology » et « connected component analysis » pour éliminer la bordure et les pixels isolés.

3.2. Méthode à base d'apprentissage profond :

la méthode de [18] commence par une étape de prétraitement qui consiste à l'extraction de la composante verte, la qualification d'histogramme et l'application de filtre Gaussien. Le but est de réduire le bruit, rendre l'intensité plus uniforme et améliorer le contraste des vaisseaux. L'étape suivante est la segmentation qui consiste à combiner trois classificateurs qui sont « Convolutional Neural Network CNN », « Random Forest RF » et « winner-takes-all ». Le premier est employé pour extraire l'ensemble des caractéristiques pour chaque pixel de façon hiérarchique (par couche). Ensuite, les propriétés de la même couche sont données comme entrée à un classificateur RF pour donner sa décision. Par la suite, le « winner-takes-all » prend comme entrée les sorties des RF et va proposer à son tour sa décision finale si le pixel correspond à un vaisseau ou non.

la méthode de [6] est basée sur des architectures Deep Learning. Cette approche est initialisée par un prétraitement afin d'améliorer la qualité de l'image en proposant une normalisation de contraste. Par la suite, ces images sont découpé en des patches de taille 27*27 qui sont augmenté par des transformations géométrique tel que la rotation et le retournement. Par la suite, ces patches sont injectés dans l'architecture proposée pour un processus d'apprentissage.

la méthode de [3] a proposé une méthode de segmentation des vaisseaux rétiens qui est basé sur l'architecture « the fully convolutional AlexNet ». Cette méthode commence par une étape de prétraitement qui consiste à remplacer le contour noir en dehors de la rétine par une couleur de fond et l'utilisation du filtre gaussien. Par la suite, un traitement de répartition de l'image en sous images de taille 50*50 est effectué. Par la suite, ces sous images vont être agrandie en taille 500*500. L'architecture utilisée prend comme entrée les sous images en RGB et donne comme sortie des sous images binaires. Par la suite, les sous images binaires vont être fusionnées pour construire une seule image binaire, où chaque sous images correspond à un numéro de référence pour identifier son appartenance et son emplacement exacte dans l'image. Cette méthode achève par une étape de post-traitement qui consiste à éliminer les bruit du à la fusion et recouvrement de l'image.

La méthode proposée par [22] est initialisée par une étape de prétraitement qui consiste à une application de Contrast Limited Adaptive Histogram Equalization [52] (CLAHE) pour

l'amélioration du contraste suivie par l'application de gamma correction. Par la suite ces images sont découpées en des patches de taille 48*48 et 96*96 pour les images de haute résolution. La segmentation des vaisseaux consiste à injecter les patches dans une architecture proposée intitulée «D-U-Net». Cette architecture correspond à la même conception de U-Net, cependant les blocs de convolution d'U-Net ont été remplacés par des blocs de convolution déformables.

La méthode proposée par [23] est initialisée par une étape de prétraitement qui consiste à une conversion de l'image au niveau de gris suivie par une normalisation des données. Par la suite, les images sont découpées en des patches de taille 48*48. La phase de segmentation consiste à une injection des patches dans l'architecture proposée Dense-Unet. Cette architecture correspond à la même conception qu'U-net dont les blocs de convolution et les couches de pooling sont remplacées par des denses blocks et des couches de transition.

