

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique  
Université Mohamed Khider – BISKRA  
Faculté des Sciences Exactes et des Sciences de la Nature et de la Vie  
Département d'informatique

N° d'ordre : .....



## THÈSE

Présentée en vue de l'obtention du diplôme de  
Doctorat LMD en Informatique

**Option :** Sciences et techniques de l'image

**Titre**

---

# Apprentissage et optimisation intelligente pour une segmentation robuste d'image

---

Par

**Bilal Khomri**

Soutenue le : 10 / 01/2019

**Devant le jury:**

Pr. Cherif Foudil	Université de Biskra	Président
Pr. Babahenini Mohamed Chaouki	Université de Biskra	Rapporteur
Dr. Djerou Leila	Université de Biskra	Co-Rapporteur
Pr. Melkemi Kamal Eddine	Université de Batna 2	Examineur
Pr. Abdelouahab Moussaoui	Université Ferhat Abbas Sétif 1	Examineur

## **DÉDICACES**

Je dédie ce travail à toute ma famille et mes amis pour leur soutien tout au long de mon parcours universitaire

## REMERCIEMENTS

En premier lieu, je remercie le bon Dieu de m'avoir donné le courage, la puissance, et la patience pour achever ce travail de thèse.

Je tiens à remercier mon directeur de thèse monsieur Pr. Babahenini Mohamed Chaouki de m'avoir accueilli au sein de son équipe pour réaliser ma thèse ainsi que pour sa disponibilité et son soutien.

Je tiens à remercier particulièrement Dr. Djerou Leila ma Co-encadreur pour m'avoir bien suivi durant mon travail, et surtout pour ses conseils, et ses remarques constructives qui m'ont permis d'améliorer et réaliser l'objectif de ce travail.

Je remercie également Pr. Cheriet Farida qui m'a supervisé durant mes stages courts et longues durées au sein du laboratoire LIV4D, Université Polytechnique de Montréal, Canada. Ainsi, que le temps et l'intérêt qu'elle a bien voulu me témoigner. J'ai pu apprendre beaucoup grâce à elle, et j'ai surtout été conforté dans mon projet de recherche, ce qui est un aboutissement de mon cursus universitaire.

Je veux également remercier tous les membres de jury : Pr. Cherif Foudil, Professeur à l'Université de Biskra, pour m'avoir fait l'honneur de présider mon jury de thèse, ainsi que Pr. Melkemi Kamal Eddine, et Pr. Abdelouahab Moussaoui, pour m'avoir fait l'honneur d'accepter de juger ce travail.

Je souhaite également exprimer ma reconnaissance envers tous les membres du LIV4D, pour m'avoir accueilli chaleureusement, et pour toutes les conversations scientifiques que l'on a pu avoir. Un grand merci à Dr. Argyrios Christodoulidis pour m'avoir aidé à surmonter plusieurs difficultés.

Je tiens aussi à remercier toute ma promotion de doctorat et tous mes collègues de laboratoire LESIA. Enfin je tiens à remercier tous ceux et celles qui m'ont aidé et soutenu de près ou de loin dans l'accomplissement de cette thèse.

## RESUME

Ce travail de thèse s'inscrit dans le domaine de segmentation d'image et s'intéresse de façon particulière au problème de la segmentation de l'image rétinienne qui consiste à l'extraction automatique des structures anatomiques et pathologiques comme les vaisseaux sanguins. Ceux-ci sont de bons indicateurs de la santé de la rétine et leur segmentation peut également aider à détecter les lésions rouges, indicatrices de la rétinopathie diabétique.

Malgré l'abondance des travaux dans ce domaine et les progrès récents dans la technologie d'acquisition de ces images, le problème de la détection des vaisseaux reste très compliqué. En effet, les images obtenues peuvent souffrir de problèmes d'illumination non uniformes, ce qui amène à une mauvaise définition des bords de vaisseaux et une interruption de la connexité du réseau vasculaire, rendant ainsi l'apparition des petits vaisseaux très faibles par rapport à la région de fond adjacente. C'est pourquoi que le fait de s'orienter vers les techniques d'apprentissage et d'optimisation intelligente est très important, ceci permettra de proposer une segmentation robuste qui améliore la détection des vaisseaux sanguins et atténué le problème de la complexité de calcul.

Dans ce contexte, notre contribution prend deux formes: la première consiste en l'exploitation de la flexibilité et la puissance de l'algorithme Elite-guided Multi-Objective Artificial Bee Colony (EMOABC) pour proposer une méthode de segmentation par seuillage, rapide et sensible au contexte des images rétiniennes, et permettant d'optimiser simultanément plusieurs critères de segmentation. Cela pourrait améliorer la robustesse vis-à-vis des différents artefacts contenus dans les images rétiniennes. La deuxième consiste à exploiter la puissance de la technique d'optimisation par essaims de particulaires (PSO) pour trouver la meilleure disposition des échelles de la méthode Multi-Scale Line Detection (MSLD), et aussi gérer le problème de la recombinaison de réponse en échelle, ce qui permet de traiter le problème de la détection de vaisseaux de diamètres différents dans les images de fond d'œil de basse et de haute résolution. L'intégration de la méthode proposée dans un système Computer-Aided Diagnosis (CAD) pour le dépistage de la rétinopathie diabétique permettrait de réduire les faux positifs due à de petits vaisseaux manqués, mal classés en lésions rouges. Pour montrer l'efficacité des méthodes proposées par rapport aux travaux reportés dans l'état de l'art, des études expérimentales sont faites, sur des différentes bases d'images rétiniennes (basse et haute résolution) utilisées dans le test.

**Mots clés :** Segmentation d'image, Image de la rétine, Segmentation des vaisseaux sanguins, Méta-heuristique d'optimisation, Optimisation multi-objectif.

## ABSTRACT

This thesis work is part of the field of image segmentation and is particularly interested in the problem of retinal image segmentation which consists of the automatic extraction of anatomical and pathological structures such as blood vessels. These are good indicators of retinal health and their segmentation can also help detect red lesions, indicative of diabetic retinopathy.

Despite the abundance of researches in this field and the recent progress in the technology of acquisition of these images, the problem of detection of vessels remains very complex, the images obtained can suffer from non-uniform illumination problems, which leads to poor vessel border definition and interruption of vascular network connectivity. This can also make the appearance of small vessels very weak compared to the adjacent bottom region. Hence the idea of moving towards learning techniques and intelligent optimization is very important, to propose a robust segmentation that improves the detection of blood vessels and alleviates the problem of computational complexity.

In this context, our contribution takes two forms: the first contribution consists of exploiting the flexibility and the power of the Elite-guided Multi-Objective Artificial Bee Colony (EMOABC) algorithm to propose a fast and context-sensitive segmentation by thresholding method for retinal images, that allows the optimization of several segmentation criteria simultaneously. This could improve the robustness against the different artifacts contained in the retinal images. The second consists of exploiting the power of the Particle Swarm Optimization (PSO) technique to find the best scales arrangement of the Multi-Scale Line Detection (MSLD) method. Also, it manages the problem of scale response recombination, which allows to deal with the problem of the detection of vessels of different diameters in low and high resolution on fundus images. The integration of the proposed method into a Computer-Aided Diagnosis (CAD) system for the screening of diabetic retinopathy would reduce false positives due to small missed vessels, poorly classified as red lesions. To show the effectiveness of the proposed methods compared to the methods reported in the state of the art, experimental studies are made, on different bases of retinal images (low and high resolution) used in the test.

**Key words:** Image segmentation, Retinal image, Blood vessel segmentation, Meta-heuristic optimization, Multi-objective optimization.

## ملخص

هذا العمل هو جزء من مجال تجزئة صورة، ويتم بشكل خاص بمشكلة تجزئة صورة الشبكية والتي تنطوي على الاستخراج التلقائي للهياكل التشريحية والمرضية مثل الأوعية الدموية، والتي هي مؤشرات جيدة لصحة الشبكية ويمكن أن يساعد تقسيمها أيضًا في الكشف عن الآفات الحمراء التي تشير إلى اعتلال الشبكية بسبب السكري.

على الرغم من وفرة الاعمال في هذا المجال والتقدم الأخير في تكنولوجيا الحصول على صور الشبكية، فإن مشكلة استخراج الأوعية لا تزال معقدة للغاية، الصور التي يتم الحصول عليها قد تعاني من مشاكل الإضاءة غير المنتظمة، مما يؤدي إلى تعريف ضعيف لحواف الأوعية و انقطاع اتصال شبكة الأوعية الدموية، كما يجعل مظهر الأوعية الصغيرة ضعيفًا جدًا مقارنة مع المنطقة الخلفية المجاورة. ومن هنا جاءت فكرة التوجه نحو تقنيات التعلم والتحسين الذكي، لتقديم تجزئة قوية تعمل على تحسين الكشف عن الأوعية الدموية والتخفيف من مشكلة التعقيد الحسابي.

في هذا السياق، تأخذ مساهمتنا شكلين: الأول يتمثل في مرونة وقوة خوارزمية مستعمرة النحل الاصطناعي (EMOABC) لاقتراح طريقة تجزئة سريعة ومراعية للسياق صور الشبكية، والذي يسمح بتحسين عدة معايير للتجزئة في وقت واحد. مما يحسن من شدة الدقة في مقابل الآفات المختلفة الموجودة في صور الشبكية. في مساهمتنا الثانية، تتمثل الطريقة المقترحة في تسخير قوة أسلوب تحسين سرب الحسيمات للعثور على أفضل ترتيب على مستوى طريقة MSLD. وأيضا التعامل مع مشكلة إعادة تركيب مقياس الاستجابة. مما يجعل من الممكن التعامل مع مشكلة الكشف عن الأوعية بأقطار مختلفة في صور شبكية العين المنخفضة والعالية الدقة. إن دمج الطريقة المقترحة في نظام CAD لفحص اعتلال الشبكية بسبب السكري من شأنه أن يقلل من الإيجابيات الكاذبة بسبب الأوعية الصغيرة المفقودة، والتي تصنف بشكل سيء على أنها آفات حمراء. لإظهار فعالية الطرق المقترحة مقارنة بالطرق المستخدمة في أحدث ما توصلت إليه الدراسات التجريبية، تم الدراسات التجريبية على صور مختلفة للشبكية (منخفضة وعالية الدقة).

**الكلمات المفتاحية:** تجزئة الصورة، صورة شبكية العين، تجزئة الأوعية الدموية، العشوائية لتحسين، التحسين المتعدد الأهداف.

## **PUBLICATIONS ET COMMUNICATIONS**

Les publications et les communications relatives à cette thèse sont les suivantes :

### **1. Revues Internationales**

1. Khomri, Bilal, et al. "Particle swarm optimization method for small retinal vessels detection on multiresolution fundus images." *SPIE Journal of biomedical optics*, vol. 23(5), (2018): 056004.
2. Khomri Bilal, et al, "Retinal blood vessel segmentation using the elite-guided multi-objective artificial bee colony algorithm ", *IET Image Processing* (2018), vol. 12(12), pp. 2163-2171.

### **2. Conférences Internationales**

1. Khomri, Bilal, et al. "Particle Swarm Optimization Approach for the Segmentation of Retinal Vessels from Fundus Images". In: *International Conference Image Analysis and Recognition*. Montréal, Canada. Springer, Cham, 2017. p. 551-558.
2. Khomri, Bilal, et al. "Automatic Histogram Thresholds using Multi-objective Bacterial Foraging Optimization". In *International Conference on Metaheuristics and Nature Inspired Computing, META 2014, Marrackech, Morocco*. p. 101-102.

### **3. Conférences Nationales**

1. Khomri, Bilal, et al. "Image Thresholding Based on Pareto Multi-objective Bacterial Foraging and Health Sorting Approach" *Séminaire Nationale en Informatique, Biskra (SNIB'15), Le 20-22 Janvier 2015, Algérie*.
2. Khomri, Bilal, et al. "Apprentissage et optimisation intelligente pour une segmentation robuste d'image" *2ème Workshop Image Graphique et Vie Artificielle, Biskra (IGVA'2014), Le 08-10 juin 2014, Algérie*.

# TABLE DES MATIERES

## Chapitre 1 : Introduction générale

I.1 Introduction.....	1
I.2 Motivation.....	1
I.3 Description de la problématique de recherche.....	2
I.4 Contributions de la recherche .....	3
I.5 Organisation de la thèse .....	4

## Chapitre 2 : Segmentation d'image par les métaheuristiques d'optimisation

II.1 Introduction .....	5
II.2 Améliorations des méthodes de segmentation d'image par les métaheuristiques d'optimisation mono-objectif .....	5
II.2.1 Méthodes de segmentation par seuillage .....	5
II.2.2 Méthodes de segmentation par croissance de régions .....	7
II.2.3 Méthodes de segmentation par chaînes de Markov .....	7
II.2.4 Méthodes de segmentation par modèles déformables .....	8
II.2.5 Méthodes de segmentation par classification .....	8
II.3 Améliorations des méthodes de segmentation d'image par les métaheuristiques d'optimisation multi-objectif.....	9
II.3.1 Optimisation multi-objectif.....	10
II.3.1.1 Calcul du fitness .....	11
II.3.1.2 Maintenir la diversité .....	13
II.3.2 segmentation d'image par les métaheuristiques d'optimisation multi-objectif .....	17
II.3.2.1 Méthodes de segmentation par seuillage .....	17
II.3.2.2 Méthodes de segmentation par classification .....	17
II.3.2.3 Méthodes de segmentation basée sur la forme .....	17
II.5 Conclusion .....	18

## Chapitre 3 : Techniques de segmentation des vaisseaux sanguins

III.1 Introduction .....	19
III.2 Anatomie de l'œil humain .....	19
III.2.1 Anatomie d'une image de fond de l'œil .....	20
III.2.2 Vaisseaux rétiniens.....	20
III.2.3 Pathologies des vaisseaux rétiniens.....	21
III.3 Les méthodes de segmentation des vaisseaux rétiniens .....	21
III.3.1 Méthodes basées sur l'intensité .....	22
III.3.1.1 Filtrage adapté .....	22
III.3.1.2 Traitement morphologique .....	24
III.3.1.3 Détection de ligne.....	26
III.3.1.4 Méthodes dérivées.....	26

III.3.1.5 Contours actifs.....	27
III.3.1.6 Suivi par croissance de région.....	28
III.3.1.7 Chemin de coût minimum.....	30
III.3.1.8 Méthodes à base d'apprentissage.....	31
III.3.2 Apprentissage en profondeur.....	35
III.3.3 Méthodes d'optimisation .....	36
III.5 Mesures de segmentation des vaisseaux rétiniens.....	37
III.4 Description des bases de données .....	38
III.4.1. Base d'images DRIVE .....	38
III.4.2. Base d'images STARE.....	38
III.4.3. Base d'images HRF.....	39
III.6 Discussion générale sur les limites des méthodes existantes .....	39
III.7 Conclusion .....	40

## **Chapitre 4 : Seuillage multiple (a multi-niveaux) par optimisation multi-objectif pour la segmentation des vaisseaux rétiniens**

IV.1 Introduction .....	41
IV.2 Etude des critères de segmentation .....	41
IV.2.1 Classe 1 : Seuillage basé sur l'histogramme.....	41
IV.2.1.1 Variance interclasse d'Otsu.....	42
IV.2.1.2 Entropie de Kapur .....	43
IV.2.1.3 Méthode de Kittler et Illingworth .....	44
IV.2.2 Classe 2 : Seuillage à base d'information spatiale .....	44
IV.2.1.1 Histogramme bidimensionnel .....	44
IV.2.1.2 Seuillage basé sur la courbe d'énergie.....	47
IV.2.3 Résultats et Évaluation .....	47
IV.3 Segmentation des images diverses par la méthode d'optimisation multi-objective de fourrage bactérien.....	51
IV.3.1 Résultats expérimentaux et discussion.....	55
IV.3.2.1 Seuillage simple .....	55
IV.3.2.2 Seuillage multiple .....	56
IV.4 Segmentation à base seuillage de l'image rétinienne par la méthode d'optimisation multi-objectif de colonie d'abeilles .....	59
IV.4.1 Colonie d'abeilles artificielles multi-objectif guidées par les élites.....	59
IV.4.2 Segmentation des vaisseaux rétiniens avec le seuillage par l'algorithme EMOABC.....	62
IV.4.3 Résultats expérimentaux et discussion.....	64
IV.4.3.1 Ajustement des paramètres .....	64
IV.4.3.2 Analyse et comparaison .....	65
IV.5 Conclusion .....	69

## **Chapitre 5 : Méthode d'optimisation par essaim de particules pour la détection de petits vaisseaux rétiniens sur des images de fond d'œil à multi-résolution**

V.1 Introduction .....	70
V.2 Algorithme de détection de ligne multi-échelle .....	70
V.3 Algorithme d'optimisation de l'essaim de particules .....	70
V.4 Algorithme de réarrangement d'échelle proposé .....	71
V.5 Algorithme de recombinaison proposé .....	73
V.6 Évaluation des performances sur l'ensemble de données haute résolution .....	75
V.6.1 Analyse et comparaison sur la segmentation de tout le réseau vasculaire .....	75
V.6.2 Analyse et comparaison sur la segmentation de petits et de grands vaisseaux .....	77
V.7 Évaluation des performances sur base de données à basse résolution .....	80
V.8 Conclusion .....	82
<b>Conclusions et perspectives</b> .....	<b>83</b>
<b>Références bibliographiques</b> .....	<b>85</b>

## TABLE DES FIGURES

I.1 Ophthalmoscope avec Ordinateur Aide à la Diagnostique .....	2
II.1 Exemple de seuillage d'une image. ....	6
II.2 Exemple d'évolution d'un modèle déformable. ....	8
II.3 Niveaux de préférence dans la relation de dominance. ....	12
II.4 Front de Pareto.....	12
II.5 Exemple de Distance de Crowding.....	15
III.1 Coupe de l'œil en 3D légendée.....	19
III.2 Anatomie du fond d'œil .....	20
III.3 Démonstration graphique du réseau de vaisseaux de la rétine.....	21
III.4 Catégories de méthodes de segmentation des vaisseaux rétiens. ....	22
III.5 Application du filtrage adapté standard dans une image de rétinopathie diabétique non proliférative. ....	24
III.6 Exemple d'ouverture de chemin appliquée sur une image de fond d'œil .....	25
III.7 Exemple d'approche de détection de la ligne multi-échelle (MSLD) appliquée à une image rétinienne de haute résolution.....	26
III.8 Exemple de segmentation d'un vaisseau par T-serpent.....	28
III.9 Exemple de suivi .....	30
III.10 Exemple d'application de la marche rapide anisotrope. ....	31
III.11 Exemple d'application de la régression multi-échelle pour la détection de la ligne centrale. ....	34
III.12 Exemple d'architecture de réseau neuronal convolutif de base (CNN).....	36
III.13 Exemple d'image normale (niveau de gris) et le résultat de la segmentation par ABC (en vert) et PS (en rouge) de la base de données DRIVE. ....	37
III.14 Exemples d'images de la base de donnée .....	38
III.15 Exemples d'images de la base de donnée STARE.....	39
III.16 Exemples d'images de la base de données HRF. ....	39
IV.1 Allures idéales d'un histogramme unimodal, et multimodal .....	42
IV.2 Seuillage d'une matrice cooccurrence .....	45
IV.3 Seuillage d'une matrice cooccurrence à partir de plusieurs seuils.....	47
IV.3 Résultats de seuillage en deux classes sur une image réel.....	49
IV.4 Résultats de seuillage en deux classes sur une image réel bruitée.....	50
IV.5 Résultats de seuillage en 2 classes .....	56
IV.6 Résultats de seuillage en 2 classes. ....	56
IV.7 Exemples d'images synthétiques .....	57
IV.8 Exemples d'images IRM.....	58
IV.9 Résultats Seuillage d'images IRM.....	58
IV.10 Présentation du changement de l'histogramme de la courbe d'énergie dans le processus de la recherche des meilleures valeurs de seuils.....	64
IV.11 Présentation de l'étape de pré-traitement sur les images rétinienne normales.....	66
IV.12 Présentation d'extraction des vaisseaux de l'image rétinienne normale.....	67
IV.12 Présentation d'extraction des vaisseaux de l'image rétinienne de la base de données DRIVE.....	67

IV.14 Comparaison des performances entre les méthodes de seuillage à deux niveaux et la méthode proposée sur les bases de données STARE et DRIVE. ....	68
V.1 Organigramme du processus de sélection des meilleures échelles par l'algorithme PSO.....	72
V.2 Exemple des trois différents calibres de vaisseaux considérés dans les vaisseaux rétiniens.. ....	72
V.3 Organigramme de la méthode de recombinaison proposée.....	74
V.4 Effet des étapes du seuillage et de post-traitement sur le résultat de la segmentation finale dans .....	75
V.5 Comparaison des performances par image du taux de sensibilité sur les groupes sains et diabétiques.....	76
V.6 Exemples de segmentation d'une image DR, et une image H à partir la base de données HRF .....	76
V.7 Exemple de segmentation de petits vaisseaux en image saine .....	79
V.8 Exemple de segmentation de petits vaisseaux dans un cas diabétique.....	79
V.9 Exemple de segmentation de grands vaisseaux.....	80

## LISTE DES TABLEAUX

Tableau IV.1 Comparaison des valeurs des mesures d'error misclassified et le temps d'exécution.....	48
Tableau IV.2 Comparaison des valeurs des mesures d'error misclassified et le temps d'exécution.....	49
Tableau IV.3 Comparaison des valeurs des mesures d'uniformité.....	56
Tableau IV.4 Comparaison des valeurs d'uniformité obtenues par cinq méthodes pour différent niveau de bruit .....	57
Tableau IV.5 Performance de la méthode proposée sur la base de données DRIVE et STARE. ....	65
Tableau IV.6 Comparaison des valeurs de moyenne d'écart type de la précision (Acc) entre les méthodologies existantes avec notre algorithme proposé sur les bases de données STARE et DRIVE. ....	68
Tableau IV.7 Comparaison des performances avec les méthodologies existantes sur les bases de données STARE et DRIVE en termes de sensibilité, de spécificité, de précision et de temps d'exécution. ....	69
Tableau V.1 Comparaison des performances de la segmentation de tout le réseau vasculaire sur l'ensemble de test en termes de sensibilité, de spécificité et de précision....	75
Tableau V.2 Comparaison des performances de différentes méthodes sur l'ensemble de test en termes de précision de spécificité de sensibilité. ....	77
Tableau V.3 Evaluation de la performance des petits vaisseaux sur les images Sains et diabétiques en utilisant les mesures de discordance standard. ....	78
Tableau V.4 Evaluation de la performance des grands vaisseaux sur les images saines et diabétiques en utilisant les mesures de discordance standard .....	80
Tableau V.5 Performance de la méthode proposée et la méthode MSLD sur la base de données DRIVE.....	81
Tableau V.6 Performance de la méthode proposée et la méthode MSLD sur la base de données STARE. ....	81
Tableau V.7 Comparaison des performances avec les méthodes de segmentation disponibles sur les bases de données STARE et DRIVE .....	81

# Chapitre 1 : Introduction générale

## I.1 Introduction

Ce chapitre motivera le lecteur sur le problème de segmentation des vaisseaux rétiniens. Pour ce faire, nous présenterons les détails nécessaires sur l'impact de la rétinopathie diabétique sur la société et la vision du patient. En outre, nous fournirons le contexte général du champ d'imagerie du fond d'œil et ses défis. De plus, nous examinerons l'importance des vaisseaux sanguins dans le diagnostic et la progression d'une maladie dans la rétinopathie. Enfin, nous donnerons les objectifs ainsi que les grandes lignes de la thèse.

## I.2 Motivation

La vision est l'un des cinq sens fondamentaux du corps humain et probablement le plus important. La majorité des informations reçues quotidiennement sont des repères visuels du monde extérieur. Par conséquent, les complications possibles de la vision peuvent entraîner une incapacité à fonctionner normalement au quotidien. C'est pourquoi, il y a un besoin fondamental d'étudier et d'éliminer les facteurs qui pourraient avoir un impact négatif sur la vision. Parmi ces facteurs, se trouve le diabète, qui toucherait selon les estimations, 285 millions de personnes [1]. Avec 7 millions de personnes [2] supplémentaires atteintes de diabète chaque année, ce nombre devrait atteindre 439 millions d'ici 2030. Cette maladie affecte indirectement les yeux et peut conduire à la cécité si elle est négligée. La maladie oculaire diabétique ou rétinopathie diabétique, qui est évitable, est le résultat de changements dans le système de circulation microvasculaire de l'œil.

La cécité et la perte visuelle peuvent être évitées grâce à une détection précoce à l'aide de l'imagerie numérique du fond de l'œil. Cette approche consiste à prendre des images en couleur de la rétine, ce qui permet aux ophtalmologistes de surveiller les changements dans la rétine et de détecter la présence d'une rétinopathie diabétique. Cette solution a été proposée pour rendre l'examen régulier largement disponible, même pour les populations des régions éloignées et mal desservies. Ainsi, des millions d'images rétiniennes pourraient nécessiter une évaluation dans le monde (images rétiniennes pour toutes les personnes atteintes de diabète, et au moins deux images par œil). La façon standard d'inspecter la rétine pour la détection est à travers l'ophtalmoscope (voir Figure I.1), les images numériques du fond d'œil ainsi que l'imagerie remplacent la méthode standard d'examen de la rétine. Dans ce cas, le médecin recherche des profils d'anomalies spécifiques dans les petits ou grands vaisseaux ainsi que sur la surface de la rétine. La procédure est effectuée manuellement, ce qui rend le travail long et fastidieux. Parallèlement, l'introduction de programmes de dépistage de la population augmentera considérablement le volume de données à traiter. Par conséquent, les méthodes de quantification informatisée et précise de la maladie peuvent être utiles pour la réduction des ressources investies.

En 1987, Baudoin et al. [2] ont été les premiers à proposer une méthode d'analyse d'images pour la détection des microanévrismes, et depuis, plusieurs algorithmes et approches ont été développés pour détecter d'autres indicateurs de maladies (microanévrismes, hémorragies ...). Pour aider au développement d'algorithmes de détection plus précis et pour

déterminer comment ces différents algorithmes se classent en termes de performances, des bases de données d'images annotées accessibles au public ont été établies et des métriques de qualité ont été proposées [3]. Des travaux récents ont prouvé que la détection automatique de la maladie précoce de l'œil diabétique peut être aussi bonne que celle d'experts humains hautement qualifiés [4].



**Figure I.1** Ophthalmoscope avec Ordinateur Aide à la Diagnostique

### **I.3 Description de la problématique de recherche**

La segmentation du réseau vasculaire est une tâche clé dans le pipeline du traitement des images de la rétine. Elle joue un rôle important dans le développement d'un système d'aide au diagnostic de la rétinopathie diabétique (RD) qui peut révéler l'artériosclérose, le diabète, l'hypertension, et les maladies cardiovasculaires et d'AVC. La progression de la RD provoque des tortuosités et des changements de diamètre dans le réseau rétinien et donne naissance à des néovaisseaux. La mise en œuvre de méthodes reposant sur la détection précoces des signes cliniques de la RD permettent d'améliorer grandement le diagnostic de ces maladies.

Cependant, la détection des vaisseaux, dans une image rétinienne est un problème très compliqué en effet, les images rétiniennes peuvent souffrir de problèmes d'illumination non uniformes, ce qui conduit à une mauvaise définition des bords de vaisseaux et une interruption de la connexité du réseau vasculaire, et rendant aussi l'apparition des petits vaisseaux très faibles par rapport à la région de fond adjacente.

L'utilisation des schémas de systèmes regroupant plusieurs critères de segmentation, en faisant appel aux méta-heuristiques d'optimisation multi-objectif, est une direction de recherche prometteuse, pour l'extraction des vaisseaux sanguins dans les images faiblement contrastées et qui présentent des lésions ayant des caractéristiques semblables que le réseau vasculaire. Cependant, les difficultés de ces schémas résident, d'une part dans, la détermination des critères contradictoires, et d'autre part, dans le choix final de la solution, parmi toutes les solutions présentées. De plus, le comportement des algorithmes de méta-heuristiques est en général, déterminé par un ensemble de paramètres qui permettent d'agir principalement selon leurs capacités à explorer et à exploiter l'espace de recherche correctement. Le réglage de ces paramètres s'avère alors être une tâche particulièrement ardue qui s'appuie sur une série d'expériences.

## Objectif de la thèse

Cette thèse se place dans le cadre du développement d'un système d'aide au diagnostic de la rétinopathie diabétique (RD). Elle consiste à proposer des méthodes de segmentation robustes permettant d'améliorer la détection des vaisseaux sanguins en réduisant le temps de traitement. Ce thème de recherche se voit assigner les objectifs majeurs suivants :

- Développer un ensemble de méthodes robustes, permettant d'automatiser au maximum le processus d'analyse les images rétiniennes.
- Adapter et/ou développer de nouveaux algorithmes de segmentation d'image basés sur les méta-heuristiques d'optimisation multi-objectif couplés à des techniques d'apprentissage pour gérer le volume et la complexité des informations véhiculées par ces images.
- Développer des algorithmes efficaces capables d'extraire des vaisseaux sanguins dans les images faiblement contrastées et présentent des lésions ayant des caractéristiques semblables que le réseau vasculaire.
- Evaluer la qualité des approches proposées, en les comparants avec les travaux reportés dans l'état de l'art.

## I.4 Contributions de la recherche

Notre recherche dans ce domaine, nous a permis d'améliorer certaines méthodes de segmentation en les traitant selon le paradigme d'optimisation multi-objectif et aussi de proposer des méthodes de segmentation robustes permettant la détection de vaisseaux sanguins avec une bonne précision et un temps de calcul réduit. Cette section passe en revue les contributions des différentes parties de cette thèse.

Dans notre première contribution, nous avons commencé notre travail par approfondir l'étude des critères de segmentation et de trouver une formalisation plus poussée des relations entre les critères de segmentation et les images à segmenter [5]. En premier lieu, nous allons nous intéresser aux méthodes de seuillage vu leur simplicité. Nous allons adopter les métaheuristiques d'optimisation pour accélérer le processus du seuillage à multi-niveaux. Nous allons également étudier la possibilité de combiner plusieurs critères de seuillage en utilisant les techniques d'optimisation multi-objectif. Avant les adapter à la segmentation de la vascularisation rétinienne, nous avons testé la robustesse de nos algorithmes proposés sur différents types d'images [6].

Due à la robustesse de ce type d'algorithmes basé sur le seuillage, nous avons l'appliqué une première fois sur la segmentation d'image rétinienne, où une méthode non supervisée est proposée basée sur l'algorithme de la colonie d'abeilles [7]. La méthode proposée exploite simultanément plusieurs critères pour améliorer la précision des résultats de la segmentation. Une fonction de courbe d'énergie est utilisée pour calculer les valeurs des critères de seuillage, afin de réduire la réponse au bruit des lésions, et sélectionner les seuils optimaux qui séparent les vaisseaux sanguins de l'arrière-plan. Afin d'accélérer le calcul, une méthode de critère d'arrêt est utilisée pour ajuster les paramètres de l'algorithme proposé. La méthode proposée est simple et plus rapide que la plupart des algorithmes non supervisés disponibles, ce qui démontre une convergence rapide vers la segmentation finale.

La deuxième contribution est de proposer une méthode visant à segmenter les plus petits vaisseaux rétiniens, dans le but de réduire les faux positifs dus à de petits vaisseaux manqués, mal classés en lésions rouges dans un système de CAD de dépistage de la rétinopathie diabétique (Diabetic Retinopathy: DR). La méthode proposée exploite la puissance de la technique PSO pour trouver la meilleure disposition des échelles dans la méthode MSLD, et aussi pour gérer le problème de la recombinaison de réponse en échelle. La performance de la méthode proposée a été évaluée sur deux bases de données d'images du fond d'œil à basse résolution (DRIVE, STARE) et à haute résolution (HRF). Les données comprenaient des cas DR et des cas rétinopathie saine (Healthy: H). Selon les bases de données (basse et haute résolution), la méthode proposée a obtenu des performances significativement meilleures par rapport à la méthode MSLD et à tous les algorithmes de segmentation des petits vaisseaux existants. Une partie de cette contribution a été d'abord publiée dans [8]. Ensuite, dans une version étendue [9].

## **I.5 Organisation de la thèse**

Cette thèse est divisée en Cinq chapitres. Le premier chapitre présente la motivation générale sur le problème de segmentation des vaisseaux rétiniens, et a pour but de définir le contexte scientifique sous lequel nos travaux ont été menés. Le deuxième chapitre fournit une étude bibliographique où sont exposées les différentes familles de méthodes de segmentation, ainsi que leur amélioration par les techniques d'optimisation. Dans le troisième chapitre, nous exposons le contexte nécessaire et la revue de la littérature qui fournira l'état de l'art des techniques de segmentation des vaisseaux sanguins, ainsi que les différentes bases de données et des mesures d'évaluation des performances des algorithmes de segmentation sont présentées. Dans le quatrième chapitre, nous étalons notre première contribution, qui est l'amélioration de la segmentation de vaisseaux vasculaires par une méthode d'optimisation non supervisée. Le cinquième chapitre, présente une méthode visant à segmenter les plus petits vaisseaux rétiniens. Enfin, ce manuscrit s'achève par une conclusion générale, où nous récapitulons nos contributions et proposons des perspectives sur la base des travaux effectués.

# **Chapitre 2 : Segmentation d'image par les métaheuristiques d'optimisation**

## **II.1 Introduction**

Les métaheuristiques d'optimisation et la segmentation d'image font parties des domaines de recherche les plus actifs. Ces dernières années, plusieurs travaux ont créé le pont entre ces deux champs de recherche. En effet, le problème de segmentation d'image est formalisé comme un problème d'optimisation combinatoire monocritère ou multicritères, où l'utilisation des métaheuristiques comme un moyen pour trouver des solutions acceptables dans un temps raisonnable [10].

Dans ce chapitre, nous présentons les principales approches de segmentation d'image et leurs améliorations à l'aide des métaheuristiques d'optimisation mono-objectif en premier lieu (section II.2). Ensuite, nous présentons un ensemble de définitions liées au problème d'optimisation multi-objectif, puis nous présentons quelques méthodes de segmentation améliorées par les métaheuristiques d'optimisation multi-objectif, (Section II.3).

## **II.2 Améliorations des méthodes de segmentation d'image par les métaheuristiques d'optimisation mono-objectif**

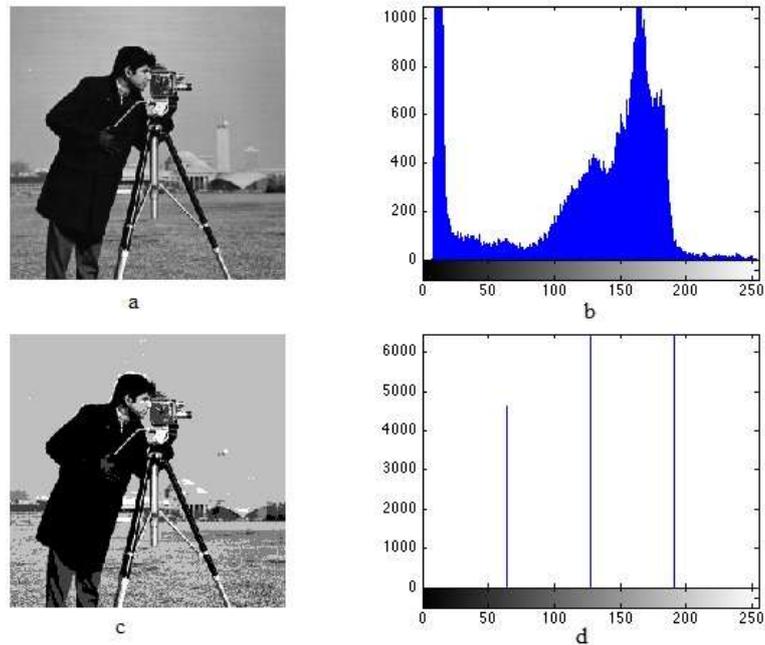
Les métaheuristiques d'optimisation sont des algorithmes généraux d'optimisation, leurs application en segmentation d'image a connu un engouement particulier ces dernières années, grâce aux avancées technologiques en matière de calcul des machines. De plus, ils ont permis d'étudier la segmentation sous un angle différent, avec des résultats plus ou moins réussis.

Dans cette section, nous présentons les principales méthodes de segmentation d'image et leurs améliorations à l'aide des métaheuristiques d'optimisation mono-objectif (monocritère). Vu le nombre important et la diversité des méthodes de segmentation, nous n'utilisons aucune classification des méthodes de segmentation, mais nous nous contentons de donner le principe des différentes approches.

### **II.2.1 Méthodes de segmentation par seuillage**

Les approches de seuillage ont connu un grand succès dans les systèmes réels, à cause de leur rapidité et leur facilité de mise en œuvre. Ce type de méthode se base sur l'hypothèse que les différents objets (régions) de l'image peuvent être distingués par leurs niveaux de gris. Pour avoir une segmentation robuste, il suffirait de trouver les valeurs des niveaux de gris délimitant chaque région (seuils). Toutes les méthodes de segmentation tentent de trouver les seuils optimaux, de sorte à séparer les différentes régions de l'image.