III. Evaluation expérimentale des méthodes de segmentation de l'arbre vasculaire rétinienne:

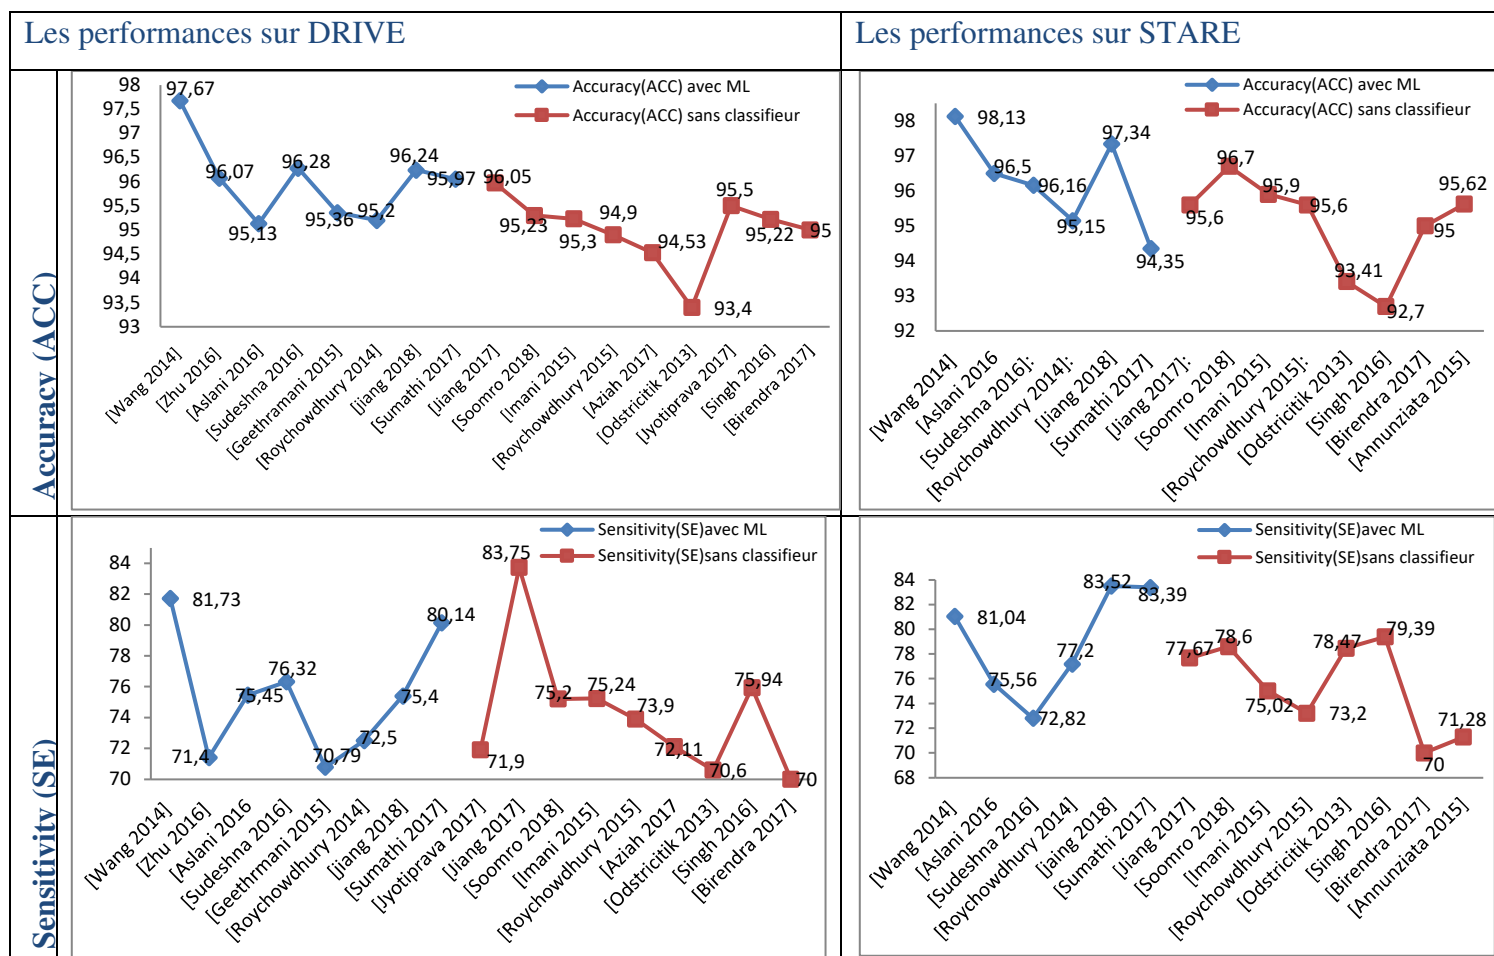
L'évaluation expérimentale des méthodes de segmentation des vaisseaux rétinienne consiste à calculer les performances à partir des images segmentées. La plus part des méthodes de segmentations ont utilisé les images des bases des données publiques DRIVE et STARE pour évaluer leurs performances, en calculant un ensemble des métriques tel que définie dans le tableau 1 et en les comparant avec d'autres travaux existants. Les bases des données DRIVE et STARE sont capturées par des angles FOV respectivement de 45° et 35°, dont leur résolution correspond respectivement à 768* 584 et 650*500. La base de données DRIVE comporte 40 images dont 7 images pathologiques avec les signes de la rétinopathie diabétique non prolifératif. STARE contient 81 images dont 51 sont infectées par la rétinopathie diabétique non prolifératif.

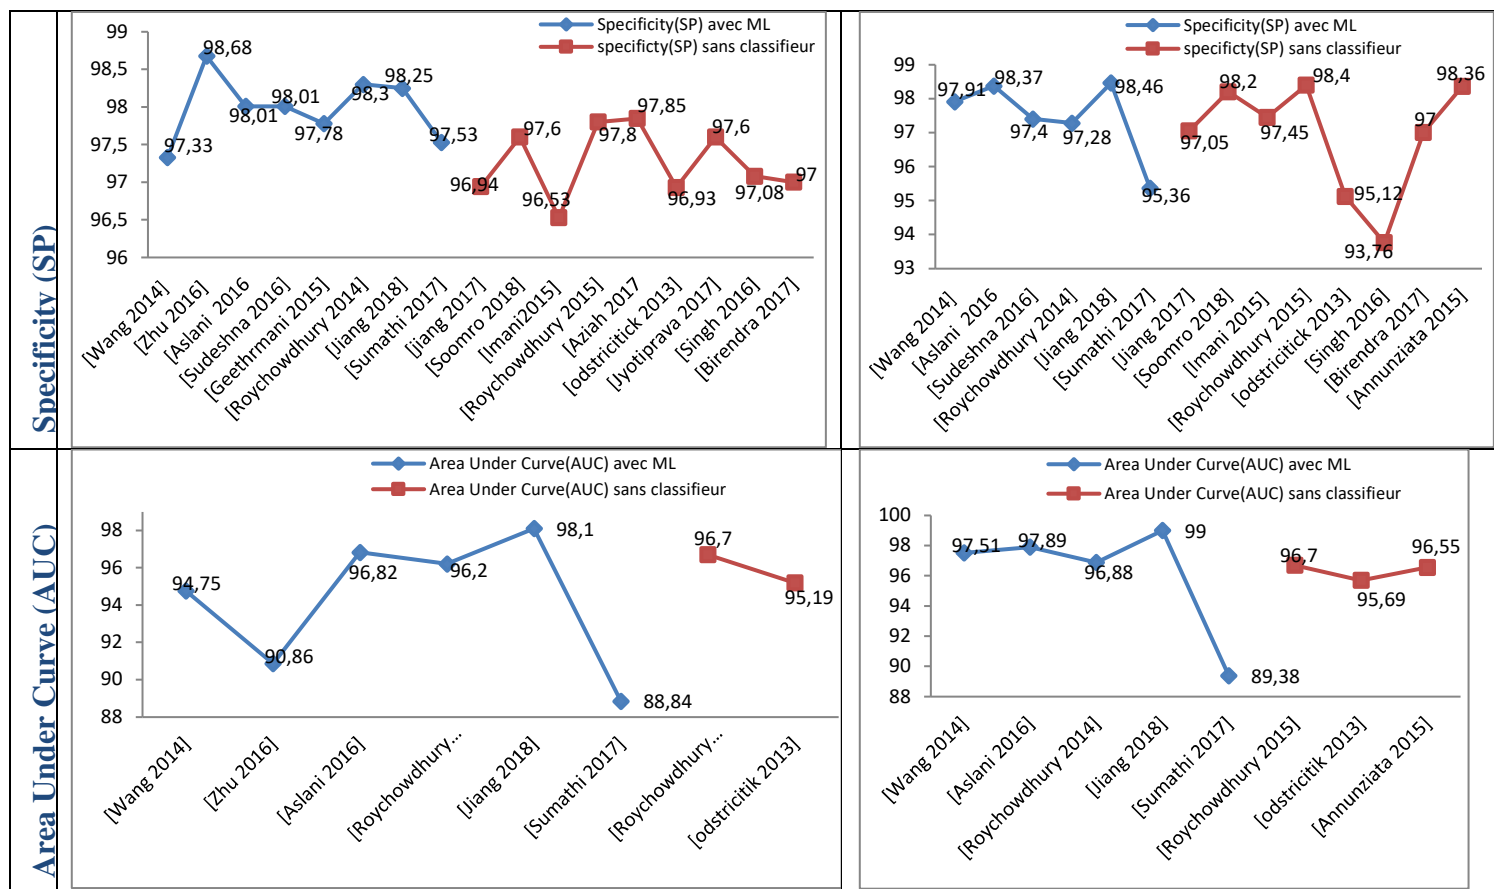
Tableau 1. Mesures de performance pour la segmentation des vaisseaux rétiniens