Les méthodes de seuillage utilisent principalement l'histogramme d'image, afin de déterminer les concentrations de pixels autour de certains niveaux de gris, et par la suite déterminer les différents seuils situés entre ces derniers. La figure II.1 représente un exemple illustratif de seuillage d'une image.



**Figure II.1** : Exemple de seuillage d'une image. (a) Image à segmenter. (b) Histogramme de l'image. (c) résultat de la segmentation (d) les seuils choisis pour segmenté l'image a (seuils = [70, 125, 180]).

On remarque à partir de la figure I.1 qu'une fois les seuils déterminés, l'affectation des pixels s'effectue selon la formule suivante (Eq. II .1):

$$I_{seg}(i,j) = k \quad \text{si} \quad S_k \leq I(i,j) < S_{k-1} \quad \text{pour } k=1,\dots,N \quad (\text{II.1})$$

Où :

$I(i,j)$  : représente le niveau de gris du pixel ayant les coordonnées  $(i, j)$  dans l'image à segmenter.

$I_{seg}(i,j)$  : représente le label affecté au pixel ayant la position  $(i, j)$  dans l'image résultant de la segmentation.

$S_k$  : est le  $k^{\text{ème}}$  seuil.

$N$  : est le nombre de régions présentes dans l'image à segmenter.

Dans la littérature, plusieurs méthodes de seuillage ont été proposées [11]. On peut les classer en deux catégories : les méthodes paramétriques et les méthodes non paramétriques. Les méthodes de seuillage paramétriques reposent sur l'hypothèse que les classes (régions) de l'image suivent des fonctions de densité de probabilité. Généralement, une combinaison de gaussiennes est utilisée. La première étape consiste à estimer les paramètres des modèles, et la deuxième étape consiste à déterminer les seuils (intersection des modes). Les méthodes non paramétriques, comme leur nom l'indique, ne nécessitent pas d'estimation de paramètres pour trouver les seuils optimaux. Ces méthodes sont basées généralement sur l'optimisation d'un critère. Les méthodes non paramétriques de référence sont : la méthode non paramétrique d'Otsu [12], qui est basée sur la minimisation du rapport entre la variance interclasse, et la méthode non paramétrique Kapur [13], qui se basée sur la maximisation de l'entropie globale de shannon.

Les métaheuristiques d'optimisation mono-objectif ont été largement exploitées par plusieurs auteurs afin de trouver les seuils optimaux minimisant différents critères de seuillage. Le recuit simulé a été utilisé dans les travaux [14] [15]. L'optimisation par colonies de fourmis a été utilisée par Zhao et al [16], et l'optimisation par essaim de particulaire par Sathya et Kayalvizhi [17] et Djerou et al [18]. Les algorithmes génétiques ont été exploités par Tao et al [19], et Hongfu [20]. De plus, d'autres métaheuristiques et leur hybridation ont été proposées par Alihodzic et al [21], et Boussaïd et al [22].

### **II.2.2 Méthodes de segmentation par croissance de régions**

Ces méthodes de segmentation consistent à choisir, en premier lieu, un ensemble de pixels représentatif de chaque région, appelés germes. Ensuite, au fur et à mesure, les régions se construisent en ajoutant les pixels connexes à leurs germes. Les pixels qui sont ajoutés à la région doivent vérifier un certain critère de similarité (ou de distance) entre les pixels à ajouter et la région construite. Dans la littérature, plusieurs méthodes de croissance de régions ont été proposées, utilisant différents critères de similarité. Ces méthodes ne sont généralement pas utilisées seules, mais dans une chaîne de traitement [23]. Ces méthodes ont deux inconvénients majeurs : elles demandent l'intervention d'un être humain (un opérateur) pour initialiser les germes, leur sensibilité aux bruits peut créer des trous à l'intérieur des régions. Plusieurs travaux ont tenté de surmonter ces inconvénients [24].

Dans notre étude bibliographique, nous n'avons trouvé qu'une seule méthode de croissance de régions améliorée par les métaheuristiques d'optimisation. Manousakas et al. [25] ont utilisé le recuit simulé dans la méthode division-fusion, afin de réduire le nombre de régions pour la segmentation d'un volume IRM 3D.

### **II.2.3 Méthodes de segmentation par chaînes de Markov**

Les chaînes de Markov ne constituent pas, en elles-mêmes, des méthodes de segmentation, mais une modélisation statistique, qui peut être utilisée dans d'autres méthodes de segmentation [23]. Ces méthodes a été introduite par S.Geman et al [26], où elles sont largement exploitée en traitement d'image. La segmentation d'image par les chaînes de Markov est basée sur le principe suivant : l'image est considérée comme une observation donnée, dont on cherche à connaître les objets (variables cachées) en disposant d'information à priori. Plus concrètement, on cherche la probabilité d'un objet en connaissant l'image et des informations à priori. En utilisant le théorème de Bayes, la probabilité à posteriori peut être calculée à partir de la probabilité à priori. Pour plus de détails sur ces méthodes, voir la thèse de Brunel [27].

La détermination des paramètres de la chaîne de Markov qui modélise l'image est un problème d'optimisation combinatoire. De ce fait, les métaheuristiques d'optimisation sont favorites pour résoudre ce problème. En ce sens, plusieurs travaux dans la littérature en été proposés en utilisant: les algorithmes génétiques [28] et les colonies de fourmis [29] [30]. Même si nous n'avons pas trouvé une exploration des autres métaheuristiques plus

récentes, dans les chaînes de Markov, nous pensons qu'elles ont un fort potentiel pour améliorer l'estimation des paramètres de ce type de modèles.

La détermination des paramètres de la chaîne de Markov qui modélise l'image est un problème d'optimisation combinatoire. Pour résoudre ce problème, les métaheuristiques d'optimisation sont favorites. En ce sens, plusieurs travaux dans la littérature en ont été proposés en utilisant: les algorithmes génétiques [28] et les colonies de fourmis [29] [30].

#### II.2.4 Méthodes de segmentation par modèles déformables

Ces méthodes de segmentation ont pour but de déterminer les contours des objets présents dans l'image. Elles utilisent principalement des courbes paramétriques fermées ou des surfaces, qui partant d'une position initiale, se déforment jusqu'à épouser la forme de l'objet à détecter (figure II.2). L'évolution de la courbe est régie par une force interne et une force externe jusqu'à atteindre un équilibre où l'énergie est minimale. Afin de garder la courbe aussi lisse que possible, la force interne doit être intrinsèquement liée à la surface ou la courbe elle-même. La force externe est définie par l'image, afin de guider la courbe vers les contours désirés. Plusieurs méthodes, basées sur les méthodes déformables, ont été proposées dans la littérature. Parmi celles qui ont trouvé le plus de succès, on cite : les contours actifs (snakes) [31] [32], la méthode des surfaces de niveau (level sets) [33] [34] et les contours actifs géodésiques [35].

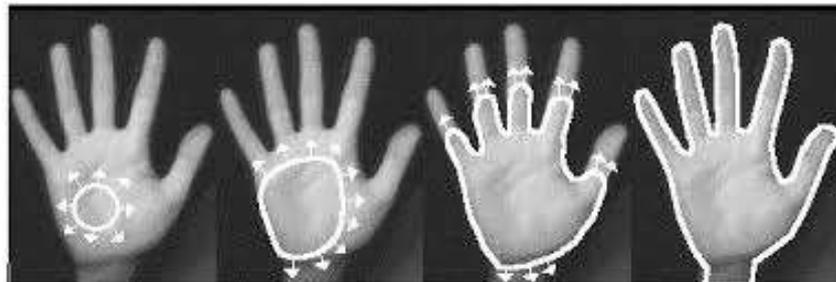


Figure II.2 : Exemple d'évolution d'un modèle déformable.

De même que les autres méthodes de segmentation, la segmentation par modèles déformables est basée sur l'optimisation d'un critère d'énergie. D'où l'utilisation des métaheuristiques d'optimisation a été figurée dans plusieurs travaux; les algorithmes génétiques ont été exploités dans [36]. L'optimisation par colonies de fourmis a été appliquée dans [37]. L'optimisation par essaims particulaires a été proposée dans les travaux [38] [39]

#### II.2.5 Méthodes de segmentation par classification

La classification est une technique de reconnaissance de formes largement utilisée dans le domaine du traitement d'image [40]. Son objectif est de trouver une partition de l'espace des attributs des données [41]. L'espace des attributs (features space) est l'ensemble des transformations des données brutes permettant de rehausser la séparabilité des différentes classes désirées. Plusieurs attributs ont été utilisés pour la segmentation d'image

[42]. Souvent, l'intensité des pixels est utilisée comme attribut des données, en introduisant les autres informations dans le processus de classification. Généralement, on distingue deux approches de classification : la classification supervisée et la classification non supervisée.

Les méthodes de classification supervisée nécessitent une base d'images déjà segmentées manuellement. Cette base permet de faire un apprentissage (training) du classifieur. Une fois les paramètres du classifieur déterminés, de nouvelles images peuvent être segmentées. L'exemple le plus simple de ces méthodes est le classifieur du plus proche voisin (nearest-neighbor) où chaque pixel est affecté à la même classe que celle du pixel présent dans la base d'apprentissage, ayant le plus proche niveau de gris.

À l'inverse des méthodes de classification supervisée, les méthodes de classification non supervisée, appelées aussi méthodes de regroupement (clustering), ne nécessitent pas une base d'images segmentées. Afin de compenser le manque d'une base d'apprentissage, ces méthodes alternent entre classification des pixels et caractérisation des classes ; en ce sens, les méthodes de regroupement apprennent d'elles-mêmes en utilisant les données disponibles [23]. Les méthodes de regroupement de données qui ont connu un large succès sont : l'algorithme des K-moyennes (K-means en anglais) ou ISODATA [43], l'algorithme espérance-maximisation (expectation-maximization) [44] et l'algorithme des C-moyennes floues (fuzzy C-means "FCM" en anglais) [45].

Les métaheuristiques d'optimisation ont été largement exploitées dans les problèmes de classification de manière générale, à cause de la nature combinatoire de ce problème. L'ouvrage de Das et al. [46] est dédié spécialement à ce sujet. Afin de remédier au problème de blocage dans des minima locaux de la méthode FCM, plusieurs travaux ont été proposés dans la littérature, qui exploitent les différentes métaheuristiques et leur hybridation [47] [48].

### **II.3 Améliorations des méthodes de segmentation d'image par les métaheuristiques d'optimisation multi-objectif**

Dans le but d'améliorer les méthodes de segmentation et les utiliser pour segmenter différents types d'images, le problème de segmentation d'image peut être reformulé comme un problème d'optimisation multi-objectif, car l'utilisation d'un seul critère de segmentation est insuffisante pour traiter la complexité de types d'images [49]. Plusieurs études ont été menées sur les métaheuristiques afin de les étendre à l'optimisation multi-objectif.

Dans cette section, on décrit le problème de l'Optimisation Multi-objectif (OM) et les concepts liés au problème de l'OM (la dominance Pareto, les techniques assurant le maintien de la diversité d'une population à un algorithme MO). De plus, nous présentons les principales de quelques méthodes de segmentation d'image et leurs améliorations à l'aide des métaheuristiques d'optimisation multi-objectif.

### II.3.1 Optimisation multi-objectif

Les métaheuristiques se prêtent à toutes sortes d'extensions, citons, en particulier, l'optimisation multi-objectif (dites aussi multi-critère) [50], où il s'agit d'optimiser simultanément plusieurs objectifs contradictoires. La solution d'un problème multi-objectif n'est pas une solution unique, mais un ensemble de solutions connu comme l'ensemble de solutions Pareto optimales. Ces solutions offrent des compromis entre les différents objectifs optimisés, et le choix d'une de ces solutions, est alors réalisé par un décideur.

Mathématiquement parlant, le problème d'optimisation multi-objectif est défini comme suit [51]:

$$MOP = \begin{cases} \text{Optimiser } f_m(\vec{x}) & m = 2, 3, \dots, M \\ \text{où } x_i^{(L)} \leq x_i \leq x_i^{(U)}, & i = 1, 2, \dots, n \end{cases} \quad (\text{II.2})$$

Tel que :

- $\vec{x}$  est le vecteur de n variables de décision  $\vec{x} = (x_1, x_2, \dots, x_n)^T$
- $M$  est le nombre de fonctions d'objectif et  $\vec{F}(\vec{x}) = (f_1(\vec{x}), f_2(\vec{x}), \dots, f_M(\vec{x}))^T$  le vecteur des fonctions d'objectif.
- $x_i^{(L)}$  et  $x_i^{(U)}$  la limite inférieure et supérieure de variable de décision  $x_i$ .

Les approches de résolution des problèmes multi-objectif peuvent être réparties en trois classes: approches basées sur la transformation du problème en un problème mono-objectif (simple objectif), approches non Pareto et approche Pareto.

**A. la transformation en un problème mono-objectif :** l'approche est qualifiée d'approche naïve de l'optimisation MO. Elle consiste tout simplement à transformer un problème multi-objectifs en un problème mono-objectif, dont il existe de nombreuses méthodes de résolution [50]. Parmi les méthodes qui utilisent cette approche, nous pouvons citer les méthodes d'agrégation, les méthodes  $\epsilon$ -contraintes, les méthodes de programmation par but. En général ces méthodes nécessitent une connaissance du problème et ne fournissent qu'une seule solution. Elles peuvent alors être classées dans la famille des méthodes d'optimisation a priori.

**B. approches non Pareto :** ces approches possèdent un processus de recherche qui traite séparément les objectifs. Deux groupes des méthodes existent dans la littérature : la sélection lexicographique et la sélection parallèle. Dans l'approche classique de la sélection lexicographique, la sélection est réalisée suivant un ordre défini a priori. Cet ordre permet de définir les poids des objectifs. Plusieurs métaheuristiques ont été utilisées pour la résolution des problèmes multiobjectifs avec sélection lexicographique [52].

Dans l'approche par sélection parallèle, l'algorithme le plus répandu est Vector Evaluated Genetic Algorithm (VEGA) [53], qui est basé sur un algorithme génétique, où la recherche de solution se fait par l'optimisation des objectifs séparément les uns des autres.

L'analyse de cet algorithme a montré que son comportement est le même qu'un algorithme réalisant une agrégation linéaire. Plusieurs auteurs ont travaillé sur l'amélioration de cet algorithme. Pour plus de détails, nous invitons le lecteur à consulter [50].

**C. approches Pareto** : ces approches utilisent directement la notion de dominance Pareto. Elles permettent d'avoir un ensemble de solutions possibles (solutions Pareto) au problème, mais ne permettent pas de choisir une alternative plutôt qu'une autre. Le choix de la solution finale revient à l'utilisateur (décideur). Cette idée, basée sur les algorithmes génétiques, a été initiée par Goldberg [54].

Les métaheuristique à base de population sont adaptées à la recherche du front Pareto car ils sont capables grâce à leur parallélisme implicite de dégager des solutions optimales de façon plus efficace qu'une méthode exhaustive. D'une manière générale, la plupart des approches Pareto trouvées dans la littérature sont incluses dans les algorithmes évolutionnaires, et une large part de ces algorithmes est des algorithmes génétiques.

L'adaptation, d'une metaheuristique d'optimisation mono-objectif pour résoudre le problème multi-objectif, tient en compte deux points :

- Le calcul de la valeur du fitness (ou d'adaptation) d'un individu et la procédure de sélection qu'il faut utiliser afin de s'approcher au maximum de la frontière de Pareto.
- Le maintien de la diversité au sein de la population de solutions pour empêcher une convergence prématurée, et par conséquent atteindre une frontière de Pareto distribuée et uniforme.

### II.3.1.1 Calcul du fitness

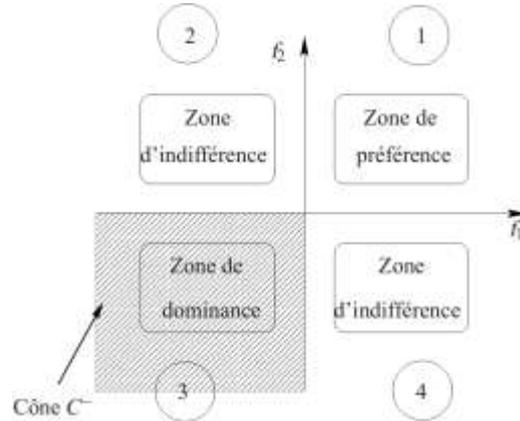
La valeur du fitness ou d'adaptation correspond à la performance d'un individu dans la résolution d'un problème donné. Par exemple, si l'on considère un problème de maximisation d'une fonction, la valeur de l'adaptation de l'individu croîtra avec sa capacité à maximiser cette fonction. La définition de la fonction d'adaptation devient plus compliquée dans le cas d'optimisation multi-objectif, car il y a plusieurs fonctions à optimiser et non pas une seule. En général, dans de telles situations, la dominance de Pareto est le seul moyen pour bien exprimer la fonction d'adaptation.

#### A. La relation de dominance

Lorsque nous avons résolu notre problème d'optimisation multi-objectif, nous avons obtenu une multitude de solutions. Seul un nombre restreint de ces solutions va nous intéresser. Pour qu'une solution soit intéressante, il faut qu'il existe une relation de **dominance** entre la solution considérée et les autres solutions.

Lorsque l'on applique la définition de la dominance, on peut définir quatre régions auxquelles on peut attribuer des niveaux de préférence. Ces régions sont représentées à la figure II.8. Par exemple, si ce graphique est centré sur une solution *A* et que l'on compare cette solution avec une solution *B*, on aura les possibilités suivantes :

- si la solution  $B$  se trouve dans le quadrant 1, alors la solution  $A$  est préférée à la solution  $B$ ;
- si la solution  $B$  se trouve dans le quadrant 3, alors la solution  $A$  est dominée par la solution  $B$ ;
- si la solution  $B$  se trouve dans l'un des quadrants 2 ou 4, alors, on ne peut pas se prononcer sur la préférence de  $A$  par rapport à  $B$  ou de  $B$  par rapport à  $A$ .

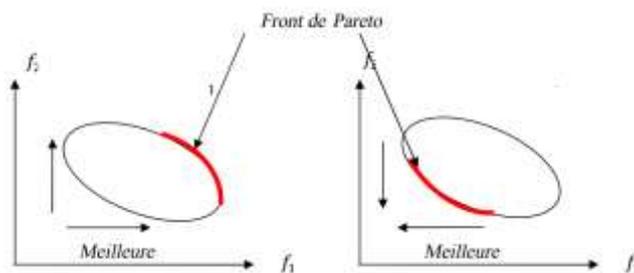


**Figure II.3 :** Niveaux de préférence dans la relation de dominance.

**Définition** (Pareto optimal) : Soit  $x = [x_1, \dots, x_n]^T$  un vecteur de décision avec :  $x \in X$  (L'espace réalisable)  $x$  est dit Pareto optimal, s'il n'existe pas une solution  $y$  domine  $x$ . Une solution Pareto optimal appelée aussi : solution efficace, non inférieur ou solution non dominée.

### B. Dominance et l'optimalité de Pareto (front de Pareto)

Le front (frontière) de Pareto est l'ensemble des solutions Pareto optimales qui sont composées des points, ne sont dominés par aucun autre solution. Le front de Pareto appelé aussi surface de compromise ou l'ensemble des solutions efficaces. La figure II.9, représente le Front du Pareto pour un problème de minimisation et maximisation de deux fonctions objectif.



**Figure II.4 :** Front de Pareto

- **Pareto optimalité faible:** Un point  $x^* \in \Omega$  est dit faiblement Pareto optimale si et seulement si :  $\exists x \in \Omega$ , Tel que  $f_i(x) < f_i(x^*)$ . Pour  $i = 1, \dots, k$ .
- **Pareto optimalité forte:** Un point  $x^* \in \Omega$  est dit fortement Pareto optimale s'il n'existe pas un autre point  $x \in \Omega$ ,  $x \neq x^*$ , Tel que  $f_i(x) \leq f_i(x^*)$ . Pour  $i = 1, \dots, k$ .

• **L'ensemble de Pareto optimalité:** Pour un problème d'optimisation multi-objectif donné, l'ensemble de Pareto optimale  $P^*$  est défini comme suit :  $P^* = \{x \in \Omega / \nexists x' \in \Omega F(x') \leq F(x)\}$ .

### La frontière de Pareto :

Pour un MO pareto donné,  $F(x)$ , et l'ensemble de Pareto optimale  $P^*$ , le front de Pareto  $PF^*$  est défini comme suit :  $PF^* = \{u = F(x) / x \in P^*\}$ .

Le pseudo-code de la fonction d'assignation du rang de Pareto est représenté dans l'algorithme II.1. Dans cet algorithme, la variable  $N$  désigne le nombre de points de l'ensemble sur lequel on effectue les comparaisons.

---

#### Algorithme II.1 Assignation du rang de Pareto.

---

```

RangCourant = 1
m = N
while N≠0 do
    For i = 1 to m do
        If  $X_i$  est Non dominé
            Rang( $X_i$ , t) = RangCourant
        End For
    For i = 1 to m do
        If Rang( $X_i$ , t) = RangCourant
            Ranger  $X_i$  dans une polution temporaire
            N = N - 1
        End For
    RangCourant = RangCourant + 1
    m = N
End While

```

---

#### II.3.1.2 Maintenir la diversité

La diversité est une notion déjà importante lors de l'optimisation de problèmes à un objectif, elle devient prépondérante lorsque l'on traite de problèmes multiobjectifs. Maintenir un certain degré de diversité dans la population d'un algorithme évolutionnaire consiste à éviter que la population ne converge prématurément vers une petite zone de l'espace de recherche ou de l'espace des objectifs. En effet, s'il n'existe pas de mécanisme de contrôle de la diversité, les opérations de sélection vont privilégier trop vite certains individus meilleurs à cette étape de la recherche. Cette convergence prématurée a comme effet de limiter la

recherche à un sous-ensemble plus restreint de l'espace de recherche, qui peut ne contenir aucune solution optimale. Dans le cas de problèmes multiobjectifs, converger prématurément rend impossible la découverte de l'intégralité du front Pareto. En effet, les individus de la population se focaliseront sur une partie du front Pareto, et ne se répartiront pas sur la totalité de ce front Pareto.

Pour remédier à ce problème, de nombreuses techniques ont été développées. Celles-ci influent sur la pression de sélection, afin de privilégier certains individus, permettant d'obtenir une population plus diversifiée. Cependant, ces techniques ajoutent un coût calculatoire non négligeable pour l'algorithme, elles doivent donc être choisies avec soin. Au-dessous, on va présenter les mécanismes de diversification les plus couramment intégrés aux algorithmes évolutionnaires.

### A. Le "sharing"

Le sharing consiste à modifier la valeur de coût d'un individu (calculée uniquement à partir de la fonction objectif du problème), et cette nouvelle valeur qui sera utilisée comme valeur d'adaptation par l'opérateur de sélection. Cette technique, introduite dans [54] est largement utilisée aujourd'hui.

Pour éviter qu'un trop grand nombre d'individus ne se concentrent autour d'un même point, il faut pénaliser la valeur d'adaptation en fonction du nombre d'individus au voisinage du regroupement: plus les individus sont regroupés, plus leur valeur d'adaptation est faible, et des individus proches les uns des autres doivent partager leur valeur d'adaptation. Dans la pratique, on estime ce taux de concentration en ouvrant un domaine autour d'un individu, puis on calcule les distances entre les individus contenus dans ce domaine.

Pour déterminer les bornes du domaine ouvert autour de l'individu choisi, on définit une distance maximale, appelée  $\sigma_{share}$ , au de laquelle les individus ne seront plus considérés comme faisant partie du domaine ouvert. La distance séparant deux individus  $i$  et  $j$  est calculée grâce à la fonction  $d(i, j)$ . La valeur d'adaptation  $F(i)$  d'un individu  $i \in P$  (population) est égale à son coût  $F'(i)$  divisé par sa valeur de niche :

$$F(i) = \frac{F'(i)}{\sum_{j \in P} Sh(d(i, j))} \quad (II.7)$$

Où la fonction  $Sh$  est définie comme suit:

$$Sh(d(i, j)) = \begin{cases} \mathbf{1} - \left(\frac{d(i, j)}{\sigma_{share}}\right)^2 & \text{si } d(i, j) < \sigma_{share} \\ \mathbf{0} & \text{sinon} \end{cases} \quad (II.8)$$

La fonction  $d(i, j)$  de calcul de distance peut être définie dans l'espace de recherche, par exemple à l'aide d'une distance de Hamming, ou dans l'espace objectif. Ce choix dépend souvent du problème, car le maintien de la diversité dans l'espace objectif, bien qu'il soit

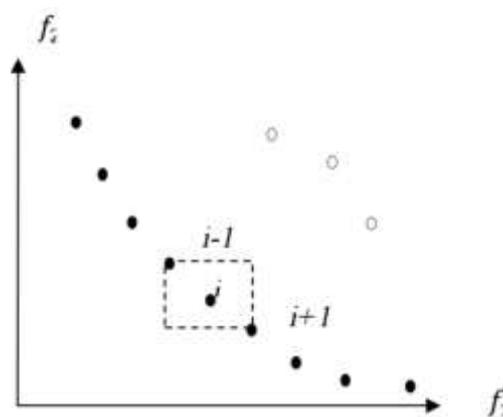
souvent plus simple à réaliser, n'assure pas forcément le maintien de la diversité dans l'espace de recherche.

## B. La réinitialisation

La réinitialisation est une technique largement utilisée par toutes les métaheuristiques, les algorithmes évolutionnaires n'échappant pas à la règle. Lors d'approches par population, elle consiste à réinitialiser un certain nombre d'individus de la population, par exemple de manière aléatoire. En introduisant de manière régulière certains individus générés aléatoirement, de nouvelles zones de l'espace de recherche, peut-être inexplorées jusqu'ici, peuvent être découvertes.

## C. La distance de surpeuplement (Crowding Distance)

Une procédure de crowding, basée sur un calcul de distance (distance de crowding) qui ne nécessite aucun paramétrage et qui est également d'une complexité algorithmique moindre que celle de sharing. La distance de crowding d'une solution particulière  $i$  se calcule en fonction du périmètre de l'hypercube ayant comme sommets les points les plus proches de  $i$  sur chaque objectif. Sur la figure II.5, est représenté l'hypercube en deux dimensions associé au point  $i$ . Le calcul de la distance de crowding nécessite, avant tout, le tri des solutions selon chaque objectif, dans un ordre ascendant. Ensuite, pour chaque objectif, les individus possédant des valeurs limites se voient associés une distance infinie. Pour les autres solutions intermédiaires, on calcule une distance de crowding égale à la différence normalisée des valeurs de fonctions objectives de deux solutions adjacentes. Ce calcul est réalisé pour chaque objectif. La distance de crowding d'une solution est obtenue en sommant les distances correspondantes à chaque objectif [55].



**Figure II.5:** Distance de Crowding (les points noirs sont des Solutions appartenant au même front)

L'algorithme décrit au-dessous montre la procédure de calcul de la distance de toutes les solutions non dominées de l'ensemble ( $I$ ). Dans cet algorithme,  $f_m^{i+1}$  et  $f_m^{i-1}$  représentent respectivement la valeur de la  $i^{\text{ème}}$  fonction objectif de la solution  $i+1$  et  $i-1$ , alors que les paramètres  $f_m^{\max}$  et  $f_m^{\min}$  représentent les valeurs maximale et minimale de la fonction objectif. Après ce calcul, toutes les solutions de  $I$  auront une distance métrique.

```

l = |I|           // Nombre de solutions dans l'ensemble
Pour chaque i, poser  $I[i]_{distance} = 0$            //Initialiser les distances
  Pour chaque objectif m
    I = Trie(I,m)
     $I[l]_{distance} = \infty$ 
    Pour i=2 to (l-1)
      
$$I[i]_{distance} = I[i]_{distance} + \frac{f_m^{i+1} - f_m^{i-1}}{f_m^{max} - f_m^{min}} \quad (II.8)$$

    FinPour
  FinPour
FinPour

```

#### D. L'élitisme

L'élitisme permet de conserver les meilleurs individus dans les générations futures. Une des premières implémentations de ce mécanisme dans un algorithme génétique est présentée dans [56].

L'élitisme est introduit pour conserver les bonnes solutions lors du passage de la génération courante à la prochaine génération. Conserver ces solutions pour les générations futures permet d'améliorer les performances des algorithmes sur certains problèmes. En effet, dans ses expérimentations, De Jong [56] a observé qu'un algorithme génétique élitiste améliorerait significativement les résultats sur des fonctions unimodales. D'un autre côté, l'élitisme peut causer une convergence prématurée sur des fonctions multimodales.

Réaliser un algorithme élitiste dans le cadre des problèmes multiobjectifs est plus difficile que pour les problèmes à un objectif. En effet, la meilleure solution n'est plus un unique individu, mais tout un ensemble dont la taille peut dépasser la taille maximale de la population. Deux adaptations du mécanisme élitiste sont considérées : la première approche regroupe les algorithmes, fondés sur les travaux de Jong, qui conservent pour les générations futures les *k* meilleurs individus [57]. Mais comment avec cette approche sélectionner *k* individus, si l'ensemble des points non dominés actuel comporte plus de *k* solutions? il y a un risque de perdre une partie du front Pareto optimal, et le concept de l'élitisme n'est plus complètement présent. Les approches présentées dans [58] [59] tendent à utiliser une population externe d'individus dans laquelle est stocké le meilleur ensemble des points non dominés découverts jusqu'ici. Cet ensemble est mis à jour continuellement pendant la recherche, et les individus stockés continus à pouvoir être choisis par l'opérateur de sélection. Ils peuvent ainsi se reproduire et transmettre leurs caractéristiques aux générations suivantes.

Actuellement, les algorithmes élitistes obtiennent de meilleurs résultats sur un grand nombre de problèmes multi-objectifs [60].

### **II.3.2 Segmentation d'image par les métaheuristiques d'optimisation multi-objectif**

L'utilisation d'un seul critère de segmentation est insuffisante pour traiter la complexité de l'image [49]. Pour pallier les faiblesses de ces méthodes, la tendance est d'utiliser plusieurs critères de segmentation pour améliorer les résultats et augmenter la robustesse vis-à-vis des différentes caractéristiques de l'image. L'utilisation des approches de l'optimisation multi-objectif a été trouvée dans les méthodes de la segmentation à base de classification, base de forme, et à base de seuillage.

#### **II.3.2.1 Méthodes de segmentation par seuillage**

L'optimisation multi-objectif en segmentation d'images a été utilisée premièrement par Bhanu et al. [61], où un algorithme génétique non élitiste d'optimisation multi-objectif a été proposé. L'application de l'optimisation multi-objectif, dans la segmentation de l'image avec les techniques du seuillage a été utilisée au début par Nakib et al. [15,49], qui ont proposé de trouver les seuils optimaux permettant d'optimiser un ensemble de critères (fonctions objectif). L'optimisation par essaim de particulaire a été utilisée par Djerou et Batouche [62]. L'optimisation par le fourrage bactérien a été proposée par Djerou et al [63,6]. Le but est d'augmenter l'information sur les positions de seuils optimaux pour obtenir la segmentation correcte.

#### **II.3.2.2 Méthodes de segmentation par classification**

Plusieurs travaux ont été proposés dans la littérature [64], qui exploitent les différentes métaheuristiques dans la segmentation de l'image avec les techniques de la classification. Comme exemple, dans [65] deux critères sont optimisés simultanément à l'aide de l'algorithme d'optimisation par essaim particulaire multi-objectif. Le premier critère est celui de la classification par c-moyennes floues amélioré, qui exploite l'information spatiale de l'image. Le deuxième critère prend en compte la position des contours des objets dans l'image segmentée et le nombre de composantes connexes. Pour plus de détails, Tsai et al [64] ont proposé une étude des métaheuristiques appliquées aux problèmes de classification de données.

#### **II.3.2.3 Méthodes de segmentation basée sur la forme**

L'utilisation de l'approche MO dans la segmentation basée sur la forme a été réalisée par Simari et Singh [66]. Ils ont introduit la notion de segmentation de forme multi-objectif et l'utilisation du partitionnement de l'espace de Voronoi multiplicativement pondéré comme une approche du paramétrage de la segmentation. Les auteurs ont proposé des approches d'ensemencement pour initialiser les centres de Voronoi, y compris une nouvelle approche évolutive à usage général. Ils ont également présenté des stratégies pour faire correspondre automatiquement les segments à leurs étiquettes correspondantes, y compris une solution efficace optimale pour les objectifs unaires. La méthode a accepté des contraintes de symétrie qui réduisent efficacement la dimensionnalité du domaine d'optimisation lorsque la connaissance préalable de la forme est disponible. Ils ont utilisé la recherche généralisée de motifs pour leur optimisation et l'utilisateur n'a besoin que d'une fonction de contrainte qui

prend en compte les paramètres non redondants et qui produit les autres à partir d'une symétrie connue.

## **II.5 Conclusion**

Dans ce chapitre, nous avons présenté les principales approches de segmentation d'image et leurs améliorations à l'aide des métaheuristiques d'optimisation mono-objectif et multi-objectif. De plus, pour chaque famille de méthodes de segmentation d'image, nous avons cité les principaux travaux qui ont introduit les métaheuristiques d'optimisation. Également, nous avons présenté un ensemble de définitions liées au problème d'optimisation multi-objectif, ses contraintes, ses objectifs.

## Chapitre 3 : Techniques de segmentation des vaisseaux sanguins

### III.1 Introduction

Dans ce chapitre, nous présentons les aspects médicaux nécessaires pour comprendre l'importance de l'analyse des images du fond d'œil. Tout d'abord, l'anatomie de l'œil et ses principaux composants sont décrites; ensuite, les pathologies liées aux vaisseaux rétiens sont présentées. Ceci sera suivi par l'état de l'art des techniques de segmentation de vaisseaux rétiens. En outre, différentes bases de données et des méthodes d'évaluation des performances des algorithmes de segmentation seront présentées. Nous terminons ce chapitre par une discussion général sur les limites de segmentation de vaisseaux rétiens.

### III.2 Anatomie de l'œil humain

L'œil est l'organe essentiel de l'appareil visuel (figure III.1), et aussi l'organe sensoriel du corps humain qui reçoit 80% des informations extérieures. Sa fonction est de transformer l'information lumineuse en influx nerveux transmis au cerveau. Il est de faible volume (6.5 cm), pèse 7 grammes, et a la forme d'une sphère d'environ 24 mm de diamètre. La membrane résistante qui donne sa couleur blanche à l'œil en le recouvrant à 80 %, sur laquelle s'insèrent les muscles oculomoteurs. Au centre se trouve la cornée, qui permet de capter les premiers rayons de lumière et de commencer la réfraction [67]. Sous la sclère, on retrouve la choroïde, couche fine irriguée de vaisseaux sanguins et assurant la nutrition de la rétine et de l'iris. La rétine, située dans le fond du globe oculaire, au contact de la choroïde, correspond à la région directement sensible à la lumière, polarisée principalement par la cornée et le cristallin. Elle est composée de cellules en cônes et en bâtonnets, sensibles aux détails de l'environnement et à la luminosité. C'est à ce niveau que le signal lumineux va être traduit en message nerveux, et être envoyé au cerveau par le nerf optique. Au centre de l'œil, derrière la cornée, se situe l'iris, région qui confère sa couleur particulière au globe oculaire. En son centre, on retrouve la pupille, région sombre qui sous l'action de muscles, se contracte ou se dilate pour laisser passer plus ou moins de lumière, à l'instar d'un diaphragme sur un appareil photo.

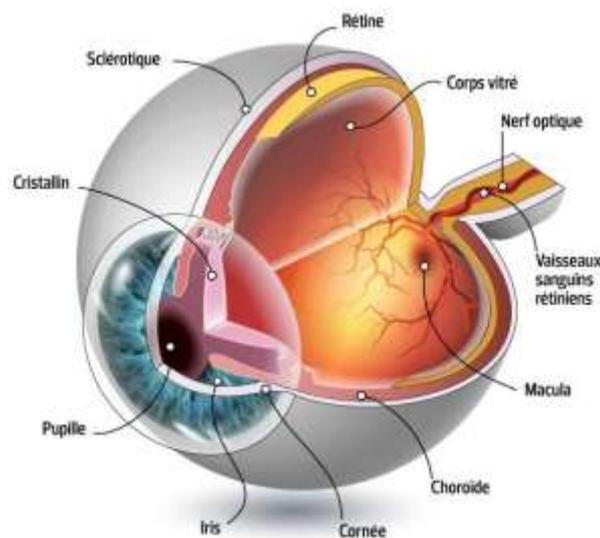


Figure III.1 : Coupe de l'œil en 3D légendée

### III.2.1 Anatomie d'une image de fond de l'œil

Une image de fond d'œil est présentée sur la figure III.2. On peut y distinguer les éléments suivants qui correspondent aux différentes parties de la rétine:

- **la macula** : également appelée « tache jaune », elle constitue la partie centrale de la rétine. Elle nous permet de voir les détails les plus fins en éclairage diurne.
- **La fovéa**: elle est située au centre d'une dépression de la macula. Comme elle est très riche en cônes, la vision y atteint la plus grande netteté.
- **La papille optique (tache aveugle)**: elle est le point d'arrivée et de départ des vaisseaux sanguins rétiniens. Elle représente également le point de départ du nerf optique. Elle est située à 4mm de la fovéa et mesure environ 1,5 mm de diamètre. Elle est appelée tache aveugle de Mariotte car elle ne comporte pas de photorécepteurs et ne perçoit pas de lumière. Ceci est dû à l'absence de cônes et de bâtonnets, cellules photoréceptrices rétiniennes nécessaires à la perception visuelle.
- **les vaisseaux sanguins** : ils sont de deux types : les artères qui transportent le sang de la papille vers la périphérie de la rétine, et les veines qui drainent le sang de la rétine vers la papille. Plus le vaisseau est près de la papille, plus son diamètre est important. Les veines diffèrent des artères par leur plus sombre aspect et par leur plus grand diamètre.