Métriques	Description
Sensitivity (SE)	$TPR / (TPR+FNR)$ où TPR
Specificity (SP)	$TNR / (TNR+FPR)$ où 1-FPR
Accuracy (ACC)	$(TNR+TPR)/(TPR+FPR+TNR+FNR)$ où $TPR + FPR/FOV$ pixel count
Area Under Curve(AUC)	Area under the ROC curve.
Matthews's Correlation Coefficient (MCC)	$(TNR*TPR-FPR*FNR)/\sqrt{(TPR+FPR)*(TPR+FNR)*(TNR+FPR)*(TNR+FNR)}$
False Discovery Rate (FDR)	$FPR/(FPR+TPR)$
Positive Predictive Value (PPV)	$TPR/(TPR+FPR)$
Negative Predictive Value (NPV)	$TNR/(TNR+FNR)$
Kappa	$(ACC-ACC_r) / (1-ACC_r)$
Precision (Pr)	$Pr = TP / (TP + FP)$
F1-score	$2*Pr*SE / (Pr + SE)$
G-mean	$\sqrt{SE*SP}$

1. Evaluation des méthodes avec ML et sans ML :

On procède dans cette session d'évaluer les méthodes avec Machine Learning et sans classificateur en se basant sur des bases des données et des métriques communs. Le but, est de déterminer la corrélation entre les familles et les performances données. Les figures suivantes montrent les performances des métriques ACC, SE, SP, AUC (illustrées en ligne) de ces deux famille (modélisées respectivement par les courbes bleu et rouge) sur les base des données DRIVE et STARE (illustrées en colonne) :





Pour le métrique Accuracy(ACC), les méthodes à base de ML proposent des performances qui varient entre 95% et 97% sur DRIVE et entre 94% et 98% sur STARE. Cependant, les performances des méthodes sans classificateurs varient entre 93% et 96% sur DRIVE et entre 92% et 96% sur STARE. Concernant la sensibilité (SE), les méthodes avec ML ont proposé des performances sur STARE qui varient entre 72% et 83%, alors que les performances des méthodes de l'autre catégorie varient entre 70% et 79%. Concernant la base de données DRIVE, on a constaté que les performances sont voisines. D'après la représentation de Spécificité (SP) sur DRIVE, les méthodes avec ML offrent des performances qui varient entre 97% et 98%, alors que les performances des autres varient entre 96% et 97%. Concernant la base de données STARE, on a constaté que les performances sont similaires. Pour l'Area Under Curve (AUC), les performances proposées par les méthodes avec et sans ML sont proches. Par conséquent, on peut déduire que les méthodes à base de Machine Learning ont engendré des performances plus hautes que les méthodes qui ne font pas recours aux classificateurs.

Conclusion :

La segmentation des vaisseaux sanguins rétiniens présente un élément fondamental pour les systèmes d'aide au diagnostic des différentes pathologies oculaires. La littérature proposée présente un état de l'art sur les méthodes de segmentation des vaisseaux sanguins rétiniens dans des images de fond d'œil.