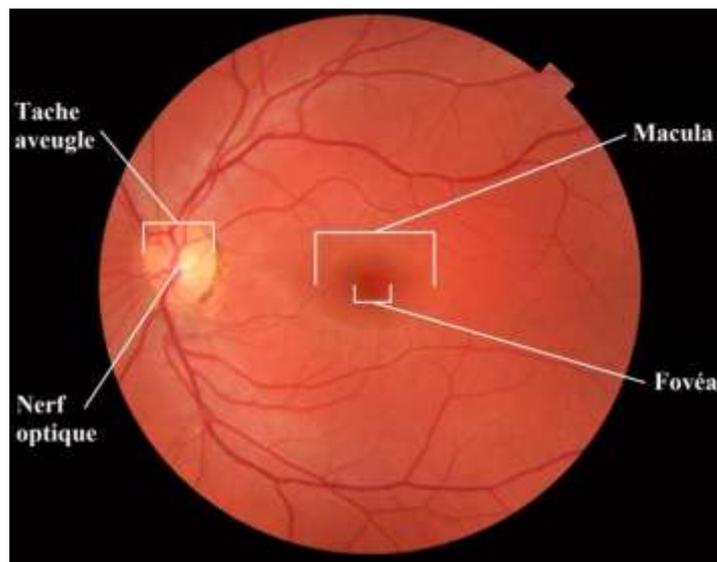
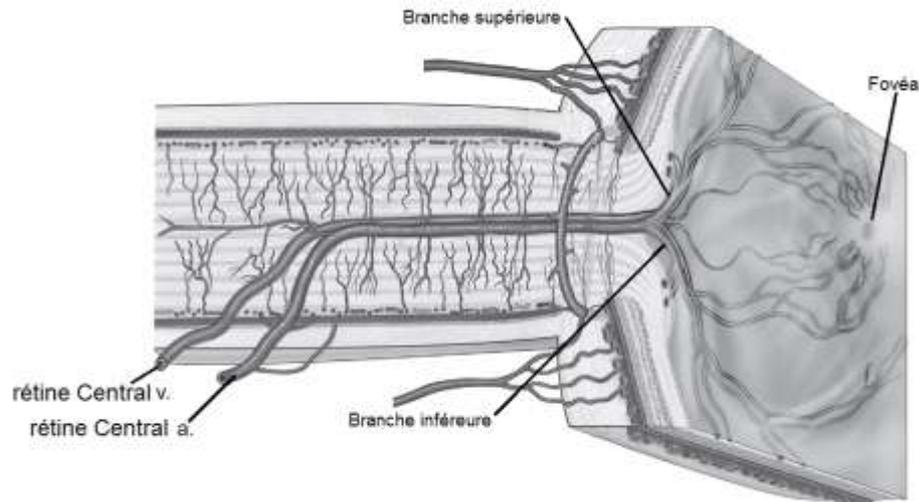


Figure III.2 : Anatomie du fond d'œil

### III.2.2 Vaisseaux rétiniens

L'apport sanguin de la rétine provient de l'artère rétinienne centrale, qui est une branche de l'artère ophtalmique (figure III.3). Il entre dans l'œil à partir du disque optique et suit un modèle assez standard au niveau des cellules ganglionnaires. Juste avant d'entrer dans l'œil, il est divisé en deux branches secondaires, l'inférieure et la supérieure. Chaque branche secondaire est en outre divisée en artères nasales et temporales. Les bifurcations continuent à

travers la périphérie, où il y a une réduction progressive dans le diamètre des vaisseaux. Ce changement graduel conduit à la bifurcation des grands vaisseaux en capillaires. Certaines branches temporales forment des arcades autour de la fovéa [68]. Le rôle du réseau vasculaire est d'organiser et d'optimiser l'approvisionnement en sang dans toutes les zones critiques de la rétine. En outre, il a été observé que le système vasculaire normal est guidé par des cellules neuronales préexistantes qui agissent comme des échafaudages pour la croissance des vaisseaux [68] [69].



**Figure III.3** Démonstration graphique du réseau de vaisseaux de la rétine. Les vaisseaux rétiens appartiennent à l'artère / veine rétinienne centrale; ils recouvrent la rétine dans une architecture arborescente, et ils sont superficiels à la rétine.

### III.2.3 Pathologies des vaisseaux rétiens

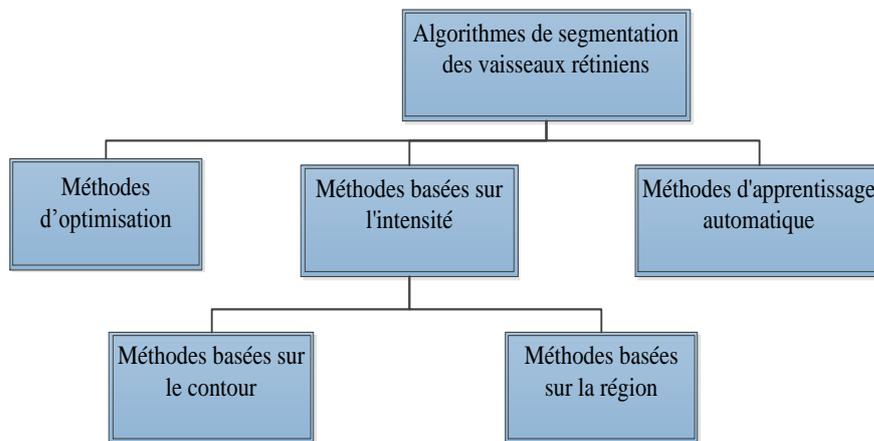
La cause principale de la rétinopathie diabétique (RD), est l'augmentation du glucose dans le sang. Elle produit des dommages dans les vaisseaux endothélium, résultant en une augmentation de leur perméabilité. Les premières manifestations des signes de la maladie sont les micro-anévrismes. La progression de la RD provoque des tortuosités et des changements de diamètre dans le réseau rétinien et donne naissance à des néovaisseaux. Par conséquent ; la segmentation du réseau vasculaire est une tâche importante pour la détection de la RD. elle peut révéler l'artériosclérose, le diabète, l'hypertension, et les maladies cardiovasculaires et d'AVC [70]. En outre, la localisation de l'arbre vasculaire est utilisée pour réduire le nombre de faux positifs dans la détection des micro-anévrismes et les hémorragies [71], [72]. Comme la structure de l'arbre vasculaire est caractéristique du patient, elle ne change pas ou très peu au cours d'une rétinopathie, cela privilégie l'usage des vaisseaux pour le recalage des images rétiennes prises à des moments différents (détection des points de bifurcation) [73]. En outre, l'arbre vasculaire est considéré comme le premier élément dans l'œil qui permet de se repérer.

### III.3 Les méthodes de segmentation des vaisseaux rétiens

Généralement, il y a eu un effort constant de classifier systématiquement toutes les méthodes de segmentation des vaisseaux rétiens selon la méthodologie suivie. Les premières méthodes de segmentation ont été catégorisées en approches base-contour ou approches base-région [74], et depuis l'établissement du domaine de la segmentation des

vaisseaux rétiniens, plusieurs nouvelles méthodes ont été présentées qui étendent et utilisent les nouvelles connaissances, de sorte que plusieurs sous-catégories ont commencé à émerger. Dernièrement, les scientifiques ont commencé à combiner des algorithmes dans des schémas hybrides, et il existe plusieurs articles qui ont été publiés dans la littérature qui présentent et catégorisent les différentes méthodes de segmentation des vaisseaux rétiniens [75] [76] [77]. Pour plus de détails, nous invitons le lecteur à consulter [78].

La catégorisation qui est suivie dans cette thèse est présentée dans la figure suivante (figure III.4). Pour chaque sous-catégorie, les principes de travail et les hypothèses seront donnés. Ensuite, une analyse critique des avantages et des inconvénients dans le contexte de la segmentation des vaisseaux rétiniens suivra.



**Figure III.4** Catégories de méthodes de segmentation des vaisseaux rétiniens.

### III.3.1 Méthodes basées sur l'intensité

Les méthodes basées sur l'intensité sont les plus grandes et les plus larges de toutes les catégories. Ces algorithmes segmentent les images en recherchant principalement des modèles d'intensité spécifiques dans les images. En revanche, les algorithmes basés sur l'intensité sont divisés entre les méthodes basées sur la région et les méthodes basées contour.

Les méthodes basées sur les contours tentent d'inclure et de regrouper dans un même contour, bord ou courbe les pixels qui satisfont un certain critère dépendant d'un modèle appliqué. Les pixels qui ne sont pas séparés par un bord sont affectés à la même catégorie.

Les méthodes basées sur une région fonctionnent de manière itérative en regroupant des pixels voisins qui ont des valeurs d'intensité similaires dans la même région ou en divisant des régions de pixels qui ont des valeurs dissemblables. Un algorithme fondamental qui applique les principes susmentionnés est la croissance de la région est présenté dans [79]. Toutes les méthodes suivantes de cette catégorie sont une extension du modèle de base. De plus, la représentation des données à l'aide de graphiques facilite l'application d'approches par chemin de coût minimum.

#### III.3.1.1 Filtrage adapté

L'une des premières méthodes de segmentation introduites pour les vaisseaux rétiniens était le filtrage adapté. Cette approche, qui a été proposée pour la première fois dans les

années 1980, est basée sur l'appariement de gabarits d'un petit segment de vaisseau représentatif le long de l'image entière dans le domaine spatial. Le filtrage adapté a été largement utilisé pour la segmentation des vaisseaux rétiniens [80] ainsi que pour la détection des artères coronaires par angiographie aux rayons X [81] et le dépistage des neurones à partir de la biomicroscopie confocale 3D [82]. Dans le cas des vaisseaux rétiniens, le modèle est construit comme un noyau de convolution 2D qui filtre l'image et améliore les vaisseaux. La conception du filtre est basée sur quatre hypothèses pour le système vasculaire. Premièrement, les grands vaisseaux présentent de petites courbures de sorte que le filtre peut être approché par un noyau droit par morceaux. Deuxièmement, le profil d'intensité transversal des vaisseaux peut être approximé par un gaussien, de sorte que le profil du filtre doit aussi être gaussien. Troisièmement, les vaisseaux peuvent apparaître dans différentes orientations et échelles, le filtre doit donc être adapté en conséquence. Enfin, les vaisseaux sont plus foncés que leur arrière-plan, de sorte que les côtés des filtres doivent être à un niveau d'intensité plus élevé que la région centrale.

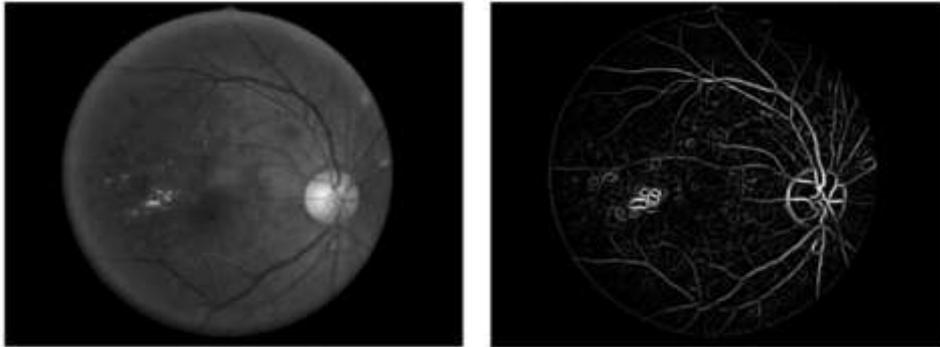
Lorsque le filtrage adapté est appliqué, l'effet est l'amélioration des vaisseaux par rapport à leur arrière-plan. Par la suite, le seuillage peut avoir lieu comme une dernière étape afin de segmenter les navires. Puisque le Gaussien est une représentation très générale, il y a des cas où il ne peut pas approcher de manière adéquate les formes des vaisseaux. Par exemple, lorsque la courbure est très élevée sur une courte distance. En outre, cette méthode a un problème de sur-segmentation des structures non pertinentes qui ressemblent à des vaisseaux. En effet, des structures physiologiques comme le disque optique ainsi que des pathologies telles que les microanévrismes et les lésions lumineuses peuvent être faussement reconnues comme une structure de vaisseau. Pour les plus petits vaisseaux en particulier (~ 3 pixels de diamètre), il peut ne pas y avoir assez d'échantillons pour modéliser le profil avec un modèle gaussien ou tout autre modèle.

Des efforts ont été déployés en vue d'améliorer plusieurs aspects de l'approche de base du filtrage adaptée ou d'introduire de nouvelles variantes en appliquant des modèles plus complexes. Par exemple, une sensibilité multi-échelle peut être obtenue en faisant varier la largeur du noyau et en retenant la réponse maximale sur toutes les échelles [83]. Récemment, un modèle gaussien à support courbe a été proposé pour modéliser des structures non droites [84]. De plus, afin de supprimer les fausses détections positives, certains auteurs ont proposé la combinaison de filtres appariés avec la dérivée de premier ordre du Gaussien [85]; tandis que d'autres exploitent les fonctionnalités dans la phase de seuillage [86]. Dans un autre cas [87], les auteurs ont utilisé le filtrage auto-adapté, où le modèle sélectionné est une version pivotée à 180° du voisinage local. Dans une autre étude, les auteurs ont optimisé de manière exhaustive les paramètres gaussiens avant l'application aux images rétiniennes afin de réduire le temps de calcul [88].

Des efforts ont été faits pour inclure plus d'informations pour couvrir tous les cas disponibles et surmonter les limitations possibles du modèle de base. Un problème est la réflexion centrale qui se produit sur les gros vaisseaux et qui apparaît comme une élévation au centre du Gaussien [89]. Certains auteurs ont d'ailleurs introduit des contraintes pour distinguer les vaisseaux des pathologies. L. Zhang et al. [90], par exemple, ont réduit les faux positifs des bords non linéaires (figure III.5) en incorporant un seuillage à double face dans le filtrage adapté gaussien. Ce modèle réduit la probabilité de réponses positives de pathologies non-vasculaires ou du disque optique. La transformation du profil d'intensité dans le domaine fréquentiel à l'aide de la congruence de phase [91] offre une échelle ainsi qu'une représentation

invariante de l'intensité de la section transversale du vaisseau, qui peut également compenser les frontières floues. Enfin, la modélisation des lésions sombres ou lumineuses a été rendue possible grâce à la modélisation multi-concavité [92]. Cette information a été à son tour incorporée dans des processus qui distinguent les vaisseaux des pathologies sur les images de la rétinopathie diabétique.

La détection de l'objet d'intérêt en le modélisant directement s'est révélée être un moyen efficace, mais simple, de filtrer la plus grande partie de la vascularisation à l'arrière-plan. Outre le filtrage adapté, d'autres méthodes basées sur des modèles ont été proposées dans la littérature.



**Figure III.5** Application du filtrage adapté standard dans une image de rétinopathie diabétique non proliférative.

### III.3.1.2 Traitement morphologique

Une représentation plus générale du vaisseau qui ne prend pas en compte l'information de section transversale est le traitement morphologique. Cette catégorie d'algorithmes tente de segmenter les vaisseaux dans l'image en examinant leur forme locale [93]. Les opérateurs morphologiques utilisés, sont essentiellement des moyens de combiner l'image avec un élément structurel qui définit la forme à chercher. Cette catégorie de méthodes est plus formalisée mathématiquement que le filtrage adapté, car leur contexte théorique repose sur la morphologie mathématique et les principes de la théorie des ensembles [94].

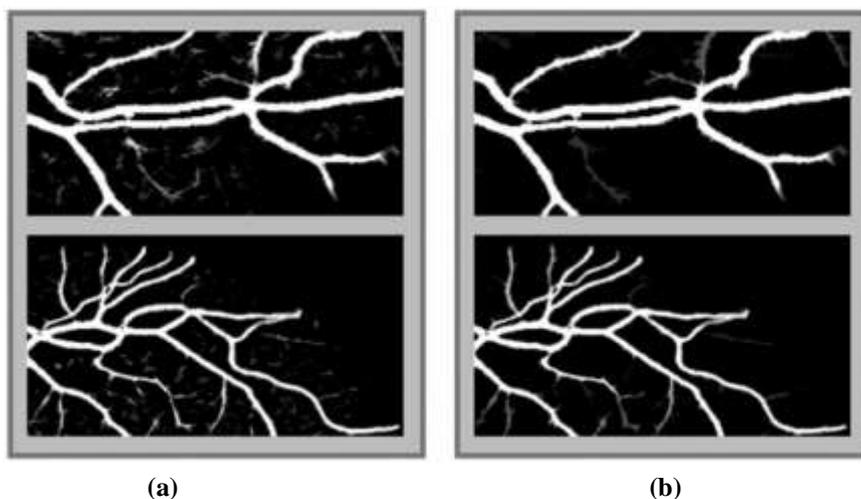
Les deux opérateurs morphologiques de base qui peuvent être utilisés sont la dilatation et l'érosion [79]. La dilatation se développe, supprime les trous et relie les objets proches séparés, en fonction de la forme de l'élément structurel. D'autre part, l'érosion rétrécit les objets et efface les petits objets isolés en arrière-plan de l'image, toujours en fonction de l'élément structural. Tous les opérateurs morphologiques, comme l'ouverture, la fermeture ou la top-hat sont des combinaisons de dilatations ou d'érosions dans différents ordres.

Les hypothèses de base qui sont considérées pour segmenter les vaisseaux comprennent le fait que les vaisseaux sont des structures allongées par morceaux, localement linéaires, de sorte que des éléments structuraux de même forme peuvent les isoler. En outre, les navires peuvent apparaître dans différentes orientations et échelles, de sorte que les éléments structuraux doivent être modifiés en conséquence. Enfin, les vaisseaux ont une intensité en niveaux de gris uniforme et plus élevée que le fond.

Les avantages de ces algorithmes par rapport aux autres méthodes disponibles incluent leur robustesse au bruit et leur coût de calcul réduit. De plus, la morphologie a été utilisée

dans les processus de pré / post-traitement [95]. Cependant, l'algorithme de base n'utilise pas les informations de section transversale des vaisseaux. De plus, le traitement morphologique est inexact en termes de localisation de la limite des vaisseaux. Les principes de base de ce type de méthodes ne sont pas non plus applicables dans les vaisseaux les plus minces ou les plus tortueux; et enfin, une sur-segmentation est fréquente à partir de structures physiologiques semblables à celles des vaisseaux. Plus particulièrement, pour les vaisseaux étroits, la taille et la forme de l'élément structural sont insuffisantes pour approcher les vaisseaux, de sorte qu'il y a une faible sensibilité dans ce cas.

Il existe plusieurs études qui utilisent un traitement morphologique soit pour améliorer ou segmenter les vaisseaux rétiniens. Dans [96], les vaisseaux étaient améliorés en appliquant un élément structural linéaire multidirectionnel; alors que récemment, A.M. Mendoca et al. [97] ont utilisé des éléments structuraux circulaires multi-échelles successives dans des opérations de top-hat pour améliorer les vaisseaux. De plus, M.S. Miri et A. Mahloojifar [98] ont proposé un nouveau schéma où des éléments multi-structuraux de différentes orientations et échelles sont utilisés dans la même zone de fenêtre pour segmenter les vaisseaux. Dans d'autres méthodes similaires [99] [100], les auteurs ont étudié le profil transversal gaussien des vaisseaux. Premièrement, ils ont calculé la courbure locale en utilisant le filtrage laplacien, et après cela, ils ont isolé les vaisseaux en appliquant un filtre alternatif avec un élément structurant linéaire et une reconstruction morphologique. Les auteurs de [101] ont tenté de surmonter le problème de la sur-segmentation du disque optique, en utilisant d'abord la morphologie pour localiser le disque optique, puis une série de processus morphologiques pour les vaisseaux rétiniens. Récemment, une nouvelle définition morphologique des chemins a été proposée (voir figure. III.6), qui peut reconnecter les pixels des vaisseaux à des chemins non rectilignes [102] [103]. Dans d'autre application, une recherche avancée inclut l'introduction de la morphologie à variation spatiale [104], où les vaisseaux à base de Hessian contrôlent la taille et l'orientation de l'élément structural. La figure III.6 représente un exemple d'ouverture de chemin appliquée sur une image de fond d'œil. Les deux images de la colonne gauche (a) représentent deux patchs d'images de fond œil, et les deux images de la colonne droite (b) représentent l'amélioration de ceux deux patchs par l'application de l'ouverture du chemin qui reconnecte la plus importante du vaisseau.

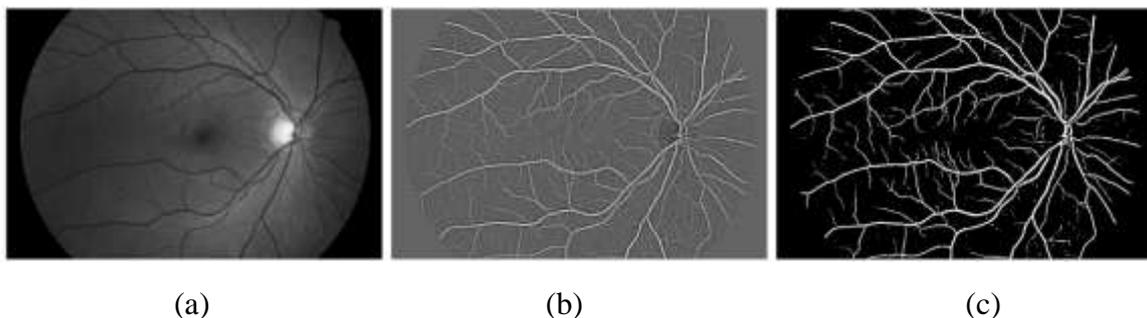


**Figure III.6** Exemple d'ouverture de chemin appliquée sur une image de fond d'œil.

### III.3.1.3 Détection de ligne

La plus simple de toutes les méthodes basées sur un modèle, qui n'inclue aucune information de largeur est la détection de ligne. L'hypothèse fondamentale qui est faite dans cette sous-catégorie d'algorithmes est que les vaisseaux sont des structures en forme de lignes allongées par morceaux avec une intensité plus faible que le fond. Dans le scénario de travail de base d'une approche à échelle unique, une ligne d'échantillonnage directe est utilisée pour calculer les intensités moyennes le long de différentes orientations à travers l'image entière dans le domaine spatial. Lorsque la ligne est parallèle aux vaisseaux, la réponse moyenne est maximale. La méthodologie est étroitement liée à la transformation de Radon et Hough discrète [105]. Cette méthode a d'abord été utilisée pour identifier les structures linéaires dans les données mammographiques [106]. Cependant, il a été récemment appliqué à des images rétiniennes [107] (figure. III.7).

Récemment, il a été adapté à des systèmes à échelles multiples pour couvrir tous les diamètres des vaisseaux disponibles en faisant varier la longueur de la ligne d'échantillonnage [108]. De plus, les approches basées sur les lignes sont peu coûteuses en termes de temps de calcul, et peuvent être combinées dans des schémas hybrides [103]. Un inconvénient du détecteur de ligne est qu'il produit des réponses élevées dans des pathologies telles que les microanévrismes et les lésions lumineuses, car ces structures ont des caractéristiques similaires à celles des vaisseaux. Cette méthode a été efficacement abordée en examinant plus attentivement les résultats obtenus par les détecteurs de ligne. Plus précisément, on peut supposer que dans le cas du vaisseau, il y aura un pic dans la réponse du filtre dans une direction spécifique, parallèle à la direction du vaisseau, tandis que dans les petits microanévrismes, la réponse sera élevée dans tous les directions. Une autre limitation est dans la détection des bifurcations des vaisseaux. Ce problème a été tenté d'être résolu en représentant l'image locale autour du point central examiné en coordonnées polaires [109]; une autre possibilité consiste à utiliser l'analyse de l'espace d'orientation [110] pour identifier des pics de réponses multiples qui indiquent l'existence d'une jonction ou d'un croisement. Sur la base des détecteurs de ligne, d'autres auteurs ont étendu la méthode à appliquer dans la localisation du disque optique [111]. Une configuration différente de plusieurs lignes parallèles, ou la mesure du contraste au lieu de l'intensité, a été mise en place afin de faciliter la détection des plus petits vaisseaux [112] [113].



**Figure III.7** Exemple d'approche de détection de la ligne multi-échelle (MSLD) appliquée à une image rétinienne de haute résolution. (a) image d'entrée, (b) réponse MSLD et (c) vaisseaux segmentés par le seuillage.

### III.3.1.4 Méthodes dérivées

Dans cette catégorie d'algorithmes, on suppose que les images sont des fonctions bidimensionnelles  $f(x, y)$  où les vaisseaux apparaissent comme des maxima ou des minima

locaux. La détection du vaisseau est ensuite effectuée en examinant les propriétés des dérivés de l'image. L'une des premières méthodes adoptées pour la segmentation des vaisseaux était la détection des contours par des dérivées ou des gradients de premier ordre. Des filtres pour la détection de contours (Sobel, Prewitt, Robert, Canny) ont été utilisés dans de nombreuses études [114] [115] [116]. Le processus est basé sur des primitives de bas niveau, où l'implémentation de filtre est faite dans un temps raisonnable. La méthode essaie d'identifier la direction du gradient local avec sa réponse. Cependant, les noyaux ne peuvent pas facilement manipuler des vaisseaux non-droits. Deuxièmement, les noyaux sont à échelle unique et ne prennent pas en compte aucune information sur la variation d'intensité. Troisièmement, la méthode ne peut détecter que la limite des grands navires; alors que sa réponse est faible si la ligne dévie du contour.

Différents groupes ont tenté d'aborder certains problèmes liés aux méthodes basées sur le gradient en prenant en compte le fait que le profil transversal des vaisseaux est un gaussien. Pour ce faire, ils ont utilisé la dérivée de premier ordre de la fonction gaussienne [97]. Le premier ordre améliore les performances des détecteurs de contour basés sur le gradient de base; cependant, il extrait uniquement les traits d'axe fragmentés. Le post-traitement est donc nécessaire pour connecter les vaisseaux fragmentés détectés. De plus, la convolution avec un filtre gaussien est équivalente à l'application du filtrage dans toutes les directions de l'image (diffusion isotrope) [117]; où la direction du gradient détermine l'orientation du filtrage. Lorsque le filtrage isotrope est appliqué aux images, il supprime le bruit excessif dans le fond; cependant au détriment de filtrer la limite de vaisseaux, en fusionnant les vaisseaux voisins les plus proche, et en filtrant dehors de petits navires. Une diffusion anisotrope a été proposée pour surmonter le problème en filtrant l'image dans une direction orthogonale au gradient détecté [118] [119]. Pour le problème de la fusion des vaisseaux voisins les plus proches, les méthodes alternatives qui ont été proposées utilisent le flux vectoriel de gradient [120] ou le flux orienté de manière optimale [121].

### III.3.1.5 Contours actifs

Contours actifs ou serpents, qui ont d'abord été proposés par Kass et al. [122], font partie de la méthodologie des modèles déformables. Ces méthodes suivent l'évolution d'un contour avec le temps en modifiant une courbe initiale en fonction de certaines contraintes ou forces.

Les contours actifs définissent la position du modèle comme  $v(s) = (x(s), y(s))$  avec  $s \in [0, I]$  et tentent de minimiser l'énergie associée à ses contraintes de forme (interne), et sa distance par rapport aux caractéristiques d'intérêt (externe) comme le montre l'équation suivante (équation III.1):

$$E_{serpent} = \frac{1}{2} \int_0^1 \left[ \alpha \left| \frac{\partial^2 v}{\partial s^2} \right| + \beta \left| \frac{\partial^4 v}{\partial s^4} \right| \right] + E_{externe} \partial s \quad (\text{III.1})$$

Dans cette équation, les deux premiers termes contrôlent l'étirement et la flexion du serpent, tandis que le troisième terme attire le serpent à la position cible. Dans le cas d'origine, c'était le gradient d'image:  $E_{externe} = -|\nabla I(x, y)|$  [122].

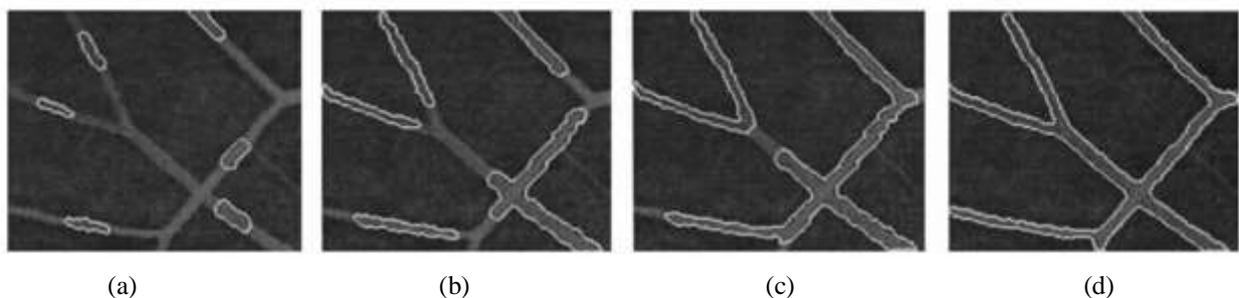
Les avantages de l'utilisation de cette famille d'algorithmes dans la segmentation des vaisseaux sont leur efficacité de calcul, au moins pour le cas 2D, la possibilité de suivre leur évolution en "temps réel", et leur interactivité. Par exemple, l'utilisateur peut placer des contraintes de haut niveau ou des points que la courbe sera obligé de converger ou d'éviter.

De plus, la courbe peut être représentée avec des splines qui permettent la précision et la douceur du sous-pixel [123]. Enfin, les contours actifs démontrent une robustesse vers des limites fragmentées ou incomplètes. D'autre part, en raison du paramétrage du contour, une bonne initialisation est une condition préalable. Si cela ne se produit pas, la courbe peut être piégée facilement dans les minimums locaux ou attiré par des caractéristiques similaires à celles de la cible dans le voisinage. L'incapacité de changer de topologie est une autre faiblesse des courbes, même s'il y a des efforts pour surmonter cette limitation.

Les contours actifs ont été largement appliqués dans de nombreuses applications de segmentation de vaisseaux 2D / 3D. De nombreuses directions de recherche ont été étudiées pour d'éventuelles améliorations. Dans le cas des forces externes, la métrique statique originale n'était pas assez robuste lorsque des concavités étaient rencontrées et elle devait être initialisée très près de la limite de l'objet d'intérêt. Les percées qui ont été proposées incluent un gonflement dynamique, comme une force de ballon [124]; tandis que le flux de vecteurs de gradient [125], et la convolution de champ de vecteurs [126] sont considérés comme état de l'art. Dans le contexte de la segmentation des vaisseaux, un nouvel avancement est le courbe-propre proposé par R. Toledo et al. [127]. La force externe, ici, apprend à reconnaître, par classification, les caractéristiques des vaisseaux en filtrant l'image à plusieurs échelles dans la direction du vecteur propre principal du tenseur structural.

Des contraintes géométriques d'ordre supérieur sont utilisées dans les courbes à ruban [128]. On suppose que les structures linéaires allongées, comme les vaisseaux, consistent en deux arêtes parallèles de diamètre variable. Ainsi, deux courbes parallèles peuvent être installés sur la limite des lignes. Similairement, Bashir Al-Diri et al. [129] ont utilisé l'approche du courbe ruban pour la segmentation, mais pour faciliter l'initialisation du modèle, ils ont tout d'abord identifié les axes par le filtrage de tramline.

Un autre inconvénient de la méthodologie originale de contour actif est l'incapacité de changer sa topologie, selon le principe de diviser et de fusionner au cours de son évolution. Ce problème a été résolu par des topologies adaptatives de T-courbes [130] et plus récemment par les réseaux actifs topologiques étendus [131]. La figure III.8 montre un exemple de T-serpents appliqués sur l'image rétinienne. Plusieurs T-courbes sont initialisés à travers les vaisseaux qui fusionnent pour segmenter les vaisseaux. Les contours actifs représentent explicitement le modèle déformable sur le plan de l'image. Une extension méthodologique consiste à représenter implicitement le modèle évolutif, en tant qu'interface entre une hypersurface et le plan image



**Figure III.8** Exemple de segmentation d'un vaisseau par T-serpent.

### III.3.1.6 Suivi par croissance de région

Un inconvénient majeur de base de la méthode de suivi par croissance de région est qu'elle ne limite pas la croissance d'une région à une forme spécifique localement, ce qui

conduit à des phénomènes de fuite dans les zones à faible contraste. Cette limitation est surmenée par l'introduction d'une contrainte dans le processus de croissance de régions. Selon cette considération, le suivi est un processus itératif, dans lequel un modèle de vaisseau est comparé à un segment d'image local pour obtenir les paramètres du trait d'axe et de la largeur du vaisseau. Ceci est suivi par la prédiction de la direction à partir de la position actuelle via l'optimisation.

Les avantages du suivi par rapport à d'autres méthodes incluent le faible fardeau de calcul puisque l'image est traitée localement. La connectivité est également préservée car la méthode est basée sur un algorithme de croissance de région. De plus, l'utilisation d'un modèle explicite permet d'extraire les informations locales de la position et du diamètre de la ligne centrale. D'autre part, les limites de la méthode comprennent l'incapacité de poursuivre le processus de suivi lorsque des zones difficiles sont rencontrées. Dans notre contexte, les régions difficiles sont celles qui démontrent une réduction du contraste et du diamètre du vaisseau/arrière-plan, des bifurcations, des traversées de vaisseaux ou des vaisseaux adjacents rencontrés.

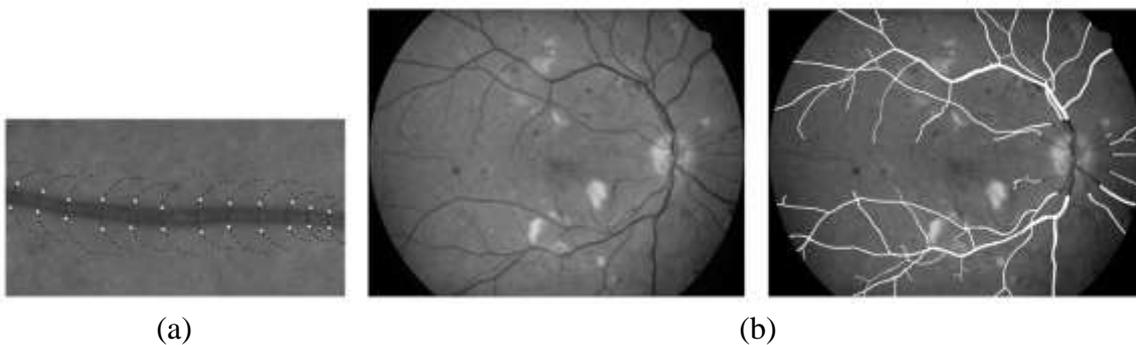
Plusieurs descriptions de modèles de vaisseaux existent dans la littérature. Par exemple, on peut supposer que la limite des vaisseaux coïncide avec les crêtes calculées par l'amplitude du gradient [132] ou la matrice de Hesse [133] dans une étape de prétraitement. La correspondance de modèle est aussi une autre option [134]. Enfin, un modèle transversal comparé ou adapté localement au profil de vaisseau perpendiculaire correspondant a été proposé [135]; le modèle peut être similaire au modèle de recherche plus spécifique; le modèle double gaussien, ou pour plus général, le modèle section-transversale ellipsoïde [136]. Le suivi tubulaire, tel que proposé dans [137], qui utilise un gabarit de section circulaire généralisé pour localiser le vaisseau, est considéré plus approprié pour notre application. Comme il s'agit d'une représentation générale des vaisseaux, il peut se rapprocher non seulement des vaisseaux de taille moyenne à grande, mais aussi des petits vaisseaux qui ont un profil transversal différent, plutôt circulaire.

L'étape d'optimisation tente de trouver l'emplacement ou la direction possible du vaisseau à l'étape suivante. La prédiction correcte de la direction locale peut être obtenue en regardant dans la direction indiquée dans une étape de suivi précédente. La prédiction correcte de la direction locale peut être obtenue en regardant dans la direction indiquée dans une étape de suivi précédente. Ensuite, dans la prochaine itération, le modèle est recentré en utilisant différentes mesures. Classification par Fuzzy C-Mean [138], filtrage de Kalman [139], filtrage de particules [140], et le suivi bayésien [141] ont été utilisés (voir figure. III.9).