De ce faite, une variété des méthodes de segmentation des vaisseaux rétiniennes ont été développées. Ces méthodes se différencient selon les techniques mises en pratique pour la segmentation des vaisseaux. Certaines, sont basées sur Machine Learning à base d'extraction des caractéristiques et à base de l'architecture d'apprentissage profond, alors que d'autres sont développées sans recours aux classificateurs. En outre, les méthodes de segmentation sont toujours initialisées par une étape de prétraitement qui consiste généralement à une amélioration de l'image entrante. Suivie par une phase de segmentation et achevée par un post-traitement qui consiste à améliorer le résultat de segmentation.

De plus, il y a une diversité des bases de données utilisées pour l'évaluation expérimentale des méthodes de segmentation telles que DRIVE, STARE, MESSIDOR.... Cependant, la plupart des méthodes n'ont été évaluées que sur DRIVE et STARE en s'appuyant sur les métriques suivantes : Accuracy(ACC), Sensitivity(SE), Specificity(SP) et Area Under Curve(AUC). Dans ce contexte, on a proposé une classification des méthodes selon la technique mise en pratique pour la segmentation : les méthodes à base des machines Learning et les méthodes qui sont développées sans classificateur. Autre on procède d'évaluer les performances des méthodes en fonction de ces répartitions. Le but est de déterminer la corrélation entre les répartitions et les performances de détection proposées. En outre, on a constaté que les méthodes qui sont basées sur machine Learning sont plus performantes que les méthodes qui sont développées sans classificateurs.

Reference :

1. R. GeethaRamani and L. Balasubramanian, "Retinal blood vessel segmentation employing image processing and data mining techniques for computerized retinal image analysis," *Biocybernetics and Biomedical Engineering*, vol. 36, no. 1, pp. 102–118, Jan. 2016, doi: 10.1016/j.bbe.2015.06.004.
2. S. Aslani and H. Sarnel, "A new supervised retinal vessel segmentation method based on robust hybrid features," *Biomedical Signal Processing and Control*, vol. 30, pp. 1–12, Sep. 2016, doi: 10.1016/j.bspc.2016.05.006.
3. Z. Jiang, H. Zhang, Y. Wang, and S.-B. Ko, "Retinal blood vessel segmentation using fully convolutional network with transfer learning," *Computerized Medical Imaging and Graphics*, vol. 68, pp. 1–15, Sep. 2018, doi: 10.1016/j.compmedimag.2018.04.005.
4. S. Roychowdhury, D. D. Koozekanani, and K. K. Parhi, "Iterative Vessel Segmentation of Fundus Images," *IEEE Transactions on Biomedical Engineering*, vol. 62, no. 7, pp. 1738–1749, Jul. 2015, doi: 10.1109/TBME.2015.2403295.
5. J. Dash and N. Bhoi, "A thresholding based technique to extract retinal blood vessels from fundus images," *Future Computing and Informatics Journal*, vol. 2, no. 2, pp. 103–109, Dec. 2017, doi: 10.1016/j.fcij.2017.10.001.
6. P. Liskowski and K. Krawiec, "Segmenting Retinal Blood Vessels With Deep Neural Networks," *IEEE Transactions on Medical Imaging*, vol. 35, no. 11, pp. 2369–2380, Nov. 2016, doi: 10.1109/TMI.2016.2546227.
7. M. M. Fraz *et al.*, "Blood vessel segmentation methodologies in retinal images – A survey," *Computer Methods and Programs in Biomedicine*, vol. 108, no. 1, pp. 407–433, Oct. 2012, doi: 10.1016/j.cmpb.2012.03.009.
8. S. Moccia, E. De Momi, S. El Hadji, and L. S. Mattos, "Blood vessel segmentation algorithms — Review of methods, datasets and evaluation metrics," *Computer Methods and Programs in Biomedicine*, vol. 158, pp. 71–91, May 2018, doi: 10.1016/j.cmpb.2018.02.001.
9. Z. Jiang, J. Yezpez, S. An, and S. Ko, "Fast, accurate and robust retinal vessel segmentation system," *Biocybernetics and Biomedical Engineering*, vol. 37, no. 3, pp. 412–421, Jan. 2017, doi: 10.1016/j.bbe.2017.04.001.
10. J. Odstroicilik *et al.*, "Retinal vessel segmentation by improved matched filtering: evaluation on a new high-resolution fundus image database," *IET Image Processing*, vol. 7, no. 4, pp. 373–383, Jun. 2013, doi: 10.1049/iet-ipr.2012.0455.
11. T. A. Soomro, T. M. Khan, M. A. U. Khan, J. Gao, M. Paul, and L. Zheng, "Impact of ICA-Based Image Enhancement Technique on Retinal Blood Vessels Segmentation," *IEEE Access*, vol. 6, pp. 3524–3538, 2018, doi: 10.1109/ACCESS.2018.2794463.
12. B. Biswal, T. Pooja, and N. Bala Subrahmanyam, "Robust retinal blood vessel segmentation using line detectors with multiple masks," *IET Image Processing*, vol. 12, no. 3, pp. 389–399, 2018, doi: 10.1049/iet-ipr.2017.0329.
13. E. Imani, M. Javidi, and H.-R. Pourreza, "Improvement of retinal blood vessel detection using morphological component analysis," *Computer Methods and Programs in Biomedicine*, vol. 118, no. 3, pp. 263–279, Mar. 2015, doi: 10.1016/j.cmpb.2015.01.004.
14. S. Roychowdhury, D. D. Koozekanani, and K. K. Parhi, "Blood Vessel Segmentation of Fundus Images by Major Vessel Extraction and Subimage Classification," *IEEE Journal of Biomedical and Health Informatics*, vol. 19, no. 3, pp. 1118–1128, May 2015, doi: 10.1109/JBHI.2014.2335617.