Le regroupement de C-mean flou est une approche de classification non supervisée. Le filtrage de Kalman identifie la direction possible en prenant en compte toutes les prédictions précédentes d'une manière probabiliste; Cependant, il s'agit d'une méthode d'hypothèse unique qui ne tient pas en compte des chemins alternatifs dans les cas de faible contraste ou de ramification. Une extension de la première méthodologie est le filtrage des particules, une approche à hypothèses multiples, qui utilise un nombre de particules représentant chacune un état alternatif. L'effet net est de surmonter les limitations précédentes au détriment de l'augmentation du coût de calcul, au moins pour les problèmes tridimensionnels. Une optimisation basée sur la maximisation du critère a posteriori de la théorie de Bayes afin d'identifier les bords du vaisseau a également été proposée. De manière purement déterministe, le test d'hypothèses multiples (MHT) [137], qui n'a été appliqué qu'aux applications 3D, trouve la meilleure direction en testant toutes les options de

branchement disponibles jusqu'à une profondeur prédéfinie dans l'espace de recherche. Cela permet à la méthode de décider de la direction du vaisseau local en utilisant les informations des étapes suivantes afin de surmonter les zones difficiles. Une autre approche qui a été proposée, est la prédiction basée sur les moments géométriques de l'image, qui a été appliquée sur l'application de la CT d'angiographie [142].

Le suivi a été combiné avec des modèles déformables pour augmenter le processus [143]. L'initialisation automatique a également été réalisée en utilisant une étape de prétraitement où les points probables des vaisseaux sont identifiés en appliquant un filtrage gaussien simple [144], ou en considérant les points de terminaison de grands vaisseaux pré-identifiés comme les graines de suivi dans les schémas hybrides. Les méthodes basées sur les régions sont subdivisées en algorithmes en fonction de la représentation des données utilisées. Les méthodes de suivi sont directement appliquées sur l'espace de l'image tout en représentant les images comme des graphiques nous permettent d'utiliser des techniques de coût minimum.



**Figure III.9** Exemple de suivi: (a) suivi des itérations le long d'un vaisseau droit. (b) suivi du résultat sur une image du fond d'œil à haute résolution

### III.3.1.7 Chemin de coût minimum

Dans le cas semi-automatique, compte tenu d'un point de départ et d'un point final à l'intérieur d'un vaisseau, il peut utiliser une approche à coût minimal pour identifier la ligne centrale. D'une manière générale, les méthodes à coût minimum essaient de minimiser une fonction de coût associée au chemin qui relie deux points. Représenter les données sous la forme d'un graphe non orienté pondéré avec des sommets comme pixels d'image et des poids de bord comme intensités peut aider à appliquer la méthode du plus court chemin proposée par Dijkstra [145]. La marche rapide [146] est un autre schéma d'optimisation numérique, lié à l'approche de l'ensemble des niveaux, qui tente de trouver le chemin le plus court en résolvant l'équation d'Eikonal.

La méthode est robuste contre les discontinuités possibles ou les zones à faible contraste [147]; par contre, le deuxième point est requis et une seule ligne centrale est définie entre deux points à la fois. Un autre problème potentiel; ils existent des cas de chemins minima locaux extraits par l'algorithme qui sont des raccourcis, en particulier dans les zones à faible contraste. Cela peut être résolu en sélectionnant un coût approprié, la règle d'agrégation des coûts et un terme pénalisant pour s'éloigner du cours souhaité. Par exemple, dans [148], les auteurs ont utilisé le vaisseau de Hesse à la place de l'intensité des niveaux de gris pour augmenter la probabilité de contraindre le chemin dans le vaisseau. Dans [149] également, les auteurs ont pénalisé les grands changements dans le niveau d'intensité moyen autour d'un voisinage qui pourrait signifier le saut du chemin vers un vaisseau proche adjacent (raccourci). En outre, ils ont pénalisé différemment la diagonale des transitions verticales ou horizontales. Un terme de régularisation de la courbure, indépendant de la longueur du

vaisseau, a été introduit et qui traite le problème des raccourcis dans les images rétiniennes [150]. Dernièrement, la combinaison de la pénalisation de la courbure avec une nouvelle métrique définie sur l'espace d'orientation a été proposée pour traiter le même problème [151]. Cependant, il a seulement été appliqué pour la détection de contours fermés dans des images naturelles.

De plus, l'extraction d'une ligne centrale unique nécessite l'exploration exhaustive de l'espace de recherche, ce qui augmente considérablement le temps de calcul. Les méthodes qui ont été proposées pour accélérer le processus de recherche comprennent la propagation bidirectionnelle [152], où la recherche est initiée à la fois par le point source et le point cible. Finalement, les arbres de recherche qui commencent à partir de ces deux points se rencontrent dans un pixel d'image, et le chemin optimal est extrait. Dans une autre approche, un système de congélation, qui sert de critère d'arrêt pour la poursuite de la recherche de branches avec des coûts très élevés, est introduit [153].

Les techniques de chemin de coût minimum ont pour but d'extraire les traits d'axe; cependant, nous pourrions être intéressés par l'extraction de vaisseaux entiers. Une façon de surmonter ce problème consiste à incorporer une dimension supplémentaire qui correspond à la largeur du vaisseau. Dans [154], les auteurs ont modifié l'algorithme de la marche rapide pour inclure la caractéristique précitée, et l'ont appliquée à plusieurs applications, y compris à des images provenant de données ophtalmologiques.

Enfin, les algorithmes nécessitent l'intervention de l'utilisateur. Par contre, une approche exploratoire a été proposée, dernièrement, pour surmonter le problème. R. Estrada et al. [155] ont développé un algorithme basé sur la représentation de la forêt, qui applique une procédure itérative jusqu'à ce que la convergence soit atteinte et que l'ensemble du réseau de vaisseaux rétiniens soit segmenté sans intervention de l'utilisateur. Récemment, Da Chen et al. [156] ont utilisé un schéma de marche rapide anisotrope appliqué sur les points clés des vaisseaux détectés pour extraire le système vasculaire rétinien complet à partir d'une seule image rétinienne. La figure III.10 donne un exemple de ce système.



**Figure III.10:** Exemple d'application de la marche rapide anisotrope proposée pour la segmentation complète des vaisseaux rétiniens.

### III.3.1.8 Méthodes à base d'apprentissage

Les algorithmes basés sur des techniques d'apprentissage automatique traitent de la détermination automatique de la classe d'un pixel examiné. Dans notre cas, nous avons généralement un problème à deux classes: 1) vaisseau et 2) non-vaisseau ou arrière-plan. Les méthodes ici sont divisées en deux sous-catégories principales: supervisé et non supervisé.

Le processus d'apprentissage est effectué après l'extraction des descripteurs de vaisseau, et une grande variété de descripteurs de caractéristiques a été proposée dans la littérature. Les descripteurs sont basés sur l'extraction de caractéristiques. Pour cela, un ensemble de caractéristique d'image N-dimensionnelle de chaque pixel est requis.

## A. Méthodes supervisé

Les algorithmes supervisés se composent généralement de deux étapes, l'étape de conception et la phase d'application. La séquence d'actions est la suivante : un classificateur spécial est utilisé en premier lieu, puis une règle pour la détection de vaisseau est statistiquement apprise en employant un ensemble d'entraînement caractéristique étiqueté. Habituellement, ce dernier est un sous-ensemble des données disponibles qui agit comme un ensemble de validation pour le classificateur. Ensuite, le classificateur entraîné est appliqué à une nouvelle image, qui appartient à l'ensemble de test, auquel cas il classe ses pixels en tant que vaisseaux ou non vaisseaux. La catégorisation résultante peut être difficile, en attribuant explicitement le pixel examiné dans l'une de la classe disponible, où le pixel examiné est affecté d'une probabilité appartenant à une classe spécifique.

Il y a certains avantages et inconvénients liés à cette catégorie d'algorithmes. Premièrement, la performance des algorithmes dépend du réglage soigneux de ses composants. L'existence d'une vérité-terrain ou d'un ensemble étiqueté manuellement, en outre, est une condition préalable puisqu'elle est utilisée pour former les classificateurs. Cet ensemble devrait être représentatif de l'ensemble de tests qui sera utilisé pour évaluer l'algorithme. Pour les plus petits vaisseaux, plus particulièrement, l'étiquetage peut être effectué avec peu de consensus sur leur position exacte parmi les experts, ce qui entraîne des défis supplémentaires pour le classificateur. La sélection des caractéristiques, en outre, devrait être appropriée pour l'application et devrait donner un bon pouvoir de discrimination. Un sur-ajustement peut également être observé. Enfin, le classificateur doit être suffisamment robuste pour pouvoir gérer le problème. Les Néovascularisations (NVs) peuvent plus particulièrement démontrer une variabilité élevée de leur forme et de leur emplacement; Avec le fait que les NVs sont rares, cela peut compliquer la construction d'un ensemble représentatif de caractéristiques. Si les conditions précédentes sont satisfaites puis supervisées, les méthodes sont généralement meilleures que les autres approches disponibles. Un autre avantage est qu'ils peuvent être perçus comme une boîte noire; par conséquent, après la phase de test, l'utilisateur entre simplement l'image, sans se soucier de régler les paramètres. La section suivante présentera quelques exemples où des algorithmes supervisés ont été utilisés pour segmenter le vaisseau rétinien. L'analyse se concentrera principalement sur l'analyse de l'existence de différentes catégories de classificateurs.

Habituellement, les méthodes sont classées en fonction du classificateur qu'elles utilisent, de sorte que nous pouvons avoir les méthodes suivantes basées sur : 1) Artificial neural networks (ANNs) [157] [158] [159], 2) K-nearest classifiers (KNNs) [160] [161], 3) Support vector machines (SVMs) [107] [109], et 4) Statistical [162] [163].

Inspirés par une unité de traitement biologique (le neurone), les ANNs ont été proposés. Un neurone artificiel est une représentation mathématique en fonction des transformations qui se produisent sur une entrée dans un neurone biologique. Basé sur l'unité fondamentale, les ANNs ont été proposées comme un premier effort pour modéliser le système de perception visuelle humaine. Le système artificiel est un réseau en couches de nœuds interconnectés, où l'entrée est transformée en fonction d'une fonction de caractéristique

et de certains poids adaptatifs. L'entrée est le vecteur de caractéristiques et la sortie est la décision concernant le vecteur d'entrée. La phase d'apprentissage implique l'ajustement du poids. ANNs est une méthode de classification non linéaire. D. Marín et al. [157] utilisé le ANN et un vecteur 7-D composé de niveau de gris et de caractéristiques à base de moment invariant pour la discrimination vaisseau / non-vaisseau.

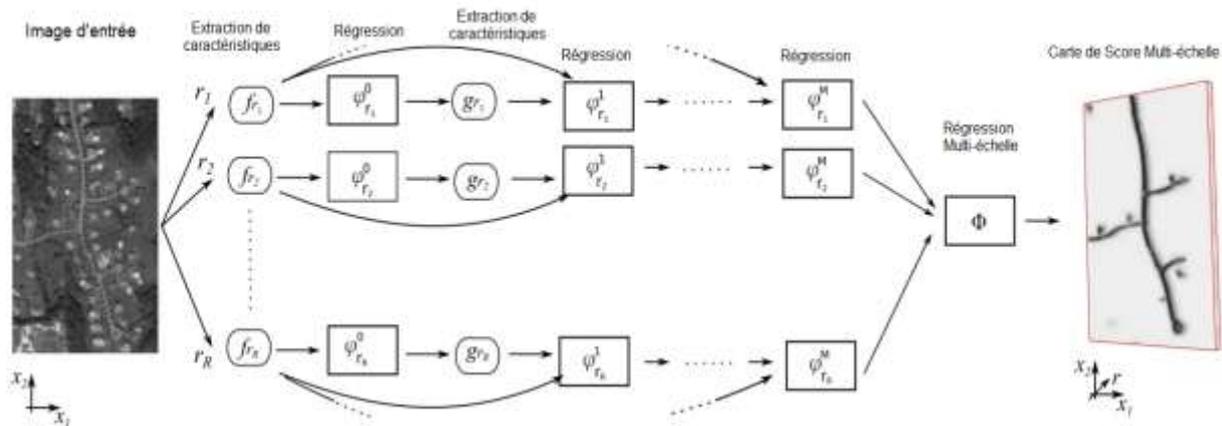
Le principe général derrière la deuxième catégorie, KNNs, est que les valeurs dans l'espace des caractéristiques sont similaires pour les pixels qui appartiennent à la même classe, dans un sens, ils sont groupés à une distance proche. Ainsi, le but est de trouver la frontière de décision qui sépare les clusters [161]. Afin de trouver cette limite ; un ensemble d'entraînement est utilisé. Une caractéristique particulière de ce classificateur est qu'il peut produire une classification souple, à savoir de la probabilité de pixel pour appartenir à une certaine classe.

SVM, essayez de trouver une limite qui sépare les fonctionnalités. Le but de ce classificateur est de trouver un hyperplan dans l'espace caractéristique N-dimensionnel qui maximise la marge fonctionnelle, à savoir la distance entre l'hyperplan et le point le plus proche de n'importe quelle classe. Ensuite, dans la phase de test, chaque vecteur de caractéristiques d'entrée sera assigné dans une classe en rapport à sa position à partir de la fonction d'hyperplan entraîné. Il existe différents algorithmes qui ont été proposés dans la littérature qui utilisent des SVM. Par exemple, Ricci et R. Perfetti [107] ont proposé un schéma, où d'abord un détecteur de ligne à échelle unique est utilisé pour obtenir les caractéristiques et ensuite le SVM est appliqué pour la classification des pixels. D'après les résultats trouvés, la performance de SVM est très bonne dans la base de données publique. En outre, une nouvelle approche consiste à combiner différents classificateurs pour augmenter le pouvoir de discrimination. Cet ensemble de schéma est utilisé pour améliorer la classification en pondérant "l'opinion" de chaque classificateur employé individuellement.

Les méthodes supervisées supplémentaires qui ont été proposées pour la segmentation des structures vasculaires sont l'apprentissage par renforcement et la régression. Les algorithmes d'apprentissage par renforcement tentent de trouver la solution optimale en interagissant avec leur environnement. Le concept de récompense ou de punition dans la phase d'apprentissage est introduit, où le retour est obtenu par une comparaison du résultat d'une action avec une segmentation ou une mesure idéale [164]. Dans [165], les auteurs ont appliqué l'apprentissage par renforcement pour faciliter le placement automatique d'un contour de segmentation sur les ventricules cardiaques. La régression est une méthode d'ajustement statistique d'une fonction à l'espace des caractéristiques [166], qui à son tour, agit comme le plan de séparation des classes. Différents types de régression existent qui dépendent de la fonction ajustée (linéaire, logistique, etc.). Dans le contexte biomédical, ce classificateur a été utilisé dans [167] (voir figure III.11) pour l'extraction des neurones et la détection des vaisseaux [168].

## **B. Méthodes non supervisé**

Comme dans la catégorie précédente, dans l'apprentissage non supervisé, nous essayons de reconnaître le motif sous-jacent des vaisseaux dans un espace de caractéristique d'image. Contrairement à l'apprentissage supervisé, un ensemble d'étiquettes de vérité-terrain n'est pas requis pour l'apprentissage.



**Figure III.11** Exemple d'application de la régression multi-échelle pour la détection de la ligne centrale.

Parmi les différentes méthodes non supervisées, le clustering est l'approche la plus étudiée. Clustering est une catégorie d'algorithmes divers qui tente de regrouper le vecteur de caractéristiques dans différents groupes de sorte que différents groupes aient autant d'objets dissemblables que possible. Les fonctions de dissimilarité mesurent la distance entre les objets, tandis qu'un sous-ensemble des caractéristiques existantes est choisi pour être utilisé dans le regroupement. Le nombre de groupes définit le nombre d'objets d'intérêt. Dans le cas du problème de la segmentation des vaisseaux saines, l'application peut être décrite comme un problème de clustering binaire (vaisseau / non vaisseau), de sorte que le nombre de clusters que nous allons utiliser est connu a priori. Cependant, pour le problème des néovaisseaux, la tâche de définir le nombre de clusters n'est pas triviale.

De nombreuses définitions sur le clustering existent dans la littérature. De plus, l'utilisation de différentes fonctions de similarité donne lieu au nombre total d'algorithmes disponibles [169]. L'initialisation des centres de clusters dans l'espace des caractéristiques est également un défi dans le problème de la segmentation des petits vaisseaux car l'étape d'optimisation ne garantit pas la convergence des centres de clusters vers le minimum global. L'initialisation des centres de clusters dans l'espace des caractéristiques est également un défi dans le problème de la segmentation des petits vaisseaux car l'étape d'optimisation ne garantit pas la convergence des centres de clusters vers le minimum global. Pour commencer, le clustering peut être distingué en hard ou soft / fuzzy. Dans le premier cas, l'algorithme attribue les caractéristiques comme appartenant à un seul cluster; tandis que dans le dernier cas, une fonction est utilisée pour montrer la probabilité d'appartenance aux entités dans tous les clusters disponibles.

L'algorithme de clustering le plus simple est le K-means qui vise à regrouper les caractéristiques dans les clusters qui se trouvent à la distance minimale. Le processus est itératif et inclut l'étape d'affectation, où les caractéristiques sont affectées aux clusters les plus proches, et l'étape de mise à jour où l'emplacement des clusters est recalculé. Comme les exemples K-NN [161] et Fuzzy C-Means [170]. Une autre approche consiste à supposer que les caractéristiques proviennent d'une distribution mixte gaussienne. Afin de trouver les paramètres de chaque distribution (moyenne, écart-type, poids), l'espérance-maximisation (EM) peut être utilisée [171]. Cette technique a également été appliquée en dehors du contexte de la classification [172]. Une autre sous-catégorie d'algorithmes est la classification hiérarchique. Ici, un dendrogramme est construit qui représente le groupement des entités

dans les groupes et leur similarité correspondante à chaque itération. Cette méthode a été appliquée dans l'étude suivante [173] pour trouver le meilleur seuil dans un histogramme d'image, qui a ensuite été utilisé pour la segmentation des vaisseaux. Récemment, des approches évolutives ont été considérées pour le clustering. Le principe de fonctionnement est tiré de l'évolution biologique, et donc la notation est la même (mutation, gène, génération, parents, filles, sélection, croisement, etc.).

La méthode de classification non supervisée équivalente à l'ANNs est les cartes auto-organisatrices ou SOM. Cette technique, proposée pour la première fois par T. Kohonen [174], repose sur les principes neurobiologiques de la perception visuelle et sur la façon dont le biosignal est traité précocement dans la rétine neurale par l'apprentissage compétitif [175]. Dans cette technique, les neurones sont reliés entre eux forment des groupes locaux dans la même couche. Plus tard, dans la phase d'apprentissage, les neurones sont en compétition dans un stimulus donné, qui est un échantillon aléatoire de l'ensemble d'apprentissage. Le gagnant est déterminé par la distance entre l'entrée et la sortie des neurones modifiés par certains poids présélectionnés. L'activité du neurone gagnant est alors répartie sur une courte distance renforçant mutuellement les poids des cellules voisines. Après de nombreux cycles d'apprentissage, les tests ont lieu où les SOM sont appliquées à un nouvel ensemble d'images. Les SOM et le clustering ont été combinés pour segmenter les vaisseaux rétiniens [176].

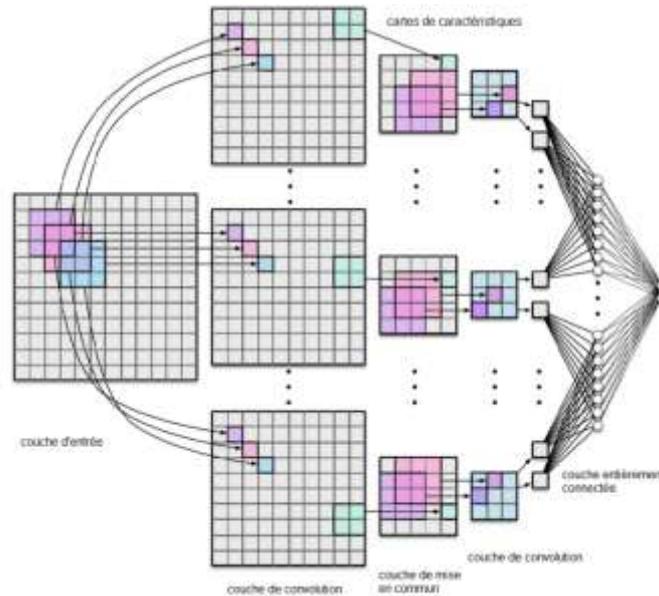
### **III.3.2 Apprentissage en profondeur**

L'apprentissage en profondeur est apparu comme une alternative à la méthode ANNs pour les tâches d'analyse d'image donnant des résultats très prometteurs [177]. Des progrès significatifs ont permis à l'apprentissage en profondeur de surpasser les ANNs traditionnelles ainsi que d'autres méthodes supervisées [178]. Ceux-ci incluent l'utilisation d'une fonction caractéristique simple pour accélérer la phase d'entraînement.

L'étape d'extraction de caractéristiques automatiques est réalisée par la convolution de l'image d'entrée avec des noyaux entraînaables (CNN). En outre, l'introduction d'architectures profondes avec de nombreuses couches interconnectées capables de représenter des hiérarchies de composition complexes, à savoir des fonctions d'ordre supérieur reposant sur des fonctionnalités de niveau inférieur telles que des formes construites par des lignes. L'utilisation de la mise en commun maximale et de l'abandon pour accélérer la phase d'entraînement et augmenter la robustesse au surapprentissage, respectivement. De plus, des unités de traitement graphique sont utilisées pour l'accélération de l'entraînement et des tests.

Cependant, les architectures profondes et plus particulièrement les CNN nécessitent beaucoup de ressources pour être efficacement appliquées. Les paramètres de base qui sont appris pendant la phase d'apprentissage sont les poids des noyaux de convolution. Selon la taille des noyaux et la profondeur de l'architecture, le nombre de paramètres à apprendre est de l'ordre de plusieurs centaines de millions. Cela peut placer une contrainte de calcul à la tâche de trouver les valeurs optimales. De plus, l'initialisation des poids est très importante. Dernièrement, l'initialisation des poids de convolution avec des filtres spécialement conçus [84] a permis d'accélérer la phase d'entraînement d'environ 82% [179]. En outre, le nombre d'échantillons d'apprentissage joue un rôle crucial dans un apprentissage efficace du CNN. Un grand nombre d'exemples, ainsi que leurs étiquettes, devraient être fournis pour que le réseau

puisse construire les caractéristiques les plus représentatives. Dans un travail récent, par exemple, P. Liskowski et K. Krawiec [180] ont entraîné leur CNN (figure III.12) sur 400.000 régions vasculaires saines atteignant une grande précision. Cependant, ceci est inadéquat dans le cas de la segmentation de néovascularisation. Comme il a été démontré que les proliférations vasculaires sont rares parmi la population dépistée. En plus de cela, ils montrent une très grande variabilité dans leur apparence, et un étiquetage au niveau pixel par un expert n'est pas fourni.



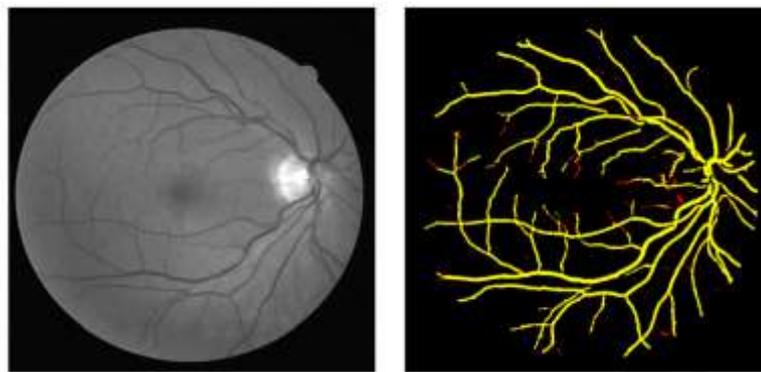
**Figure III.12** Exemple d'architecture de réseau neuronal convolutif de base (CNN).

### III.3.3 Méthodes d'optimisation

Plusieurs algorithmes d'optimisation inspirés de la nature ont été proposés pour la segmentation des vaisseaux sanguins rétiniens. Cependant, la plupart des algorithmes bio-inspirés existants ne prennent pas en compte les différentes caractéristiques des vaisseaux (petits ou grands) dans leur processus d'optimisation, car ils n'utilisent qu'un seul critère basé sur une caractéristique spécifique. Par exemple, Al-Rawi et al. [181] ont utilisé un algorithme génétique pour obtenir les paramètres de seuillage optimaux pour le filtre adapté (MF). Cinsdikici et al. [182] ont utilisé un algorithme de colonie de fourmis et un modèle hybride du MF pour réduire la forte réponse de la frontière des lésions diabétiques brillantes ou sombres, ce qui à son tour réduit les faux positifs. En outre, Asad et al. [183] ont proposé une nouvelle approche de sélection des caractéristiques basée sur l'optimisation des colonies de fourmis afin de minimiser la complexité de la classification en supprimant les caractéristiques redondantes. Dans [184], la fonction objectif probabiliste de regroupement des c-moyens flous est optimisée par une technique de recherche de coucou pour trouver la meilleure segmentation.

Malgré qu'il existe de nombreuses méthodes prometteuses basées sur des algorithmes d'optimisation qui ont été proposées dans la littérature, les méthodes peuvent être améliorées en tenant compte des informations contextuelles locales. Récemment, Hassanien et al. [185] et Emary et al. [186] ont démontré que l'inclusion de plusieurs critères dans la phase de segmentation donne des résultats satisfaisants et aide à extraire les petits vaisseaux. Dans [185] par exemple, l'algorithme proposé est basé sur deux niveaux de clustering. Au premier niveau, l'algorithme d'optimisation de la colonie d'abeilles artificielles (ABC) optimise la

fonction Fuzzy C-Means (FCM) pour localiser les vaisseaux de diamètre moyen. Au deuxième niveau, les centres de cluster obtenus ont été améliorés en utilisant une approche d'optimisation de la recherche de modèles (PS) en mettant l'accent sur la localisation des vaisseaux de petit diamètre, où le Thinnest-ratio était utilisé comme fonction de fitness (voir figure. III.13). Dans [186], une nouvelle méthode a été proposée basée sur la pollinisation florale (FPSA) et la recherche de modèles algorithmes. Dans la première étape, l'algorithme FPSA cherche le système vasculaire complet à partir des images rétiniennes, puis l'algorithme PS est utilisé pour localiser les petits vaisseaux qui ne sont pas identifiés par le premier algorithme d'optimisation. Cependant, la limitation de ces méthodes est qu'elles optimisent les différents critères séparément en utilisant différents algorithmes d'optimisation, ce qui prend du temps.



(a) Image rétinienne

(b) Images segmentée

**Figure III.13:** Exemple d'image normale (niveau de gris) et le résultat de la segmentation par ABC (en vert) et PS (en rouge) de la base de données DRIVE.

### III.4 Mesures de segmentation des vaisseaux rétiens

D'une manière générale, l'absence d'un algorithme de segmentation qui pourrait fonctionner aussi bien dans toutes sortes de scénarios a soulevé le besoin d'évaluer efficacement la performance de segmentation. Pour cette raison, différentes métriques d'évaluation ont été développées pour évaluer et classer les performances des différents algorithmes appliqués la segmentation des vaisseaux. Les divers schémas qui classent les métriques de segmentation dans une gamme de catégories ont été proposés dans la littérature [187].

Basée sur les différentes bases de données (basse et haute résolution) dans la littérature, une famille de mesures très bien documentée est basée sur les métriques de discordance [188] qui comptent le nombre de pixels segmentés entre la segmentation automatique ou semi-automatique et la segmentation manuel (segmentation par un expert), et habituellement un pourcentage est calculé pour les métriques pour chaque image sélectionnée. Des valeurs plus élevées sont préférées. Les mesures les plus utilisées dans la littérature sont : Sensibilité (Sen), Spécificité (Spec) and Précision (Acc). La sensibilité (équation 4) quantifie la capacité de l'algorithme à détecter correctement les pixels du vaisseau, tandis que la spécificité (équation 5) quantifie la capacité de l'algorithme à identifier correctement les pixels non vasculaires, ou le fond. Enfin, la précision (équation 6) est le rapport entre le nombre total de pixels correctement classés et le nombre de pixels dans le champ de vision de l'image.

$$\text{Sensibilité} = \frac{TP}{TP + FN} \quad (4)$$

$$\text{Spécificité} = \frac{TN}{TN + FP} \quad (5)$$

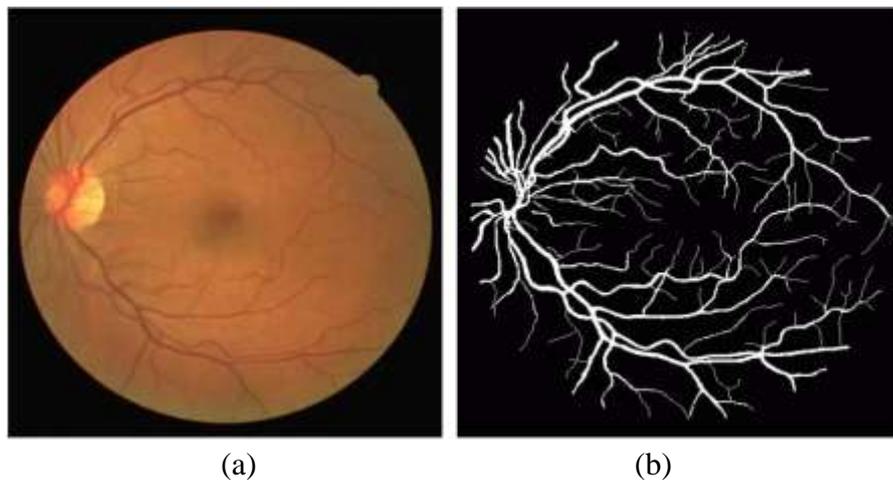
$$\text{Accuracy} = \frac{TP + TN}{TP + FN + FP + TN} \quad (6)$$

### III.5 Description des bases de données

Les bases d'images sont une ressource essentielle dans le développement des algorithmes d'analyse d'images rétiniennes, ils aident considérablement les chercheurs à évaluer et comparer les méthodes développées par rapport aux travaux reportés dans l'état de l'art. Elles conduisent à la mise au point de meilleurs algorithmes. Dans cette section, nous présentons les différentes bases de données les plus utilisées dans la littérature :

#### III.5.1 Base d'images DRIVE

La base d'image Drive comprend 40 [161] images couleur du fond d'œil, dont 7 qui présentent des pathologies. Les images sont acquises avec un rétinographe non mydriatique (Canon RC5) avec un champ de vision de 45 degré (FOV). Elles sont enregistrées au format JPEG, avec une taille de 768 \*584 pixels. La base d'image est divisée en deux ensembles (20 images pour l'apprentissage et le reste pour le test). La segmentation manuelle du réseau vasculaire est effectuée par deux ophtalmologues expérimentés. Un exemple d'image de la base de données DRIVE est montré dans la figure.III.14.



**Figure III.14:** Exemples d'images de la base de donnée DRIVE ; (a) : image saine ; (b) : segmentation manuelle du réseau vasculaire par un ophtalmologue.

#### III.5.2 Base d'images STARE

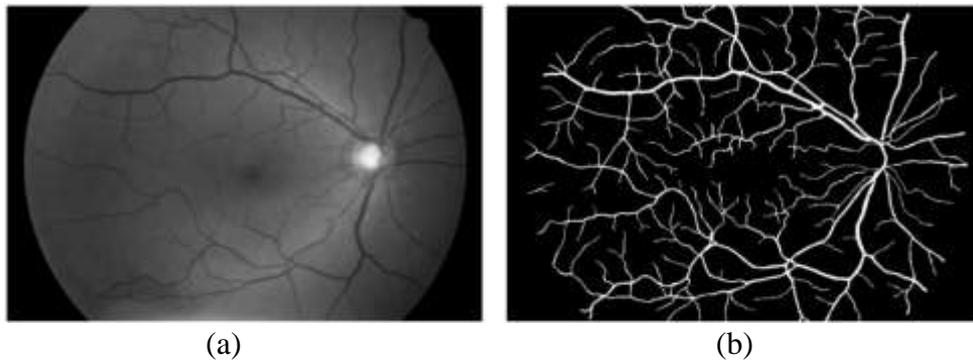
Cette base d'image est composée de 20 images couleur de la rétine dont 10 images saines et 10 pathologiques [86]. Les images sont acquises par un rétinographe de type TopCon TRV-50 avec un champ de vision de 35 degrés. Les images sont constituées de 605 \*700 avec 24 bits par pixel. Dans les 20 images, le réseau vasculaire est segmenté manuellement par deux experts en ophtalmologie. Un exemple d'image de la base de données STARE est montré dans la figure.III.15.



**Figure III.15:** Exemples d'images de la base de donnée STARE ; (a) : image pathologique ; (b) : segmentation manuelle du réseau vasculaire par un ophtalmologue.

### III.5.3 Base d'images HRF

La base de données Erlangen High-Resolution Fundus (HRF) [189] a été récemment établie par un groupe de recherche collaboratif; la base de données contient 15 images saines (H), 15 images de rétinopathie diabétique (DR) et 15 images glaucomateuses (G). Les images ont été acquises à l'aide d'une caméra CANON CF-60UVi avec une résolution d'image fixe de  $3504 \times 2336$  pixels. Des segmentations manuelles des vaisseaux par un expert sont également disponibles pour les trois catégories d'images. Un exemple d'image de la base de données HRF est montré dans la figure.III.16.



**Figure.III.16:** Exemples d'images de la base de données HRF ; (a) : image saine (niveau de gris) ; (b) : segmentation manuelle du réseau vasculaire par un ophtalmologue.

### III.6 Discussion générale sur les limites des méthodes existantes

La littérature actuelle se limite au problème de la segmentation des vaisseaux rétiens de façons globales (de taille moyenne à une grande). Les auteurs des travaux existants se sont principalement concentrés sur la possibilité de démontrer que les différentes méthodes proposées étaient suffisantes pour aborder le problème de la segmentation globale des vaisseaux rétiens à l'aide de mesures de discordance standard. Cependant, les petits vaisseaux présentent des défis qui en font un problème difficile à résoudre. Comme les nouveaux développements nécessitent des systèmes de diagnostic assisté par ordinateur (CAD) complets avec plusieurs étapes qui pourraient être en mesure d'assister et de détecter toutes les étapes possibles de la rétinopathie diabétique menaçant la vue, l'importance des petits vaisseaux devient de plus en plus pertinente.

### **III.7 Conclusion**

Dans la première partie de ce chapitre, nous avons détaillé les aspects médicaux nécessaires pour comprendre l'importance de l'analyse des images du fond d'œil. Ensuite, il nous a semblé intéressant de définir les pathologies liées aux vaisseaux réiniens. La seconde partie de ce chapitre est consacrée de la définition de l'art des techniques de segmentation de vaisseaux réiniens.

Comme il a été présenté dans ce chapitre, plusieurs algorithmes ont été proposés pour isoler le système vasculaire. Cependant, soit ils sont incapables d'identifier correctement les plus petits vaisseaux, ou ils ne sont pas testés dans les ensembles de données contenant les plus petits vaisseaux exclusivement. Par conséquent, le deuxième objectif de la thèse est la segmentation des petits vaisseaux.

# **Chapitre 4 : Seuillage multiple (a multi-niveaux) par optimisation multi-objectif pour la segmentation des vaisseaux rétiniens**

## **IV.1 Introduction**

Le seuillage est la technique de segmentation la plus répandue pour extraire les objets du fond de l'image. Les avantages de cette technique sont sa facilité de mise en œuvre et son efficacité dans les systèmes en temps réel [190]. En se basant sur une technique de seuillage, nous présentons notre première contribution pour l'amélioration de la segmentation de vaisseaux vasculaire par une méthode d'optimisation non supervisé.

La segmentation optimale par seuillage nécessite une localisation optimale des seuils dans un histogramme qui possède plusieurs modes (pics). Cependant, dans la pratique, il y a plusieurs cas où l'histogramme possède qu'un seul mode, ce qui rend l'opération de segmentation plus complexe. Afin de résoudre ce problème de seuils optimaux, et de prendre en considération les différents artefacts de l'image à segmentée, nous commençons notre contribution par approfondir l'étude des critères de seuillage afin de trouver une formalisation plus poussée des relations entre ces critères et les images à segmenter (Section I).

Dans la deuxième section de ce chapitre, nous allons également étudier la possibilité de combiner plusieurs critères de seuillage en utilisant une technique d'optimisation multi-objectif. De plus, nous allons adopter une métaheuristique d'optimisation (Fourragement Bactérien) pour accélérer le processus du seuillage à multi-niveaux. Cependant, avant d'adapter les techniques de seuillage à la segmentation de la vascularisation rétinienne, nous avons testé la robustesse de nos algorithmes proposés sur différents types d'images. Le but est de tester la robustesse de la combinaison de plusieurs critères de seuillage sur des images diverses.

À la fin de ce chapitre (Section III), nous présentons notre premier algorithme pour la segmentation de l'image rétinienne, où la méthode non supervisée proposée est basée sur l'algorithme de la colonie d'abeilles. La méthode proposée exploite simultanément plusieurs critères pour améliorer la précision des résultats de la segmentation. Une fonction de courbe d'énergie est utilisée pour calculer les valeurs des critères de seuillage, afin de réduire la réponse au bruit des lésions, et sélectionner les seuils optimaux qui séparent les vaisseaux sanguins de l'arrière-plan.

## **IV.2 Etude des critères de seuillage**

Dans cette étude, nous nous intéressons aux méthodes de seuillage vu leur simplicité. En premier lieu, nous classons les méthodes de seuillage en deux classes : les méthodes basées sur l'histogramme traditionnel et les méthodes basées sur l'information contextuelle. Ensuite, nous testons chaque méthode dans les deux classes sur des images diverses. À la fin de cette section, nous montrons les résultats de différentes méthodes en se basant sur une mesure de performance [5].

### **IV.2.1 Classe 1 : Seuillage basé sur l'histogramme**

La segmentation par seuillage d'histogramme repose sur l'exploitation de l'histogramme de toute l'image. Elle permet de répartir les pixels en classes en fonction de leurs niveaux de gris. Les classes sont alors délimitées par des seuils.

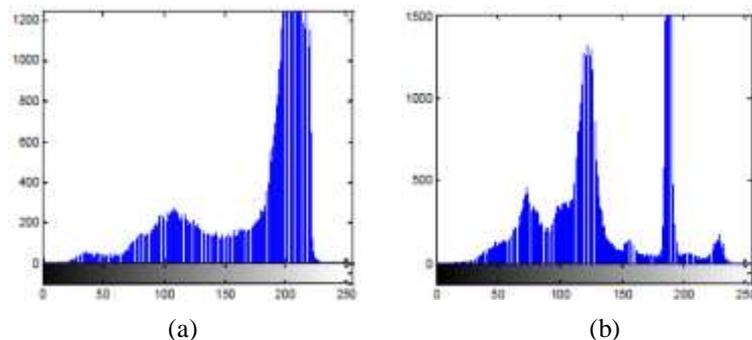
L'histogramme est une courbe monodimensionnelle qui caractérise la distribution des niveaux de gris, il est décrit par une fonction mono-variable discrète  $p(i)$  qui représente respectivement la fréquence ou la probabilité d'apparition du niveau de gris  $i$ , tel que :

$$p(i) = \frac{h(i)}{N}$$

$h(i)$  étant le nombre de pixels ayant le niveau de gris  $i$  et  $N$  le nombre total de pixels dans l'image.

À partir de l'allure de l'histogramme, nous pouvons déduire le nombre de classes ainsi que la position relative des seuils. Dans le cas d'une image composée d'une ou plusieurs régions de même type, et d'un fond visuellement différent, l'histogramme est bimodal et il est possible de séparer les régions du fond par un simple seuil qui se situe sur la vallée entre les deux modes (figure IV.1(a)). Si l'image est constituée de régions ayant les caractéristiques différentes, son histogramme est multimodal (figure V.1(b)), tels que chacun des modes correspond à une région.

En pratique, il est rare de trouver un histogramme qui présente des modes bien distincts. En effet, la plupart des images présentent des histogrammes bruités caractérisés par des modes non discernables. Dans ce cas-là, pour trouver les meilleurs seuils qui séparent les différentes classes (objets), plusieurs méthodes de seuillages simple et de seuillage multi-niveaux ont été proposées.



**Figure.IV.1** Allures idéales d'un histogramme (a) unimodal, (b) multimodal

Dans notre étude, nous considérons seulement les trois méthodes de seuillage non paramétriques suivantes: la méthode d'Otsu [12], la méthode de Kapur [13], et la méthode de Kittler et Illingworth [191]. Car, la plupart des techniques parues ensuite sont basées sur l'un des trois principes.

#### IV.2.1.1 Variance interclasse d'Otsu

Dans cette méthode [12], le calcul de critère pour le seuillage simple est basé sur la densité de probabilité des différents pixels de l'image, qui est obtenue en normalisant l'histogramme de l'image :

$$p_i = \frac{h(i)}{\sum_{j=0}^{L-1} h(j)} \quad \text{avec } p_i \geq 0, \text{ et } \sum_{i=0}^{L-1} p_i = 1 \quad (\text{IV.1})$$

Où  $h(i)$  est le nombre d'occurrence du pixel de niveau de gris  $i \in [0, L-1]$  et  $L$  le nombre de niveaux de gris.

La fonction objectif  $f$  est maximisée :  $f(t_1) = \omega_0 \omega_1 (u_0 - u_1)^2$  (IV.2)

$$\begin{aligned} \omega_0(t_1) &= \sum_{i=0}^{i=t_1} p_i & \omega_1(t_1) &= \sum_{i=t_1+1}^{i=L-1} p_i \\ u_0(t_1) &= \sum_{i=0}^{i=t_1} \frac{i p_i}{\omega_0} & u_1(t_1) &= \sum_{i=t_1+1}^{i=L-1} \frac{i p_i}{\omega_1} \end{aligned}$$

Dans le seuillage multi-niveaux la variance entre  $K+1$  classes de l'image est donnée comme suit :

$$\begin{aligned} f(t_1, t_2, \dots, t_k) &= \omega_0 \omega_1 (u_0 - u_1)^2 + \omega_0 \omega_2 (u_0 - u_2)^2 \\ &\quad + \omega_0 \omega_3 (u_0 - u_3)^2 + \dots + \omega_0 \omega_k (u_0 - u_k)^2 \\ &\quad + \omega_1 \omega_2 (u_1 - u_2)^2 + \omega_1 \omega_3 (u_1 - u_3)^2 \\ &\quad + \dots + \omega_1 \omega_k (u_1 - u_k)^2 + \omega_{k-1} \omega_k (u_{k-1} - u_k)^2 \\ \omega_n(t) &= \sum_{i=t_{n+1}}^{i=t_n+1} p_i & u_n(t) &= \sum_{i=t_{n+1}}^{i=t_n+1} \frac{i p_i}{\omega_n} \quad 1 < n < (k+1) \end{aligned} \quad (IV.3)$$

Les seuils optimaux  $t_1^*, t_2^*, \dots, t_k^*$  font la variance d'interclasse maximale :

$$t_1^*, t_2^*, \dots, t_k^* = \text{Arg max}_{0 < t_1 < t_2 < \dots < t_k < L} f(t_1, t_2, \dots, t_k)$$

#### IV.2.1.2 Entropie de Kapur

La méthode de Kapur de seuillage simple [13], est basée sur la maximisation de l'entropie totale de Shannon. Dans le cas de la segmentation d'une image en deux classes (A et B), la méthode suppose que les objets et le fond possèdent deux densités de probabilité indépendantes. Le seuil optimal de segmentation est celui qui permet de maximiser l'entropie totale de l'image partitionnée.

Les densités de probabilité des deux classes (A et B) sont définies par :

$$\text{Classe A : } \frac{p_1}{p_t}, \frac{p_2}{p_t}, \frac{p_3}{p_t}, \dots, \frac{p_t}{p_t} \quad \text{Classe B : } \frac{p_{t+1}}{1-p_t}, \frac{p_{t+2}}{1-p_t}, \frac{p_{t+3}}{1-p_t}, \dots, \frac{p_L}{1-p_t}$$

Où  $L$  est le nombre total de niveaux de gris et  $P_t$  la probabilité cumulée définie dans Eq. (IV.1).

Les entropies des deux classes A et B sont définies par :

$$H_A(t) = - \sum_{i=1}^t \frac{p_i}{p_t} \log \frac{p_i}{p_t} \quad H_B(t) = - \sum_{i=t+1}^L \frac{p_i}{1-p_t} \log \frac{p_i}{1-p_t}$$

$$\text{L'entropie totale s'écrit : } H_T(t) = H_A(t) + H_B(t) \quad (IV.4)$$

Dans le seuillage multi-niveaux l'entropie totale de l'image comporte  $k+1$  classes est donnée comme suit:

$$\begin{aligned} f(t_1, t_2, \dots, t_k) &= H_0 + H_1 + \dots + H_k \\ \text{Avec } H_0 &= - \sum_{i=0}^{t_1} \frac{p_i}{w_0} \ln \frac{p_i}{w_0}, & w_0 &= \sum_{i=0}^{t_1} p_i, \\ H_1 &= - \sum_{i=t_1+1}^{t_2} \frac{p_i}{w_1} \ln \frac{p_i}{w_1}, & w_1 &= \sum_{i=t_1+1}^{t_2} p_i, \\ H_2 &= - \sum_{i=t_2+1}^{t_3} \frac{p_i}{w_2} \ln \frac{p_i}{w_2}, & w_2 &= \sum_{i=t_1+1}^{t_2} p_i, \\ \dots, H_k &= - \sum_{i=t_k+1}^{L-1} \frac{p_i}{w_k} \ln \frac{p_i}{w_k}, & w_k &= \sum_{i=t_k+1}^{L-1} p_i \end{aligned} \quad (IV.5)$$

Les seuils optimaux  $t_1^*, t_2^*, \dots, t_k^*$  font l'entropie totale maximale:

$$t_1^*, t_2^*, \dots, t_k^* = \text{Arg max}_{0 < t_1 < t_2 < \dots < t_k < L} f(t_1, t_2, \dots, t_k)$$

### IV.2.1.3 Méthode de Kittler et Illingworth

Dans le seuillage simple cette méthode considère l'histogramme des niveaux de gris comme une fonction de densité de probabilité  $p(i)$  d'un mélange de populations formées des niveaux de gris des objets et du fond. La fonction de seuillage de Kittler and Illingworth [191]  $f(t)$ , est donnée comme suit :

$$f(t) = 1 + 2\{P_1(t) \log_e \sigma_1(t) + P_2(t) \log_e \sigma_2(t)\} - 2\{P_1(t) \log_e P_1(t) + P_2(t) \log_e P_2(t)\} \quad (\text{IV.6})$$

Où

$$\begin{aligned} p_1(t) &= \sum_{g=0}^t h(g), & p_2(t) &= \sum_{g=t+1}^{L-1} h(g), \\ u_1(t) &= \frac{(\sum_{g=0}^t h(g)g)}{p_1(t)}, & u_2(t) &= \frac{(\sum_{g=t+1}^{L-1} h(g)g)}{p_2(t)}, \\ \sigma_1^2(t) &= \frac{\{\sum_{g=0}^t (g-u_1(t))^2 h(g)\}}{p_1(t)}, & \sigma_2^2(t) &= \frac{\{\sum_{g=t+1}^{L-1} (g-u_2(t))^2 h(g)\}}{p_2(t)}, \end{aligned}$$

Le seuil optimal est obtenu en minimisant  $f(t)$  comme suit :

$$t^* = \text{ArgMin} f(t)$$

Dans le seuillage multi-niveaux le critère d'erreur minimum (méthode de Kittler et Illingworth) [191] adapté à un mélange de gaussiennes, visant à minimiser l'erreur entre cette distribution paramétrique et l'histogramme réel comme suit:

$$f(t_1, t_2, \dots, t_k) = 1 + 2 \times \sum_{i=0}^k (w_i ((\ln \sigma_i - \ln w_i))) \quad (\text{IV.7})$$

Où

$$w_n = \sum_{i=t_n}^{t_{n+1}-1} p(i), \quad \sigma_n^2(t) = \sum_{i=t_n}^{t_{n+1}-1} \frac{p(i) \times (i - u_n)^2}{w_n}, \quad \text{and} \quad u_n = \sum_{i=t_n}^{t_{n+1}-1} \frac{p(i) \times i}{w_n}$$

Les seuils optimaux  $t_1^*, t_2^*, \dots, t_k^*$  font l'entropie totale maximale:

$$t_1^*, t_2^*, \dots, t_k^* = \text{ArgMin}_{0 < t_1 < t_2 < \dots < L} f(t_1, t_1, \dots, t_k)$$

## IV.2.2 Classe 2 : Seuillage à base d'information spatiale

### IV.2.2.1 Histogramme bidimensionnel

L'idée de base de l'histogramme bidimensionnel revient à Pal et al [192], qui ont proposé d'ajouter de l'information à distribution spatiale des pixels, afin de segmenter les images. Cette information spatiale consiste en un histogramme à deux dimensions, où est recueillie la matrice de cooccurrence des pixels.

Un histogramme bidimensionnel est défini d'une manière générale comme une fonction à deux variables discrètes  $x_1$  et  $x_2$  indiquant la fréquence ou la probabilité d'apparition de deux valeurs de ses variables  $x_1$  et  $x_2$ . La variable  $x_1$  correspond généralement

au niveau de gris des pixels de coordonnées  $(x, y)$  noté  $i = l(x, y)$  et la variable  $x_2$  au niveau de gris noté  $j = g(x, y)$  d'un pixel voisin, ou au niveau de gris moyen, minimal ou maximal de chaque pixel ou encore au gradient du pixel considéré. On note  $h_{ij}$  la fréquence d'apparition de couple de niveaux de gris  $(i, j)$ . L'histogramme bidimensionnel d'une image peut être alors représenté par la fonction de probabilités jointe  $p_{ij}$  donnée par :

$$p_{ij} = \frac{h_{ij}}{N^2} \text{ avec } i, j = 0, 1, 2, \dots, L-1 \text{ tel que } i = l(x, y) \text{ et } j = g(x, y) \text{ et } \sum_{i=1}^L \sum_{j=1}^L p_{ij} = 1$$

### A. Méthodes de seuillage simple basées sur les matrices de cooccurrence

Le seuillage basé sur les matrices de cooccurrence consiste à chercher le seuil  $t$  qui divise l'ensemble des pixels en deux classes  $C_1$  et  $C_2$ . En fonction du seuil, la matrice de cooccurrence  $M$  ou de transition  $T$  peut être découpée en quatre régions notées a, b, c et d comme le montre la figure IV.2.

- la zone  $a$  est formée des pixels appartenant à la classe  $C_1$ .
- la zone  $b$  est formée des pixels appartenant à la classe  $C_2$ .
- les zones  $c$  et  $d$  correspondent aux pixels de transition entre les deux classes  $C_1$  et  $C_2$ .

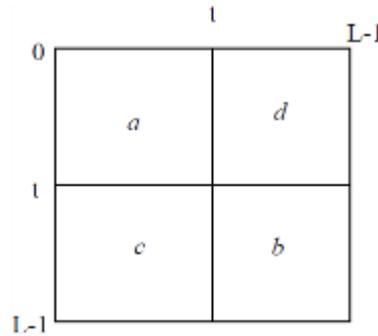


Figure IV.2: Seuillage d'une matrice cooccurrence

**Variance interclasse d'Otsu à bi-dimension:** Cette méthode [193] suppose que l'image est répartie en deux classes  $C_1$  et  $C_2$  (objet et fond). Les probabilités a priori des deux classes sont:

$$w_0 = P_r(C_1) = \sum_{i=0}^{s-1} \sum_{j=0}^{t-1} p_{ij} = w_0(s, t)$$

$$w_1 = P_r(C_2) = \sum_{i=s+1}^{L-1} \sum_{j=t+1}^{L-1} p_{ij} = w_1(s, t)$$

Les niveaux moyen des classes correspondantes sont donnés par :

$$u_0 = (u_{0i}, u_{0j})^T = \left( \sum_{i=0}^s \sum_{j=0}^t \frac{ip_{ij}}{w_0}, \sum_{i=0}^s \sum_{j=0}^t \frac{jp_{ij}}{w_0} \right)^T$$

$$u_1 = (u_{1i}, u_{1j})^T = \left( \sum_{i=s+1}^{L-1} \sum_{j=t+1}^{L-1} \frac{ip_{ij}}{w_1}, \sum_{i=s+1}^{L-1} \sum_{j=t+1}^{L-1} \frac{jp_{ij}}{w_1} \right)^T$$

Le vecteur total de niveau moyen est donné par :

$$u_T = (u_{Ti}, u_{Tj})^T = \left( \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} i p_{ij}, \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} j p_{ij} \right)^T$$

La matrice de variance interclasse est définie par :

$$TrS_b(s, t) = \sum_{k=0}^1 (w_k [(u_{ki} - u_{Ti})^2 + (u_{kj} - u_{Tj})^2]) \quad (IV.8)$$

Le vecteur de seuil optimal  $(s^*, t^*)$  est :

$$(s^*, t^*) = Argmax TrS_b(s, t) \quad 0 \leq s, t \leq L - 1$$

**Entropie de Shannon à bi-dimension:** a été la premier à avoir appliqué le principe de l'entropie de Shannon 2D sur des histogrammes à deux dimensions [194]. Les probabilités des classes  $C_1$  (fond) et  $C_2$  (objet) sont notées  $P_1$  et  $P_2$ . Pour un vecteur de seuil  $(s, t)$  donné,  $P_1$  et  $P_2$  sont définies comme suit:

$$P_1 = \sum_{i=0}^{s-1} \sum_{j=0}^{t-1} p_{ij} \quad P_2 = \sum_{i=s}^{L-1} \sum_{j=t}^{L-1} p_{ij}$$

Les entropies des classes  $C_1$  et  $C_2$  s'écrivent :

$$H^1(s, t) = \sum_{i=0}^{s-1} \sum_{j=0}^{t-1} \frac{p_{ij}}{p_1} \log\left(\frac{p_{ij}}{p_1}\right) \quad H^2(s, t) = \sum_{i=s}^{L-1} \sum_{j=t}^{L-1} \frac{p_{ij}}{p_2} \log\left(\frac{p_{ij}}{p_2}\right)$$

L'entropie totale est alors calculée comme suit :

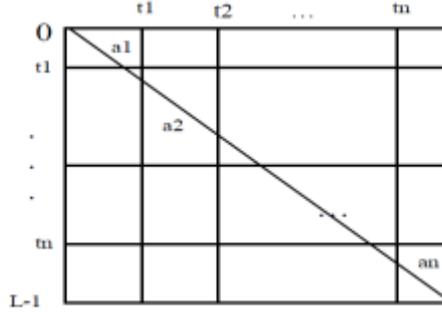
$$H^T(s, t) = H^1(s, t) + H^2(s, t) \quad (IV.9)$$

D'après le principe du maximum d'entropie, le vecteur de seuillage optimal  $(s^*, t^*)$  est celui qui maximise l'entropie totale :

$$H^T(s^*, t^*) = Argmax\{H^T(s, t)\}$$

## B. Méthodes de seuillage multi-niveau basées sur les matrices de cooccurrence :

D'autres méthodes de seuillage basées sur les matrices de cooccurrence ont été proposées. Comme dans le cas d'un histogramme monodimensionnel, la segmentation par seuillage à partir de plusieurs seuils d'un histogramme bidimensionnel représenté par une matrice de cooccurrence consiste à répartir les pixels en  $k+1$  classes ( $C_1, C_2, \dots, C_{k+1}$ ), à partir d'un ensemble de seuils  $T = \{t_1, t_2, \dots, t_k\}$ . Par convenance, nous utilisons aussi deux autres seuils,  $t_0 = 0$  et  $t_{l-1}$ , un pixel de niveau de gris  $l(x, y)$  est affecté à la classe  $C_{k+1}$  si  $t_k \leq l(x, y) \leq t_{k+1}$  avec  $k = 0, 1, 2, \dots, k-1$ . La matrice de cooccurrence est dans ce cas découpée en plusieurs régions comme le montre la figure IV.3. Les zones situées sur la diagonale correspondent aux classes alors que les zones hors diagonale correspondent aux transitions entre les classes ou au bruit.



**Figure IV.3:** Seuillage d'une matrice cooccurrence à partir de plusieurs seuils

Les formules des sections précédentes peuvent facilement être étendues au seuillage multi-niveau [195]. En supposant qu'il y a  $k$  seuils,  $(t_1, t_2, \dots, t_k)$ , qui divisent l'image originale en  $k+1$  classes:  $C_1$  pour  $[1, \dots, t_1]$ ,  $C_2$  pour  $[t_1 + 1, \dots, t_2]$ , ...,  $C_i$  pour  $[t_{i-1} + 1 + 1, \dots, t_i]$ , ..., et  $C_{k+1}$  pour  $[t_k + 1, \dots, L]$ , les seuils optimaux  $(t_1^*, t_2^*, \dots, t_k^*)$  sont choisis en maximisant Eq.IV.8 et Eq.IV.9 pour les méthodes Otsu 2D et Kapur 2D respectivement.

#### IV.2.2.2 Seuillage basé sur la courbe d'énergie

Dans notre étude de critère de segmentation d'image, nous proposons d'utiliser la courbe d'énergie [196] qui est semblable à l'histogramme de l'image, afin de prendre en compte l'information contextuelle spatiale de l'image dans le choix des seuils optimaux.

Pour calculer l'énergie de l'image  $I$  dans chaque niveau de gris  $l$  ( $0 \leq l \leq L$ ), on génère d'abord une matrice binaire bidimensionnelle  $B_l = \{b_{ij}, 1 \leq i \leq m, 1 \leq j \leq n\}$ , telle que la valeur de chaque élément  $b_{ij}$  dans  $B_l$  est affectée soit par 1 soit par -1 en fonction de la valeur de niveau de gris de  $l_{ij}$ . Soit  $C = \{c_{ij}, 1 \leq i \leq m, 1 \leq j \leq n\}$  une autre matrice telle que  $c_{ij} = 1, \forall (i, j)$ . Ensuite, la valeur d'énergie  $E$  de l'image  $I$  à la valeur de gris  $l$  est définie comme suit :

$$E_l = \sum_{i=1}^m \sum_{j=1}^n \sum_{pq \in N_{ij}^2} b_{ij} \cdot b_{pq} + \sum_{i=1}^m \sum_{j=1}^n \sum_{pq \in N_{ij}^2} c_{ij} \cdot c_{pq} \quad (IV.10)$$

Où :

$b_{pq}$  représente la valeur de niveau de gris du pixel voisin  $b_{ij}$  dans le système de voisinage de second ordre ( $N^2$ ), et  $c_{pq} = 1, \forall (p, q)$  tel que  $(p, q) \in \{(\pm 1, 0), (0, \pm 1), (1, \pm 1), (-1, \pm 1)\}$ .

La courbe d'énergie est utilisée comme une entrée pour les méthodes de seuillages à la place de l'histogramme pour calculer la probabilité  $p_l$  à  $l$  pixel. La probabilité  $p_l$  au niveau de gris  $l$  est définie comme suit:

$$p_l = \frac{E_l}{N}, (0 \leq l \leq L) \quad (IV.11)$$

#### IV.2.3 Résultats et Évaluation

Après la classification des méthodes de références de segmentation par seuillage, nous présenterons maintenant quelques résultats de la recherche des seuils de façon exhaustive à partir des histogrammes monodimensionnels, bidimensionnels et à base d'énergie.

Afin de mieux évaluer les nombreuses méthodes programmées, nous avons choisi plusieurs images de test. Ces images sont des images en niveaux de gris de différentes tailles codées sur 24 bits, la plupart des images sélectionnées à partir de la base de données de Berkeley [197].

La comparaison de la performance de la segmentation est basée sur le temps du calcul et la qualité de la segmentation en utilisant un critère d'évaluation. Nous avons utilisé le critère "Error Misclassified Measure (ME)" [198], ME est défini en termes de corrélation d'images avec l'observation humaine. C'est le rapport du nombre de pixels dans l'arrière-plan faussement classé dans le premier plan, et vice versa. ME est donné par:

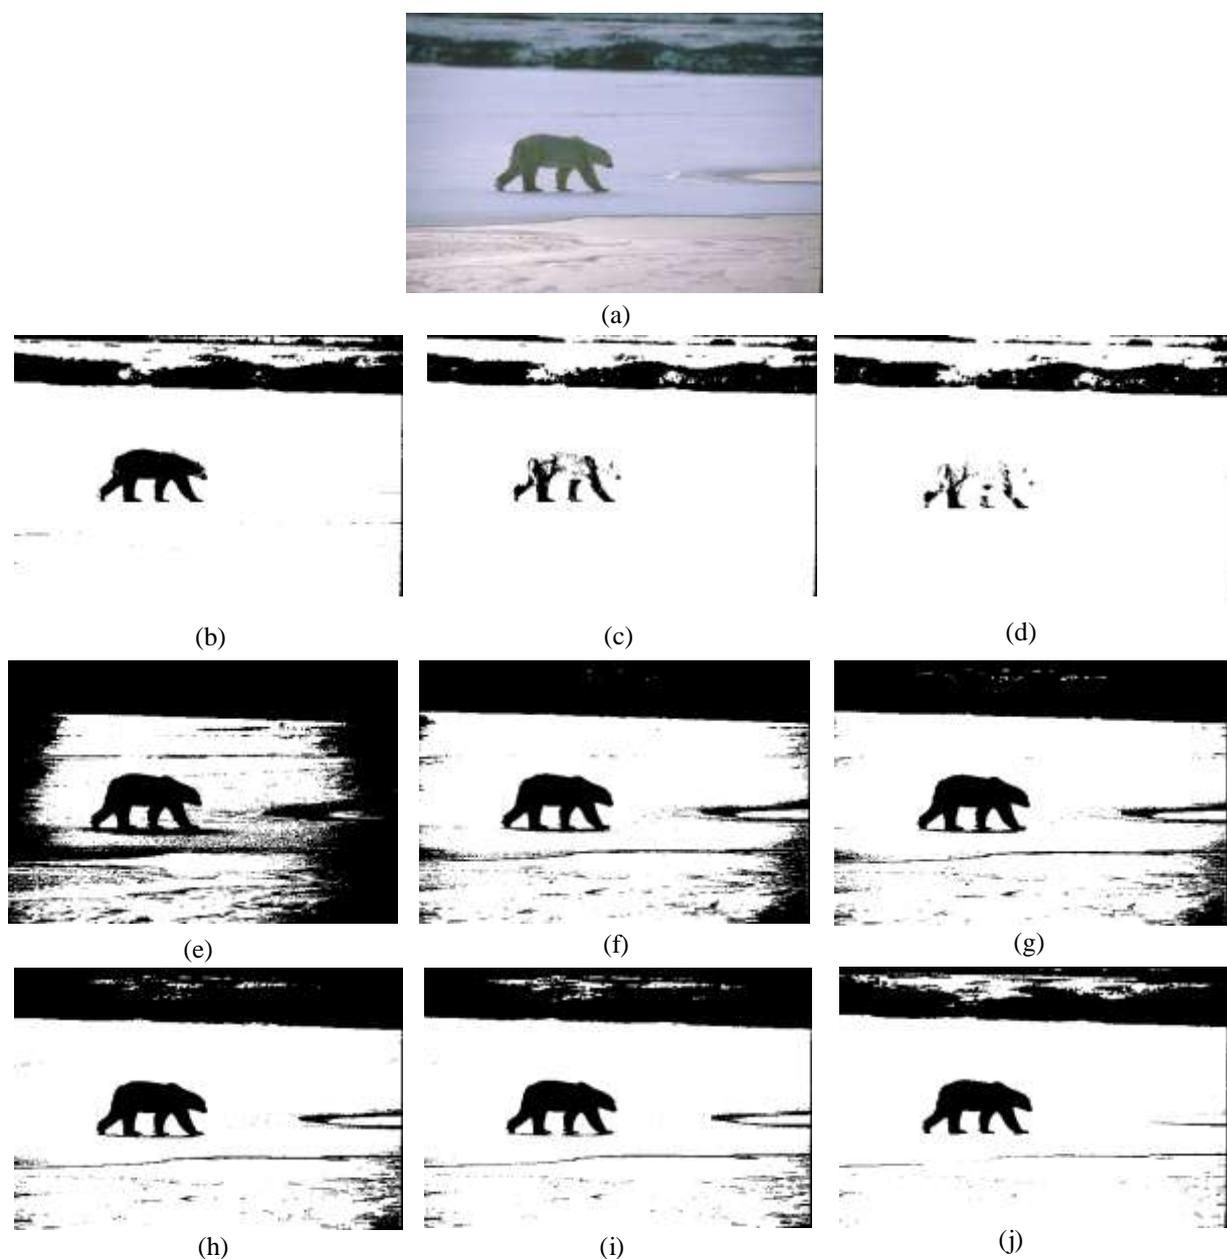
$$ME = \left( 1 - \frac{|B_0 \cap B_T| + |F_0 \cap F_T|}{|B_0| + |F_0|} \right) 100 \quad (IV.12)$$

Où  $B_0$  et  $F_0$  sont l'arrière-plan et de premier plan de l'image originale respectivement.  $B_T$  et  $F_T$  sont l'arrière-plan et le premier plan de l'image segmentée respectivement. Dans le cas idéal ME est égale 0%, et dans les pires des cas est égal à 100%.

Les deux figures et les deux tableaux suivantes montrent deux exemples d'images réel segmentées par le seuillage d'histogrammes monodimensionnels, bidimensionnels, et à base d'énergie. De plus, dans la deuxième figure IV.4, l'image de teste est bruitée par la méthode Speckle, afin de tester la robustesse de chaque critère de seuillage devant une image plus complexes

**Tableau IV.1:** Comparaison des valeurs des mesures d'error misclassified et le temps d'exécution

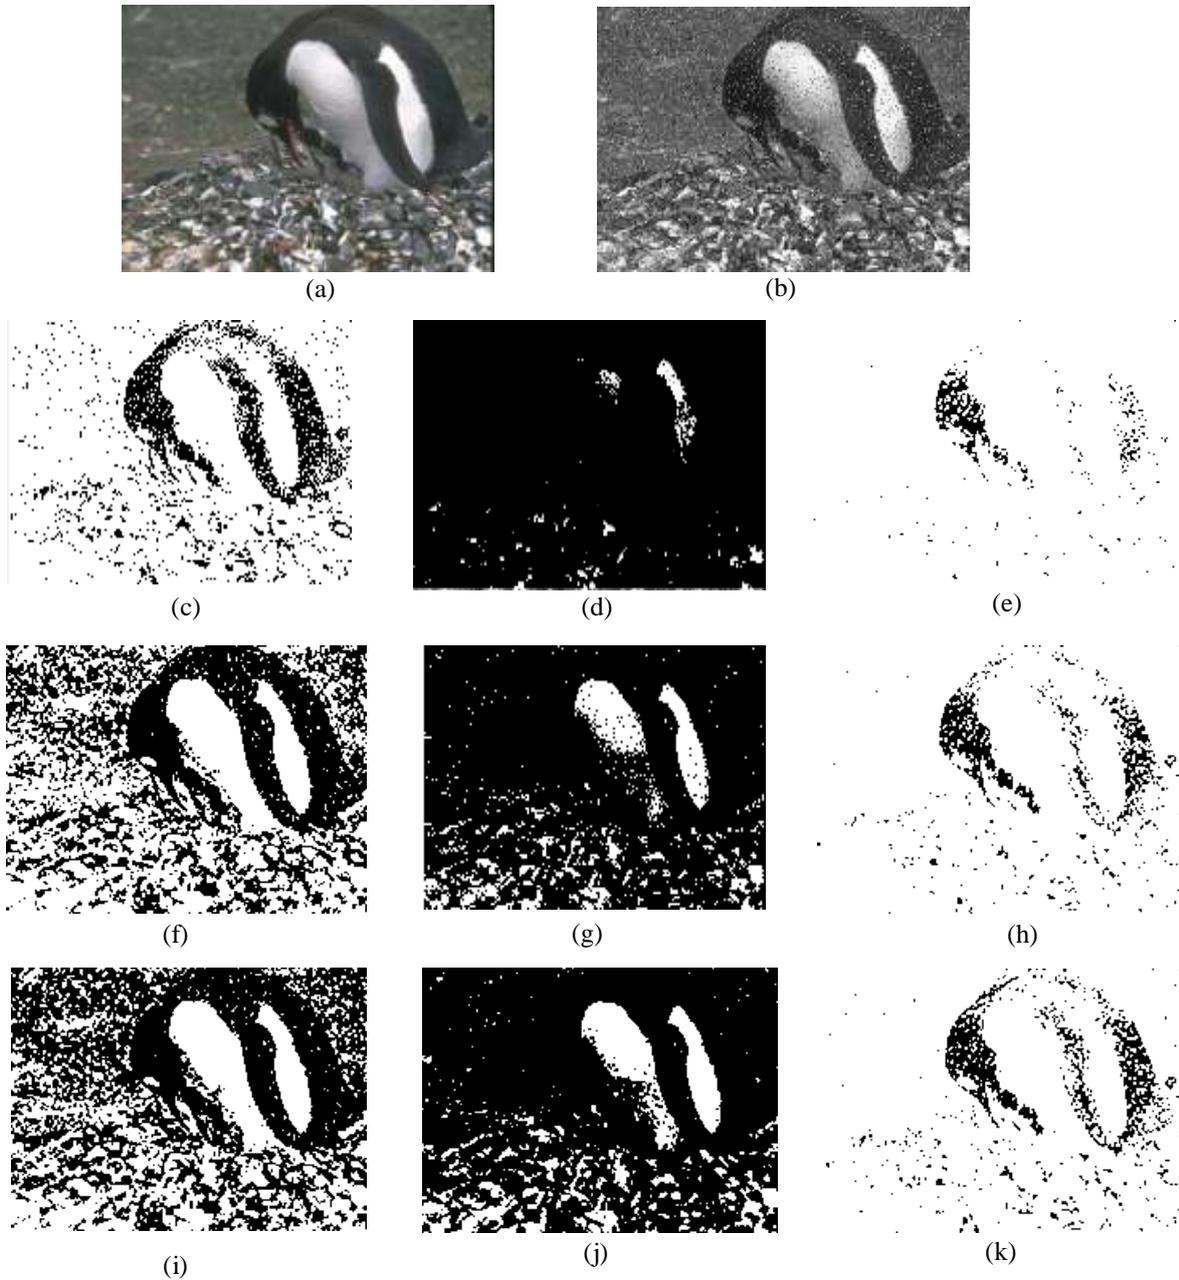
Image de Figure.IV.3	Hist-Mono		Hist-BI		Energy	
	ME	Temps (Sec)	ME	Temps (Sec)	ME	Temps (Sec)
Otsu	25.15%	0.15	20.50 %	16	10.30%	12
Kapur	35.50 %	0.25	20.20 %	33	10.15%	22.35
Kittler	42.32 %	0.45	20.10 %	32.35	10.52%	17



**Figure. IV.3** Résultats de seuillage en deux classes sur une image réel, (a) image original. (b), (e),et (h) sont les résultats de segmentation par les critères Otsu, Kapur, et Kittler basés sur Hist-Mono respectivement. (c), (f),et (i) sont les résultats la segmentation par les critères Otsu, Kapur, et Kittler basés sur Bi-Mono respectivement. (d), (g),et (j) sont les résultats la segmentation par les critères Otsu, Kapur, et Kittler basés sur Energy-curve respectivement.

**Tableau IV.2:** Comparaison des valeurs des mesures d'erreur misclassified et le temps d'exécution

Image de Figure.IV.4	Hist-Mono		Hist-BI		Energy	
	ME	Temps (Sec)	ME	Temps (Sec)	ME	Temps (Sec)
Otsu	35.13%	0.10	10.30 %	15	9.80%	12
Kapur	55.10 %	0.25	50.20 %	43	48.10%	22.35
Kittler	72.30 %	0.35	70.10 %	30.35	68.50%	18



**Figure. IV.4** Résultats de seuillage en deux classes sur une image réel bruitée, (a) image original. (b) image bruitée. (c), (f),et (i) sont les résultats de segmentation par les critères Otsu, Kapur, et Kittler basés sur Hist-Mono respectivement. (d), (g),et (j) sont les résultats la segmentation par les critères Otsu, Kapur, et Kittler basés sur Bi-Mono respectivement. (e), (h),et (k) sont les résultats la segmentation par les critères Otsu, Kapur, et Kittler basés sur Energy-curve respectivement.

D'après les résultats obtenus dans cette étude, nous avons retenus les points suivants :

- ✓ Les résultats d'évaluation par la mesure ME sont compatibles à ceux de l'évaluation visuelle, pour 80% d'images de la base utilisée.
- ✓ Il n'existe pas de critère unique et suffisant pour segmenter de manière optimale toutes les images et le choix des critères de seuillage n'est pas évident, du fait de leur nombre et de leur diversité.

- ✓ Les performances des méthodes basées sur le seuillage d'histogrammes mono-dimensionnel se dégradent rapidement lorsque les images à segmenter sont très bruitées
- ✓ Les critères utilisent l'histogramme bidimensionnel ou l'histogramme à base d'énergie, donnent une bonne qualité de segmentation surtout sur les images texturées, et les images bruitées.
- ✓ La complexité des méthodes de segmentation d'image est dépendante du nombre de seuils, la complexité des images et le type de critères.
- ✓ L'évolution des temps de calcul de segmentation d'images augmente lorsque le nombre de seuils augmente, et la détermination d'un vecteur de seuils optimaux dans l'espace des niveaux de gris rend la segmentation des images assimilable à un problème d'optimisation.
- ✓ Les critères basés sur l'information contextuel spatial (critères basés sur l'histogramme bidimensionnel ou l'histogramme à base d'énergie) sont coûteux en terme du temps de calcul.