15. A. Ali, A. Hussain, and W. M. D. Wan Zaki, "Vessel extraction in retinal images using automatic thresholding and Gabor Wavelet," in *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Jul. 2017, pp. 365–368, doi: 10.1109/EMBC.2017.8036838.
16. N. P. Singh and R. Srivastava, "Retinal blood vessels segmentation by using Gumbel probability distribution function based matched filter," *Comput Methods Programs Biomed.*, vol. 129, pp. 40–50, Jun. 2016, doi: 10.1016/j.cmpb.2016.03.001.
17. S. Thangaraj, V. Periyasamy, and R. Balaji, "Retinal vessel segmentation using neural network," *IET Image Processing*, vol. 12, no. 5, pp. 669–678, 2018, doi: 10.1049/iet-ipr.2017.0284.
18. S. Wang, Y. Yin, G. Cao, B. Wei, Y. Zheng, and G. Yang, "Hierarchical retinal blood vessel segmentation based on feature and ensemble learning," *Neurocomputing*, vol. 149, pp. 708–717, Feb. 2015, doi: 10.1016/j.neucom.2014.07.059.
19. S. Sil Kar and S. P. Maity, "Retinal blood vessel extraction using tunable bandpass filter and fuzzy conditional entropy," *Computer Methods and Programs in Biomedicine*, vol. 133, pp. 111–132, Sep. 2016, doi: 10.1016/j.cmpb.2016.05.015.
20. R. Annunziata, A. Garzelli, L. Ballerini, A. Mecocci, and E. Trucco, "Leveraging Multiscale Hessian-Based Enhancement With a Novel Exudate Inpainting Technique for Retinal Vessel Segmentation," *IEEE Journal of Biomedical and Health Informatics*, vol. 20, no. 4, pp. 1129–1138, Jul. 2016, doi: 10.1109/JBHI.2015.2440091.
21. C. Zhu *et al.*, "Retinal vessel segmentation in colour fundus images using Extreme Learning Machine," *Computerized Medical Imaging and Graphics*, vol. 55, pp. 68–77, Jan. 2017, doi: 10.1016/j.compmedimag.2016.05.004.
22. Q. Jin, Z. Meng, T. D. Pham, Q. Chen, L. Wei, and R. Su, "DUNet: A deformable network for retinal vessel segmentation," *Knowledge-Based Systems*, vol. 178, pp. 149–162, Aug. 2019, doi: 10.1016/j.knosys.2019.04.025.
23. C. Wang, Z. Zhao, Q. Ren, Y. Xu, and Y. Yu, "Dense U-net Based on Patch-Based Learning for Retinal Vessel Segmentation," *Entropy*, vol. 21, p. 168, Feb. 2019, doi: 10.3390/e21020168.