### **IV.3 Segmentation des images diverses par la méthode d'optimisation multi-objective de fourragement bactérien.**

Dans cette section, nous présentons une méthode pour la segmentation des images diverses, qui est basé sur Multi-objective Bacterial Foraging Optimization Algorithm (MBFOA). Le but est de voir l'adaptabilité d'un algorithme d'optimisation multi-objectif pour résoudre le problème de seuillage simple et le seuillage multiple. Le concept d'approche de Health-sorting et le mécanisme de dominance de Pareto est incorporé pour améliorer la rapidité de recherche du front de Pareto optimal.

Bacterial Foraging Optimization (BFO) est un algorithme d'optimisation basé sur le comportement alimentaire des bactéries E.coli. En général, la stratégie de recherche de nourriture est régie par quatre processus distincts: chimiotaxie, essaimage, reproduction, élimination et dispersion [199]. Bien qu'un grand nombre d'articles aient été publiés sur l'analyse du comportement de recherche de nourriture et des propriétés d'auto-adaptabilité du BFO en tant qu'optimiseur à objectif unique. Jusqu'à présent, à notre connaissance, il existe peu d'analyse pour le BFO multi-objectif.

Niu et al. [200] ont exposé le potentiel de l'implémentation de fourragement bactérien en tant que processus d'optimisation multi-objectif et ont proposé un algorithme d'optimisation multi-objectif de fourragement bactérien (MBFOA). Dans cet algorithme, un mécanisme de survie par l'approche de Health-sorting et le mécanisme de dominance de Pareto sont intégrés pour trouver une meilleure distribution des solutions et une convergence plus rapide vers le front de Pareto optimal. La diversité est préservée en gardant certaines solutions infaisables aux frontières, le choix repose sur une probabilité donnée.

Ce travail représente la première adaptation de MBFOA dans la résolution de problèmes de seuillage d'image. Elle consiste à prouver que les techniques de seuillage basées sur la combinaison de certains critères donnent un bon résultat de segmentation et aident à

surmonter les faiblesses de ces critères lorsqu'ils sont utilisés séparément. Le processus d'adaptation de cet algorithme dans la résolution de ce problème peut être résumé comme suit:

Supposons qu'une image  $I$  ayant  $N$  pixels avec  $L + 1$  niveaux de gris  $L = \{0, 1, \dots, L\}$  doit être classée en  $k + 1$  classes ( $C_0, C_2, \dots, C_k$ ) avec l'ensemble de  $k$  seuils. Afin d'optimiser  $M$  critères de segmentation simultanément et obtenir le front de Pareto puis la solution optimale de Pareto (valeurs de seuil optimales pour la segmentation d'image), nous adaptons l'algorithme d'optimisation de recherche de nourriture bactérienne [200] qui consiste à utiliser une colonie de  $S$  bactéries  $Bac = (X_j^1, \dots, X_j^i, \dots, X_j^S)$  situées initialement à des positions aléatoires sur cet espace paramétrique.  $X_j^i = (x_{j,1}^i, \dots, x_{j,p}^i, \dots, x_{j,k}^i)$  est la  $i^{\text{ème}}$  bactérie dans la  $j^{\text{ème}}$  étape chimiotactique, et  $x_{j,p}^i$  est le paramètre  $p$  de la bactérie  $X_j^i$ , tel que  $x_{j,p}^i \in [0, L - 1]$ . Chaque bactérie représente un ensemble de  $k$  seuils pouvant être une solution de problème de seuillage.

MBFOA qui a  $M$  objectifs à résoudre, doit calculer les valeurs de chaque fonction  $J_r(X_j^i); r = 1, \dots, M$  comme suit:

$$J_r(X_j^i) = f_r(X_j^i) + J_{cc-r}(X_j^i) \quad (IV.12)$$

et :

$$J_{cc-r}(X_j^i) = \sum_{i=1}^S \left[ -d_{attract} \exp \left( -\omega_{attract} \sum_{m=1}^k (X_{gm-r_m} - X_m^i)^2 \right) \right] + \sum_{i=1}^S \left[ h_{repellant} \exp \left( -\omega_{repellant} \sum_{m=1}^k (X_{gm-r_m} - X_m^i)^2 \right) \right] \quad (IV.13)$$

Où:  $f_r(X_j^i)$  est la valeur de la fonction objectif (critère de seuillage) et  $J_{cc-r}(X_j^i)$  représente un profil attractif-répulsif qui fournit la valeur de coût.  $d_{attract}$ ,  $\omega_{attract}$ ,  $h_{repellent}$ , et  $\omega_{repellent}$  sont des coefficients différents à choisir judicieusement,  $X_{gm-r_m}$  c'est le  $m^{\text{ème}}$  paramètre de la bactérie optimale globale  $X_{gm-r}$  selon la fonction objectif  $f_r(X_j^i)$  (critère de seuillage).

La santé de la bactérie  $X_j^i$  ( $J_{health-r}^i$ ) est la somme des valeurs de fonction  $J_r(X_j^i)$  acceptées dans le processus de chimiotaxie (dans  $NC$  étapes), c'est une mesure du nombre de nutriments que la  $i^{\text{ème}}$  bactérie a eu au cours de sa vie et de son efficacité à éviter les substances nocives. Le coût est plus élevé de  $J_{health-r}^i$  signifie que la santé est inférieure.

$$J_{health-r}^i = \sum_j^{NC} J_r(X_j^i); r=1 \dots M \quad (IV.14)$$

L'équation de chimiotactique pour la mise à jour de la position de la bactérie est décrite comme suit:

$$X_{j+1}^i = X_j^i + C(i) \frac{\Delta(i)}{\sqrt{\Delta^T \Delta(i)}} \quad (IV.15)$$

Où:  $\Delta_j^i$  est un vecteur aléatoire généré par la bactérie forte  $i$ , dans laquelle chaque élément  $\Delta_{j,p}^i$  est un nombre aléatoire sur  $[-1,1]$  et  $C(i)$  est la taille du pas pris dans la direction aléatoire spécifiée par le culbutage (unité de longueur de course).

Trier les valeurs de santé  $J_{health}^i$  de chaque bactérie de petites à grandes pour se préparer à l'étape Pareto-optimale. Les bactéries ayant les valeurs les plus élevées de  $J_{health}^i$  ont de fortes chances de mourir et celles qui ont les meilleures valeurs sont probablement gardées pour se reproduire. D'après l'ordre de  $J_{health}^i$ , si la  $j^{ème}$  bactérie est dominée par la  $i^{ème}$  bactérie, la  $j^{ème}$  bactérie doit mourir.

Le nombre de bactéries mortes ne dépasse pas 50% du groupe pour conserver la diversité des solutions finales. Afin de garder la taille absolue de la population, les meilleures bactéries sont sélectionnées pour la reproduction (les copies sont placées au même endroit que leurs parents). Avec l'ensemble du processus de calcul, de tri, de division et de reproduction, les bactéries génèrent un meilleur groupe avec de meilleures solutions.

L'algorithme MBFOT (optimisation multi-objectif de fourrage bactérien pour le seuillage d'image) proposé pour la segmentation d'image consiste à optimiser simultanément les fonctions objectif: Kapur [13] et Otsu [12]. Ensuite, les vecteurs de seuil optimaux  $X$  correspondent à la solution de Pareto. L'algorithme proposé est résumé ci-dessous :

### Algorithme proposé

#### Étape 1: Initialisation

1) Entrez les paramètres:

S: nombre de bactéries

k: Nombre de paramètres (seuils)

M: nombre de fonctions objectifs (critères de seuillage)

Nc: nombre d'étapes de chimiotaxie

Ns: nombre d'étapes de natation

Nre: nombre d'étapes de reproduction

Ned: nombre d'étapes d'élimination et de dispersion

Ped: Probabilité d'élimination et de dispersion

2) Générer les premières positions ( $j = 0, l = 0, k = 0$ ) des valeurs de seuil aléatoirement pour une population Bac de bactéries.

**Étape 2:** Pour  $i = 1$  à Ned (boucle d'élimination et de dispersion)

**Étape 3:** Pour  $k = 1$  à Nre (boucle de reproduction)

**Étape 4:** Pour  $j = 1$  à Nc (boucle de chimiotaxie)

1) Pour chaque bactérie  $X_j^i$  en Bac;  $i = 1, \dots, S$ ,

a) Calculer les valeurs des fonctions objectifs  $r = 1,2$ , en utilisant respectivement Eq.IV.3(Otsu) et Eq.IV.5(Kapur).

- b) Déterminer la bactérie optimale  $X_{gm-r}$ ,  $r = 1,2$ .
- c) Calculer les valeurs des fonctions:  $J_r(X_j^i)$ ;  $r = 1,2$  en utilisant Eq.IV.12
- d) Sauvegardez la valeur, car nous pouvons trouver une meilleure valeur via une course;  $J_{last-r}(X_j^i) = J_r(X_j^i)$ ;  $r = 1,2$
- e) Tumble:
  - Générer un vecteur aléatoire  $\Delta_j^i \in \mathfrak{R}^k$
  - Appliquer l'équation chimiotactique pour la mise à jour de la position, en utilisant Eq.IV.15
  - Déterminer la bactérie optimale  $X_{gm-r}$ ,  $r = 1,2$ .
  - Calculer les valeurs de fonction:  $J_r(X_j^i)$ ;  $r = 1,2$  en utilisant l'équation IV.1
  - Si  $J_r(X_j^i) < J_{last-r}(X_j^i)$  alors  $J_{last-r}(X_j^i) = J_1(X_j^i)$ ;  $r = 1,2$
- f) Nager: Pour  $m = 1$  à  $N_s$ 
  - Appliquer l'équation chimiotactique pour la mise à jour de la position, en utilisant Eq.IV.14.
  - Déterminer la bactérie optimale  $X_{gm-r}$ ,  $r = 1,2$ .
  - Calculer les valeurs de fonction:  $J_r(X_j^i)$ ;  $r = 1,2$  en utilisant l'équation IV.1
  - Si  $J_r(X_j^i) < J_{last-r}(X_j^i)$  alors  $J_{last-r}(X_j^i) = J_1(X_j^i)$ ;  $r = 1,2$
- g) Fin pour (nager)

**Étape 5:** Fin pour (Fin de l'étape 4: étape de chimiotaxie)

**Étape 6:** Reproduction

- 1) Trier les bactéries dans l'ordre des valeurs ascendantes de leur santé.
- 2) Les bactéries ayant les valeurs de santé les plus élevées et dominées doivent mourir, et les autres bactéries non dominées avec les meilleures valeurs de santé se reproduisent.
- 3) Le nombre d'individus meurent n'est pas supérieur à  $S_r$  ( $S_r = S / 2$ ), sinon copiez les meilleures bactéries afin de garder le nombre de groupe inchangeable.

**Étape 7:** Fin pour (Fin de l'étape 2: Boucle de reproduction)

**Étape 8:** Élimination-dispersion:

- 1) Pour chaque bactérie  $X_j^i$  en Bac;  $i = 1, \dots, S$ ,
  - a) Génère un nombre aléatoire (rand)
  - b) Si  $rand \leq Ped$  alors
    - La bactérie est éliminée et dispersée dans un nouvel emplacement aléatoire
    - Sinon
    - La bactérie reste à son emplacement d'origine.

**Étape 9:** Fin pour (Fin de l'étape 1: élimination-boucle de dispersion)

**Étape 10:** Renvoyez les résultats: les valeurs de seuil et l'image segmentée.

### IV.3.1 Résultats expérimentaux et discussion

Pour évaluer la performance de l'algorithme MBFOT dans le seuillage simple, nous présentons quelques expérimentations avec deux images naturelles (House, Avion) sélectionnées à partir de la base de données de Berkeley [197]. Dans le seuillage multiple, deux types d'images sont considérés pour évaluer l'efficacité de l'approche proposée: les images synthétiques et les coupes d'IRM cérébrales pondérées en T2 [201].

Pour évaluer la qualité de la segmentation, un critère basé sur la mesure d'homogénéité  $u$  [11] (Voir Eq.IV.16) des classes de l'image segmentée est utilisé.

$$u = 1 - 2(N - 1) \sum_{j=1}^N \sum_{i \in C_j} (I_i - \mu_j)^2 / M \cdot (I_{max} - I_{min})^2 \quad (IV.16)$$

Où :  $N$  est le nombre de classes,  $C_j$  la classe  $j$ ,  $M$  le nombre de pixels dans l'image,  $I_i$  le niveau de gris du pixel  $i$ ,  $\mu_j$  le niveau de gris moyen des pixels dans l'image,  $I_{min}$  est le niveau de gris le plus faible dans l'image originale et  $I_{max}$  le niveau le plus élevé. L'uniformité est dite bonne si elle est proche de 1 et vice versa.

Les paramètres MBFOT ont été établis empiriquement; les valeurs des paramètres de MBFOT avec lesquels nous avons obtenu de bons résultats sont:  $S = 100$ ,  $N_c = 20$ ,  $N_s = 10$ ,  $N_{re} = 4$ ,  $N_{ed} = 4$ ,  $P_{ed} = 0.2$ ,  $C = 0.1$ . Ces valeurs sont appliquées pour la segmentation de toutes les images de test.

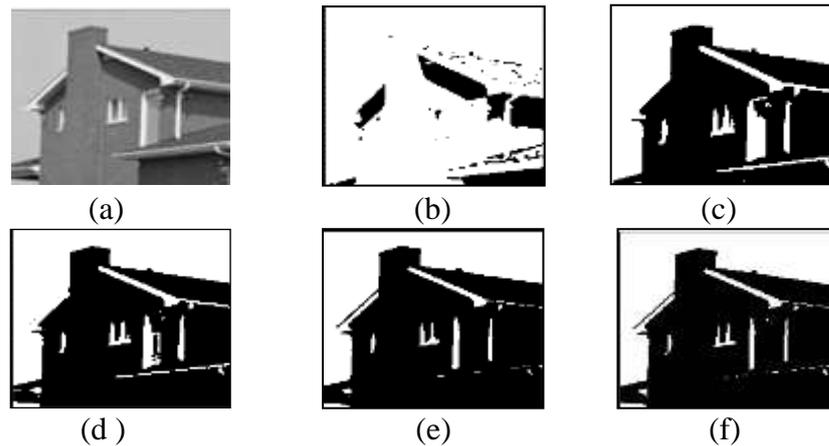
Afin de montrer la performance des résultats de seuillage dans la segmentation basée sur l'optimisation simultanée de certains critères et de leurs résultats lorsque ces critères sont utilisés séparément, nous évaluons les résultats trouvés en comparaison avec trois autres méthodes: algorithme TPMO (Thresholding using Pareto MO) [49] basé sur l'algorithme NSGA-II [4], TPBMO (Thresholding utilisant Pareto Bacteria Chemotaxis MO) [63] et ABF (Amended Bacterial Foraging) [202] qui est un algorithme d'optimisation mono-objectif basé sur le fourragement bactérien. Enfin, la qualité d'images segmentées est évaluée par la mesure de l'uniformité [203].

#### IV.3.1.1 Seuillage simple

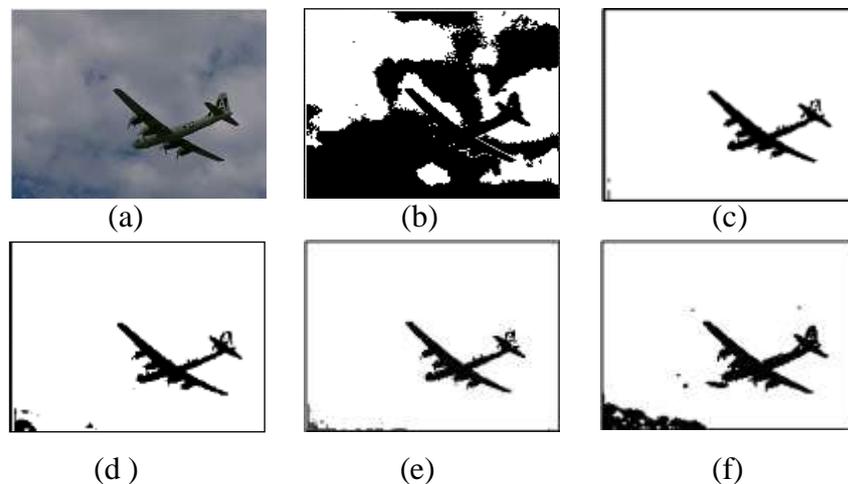
À partir des résultats présentés sur la figure IV.5, la segmentation de l'image House par MBFOAT, TPMO et TPBMO est de bonne qualité que ABF-Otsu et ABF-Kapur. De plus, les limites de la maison sont bien protégées d'un point de vue visuel. Dans la figure IV.6, nous remarquons que l'avion est globalement bien extrait du fond dans les quatre méthodes: ABF-Otsu, MBFOAT, TPMO et TPBMO, bien que certains pixels du fuselage de l'avion soient absents, parce que classés en arrière-plan et vice versa. Mais la segmentation de l'avion avec ABF-Kapur est pire: plus de points, appartenant au fond, sont stockés dans la même classe des pixels qui composent l'avion.

A partir des résultats présentés dans le tableau IV.3, nous pouvons voir que, pour presque toutes les images, les algorithmes (MBFOAT, TPMO et TPBMO), basés sur l'optimisation simultanée de deux critères, donnent les plus hautes valeurs de mesure

d'uniformité. En plus, MBFOAT proposé produit les meilleurs résultats concernant la segmentation des images House et Plane.



**Figure. IV.5** Résultats seuillage en 2 classes : (a): Image House, (b): Segmentation par ABF-Kapur, (c): Segmentation par ABF-Otsu, (d) Segmentation par TPBMO, (e) : Segmentation par TPMO, (f): Segmentation par MBFOT.



**Figure. IV.6** Résultats de seuillage en 2 classes: (a): Image Avion, (b): Segmentation par ABF-Kapur, (c): Segmentation par ABF-Otsu, (d) Segmentation par TPBMO, (e) : Segmentation par TPMO, (f): Segmentation par MBFOT.

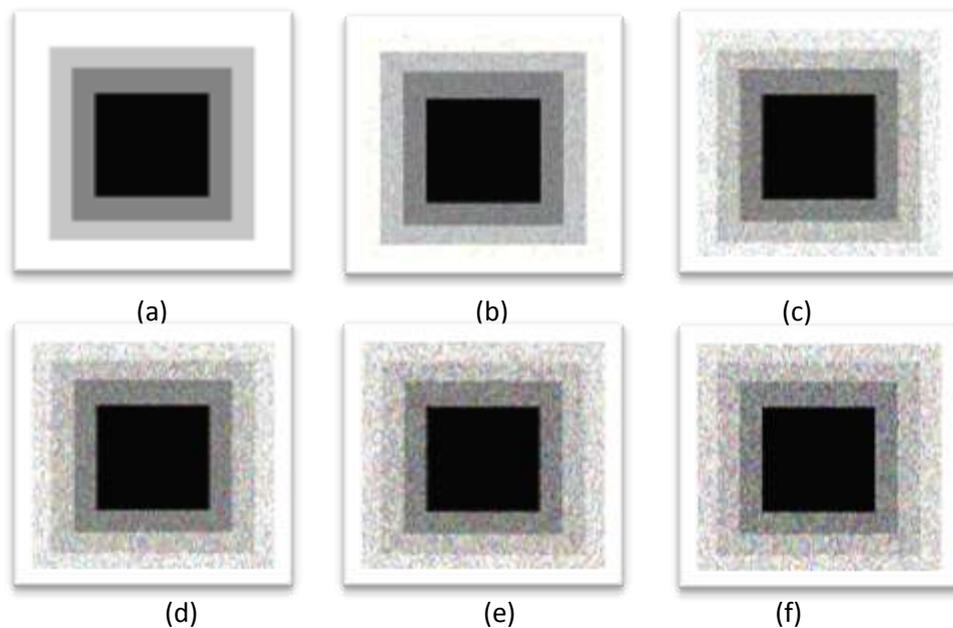
**Tableau IV.3:** Comparaison des valeurs des mesures d'uniformité

Images	ABF-Kapur	ABF-Otsu	TPBMO	TPMO	<b>MBFOT</b>
House	0.945	0.961	0.959	0.966	<b>0.976</b>
Avion	0.835	0.954	0.965	0.963	<b>0.972</b>
IRM	0.922	0.901	0.931	0.953	<b>0.942</b>

### IV.3.1.2 Seuillage multiple

Afin de prendre en considération l'information contextuelle dans les images biomédicales, et les images synthétiques bruitées; l'histogramme 2D est utilisés au lieu l'histogramme traditionnel pour calculer les valeurs des fonctions objectifs dans le processus

d'optimisation. Le but de cette deuxième expérimentation est d'évaluer l'efficacité de notre algorithme en termes de sensibilité au bruit sur le seuillage multiple. Dans ce cas, nous avons corrompu les images synthétiques par la méthode de bruit de Speckle avec une différente Variance ( $V$ ) de bruit. La figure IV.7 illustre les images de test.



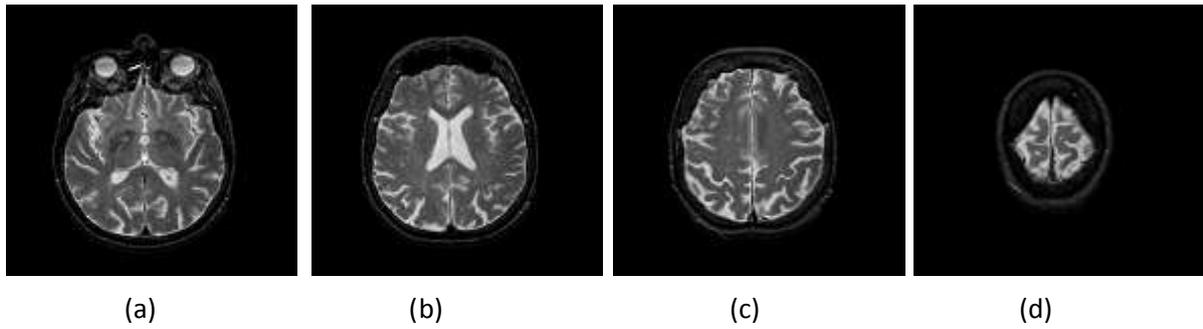
**Figure. IV.7** Images synthétiques: (a) Image originale, (b) Image brouillée ( $V = 0.01$ ), (c) Image brouillée ( $V = 0.03$ ), (d) Image brouillée ( $V = 0.05$ ), (e) Image brouillée ( $V = 0.07$ ), (F) Image bruitée ( $V = 0.09$ ).

Dans le tableau IV.4, nous pouvons voir de les valeurs de mesure d'uniformité de la segmentation des images de teste bruitées en 4 classes, que l'algorithme proposé basée sur l'histogramme 2D fournit les valeurs de  $U$  les plus élevées que celles utilisées de l'histogramme traditionnel, car l'histogramme 2D joue un rôle important dans la segmentation correcte des images bruitées, et il est plus robuste vis-à-vis des différents niveaux de bruit.

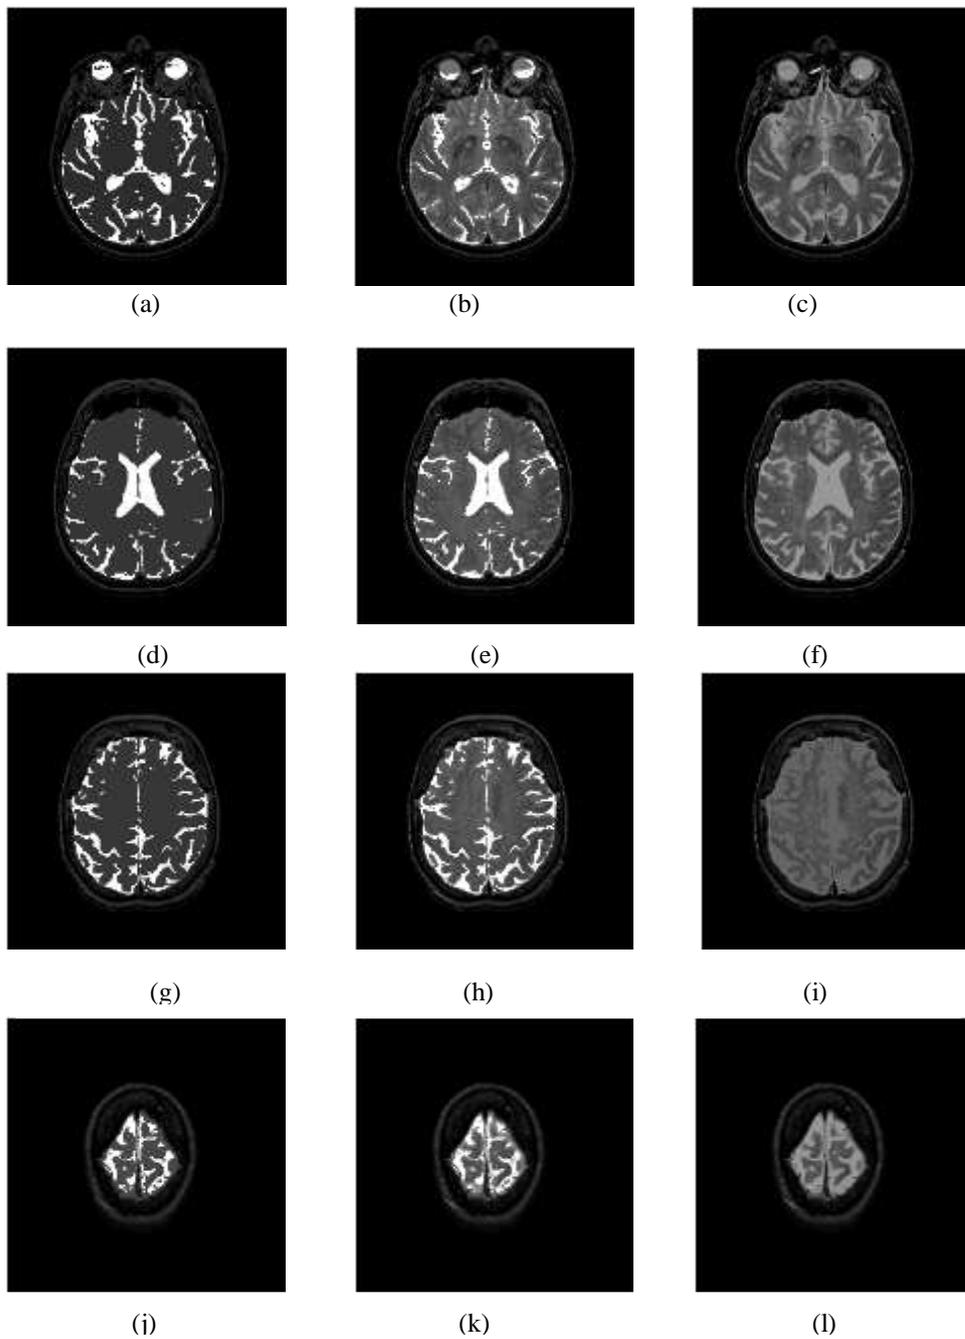
**Tableau IV.4:** Comparaison des valeurs d'uniformité obtenues par cinq méthodes pour différent niveau de bruit

Images	V	ABF-Kapur	ABF-Otsu	TPBMO	TPMO	MBFOT
Image b	0.01	0.921	0.953	0.961	0.964	<b>0.978</b>
Image c	0.03	0.913	0.931	0.956	0.961	<b>0.976</b>
Image d	0.05	0.905	0.925	0.938	0.958	<b>0.973</b>
Image e	0.07	0.872	0.922	0.932	0.954	<b>0.968</b>
Image f	0.09	0.858	0.907	0.928	0.942	<b>0.967</b>

La figure IV.8 illustre les images de test. À partir des résultats de segmentation illustrés dans la figure IV.9, nous pouvons remarquer de tous les résultats obtenus, que les images IRM segmentées par 3 et 4 seuils sont beaucoup plus lisses et homogènes: la matière grise, la substance blanche et le liquide céphalorachidien sont bien détectés. Ainsi, nous pouvons conclure que les augmentations du nombre de seuils améliorent la qualité et le détail de l'image IRM segmentée et la rendent similaire à l'image de test.



**Figure IV.8** Images IRM: (a) Tranche 27, (b) Tranche 32, (c) Tranche 38, (d) Tranche 48



**Figure IV.9** Résultats Seuillage dans 3, 4 et 5 classes d'images IRM de gauche à droite respectivement.

Dans la segmentation des images médicales ou les images bruitées, nous avons conclu que l'histogramme simple est incapable de prendre en compte les informations contextuelles, et cela peut affecter négativement sur l'extraction des différents objets de l'image à segmenté. Cependant, le temps de calcul augmente d'une façon non raisonnable lorsqu'on passe d'un histogramme monodimensionnel à un histogramme bidimensionnel. Dans ce cas-là, la fonction de courbe d'énergie sera une bonne alternative pour surmonter le problème de la complexité de temps dans la méthode proposée.

La méthode proposée est validée par des images diverses. La comparaison avec deux autres algorithmes de seuillage multi-objectif et avec un seuillage mono-objectif montre que la segmentation d'image basée sur l'optimisation simultanée de certains critères donne des résultats satisfaisants, et augmente la capacité d'appliquer une même technique à une grande variété d'images et montre aussi son robustesse dans le non dépendance vis-à-vis du type de l'image à segmenter. Par contre, le réglage des paramètres de l'algorithme adapté MBFO est plus ardu, et cela à cause du grand nombre de paramètres à initialiser dans le début de processus d'optimisation.

#### **IV.4 Segmentation à base seuillage de l'image rétinienne par la méthode d'optimisation multi-objectif de colonie d'abeilles**

Dans cette section, nous présentons notre première méthode pour la segmentation d'image rétinienne. Nous exploitons la flexibilité et la puissance d'EMOABC (Elite-guided Multi-Objective Artificial Bee Colony) algorithme pour proposer une méthode de segmentation des images permettant d'optimiser plusieurs critères de segmentation simultanément, cela pourrait améliorer la robustesse vis-à-vis différents artefacts contenus dans les images rétiniennes. Nous utilisons simultanément deux critères de seuillage Otsu [12] et Kapur [13] en fonction de la fonction de courbe d'énergie [196], dans le but d'incorporer les informations contextuelles spatiales et de sélectionner la meilleure classe qui sépare les vaisseaux du fond d'œil.

##### **IV.4.1 Colonie d'abeilles artificielles multi-objectif guidées par les élites**

L'algorithme de la colonie d'abeilles artificielles (ABC) est une nouvelle méthode d'optimisation développée par Karaboga [204]. Il imite les comportements des abeilles naturelles cherchant des sources de nourriture et partageant l'information avec d'autres abeilles. Il est simple dans son concept, facile à mettre en œuvre et possède très peu de paramètres de contrôle en comparaison avec d'autres techniques évolutives telles que l'algorithme génétique et l'algorithme d'optimisation de fourrage bactérienne [205]. Depuis son invention, il a reçu un intérêt croissant, où de nombreux chercheurs ont appliqué la méthode pour résoudre divers problèmes d'optimisation [206]. L'extension de l'ABC de base pour pouvoir traiter des problèmes multi-objectif a reçu plus d'attention de la part des chercheurs. Certains excellents travaux ont adapté l'algorithme ABC de base aux problèmes multi-objectif [185] [207] afin d'accélérer la convergence de l'algorithme d'optimisation ABC et d'obtenir une solution de haute qualité dans un temps raisonnable.

L'algorithme d'EMOABC a été récemment proposé par Huo et al. [208] était basé sur un algorithme ABC amélioré. La stratégie de génération de solutions guidée par les élites (ESGS) est conçue pour exploiter le voisinage des solutions existantes en se basant sur les orientations de l'élite. En outre, il implique également certaines stratégies d'optimisation

multi-objectif, comme la méthode de tri rapide non-dominée et la stratégie de sélection de la population [208].

Dans l'algorithme EMOABC, chaque source de nourriture représente une solution réalisable  $x^d = (x_1^d, \dots, x_i^d, \dots, x_n^d)$  du problème à résoudre, et la qualité de nectar de la source de nourriture indique la fitness de cette solution réalisable, indiquant la qualité de cette solution représentée par un vecteur de  $m$  fonctions objectifs  $F(x^d) = [f_1(x^d), \dots, f_k(x^d), \dots, f_m(x^d)]$ .

Les abeilles sont classées en trois groupes: butineuses actives (employées), inactives et les éclaireuses (scouts). Chaque butineuse active recherche le voisinage de la source de nourriture basée sur la stratégie de génération de solution guidée par l'élite (ESGS) et ensuite sa quantité de nectar est évaluée par un vecteur  $F$  de  $m$  fonctions objectifs  $(f_1, \dots, f_k, \dots, f_m)$ . Les butineuses inactives sont placées sur les sources de nourriture en utilisant un processus de sélection basé sur la probabilité. Comme la quantité de nectar d'une source de nourriture augmente, la valeur de probabilité avec laquelle la source de nourriture est préférée par les butineuses inactives augmente de la même manière que le processus de sélection naturelle.

L'algorithme EMOABC se compose de deux parties principales: l'initialisation et le processus d'itération:

### A. Initialisation

Dans la partie d'initialisation, l'algorithme commence par créer aléatoirement une population  $P = (x^1, \dots, x^d, \dots, x^{SN})$  des sources de nourriture  $SN$  (abeilles), de sorte que chaque solution (abeille)  $x^d = (x_1^d, \dots, x_i^d, \dots, x_n^d)$  est un vecteur  $n$ -dimensionnel,  $n$  est le nombre de paramètres d'optimisation. Chaque paramètre  $x_i^d$  de la solution  $x^d, i = 1, \dots, n$ . est généré comme suit:

$$x_i^d = lb_i + rand(0,1) * (ub_i - lb_i) \quad (IV. 17)$$

où  $lb_i$  et  $ub_i$  sont les limites inférieure et supérieure du paramètre  $x_i^d$ , respectivement.

### B. Processus d'itération

Après l'initialisation, la population des positions (solutions) est soumise à des cycles répétés,  $C = 1, 2, \dots, MCN$ , des processus de recherche des abeilles butineuses actives, inactives et des éclaireuses.

**Étape1:** Envoyer des abeilles butineuses actives (employées)

- Pour chaque abeille employée  $x^d$  on calcule les  $m$  valeurs de fonctions objectif  $(f_1(x^d), \dots, f_k(x^d), \dots, f_m(x^d))$ .
- Appliquer une procédure non-dominante rapide [208] pour identifier les rangs de solutions  $(x^d; d=1, \dots, SN)$  et mémoriser les solutions avec rang = 1 comme Elite Set (ES)
- Basé sur la stratégie de génération de solution guidée par l'élite [208], chaque abeille employée  $x^d = (x_1^d, \dots, x_i^d, \dots, x_n^d)$  recherche le voisin de la source de nourriture pour produire une nouvelle solution  $v^d = (v_1^d, \dots, v_i^d, \dots, v_n^d)$ . La mise à jour de l'équation de recherche locale pour chaque abeille  $v^d$  est la suivante:

$$v_i^d = x_i^d + \phi_i^d * (x_i^d, x_i^e) + \psi_i^d * (y^j - x_i^d), y^j \in ES, \quad (IV. 18)$$

où  $x_i^d + \vartheta_i^d * (x_i^d, x_i^e)$  est l'originale stratégie de recherche locale,  $\psi_i^d * (y^i - x_i^d)$  est la stratégie guidée par l'élite,  $x_i^d$  et  $v_i^d$  sont les nouvelles et les anciennes sources de nourriture respectivement,  $\vartheta_i^d$  et  $\psi_i^d$  sont des nombres aléatoires compris entre  $[0, 2]$  et  $[-1, 1]$ , et  $y^i$  représente le  $i$ ème élément de la solution sélectionné à partir du premier front non dominé (Elite Set: ES) de façon aléatoire.

- Calculer les valeurs de la fonction objectif  $(f_1(v^d), \dots, f_k(v^d), \dots, f_m(v^d))$  de chaque solution  $v^d$ .
- Appliquer le concept de domination entre  $x^d$  et  $v^d$  pour sélectionner les solutions non dominées:
  - Si la solution  $x^d$  ne pouvait pas être améliorée ( $v^d$  est dominée par  $x^d$ ), incrémenter son compteur.
  - Si la solution  $x^d$  était améliorée ( $x^d$  est dominée par  $v^d$ ), mettre son compteur d'incrément à 0 et remplacer la solution  $x^d$  par  $v^d$ .
  - Si aucune solution ( $x^d$  ou  $v^d$ ) ne domine l'autre, inclure la solution  $v^d$  dans  $P$ , dans ce cas, la taille de la population  $P$  pourrait être supérieure à  $SN$ .
- Effectuer un tri non-dominé à la population  $P$  pour identifier les différents rangs et mémoriser les solutions avec le rang = 1 comme l'ensemble d'élite (ES).
- Sélectionner les solutions SN, à partir de  $P$ , comme nouvelle population  $P$ , basée sur la stratégie de sélection de population qui consiste à sélectionner la solution ayant le rang le plus bas pour une meilleure qualité d'évolution, et préférer la solution avec une plus grande distance de crowding pour rendre la répartition de la population plus homogène, améliorant ainsi la diversité de la solution.

## Étape 2: Phase des abeilles butineuses inactives

Produire de nouvelles solutions  $v^d$ ,  $d = 1, \dots, SN$ , pour les abeilles butineuses inactives basés sur les solution  $x^d$ , qui sont sélectionnées en fonction de la probabilité de sélection  $p^d$ , ensuite les évaluer selon le schéma suivant:

- Calculer les probabilités  $p^d$  pour les solutions  $x^d$  ( $d = 1, \dots, SN$ ) de la population  $P$ , par l'équation (19).

$$p^d = \frac{0.9 \times fit(x^d)}{\max_{d=1}^{SN} fit(x^d)} - 0.1 \quad (IV.19)$$

Ensuite  $fit(x^d)$  peut être calculé par:

$$fit(x^d) = \frac{1}{m} \left( \sum_{k=1}^m f'_d(x^d) \right) \quad (IV.20)$$

Et  $f'_d(x^d)$  calculé comme suit:

$$f'_d(x^d) = \begin{cases} \frac{\max f_k - f_k(x^d)}{\max f_k - \min f_k} & , \quad \text{if } \max f_k \neq \min f_k \\ 1 & , \quad \text{if } \max f_k = \min f_k \end{cases}$$

où:  $\max f_k = \max_{d=1}^{SN} f_k(x^d)$ , et  $\min f_k = \min_{d=1}^{SN} f_k(x^d)$ .

- Produire une nouvelle solution pour l'abeille butineuse inactive à partir de la solution choisie en fonction de  $v^d$ .
- Évaluer les valeurs de la fonction objectif  $(f_l(v^d), \dots, f_k(v^d), \dots, f_m(v^d))$  des solutions  $v^d$ .
- Appliquer le concept de domination entre  $x^d$  et  $v^d$  pour sélectionner les solutions non dominées:
  - Si la solution  $x^d$  ne pouvait pas être améliorée ( $v^d$  est dominée par  $x^d$ ), incrémenter son compteur.
  - Si la solution  $x^d$  était améliorée ( $x^d$  est dominée par  $v^d$ ), mettre son compteur d'incrément à 0 et remplacer la solution  $x^d$  par  $v^d$ .
  - Si aucune solution ( $x^d$  ou  $v^d$ ) ne domine l'autre, inclure la solution  $v^d$  dans  $P$ .
- Trier les solutions de  $P$  basé sur la méthode de tri non dominée et mémoriser les solutions avec le rang = 1 comme ES.
- Choisir les solutions SN comme nouvelle population basé sur la stratégie de sélection de la population.

### Étape 3: la phase des éclaireuses (scouts)

- Si une solution n'est pas mise à jour après une limite d'itérations, cette source de nourriture sera abandonnée. L'abeille employée associée deviendrait un éclaireur, et générerait une nouvelle source de nourriture aléatoire par Eq. (IV.17).

## IV.4.2 Segmentation des vaisseaux rétiniens avec le seuillage par l'algorithme EMOABC

Dans ce travail, nous adaptons l'algorithme EMOABC pour proposer une méthode de segmentation rétinienne non supervisée. L'algorithme d'optimisation utilisé permet d'extraire les vaisseaux sanguins de manière itérative à partir du fond de l'image rétinienne en fonction de l'optimisation de deux fonctions objectif de seuillage.

Dans l'étape d'initialisation, l'approche proposée consiste à utiliser une population  $P$  de sources alimentaires  $SN$  (abeilles) telles que  $P = (x^1, \dots, x^d, \dots, x^{SN})$ , et chaque  $x^d$  est situé initialement à des positions aléatoires sur l'espace de recherche, où  $x^d = (x_1^d, \dots, x_i^d, \dots, x_n^d)$  représente une solution pour la segmentation par seuillage, qui est représenté par un ensemble de  $n$  seuils tels que  $1 < \dots < x_{i-1}^d < x_i^d < x_{i+1}^d < \dots < x_n^d < L - 1$ , pour une image avec  $L$  niveaux de gris.

Deuxièmement, l'algorithme EMOABC (étapes du processus d'itération) est appliqué pour séparer les différents objets de l'image rétinienne en trouvant le "meilleur" ensemble de seuils  $x^d$  de  $P$ , qui maximisent simultanément deux fonctions objectif (critères de seuillage)  $f_1$  et  $f_2$  représentant respectivement l'entropie intra-classe de Kapur [13], et la variance interclasse d'Otsu [12], où ces deux critères de seuillage incorporent les informations contextuelles spatiales dans le processus de sélection de seuil, en utilisant la courbe d'énergie [196] comme entrée au lieu de l'histogramme traditionnel. Ensuite, le vecteur de seuil optimal  $x^* = \{x_1^*, \dots, x_i^*, \dots, x_n^*\}$  correspond à la solution de Pareto [208].

Comme nous le savons, la robustesse de tout algorithme d'optimisation de seuillage dépend du nombre de seuils, où l'algorithme d'optimisation est plus efficace quand moins de nombre de seuils seront traités. Dans ce cas, nous proposons d'itérer le processus d'algorithme de seuillage EMOABC pendant  $n$  fois jusqu'à l'obtention de la classe de réseau vasculaire en réduisant le nombre de seuils dans chaque itération, afin d'atténuer la classification de la lésion rouge et des bruits progressivement comme classe des vaisseaux, pour chaque itération, l'algorithme EMOABC cherche le vecteur de seuil optimal  $x^* = \{x_1^*, \dots, x_i^*, \dots, x_n^*\}$  composé de  $n$  seuils qui divisent la courbe d'énergie est en  $(n + 1)$  segments disjoints:

$$S_0 = \{0, 1, \dots, x_1^*\}, S_1 = \{x_1^* + 1, \dots, x_2^*\}, \dots, S_d = \{x_i^* + 1, \dots, x_{i+1}^*\}, \dots, S_n = \{x_n^* + 1, \dots, L\}.$$

où chaque segment  $S_d$  correspond aux niveaux de gris des pixels appartenant au même objet (classe) dans l'image. Comme un exemple, dans la figure IV.2 (a):  $S_0, S_1,$  et  $S_2$  appartiennent aux classes d'arrière-plan (bruits et lésions rouges), et  $S_3$  appartient à la classe des vaisseaux. À chaque itération, lorsque le nombre de seuils  $n$  est réduit de un seuil, la courbe d'énergie est modifiée comme suit:

$$E(d)=0, \forall d \in [0, x_1^*] \quad (IV.21)$$

À la fin de l'itération, nous ne conservons que la valeur de seuil optimale qui sépare les vaisseaux rétiniens des classes de fond. Les étapes principales de l'algorithme proposé sont données par l'algorithme 1. De plus, la figure IV.11 montre un exemple de changement de forme de l'histogramme de la courbe d'énergie à chaque itération.

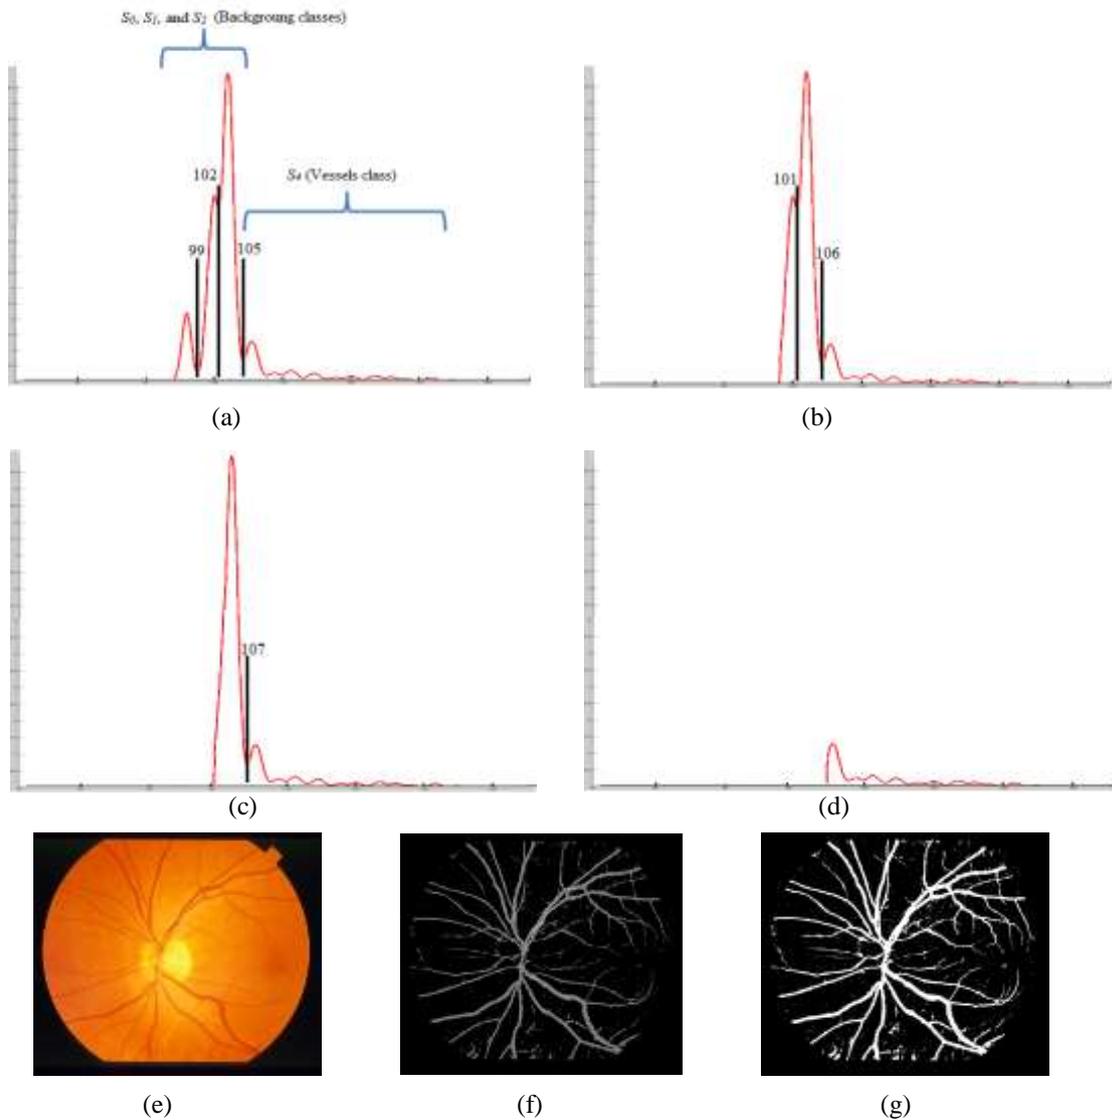
Avant l'application de l'algorithme proposé pour la localisation des vaisseaux rétiniens, une étape de pré-traitement est appliquée sur l'image d'entrée, basée sur le traitement morphologique de Top-hat [209], un élément structurant en forme de disque est utilisé, avec douze pixels de rayon. De plus, une méthode de post-traitement basée sur l'ouverture morphologique par reconstruction est utilisée pour retirer les petits composants et relier les vaisseaux fragmentés. L'opération est accomplie en utilisant un élément structurant en forme de disque de huit pixels de rayon. Le choix de la forme de l'élément structurant et de ses paramètres est empirique et doit être adapté à la résolution de l'image.

---

**Algorithme.1:** Seuillage itératif par l'algorithme proposé

---

- 1- Entrer l'image de pré-traitement
  - 2- Calculer la courbe d'énergie  $E(d)$  selon Eq.21 à chaque niveau de gris  $d$  ( $0 \leq d \leq L$ ) de l'image de pré-traitement.
  - 3- Initialiser les paramètres:
    - $n$ : le nombre initial de seuils
    - $SN$ : nombre de solution dans la population P (sources de nourriture ou abeilles).
    - $M CN$ : nombre maximal de cycles de l'algorithme EMOABC
  - 4- Tant que ( $n \leq 1$ ) faire
    - Appliquer l'algorithme EMOABC pour produire le meilleur ensemble de seuils  $x^* = \{x_1^*, \dots, x_i^*, \dots, x_n^*\}$ , en tenant compte de la courbe d'énergie  $E$  et les fonctions de seuillage  $f_1$  et  $f_2$ .
    - Réduire le nombre de seuils:  $n = n-1$
    - Modifier la courbe d'énergie  $E$  en utilisant Eq IV.21.
 Fin de Tant que
  - 5- Retour du résultat: image binaire
-



**Figure. IV.11** : Présentation du changement de l'histogramme de la courbe d'énergie dans le processus de la recherche des meilleures valeurs de seuils, où (a), (b), (c) et (d) sont les histogrammes de courbe d'énergie avec les valeurs de seuils obtenues dans chaque itération par l'algorithme proposé. (e) est l'image rétinienne d'entrée, (f) représente la classe des vaisseaux en niveaux de gris en fonction de la valeur de seuil finale obtenue, et (g) est une image rétinienne binaire.

#### IV.4.3 Résultats expérimentaux et discussion

##### IV.4.3.1 Ajustement des paramètres

Pour trouver les meilleurs paramètres de l'algorithme heuristique de seuillage proposé, un critère d'arrêt a été proposé [210] qui peut être utilisé pour trouver les valeurs de seuils précises pour le processus de la segmentation et conserver les meilleurs paramètres pour l'algorithme heuristique proposé. Dans ce travail, les meilleurs paramètres sont obtenus en s'entraînant avec les images de la base de données Train-DRIVE [161].

Nous avons effectué une analyse sur l'impact des paramètres de l'algorithme proposé sur la qualité de la segmentation des vaisseaux: le nombre maximal de cycles ( $MCN$ ), la taille de la population ( $SN$ ) et le processus de seuillage itératif maximal ( $n$ ). Tout d'abord, nous avons fait varier le nombre de  $n$  en 2, 3, 4 et 5, et fixer le reste des paramètres à  $SN = 40$  et  $MCN = 50$ . Deuxièmement, nous avons changé le nombre de  $MCN$  et fixer les valeurs des paramètres  $n$  et  $SN$  à 3 et 40, respectivement. Troisièmement, nous avons modifié le  $SN$ , et fixer  $n$  et  $MCN$  à 3 et 50, respectivement. Pour conserver les meilleurs paramètres, nous estimons la qualité des navires segmentés en fonction de la valeur du critère d'arrêt, comme cela est indiqué dans l'équation IV.22, dans chaque changement de  $n$ ,  $MCN$  et  $SN$ . Les meilleurs paramètres de l'algorithme de seuillage itératif proposé qui correspondent au minimum de l'équation IV.22 sont  $n = 3$ ,  $MCN = 40$  et  $SN = 35$ , qui garantissent une plus grande précision de segmentation des vaisseaux dans un temps d'exécution raisonnable.

$$E_t = \frac{\sum_{i=1}^{n_1} \sum_{j=1}^{n_2} [fp_t(i, j) + fn_t(i, j)]}{TP_t + TN_t + FP_t + FN_t} \quad (IV.22)$$

$$TP_t = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} tp_t(i, j), \quad TN_t = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} tn_t(i, j) \quad (IV.23)$$

$$FP_t = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} fp_t(i, j), \quad FN_t = \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} fn_t(i, j) \quad (IV.24)$$

où ( $tp_t$ ), ( $tn_t$ ), ( $fp_t$ ), et ( $fn_t$ ) sont : vrai positif, vrai négatif, faux positif et faux négatif, respectivement pour un pixel dans un emplacement ( $i, j$ ). Dans les équations (IV.23) - (IV.24) TP, TN, FP, et FN représentent le nombre total de pixels sont respectivement des vrais positifs, des vrais négatifs, des faux positifs et des faux négatifs.

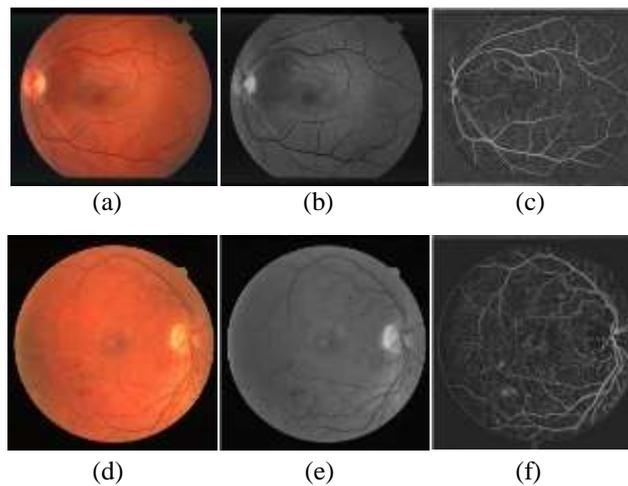
#### IV.4.2.2 Analyse et comparaison

Tableau IV.5 montre les performances de la méthode proposée pour la segmentation des vaisseaux sur les bases de données DRIVE et STARE basées sur les différentes mesures de discordance. À partir de ce tableau, nous pouvons remarquer la robustesse de l'algorithme par rapport à l'image d'entrée, normale ou anormale, car elle est généralement stable pour les images normales et même pour les images avec des lésions (exsudats, hémorragies). La figure IV.12 montre des exemples d'images rétinienne normales et anormales améliorées par le pré-traitement morphologique de Top-hat. Nous remarquons que le pré-traitement proposé améliore la différence de contraste entre les vaisseaux et le fond, où les pixels les plus brillants dans l'image représentent les portions majeures du système vasculaire.

**Tableau IV.5 :** Performance de la méthode proposée sur la base de données DRIVE et STARE.

Test Data	DRIVE			STARE		
Image	Sen	Spec	Acc	Sen	Spec	Acc
01	0.768	0.976	0.949	0.679	0.940	0.913
02	0.830	0.969	0.948	0.609	0.951	0.921
03	0.732	0.975	0.943	0.714	0.934	0.916

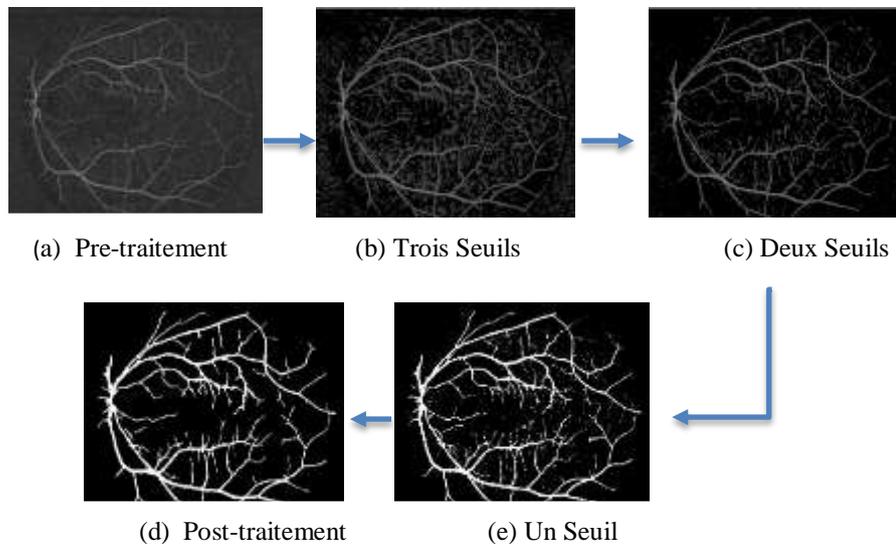
04	0.752	0.971	0.943	0.573	0.973	0.932
05	0.781	0.976	0.953	0.560	0.965	0.916
06	0.634	0.984	0.936	0.801	0.952	0.93
07	0.731	0.972	0.947	0.856	0.963	0.952
08	0.822	0.951	0.938	0.832	0.971	0.957
09	0.694	0.971	0.939	0.814	0.978	0.961
10	0.686	0.987	0.955	0.633	0.963	0.927
11	0.701	0.984	0.950	0.753	0.976	0.955
12	0.757	0.971	0.946	0.891	0.964	0.956
13	0.664	0.977	0.931	0.818	0.960	0.943
14	0.809	0.968	0.951	0.809	0.961	0.943
15	0.665	0.981	0.947	0.699	0.981	0.94
16	0.735	0.982	0.952	0.711	0.954	0.921
17	0.801	0.966	0.948	0.794	0.972	0.95
18	0.746	0.974	0.944	0.681	0.978	0.958
19	0.780	0.968	0.941	0.763	0.960	0.949
20	0.688	0.977	0.938	0.950	0.933	
Mean	0.739	0.974	0.945	0.759	0.962	0.940



**Figure IV.11** Présentation de l'étape de pré-traitement sur les images rétiniennes normales et anormales des bases de données Stare et Drive respectivement. (a) et (d) sont les images rétiniennes normales et anormales. (b) et (e) sont les images du canal vert. (c) et (f) sont les images améliorées par reconstruction Top-hat.

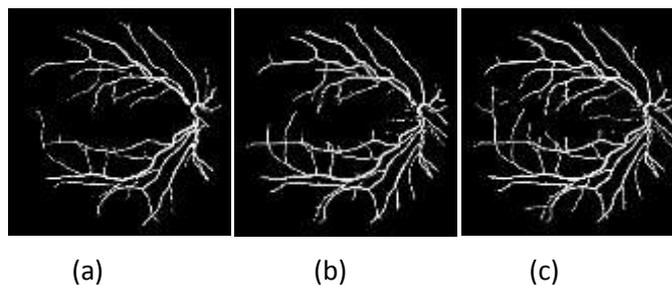
Figure IV.12 montre l'extraction itérative des vaisseaux sanguins à partir d'une image normale de la base de données DRIVE. D'abord, l'image améliorée par le pré-traitement est utilisée comme une entrée, puis le processus de l'algorithme EMOABC itère au moins trois fois pour obtenir l'image binaire. Enfin, le post-traitement est appliqué sur l'image binaire pour supprimer les petits composants et reconnecter les vaisseaux fragmentés. À partir de cette figure, nous pouvons remarquer que l'application de l'algorithme EMOABC de seuillage itératif réduit l'apparence des lésions et du bruit lors de l'itération, et qu'à chaque étape de

l'algorithme proposé classe certains petits composants (exsudats, hémorragies) dans la même classe avec le fond. Cependant, le système proposé a la limitation suivante, dans le résultat final de l'image rétinienne; quelques petites lésions sont incluses dans le système vasculaire. Ceci est dû au fait qu'ils ont la même intensité de niveau de gris avec les petits vaisseaux et qu'ils sont donc considérés comme des vaisseaux.

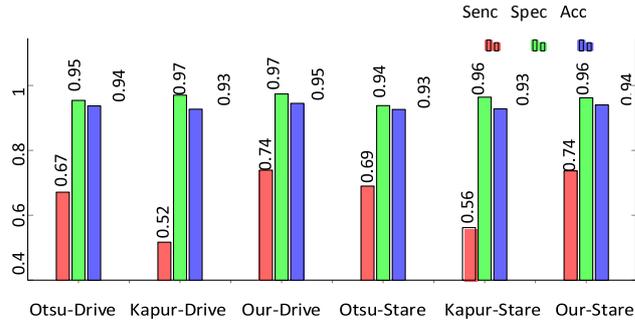


**Figure IV.12** : Présentation d'extraction des vaisseaux de l'image rétinienne normale de la base de données STARE, où, (a) résultat du pré-traitement. (b), (c) et (e) sont les résultats de l'application de l'algorithme EMOABC de seuillage multi-niveau itératif. (d) Résultat de post-traitement.

Pour montrer l'avantage de seuillage d'image basée sur l'optimisation simultanée de certains critères, et lorsqu'ils sont utilisés séparément. La figure IV.14 donne les métriques de discordances moyennes de l'algorithme de seuillage multi-niveau itératif par rapport au seuillage à deux niveaux en utilisant les méthodes Kapur et Otsu. À partir de cette figure, nous remarquons que l'approche proposée atteint une sensibilité considérablement plus élevée que les méthodes de seuillage à deux niveaux sur les bases de données DRIVE (proposé 0.74 vs. Otsu 0.67, Kapur 0.52) et STARE (proposé 0.74 vs. Otsu 0.69, Kapur 0.56), ce qui conduit à une segmentation de plus de vaisseaux. En outre, l'exemple de la figure IV.13 montre que l'optimisation de deux critères simultanément, dans un schéma itératif, est plus efficace que s'ils étaient utilisés séparément. Qualitativement, nous pouvons remarquer que l'algorithme proposé détecte plus de vaisseaux que les deux autres méthodes de seuillage. En général, nous pouvons déduire à partir de la figure IV.14 que l'algorithme proposé atteint des valeurs les plus élevées de métriques de discordance pour les deux bases de données par rapport aux méthodes de seuillage simples.



**Figure. IV.13**: Présentation de l'extraction des vaisseaux rétiniens de la base de données DRIVE, en utilisant (a) Kapur, (b) Otsu, et (c) la méthode proposée.



**Figure. IV.14:** Comparaison des performances entre les méthodes de seuillage à deux niveaux et la méthode proposée sur les bases de données STARE et DRIVE.

Tableau IV.7 présente la comparaison des performances par rapport à d'autres approches existantes. À partir de ce tableau, nous observons que la complexité du temps de la méthode de segmentation des vaisseaux proposée est inférieure à la plupart des méthodes existantes. L'approche proposée obtient des résultats comparables aux méthodes existantes en terme de Spec et Acc, à l'exception des approches supervisées [157], [161] sur l'ensemble de données STARE. L'approche de Staal et al. [161] semble être meilleure que notre approche, cependant, elle est d'une complexité de calcul plus élevée pour trouver les vaisseaux. En outre, nous remarquons que la méthode de segmentation des vaisseaux proposée surpasse les algorithmes de métaheuristiques de segmentation des vaisseaux [182], [183], [184], [185], et [186]. De plus, notre méthode est plus rapide et présente des performances plus élevées dans les deux bases de données testées. Nous pouvons également déduire du tableau IV.7 que la méthode proposée pourrait permettre d'obtenir des résultats d'extraction des vaisseaux significativement meilleurs, comme le démontrent ses valeurs plus élevées de Sen provenant des deux bases de données. Par ailleurs, dans la méthode proposée, nous avons uniquement utilisé l'ensemble de données de DRIVE-training pour régler les paramètres, tandis que la plupart des méthodes non supervisées et supervisées existantes utilisaient les ensembles de données DRIVE et STARE pour conserver les meilleurs paramètres. Le tableau IV.6 présente la moyenne de l'écart-type (SD) de la mesure Acc à partir de l'algorithme proposé, ainsi que les différentes méthodes existantes sur les bases de données STARE et DRIVE.

**Tableau IV.6** Comparaison des valeurs de moyenne d'écart type de la précision (Acc) entre les méthodologies existantes avec notre algorithme proposé sur les bases de données STARE et DRIVE.

Methods	SD Acc	
	DRIVE	STARE
Marin et al. [157]	0.0063	-
Hassanien et al [185]	0.0041	0.0142
Emary et al. [184]	0.0110	0.0136
Asad et al. [186]	-	0.0170
Cinsdikici et al [182]	0.0058	-
Staal et al. [161]	0.0065	-
<b>Méthode proposée</b>	<b>0.0062</b>	<b>0.0159</b>

**Tableau IV.5** : Comparaison des performances avec les méthodes existantes sur les bases de données STARE et DRIVE en termes de sensibilité, de spécificité, de précision, et de temps d'exécution.

Base de teste	DRIVE				STARE				
Method	Sen	Spec	Acc	Time	Sen	Spec	Acc	Time	System
<b>Supervisé</b>									
Marin et al. [157]	0.706	0.980	0.945	90 s	0.694	0.981	0.952	90 s	2.13 GHz,1-GB RAM
Staal et al. [161]	0.719	0.977	0.944	15 min	0.697	0.981	0.952	15 min	1.0 GHz,1-GB RAM
Soares et al. [162]	0.733	0.978	0.946	3 min	0.720	0.975	0.948	3 min	2.17 GHz,1-GB RAM
Mendonca et al [209]	0.734	0.976	0.945	2.5 min	0.699	0.973	0.944	3 min	3.2 GHz,1-GB RAM
Budai et al.[17]	0.644	0.987	0.957	5 s	0.580	0.982	0.938	6 s	2.3 GHz,4-GB RAM
<b>non supervisé</b>									
Nguyen et al. [108]	0.698	0.972	0.941	5.6 s	0.836	0.945	0.932	5.6 s	2.6 GHz,4-GB RAM
Miri et al [98]	0.715	0.976	0.943	50 s	-	-	-	-	3 GHz,1-GB RAM
Emary et al [184]	0.628	0.984	0.938	-	0.586	0.987	0.944	-	-
Asad et al [183]	-	-	-	-	0.853	0.921	0.913	42 s	2.53 GHz,3-GB RAM
Cinsdikici et al [182]	-	-	0.929	35 s	-	-	-	-	-
Hassanien et al [185]	0.721	0.971	0.938	-	0.649	0.982	0.946	-	-
Emary et al [186]	-	-	0.936	102 s	-	-	-	-	-
Méthode proposée	0.739	0.974	0.945	2.21 s	0.737	0.962	0.940	3.14 s	2.6 GHz,4-GB RAM

## IV.5 Conclusion

Dans ce chapitre, nous avons commencé notre travail par approfondir l'étude des critères de segmentation (seuillage) afin de trouver une formalisation plus poussée des relations entre les critères de segmentation et les images à segmenter. Nous avons classifié ces critères en deux classes, ensuite une quantification de l'évaluation des résultats a été également traitée via une mesure de performance. Dans la deuxième section, nous avons adopté une méthode de métaheuristique d'optimisation pour accélérer le processus du seuillage à multi-niveaux, où nous avons combiné plusieurs critères de seuillage en utilisant une technique d'optimisation multi-objectif. La robustesse de notre algorithme proposé a été testée sur différents types d'images. Due à la robustesse de ce type d'algorithmes basé sur le seuillage, dans la troisième section nous avons l'appliqué une première fois sur la segmentation d'image rétinienne, où une méthode non supervisée est proposée basée sur l'algorithme de la colonie d'abeilles, afin de sélectionner les seuils optimaux qui séparent les vaisseaux sanguins de l'arrière-plan.

# Chapitre 5 : Méthode d'optimisation par essaim de particules pour la détection de petits vaisseaux rétiens sur des images de fond d'œil à multi-résolution

## V.1 Introduction

Dans ce chapitre, nous présentons notre deuxième contribution dans le domaine de la segmentation des images médicales, particulièrement sur les images de la rétine, où nous analysons la méthode développée pour la segmentation des plus petits vaisseaux. Pour cela nous avons exploité la flexibilité des fonctions de fitness multi-objectifs et la puissance de l'algorithme PSO pour la segmentation de l'image rétinienne. Nous commençons par présenter l'algorithme proposé par Nguyen et al. [108], qui représente la première étape de notre méthode, ensuite, nous présentons les concepts de base de l'algorithme PSO [211].

La méthode proposée consiste à trouver la meilleure disposition des échelles de détection de ligne, en appliquant l'algorithme PSO (section 4.3.3). Enfin, l'étape de recombinaison proposée est présentée dans la section 4.3.4. La méthode est appliquée sur des images de fond d'œil à haute et basse résolution qui sont accessibles au public.

## V.2 Algorithme de détection de ligne multi-échelle

La méthode MSLD [108] est un modèle généralisé de la méthode de détection de ligne à échelle unique [107]. Comme proposé initialement, il utilise un segment d'échantillonnage linéaire de longueur variable qui tourne autour d'un pixel central. L'intensité moyenne le long du segment est calculée dans le but de maximiser sa réponse  $I_{max}^L$  lorsque le segment est parallèle à la direction du vaisseau. La réponse maximale est ensuite corrigée en la comparant à l'intensité moyenne au voisinage  $I_{avg}^w$  du pixel central. La taille du voisinage est égale à la plus grande échelle choisie, ou la longueur de ligne. La réponse de ligne pour une seule échelle est calculée comme suit:

$$R_{max}^L = I_{max}^L - I_{avg}^w, \quad (V.1)$$

Selon les auteurs [108], la longueur choisie du paramètre d'échelle  $W$  est deux fois le diamètre d'un vaisseau typique dans l'image rétinienne. Ainsi, une image à haute résolution, comme dans la base de données HRF [189], nécessite une valeur proche de  $W = 40$  pixels avec un incrément de deux. En revanche, pour une image basse résolution, comme dans la base de données DRIVE [161], la moitié de la valeur précédente est suffisante. Pour obtenir la réponse MSLD finale, l'équation suivante (équation V.2) est utilisée pour calculer la combinaison linéaire des réponses linéaires sur toutes les échelles disponibles :

$$R_{Combined} = \frac{1}{n_L + 1} \left( \sum_L R_W^L + I_{igc} \right) \quad (V.2)$$

Où  $n_L$  est le nombre d'échelles,  $R_W^L$  est la réponse du détecteur de ligne à l'échelle  $L$ , et  $I_{igc}$  est le pixel de valeur du canal vert inversé.

## V.3 Algorithme d'optimisation de l'essaim de particules

L'algorithme PSO est une technique de calcul évolutive proposée par Eberhart et Kennedy [211]. L'avantage de PSO est qu'il est simple dans le concept, facile à mettre en

œuvre, et il y a très peu de paramètres de contrôle à ajuster en comparaison avec d'autres techniques évolutives. La méthode est utilisée pour l'optimisation stochastique, où elle est similaire aux principes d'intelligence de l'essaim observés dans les comportements naturels des groupes d'espèces animales. Ceux-ci sont connus collectivement comme des essaims, et ils peuvent inclure des nuées d'oiseaux, ou même le comportement sociologique d'un groupe de personnes [212]. Chaque individu de l'essaim est représenté par une particule. Dans l'algorithme PSO, les candidats particules sont appelés des solutions. Pour trouver une solution optimale, les particules traversent l'espace de recherche et suivent les particules qui se trouvent à leurs meilleures positions antérieures, ainsi que les sources de nourriture proches. Dans chaque étape de la procédure de PSO,  $\overline{gbest}_i$  est la meilleure valeur globale obtenue de la population lorsque l'ensemble de l'essaim est mis à jour. Pour chaque itération de l'algorithme, la nouvelle position d'une particule est calculée en fonction de sa position précédente  $\overline{X}_i$ , sa vitesse  $\overline{V}_i$  ou du taux de changement de position, et de sa valeur  $\overline{gbest}_i$ . C'est un processus itératif qui est répété jusqu'à ce qu'un critère de convergence prédéfini soit satisfait. L'algorithme 1 présente les étapes de base de l'algorithme PSO.

**Algorithme 1.** Les étapes de base de l'algorithme PSO

---

```
Initialiser swarm (Initialiser  $\overline{X}_i$ ,  $\overline{V}_i$  et  $\overline{gbest}_i$ )
```

---

```
Boucle:
  Pour toutes les particules
    Evaluer la fonction Fitness ( $\overline{f}_i$ ) de chaque particule  $\overline{X}_i$ 
    Mettre à jour  $\overline{X}_i$ ,  $\overline{V}_i$ , et  $\overline{gbest}_i$ 
    Mettre à jour la nouvelle position  $\overline{X}_i$ 
  Fin
Jusqu'à l'arrêt des critères (convergence)
```

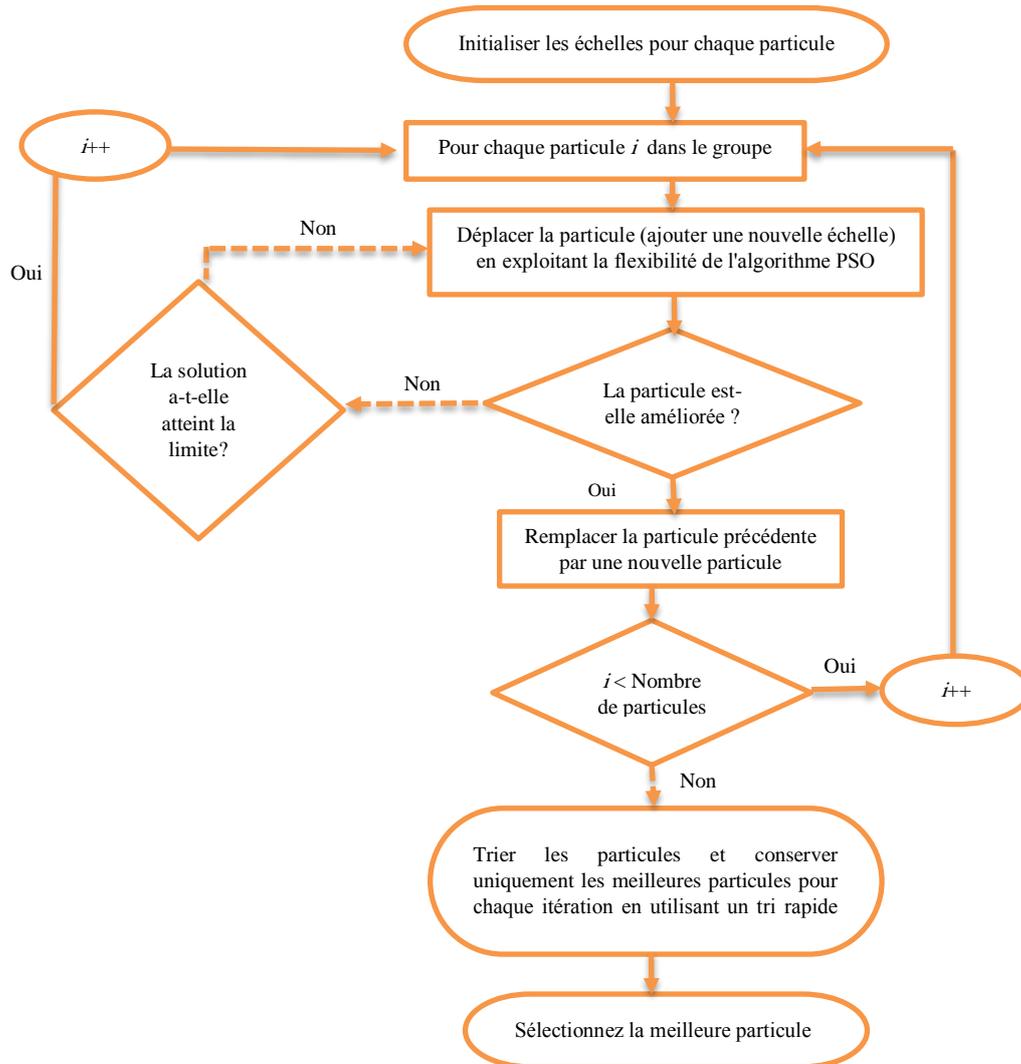
---

**V.4 L'algorithme de réarrangement d'échelle proposé**

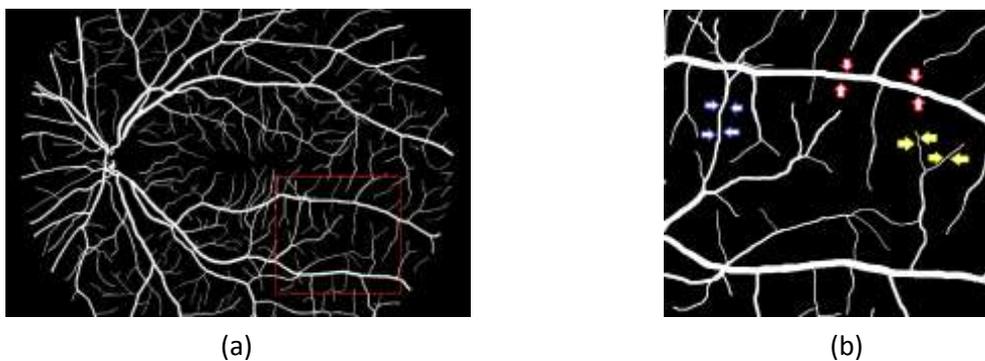
Notre contribution principale est l'optimisation de la disposition des échelles disponibles dans la méthode MSLD en exploitant la flexibilité de l'algorithme PSO. Dans la méthode MSLD, toutes les échelles disponibles entre le minimum et le maximum sont généralement prises en compte quel que soit la taille de vaisseau. Ceci est déficient parce que les vaisseaux produisent généralement la réponse de ligne optimale à une échelle particulière qui dépend de leur diamètre. Dans l'algorithme proposé, nous sélectionnons les échelles les plus optimales, et ne retenons que celles qui contribuent à l'optimisation globale des fonctions objectifs.

Dans notre application, nous supposons que les images rétinienne contiennent trois calibres de vaisseaux : 1) petit, 2) grand, et 3) moyenne (voir figure V.2). Selon le diagramme (figure V.1), à l'étape d'initialisation, nous assignons chaque particule  $\overline{X}_i$  à une échelle spécifique parmi les trois calibres de vaisseaux disponibles. Le processus d'optimisation est itératif. À la deuxième étape, nous ajoutons une nouvelle échelle pour chaque particule afin d'extraire plus de vaisseaux de l'image rétinienne. Ensuite, nous comparons la nouvelle particule avec la particule précédente en fonction de sa position  $\overline{X}_i$  en utilisant les fonctions objectifs. Dans notre cas, les fonctions objectifs que nous utilisons représentent la sensibilité et la spécificité de l'image segmentée (Eq V.4 et Eq V.5). Nous trions les particules, afin de ne garder que le meilleur pour chaque itération, en appliquant les stratégies d'optimisation multi-

objectif proposée par Huo et al. [208]; Non-Dominated Sorting Method, et Population Selection Strategy. À la fin du processus, nous conservons la meilleure particule qui a donné les meilleures échelles.



**Figure V.1 :** Organigramme du processus de sélection des meilleures échelles par l'algorithme PSO



**Figure. V.2 :** Exemple des trois différents calibres de vaisseaux considérés dans les vaisseaux rétiniens. (a) une image rétinienne de référence à partir de base de données de haute résolution (HRF) [36]; (b) une région agrandie correspondant au carré rouge dans (a); les flèches rouges indiquent les grands navires, les flèches jaunes indiquent les petits navires, tandis que les flèches bleues indiquent les navires de moyen calibre.

## V.5 L'algorithme de recombinaison proposé

De plus, nous proposons de regrouper les échelles identifiées en fonction de leur contribution à la détection de chaque vaisseau. Nous visons à éviter l'impact négatif de la combinaison des échelles à un niveau inférieur ou supérieur à celui optimal pour un vaisseau d'une taille spécifique. Le processus proposé de recombinaison à l'échelle est démontré sur la figure V.3.

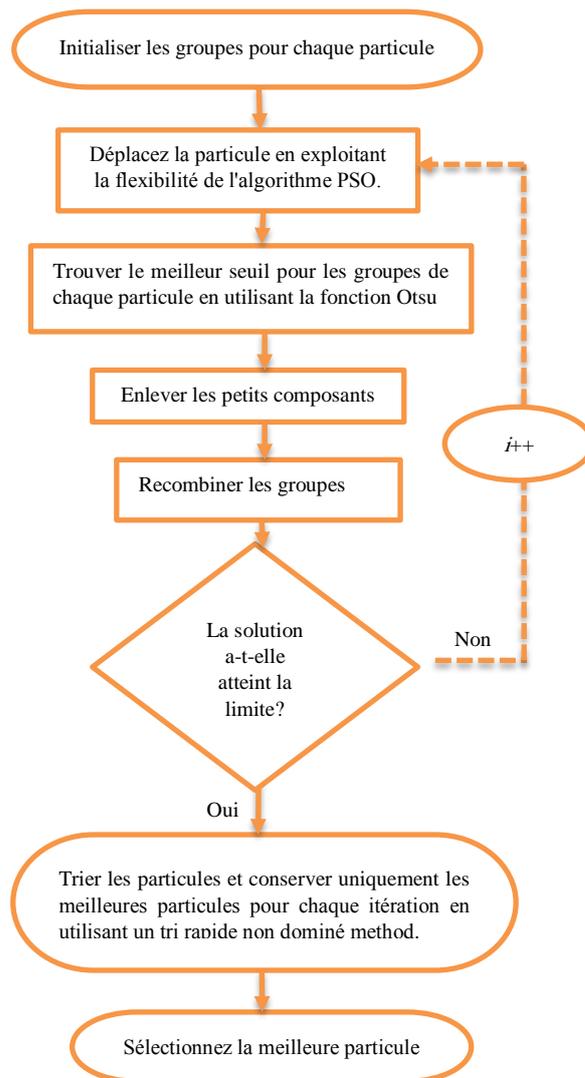
Dans l'approche MSLD, la réponse de recombinaison finale dépend du nombre d'échelles disponibles (équation V.2), la méthode pondérant également la contribution de chaque échelle. Cependant, ceci n'est pas optimal car les contributions de certaines échelles qui ne sont pas pertinentes pour les vaisseaux examinés, et la correction par rapport au voisinage de moyenne (équation V.1) peuvent réduire la réponse globale de détection de ligne.

Par exemple, dans la phase de recombinaison, la réponse de ligne des petits vaisseaux diminue lorsque des échelles élevées sont utilisées dans le cluster, car la réponse de ligne est corrigée en fonction de l'utilisation d'une grande moyenne. Dans certaines régions, à la périphérie et au centre de la rétine, le contraste entre les petits vaisseaux et le fond est faible. De plus, les petits vaisseaux sont minces et semblent tortueux, et leur morphologie pourrait être affectée dans des cas pathologiques. Lorsque l'approche MSLD est appliquée à cette catégorie de navires, il y a une réduction globale de la réponse de la ligne multi-échelle recombinaisonnée  $R_{Combined}$ , qui est une combinaison de deux facteurs. Premièrement, la longueur de la ligne d'échantillonnage à des échelles élevées dépasse la taille des petits vaisseaux, et donc la moyenne globale  $I_{max}^L$  est normalisée par les pixels de fond adjacents aux vaisseaux. Deuxièmement, la fenêtre de calcul de moyenne à partir de grandes échelles considère un nombre significatif de pixels de fond, ce qui augmente globalement la valeur de  $I_{avg}^w$ . Par conséquent, la valeur de réponse MSLD finale est réduite dans les régions à faible contraste avec de petits vaisseaux. De même, la réponse de la ligne centrale des grands vaisseaux diminue lorsque les échelles inférieures dans le cluster sont utilisées en raison de la petite zone de moyenne qui s'adapte complètement à l'intérieur du vaisseau. L'algorithme PSO est une alternative appropriée pour classer les échelles en fonction de la taille des vaisseaux. Pour ce faire, nous avons recherché le meilleur seuil pour chaque cluster  $Gr_i$ , et enlevé les petits composants des résultats segmentés. Finalement, nous avons recombinaisonné les résultats selon l'équation suivante:

$$Gr_{Combined} = \frac{1}{n}(Gr_i + Gr_{i+1} + \dots + Gr_n) \quad (V.3)$$

où  $n$  est le nombre de cluster.

Pour la classification d'une région comme vaisseau ou arrière-plan, nous avons utilisé la méthode d'Otsu pour trouver le meilleur seuil qui augmente la séparation entre les deux classes, de sorte que leur propagation combinée soit minimale [12]. Comme de petites structures linéaires isolées peuvent être mal classées en tant que vaisseau sanguin, nous avons appliqué l'ouverture de la zone morphologique (voir figure V.4) pour supprimer tous les composants connectés dont la taille de la zone était inférieure à  $P$  pixels. Le choix de la valeur du paramètre  $P$  est empirique et devrait être adapté à la base de données utilisée.



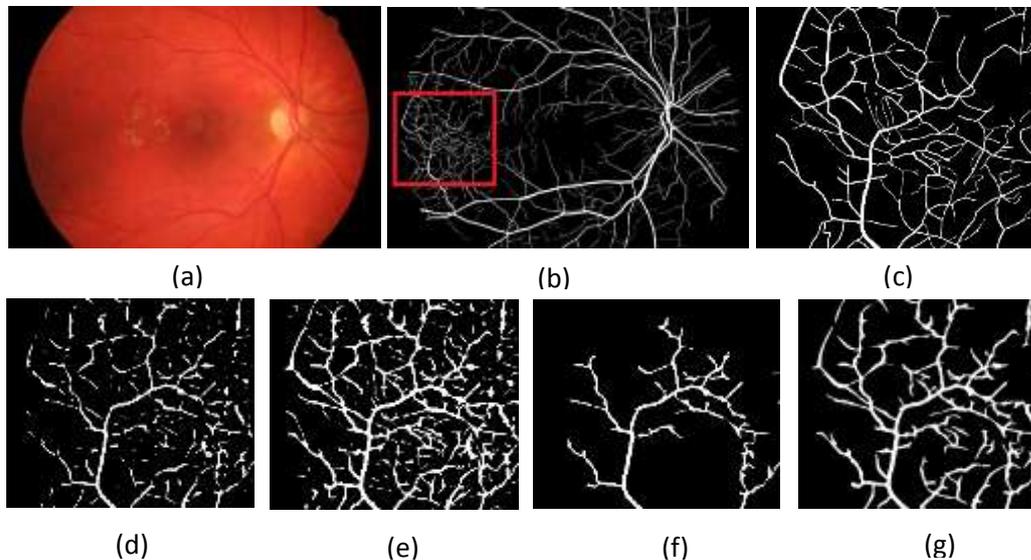
**Figure. V.3 :** Organigramme de la méthode de recombinaison proposée

## V.6 Évaluation des performances sur la base de données haute résolution

Les travaux existant sur la segmentation des vaisseaux n'ont été validés que sur des ensembles de données à basse résolution [181]- [186]. Au lieu de cela, dans cette étude, nous avons considéré un ensemble de données à haute résolution afin de démontrer l'efficacité de la méthode proposée sur différentes résolutions d'images rétiniennes. Dans notre expérimentation, les deux groupes, sain (H) et rétinopathie diabétique (DR) ont été utilisés pour comparer la méthode MSLD et la méthode proposée. Après l'application de la méthode proposée, l'algorithme partitionne les échelles disponibles en trois groupes ( $L_1, L_2, L_3$ ) avec:  $L_1 = \{3, 7, 9\}$ ,  $L_2 = \{13, 15, 19, 21\}$  et  $L_3 = \{25, 27, 37\}$ . Par la suite, les seuils de chaque groupe sont fixés à  $T_{L1} = 0.65$ ,  $T_{L2} = 0.75$ , et  $T_{L3} = 0.48$ , tandis que la valeur de seuil utilisée pour la méthode MSLD est  $T = 0.63$ .

Dans l'ensemble, le nombre d'échelles a été réduit de 21 à 10. Qualitativement, à partir des images binarisées de la figure V.4 (d) et de la figure V.4 (e), nous pouvons voir l'efficacité d'un seuil spécifique pour chaque groupe le cas où un seuil commun à toutes les échelles est utilisé. La méthode proposée extrait les vaisseaux de manière plus fiable que la méthode

MSLD et avec moins de bruit de fond. Nous pouvons conclure que le choix d'un seul seuil pour toutes les échelles n'est pas suffisant pour bien segmenter les différentes tailles de vaisseaux réiniens. De plus, le choix de la valeur de seuil est effectué manuellement dans la méthode MSLD, tandis que la méthode proposée sélectionne automatiquement les seuils en fonction de l'optimisation de la segmentation finale. La robustesse de la méthode proposée a été évaluée quantitativement selon deux stratégies. Tout d'abord, lorsque la vascularisation complète est considérée, et deuxièmement, en séparant les grands et les petits vaisseaux.



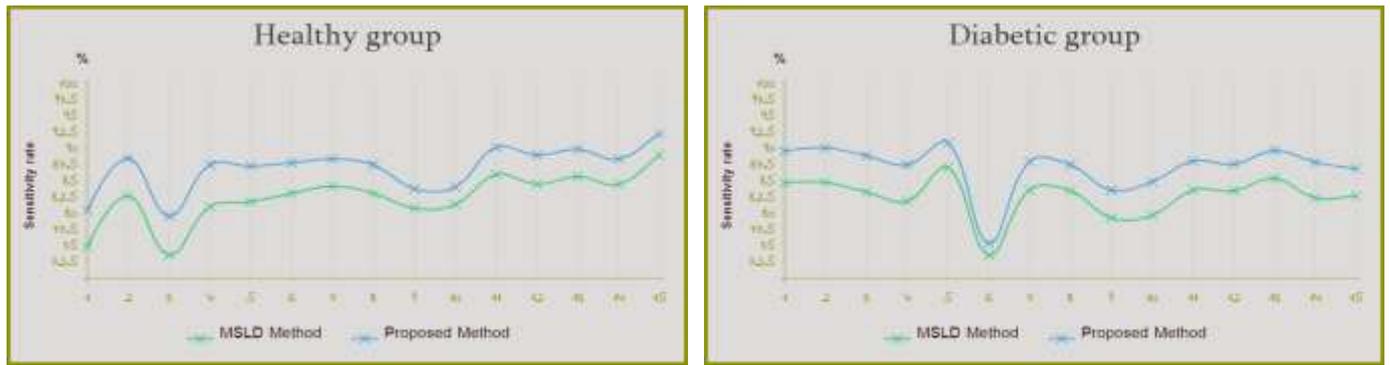
**Figure. V.4** Effet des étapes du seuillage et de post-traitement sur le résultat de la segmentation finale (Cas de l'image 06 DR, base de données HRF): (a) est l'image du fond d'œil diabétique; (b) image d'une segmentation manuel; (c) la segmentation manuel correspondant au carré rouge dans (b); (d) et (e) sont la segmentation par le MSLD méthode et l'algorithme proposé respectivement; et (f) et (g) montrent l'effet du post-traitement sur la segmentation finale pour l'approche MSLD et la méthode proposée, respectivement.

### V.6.1 Analyse et comparaison sur la segmentation de tout le réseau vasculaire

Le tableau 1 montre les résultats en termes de mesures de discordance standard dans le groupe d'images saines et diabétiques. Les méthodes proposées ont permis la segmentation de plus de vaisseaux que le MSLD. La méthode proposée a amélioré le taux de sensibilité pour la segmentation entière de la vascularisation par rapport à la méthode MSLD de 4,51% pour l'ensemble de test. La figure V.5 démontre le taux de sensibilité de performance par image de la méthode proposée et la méthode MSLD sur les ensembles de données H et DR. À partir de ces deux graphiques, nous pouvons voir que la méthode proposée a atteint un taux de sensibilité systématiquement plus élevé que la méthode MSLD. La différence est stable, que l'image soit saine ou qu'elle contienne divers types de lésions telles que des exsudats, des hémorragies ou une néovascularisation.

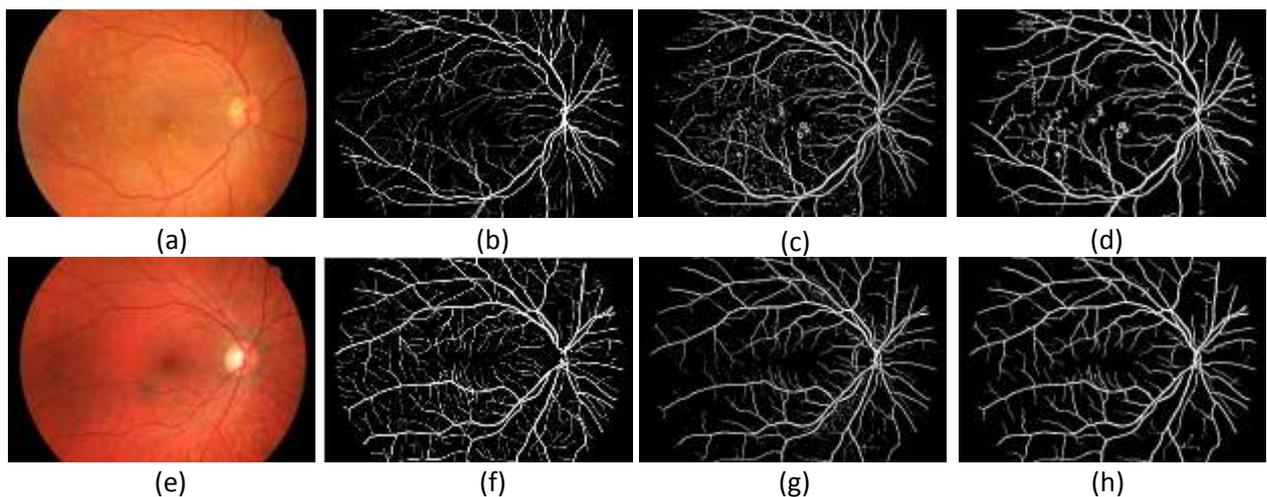
**Tableau V.1** Comparaison des performances de la segmentation de tout le réseau vasculaire sur l'ensemble de test en termes de sensibilité, de spécificité et de précision.

Méthode	Sensibilité ( $\mu \pm \sigma$ )	Spécificité ( $\mu \pm \sigma$ )	Précision ( $\mu \pm \sigma$ )	Temps (Min)
La méthode MSLD	82.58% $\pm$ 3.65%	95.40% $\pm$ 2.14%	94.13% $\pm$ 1.72%	3.31
<b>La méthode proposée</b>	<b>87.09%<math>\pm</math>3.46%</b>	<b>95.40%<math>\pm</math>1.78%</b>	<b>94.54%<math>\pm</math>1.51%</b>	<b>3.27</b>



**Figure. V.5 :** Comparaison des performances par image du taux de sensibilité sur les groupes sains et diabétiques.

La figure V.6 montre des résultats qualitatifs sur la segmentation d'images saines et diabétiques pour les deux méthodes comparées. Les deux exemples démontrent la robustesse de la méthode proposée par rapport à l'approche MSLD. Dans le cas de l'image diabétique, nous pouvons voir que certaines anomalies, constituées principalement de lésions et de structures de fond linéaires, sont isolées lors de l'application de la méthode MSLD. Cependant, la méthode proposée a résolu ce problème en réduisant la réponse des structures de fond. Pour les vaisseaux de petit diamètre, la méthode MSLD fournit des valeurs de réponse de ligne faibles, principalement parce que les échelles ne sont pas correctement réarrangées ou recombinaées. De même, pour le cas sain, nous pouvons voir que la méthode proposée a détecté plus de vaisseaux, grands et minces, avec moins de bruit de fond que la méthode MSLD.



**Figure.V.6 :** Exemples de segmentation d'une image DR, et une image H à partir la base de données HRF. (a) et (e) sont les images du fond d'œil diabétique et saine, respectivement; (b) et (f) des images de segmentation manuel; (c) et (g) sont les résultats de segmentation par la méthode MSLD; tandis que (d) et (h) sont les résultats de la segmentation par la méthode proposée.

Le tableau 2 montre les performances de la méthode proposée par rapport aux autres méthodes existantes dans la base de données haute résolution. Nous pouvons observer que le taux de sensibilité de la méthode de segmentation de vaisseau proposée est plus élevé que la plupart des autres méthodes sur l'ensemble du test. Par rapport à un algorithme récemment

proposé basé sur la combinaison du MSLD avec une approche d'organisation perceptuelle [31], les taux de spécificité et de précision sont similaires pour les deux méthodes; cependant, le taux de sensibilité est plus élevé pour la méthode proposée de 2,03%. De plus, la précision de segmentation de la méthode proposée est comparable à la plupart des autres méthodes, atteignant un taux d'environ 95%. Hannink et al. [213] ont réussi à obtenir une précision légèrement meilleure que notre méthode; cependant, au détriment d'un taux de sensibilité considérablement inférieur.

Pour une comparaison robuste de la complexité temporelle, nous avons implémenté et exécuté les méthodes basées sur l'approche MSLD telles que les méthodes de Nguyen et al. [108] et Christodoulidis et al. [214] dans le même ordinateur. Nous pouvons observer à partir du tableau V.2 que la complexité temporelle de la méthode proposée est légèrement meilleure par rapport à la méthode MSLD [108]. Pour la méthode de Christodoulidis, la complexité temporelle est significativement plus faible pour la méthode proposée, segmentant les vaisseaux environ six fois plus vite que leur méthode. Pour les autres méthodes hybrides, elles reposent sur l'utilisation de plusieurs étapes pour atteindre la segmentation finale, ce qui augmente leur temps de calcul global.

**Tableau V.2:** Comparaison des performances de différentes méthodes sur l'ensemble de test en termes de précision de spécificité de sensibilité. \* (P <0,05, deux simple t-test).

Méthode	Sensibilité ( $\mu \pm \sigma$ )	Spécificité ( $\mu \pm \sigma$ )	Précision ( $\mu \pm \sigma$ )	Temps (Min)	Système
Frangi et al. [215]	60.55%±6.52%	98.05%±2.25%	95.05%±2.05%	0.65 m	2.3 GHz,4-GB RAM
Yu et al. [216]	77.89%	96.96%	95.13%	-	-
Budai et al. [217]	66.00%	98.45%	95.80%	0.44 m	2.3 GHz,4-GB RAM
Odstrcilik et al. [189]	76.62%	96.84%	94.92%	18 m	2.3 GHz,4-GB RAM
Nguyen et al [108]	82.58%±3.65%	95.40%±2.14%	94.13%±2.14%	3.31 m	2.6 GHz,4-GB RAM
Hannink et al. [213]	79.85%±5.02%	97.55%±2.01%	96.10%±1.7%	-	-
Annunziata et al. [218]	69.08%	98.61%	95.70%	-	-
Christodoulidis et al. [214]	85.06%±4.03%	95.82%±1.15%	94.79%±1.06%	18.31 m	2.6 GHz,4-GB RAM
<b>Méthode proposée*</b>	<b>87.09%±3.46%</b>	<b>95.40%±1.78%</b>	<b>94.54%±1.51%</b>	<b>3.27 m</b>	<b>2.6 GHz,4-GB RAM</b>

## V.6.2 Analyse et comparaison sur la segmentation de petits et de grands vaisseaux

Dans cette section, nous nous concentrons davantage sur l'analyse de la performance de deux différentes catégories de vaisseaux dans les images: les petits et les grands vaisseaux. Ceci est nécessaire parce qu'il y a une inhomogénéité de population dans les différentes catégories de vaisseaux [107]. Par conséquent, les paramètres de discordance standard ne permettent pas de quantifier correctement les performances de la plus petite catégorie de vaisseaux lorsque tous les vaisseaux sont considérés. Les différentes catégories de vaisseaux ont été examinées et analysées séparément. Dans le contexte des données à haute résolution, et plus particulièrement pour la base de données HRF, nous avons considéré que les pixels des vaisseaux appartenant à des vaisseaux de diamètre inférieur à 8 pixels ( $D \leq 8$  pixels) sont petits. Nous avons évalué séparément la performance de la méthode proposée sur les données H et DR. Les mêmes valeurs de seuils utilisées pour l'analyse de performance globale (section V.4) ont été utilisées séparément pour l'analyse des petits et des grands vaisseaux.

Le tableau V.3 présente l'évaluation des performances sur les petits vaisseaux dans chaque groupe d'images. Nous pouvons voir que les performances sur les différentes mesures étaient plus élevées pour la méthode proposée par rapport à la méthode MSLD avec ( $p < 0,05$ ,

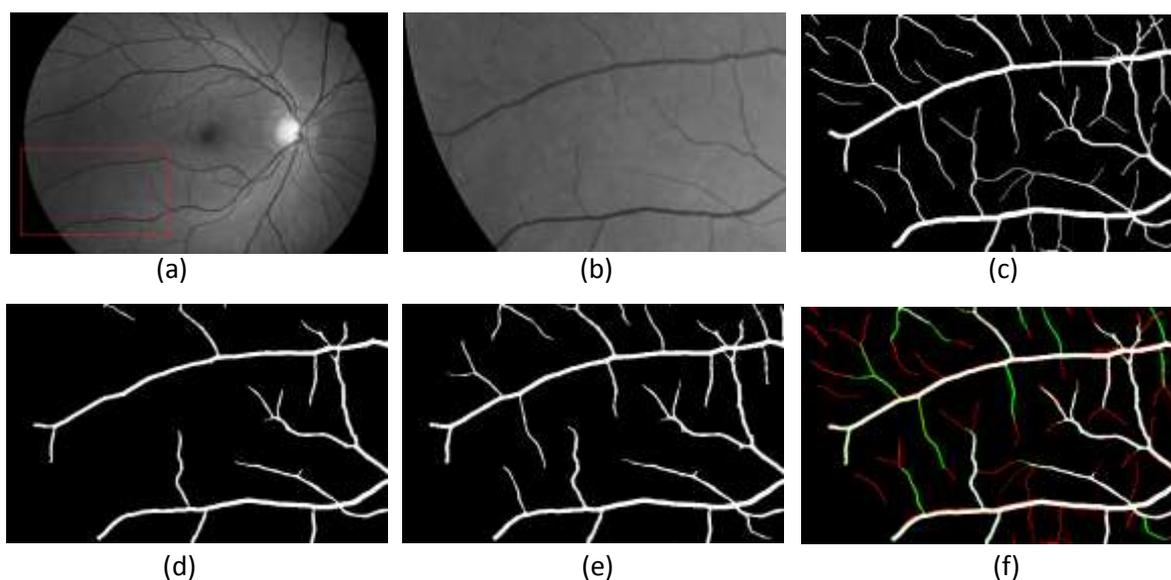
simple t-test). À un taux de spécificité similaire, la méthode proposée a amélioré le taux de sensibilité de 11,02% pour les cas sains et de 4,42% pour les diabétiques, respectivement.

**Tableau V.3** Evaluation de la performance des petits vaisseaux ( $D \leq 8$  pixels) sur les images Sains et diabétiques en utilisant les mesures de discordance standard.

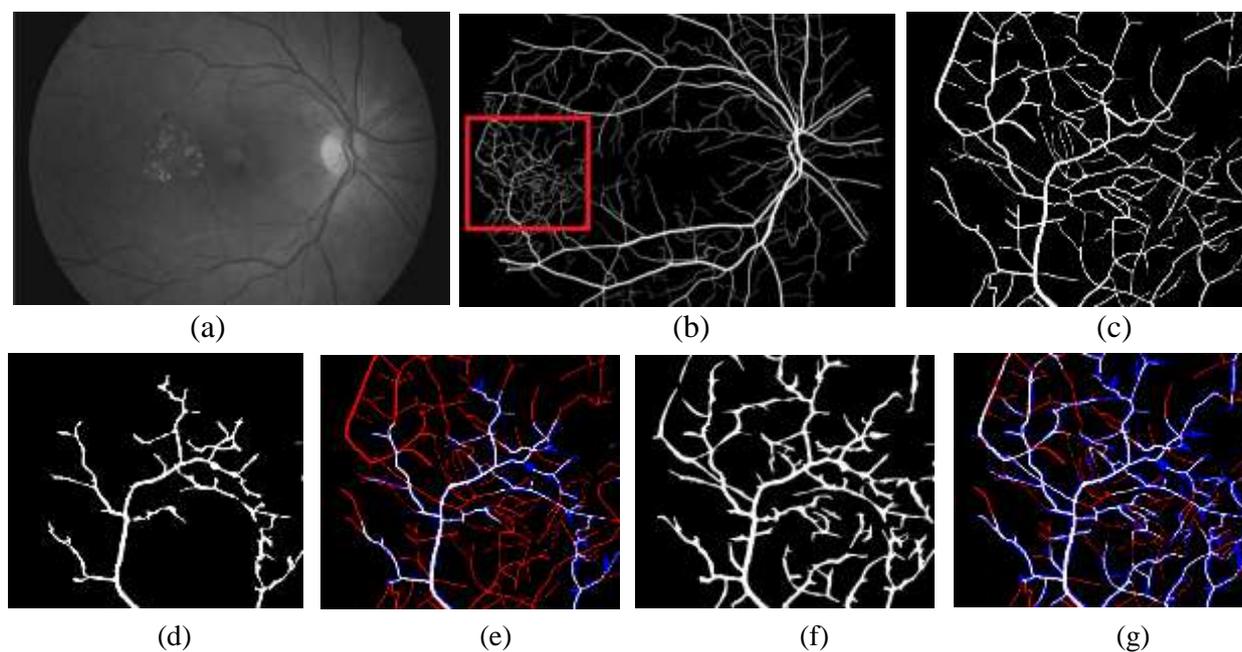
Méthode		Sensibilité ( $\mu \pm \sigma$ )	Spécificité ( $\mu \pm \sigma$ )	Précision ( $\mu \pm \sigma$ )
H	La méthode MSLD	52.80% $\pm$ 8.64%	97.61% $\pm$ 0.51%	96.51% $\pm$ 0.63%
	<b>La méthode proposée</b>	<b>63.82% <math>\pm</math> 8.38%</b>	<b>97.38% <math>\pm</math> 0.41%</b>	<b>96.52% <math>\pm</math> 0.40%</b>
DR	La méthode MSLD	65.83% $\pm$ 6.64%	94.40% $\pm$ 1.36%	93.60% $\pm$ 1.21%
	<b>La méthode proposée</b>	<b>70.25% <math>\pm</math> 7.10%</b>	<b>94.1% <math>\pm</math> 0.79%</b>	<b>93.49% <math>\pm</math> 0.76%</b>

Figures V.7 et V.8 montrent des exemples de cas sains et de cas diabétiques, où l'analyse se concentre sur les plus petits vaisseaux. Les vaisseaux segmentés sont colorés selon la matrice de confusion: les pixels blancs représentent les vrais positifs (TP), les pixels noirs sont les vrais négatifs (TN), les pixels bleus sont les faux positifs (FP), tandis que les pixels rouges sont les faux négatifs (FN). Les pixels verts de la figure V.7 (f) sont les vrais positifs détectés par l'algorithme proposé, mais manqués par la méthode MSLD. Qualitativement, pour le cas sain (figure. V.7), la méthode proposée a segmenté plus de petits vaisseaux par rapport à la méthode MSLD (Sensibilité: 80,52% vs 74,98%) à un niveau de bruit de fond similaire (Spécificité: 97,78% vs 97,87%). Pour évaluer encore plus si la méthode proposée segmente de plus de petits vaisseaux que la méthode MSLD, nous incluons la figure. V.8, qui correspond à un cas diabétique. À la périphérie de cette image, il y a beaucoup de vaisseaux alambiqués qui pourraient être des vaisseaux néovaisseaux. D'après les résultats, nous pouvons voir que la méthode proposée a réussi à inclure beaucoup plus de vaisseaux minces et tortueux par rapport à la méthode MSLD (Sensibilité: 75,85% contre 73,67%). Cependant, dans notre méthode, de petits vaisseaux faussement positifs ont été reconnectés au système vasculaire principal (voir les vaisseaux bleus de la figure V.8g), ou leurs limites ont été surestimées. Le modèle en ligne droite du détecteur de ligne de base n'était pas en mesure d'approcher des cas difficiles tels que ceux rencontrés dans des vaisseaux alambiqués.

Le tableau 4 donne l'évaluation des performances pour les grands vaisseaux dans chaque catégorie d'image. Dans ce tableau, nous montrons que la spécificité et la précision étaient équivalentes dans les deux méthodes. Le taux de sensibilité était significativement plus élevé pour notre méthode par rapport à la méthode MSLD ( $p < 0,05$ , deux simple t-test). L'amélioration du taux de sensibilité pour les cas sains et diabétiques était de 6,6% et 6,2% respectivement. La figure V.9 fournit un exemple où l'analyse se concentre sur les grands vaisseaux. Qualitativement, notre méthode a segmenté la plupart des grands vaisseaux (voir Figure. V.9g) en comparaison avec la méthode MSLD (voir Figure. V.9d). Cependant, certains vaisseaux faussement positifs ont été reconnectés au système vasculaire principal par la méthode proposée (pixels bleus dans l'image g).



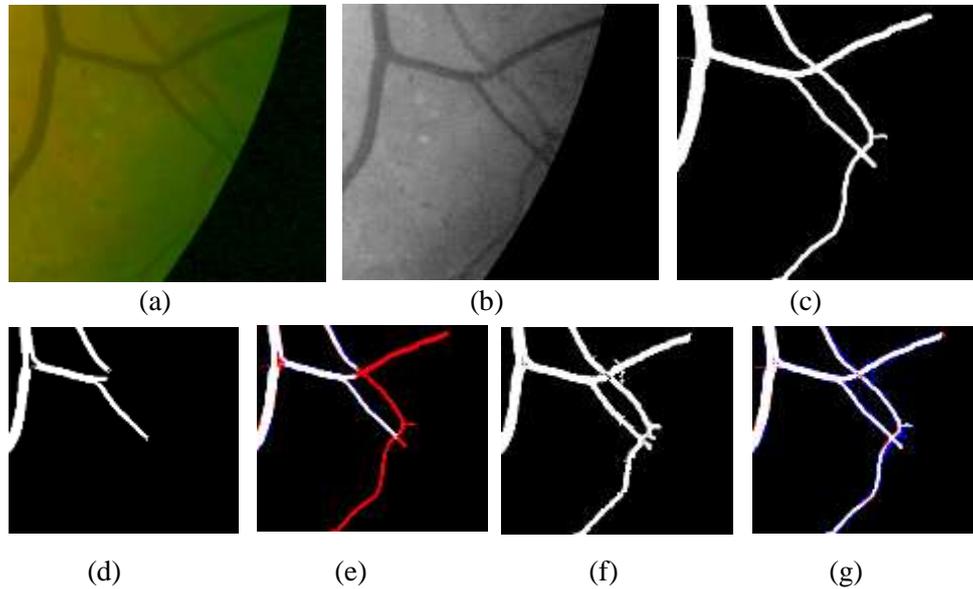
**Figure. V.7** Exemple de segmentation de petits vaisseaux en image saine à partir de la base de données HRF. (a) image d'entrée en niveaux de gris; (b) une région agrandie correspondant à l'insertion dans (a); (c) une région agrandie de la segmentation manuelle; (d) résultat de segmentation MSLD; (e) notre résultat de segmentation; et (f) la fusion entre la segmentation manuelle et le résultat de la segmentation de la méthode proposée (l'interprétation de chaque couleur de la figure (f) est présentée ci-dessus dans cette section).



**Figure. V.8** Exemple de segmentation de petits vaisseaux dans un cas diabétique. (a) image d'entrée en niveaux de gris; (b) la segmentation manuelle; (c) une région agrandie de la segmentation manuelle; (d) et (f) sont les résultats de la segmentation MSLD et de la méthode proposée; (e) et (g) sont la fusion entre la segmentation manuelle et le MSLD et les résultats de segmentation de la méthode proposée (l'interprétation de chaque couleur dans ces figures sont présentées ci-dessus dans cette section).

**Tableau V.4** Evaluation de la performance des grands vaisseaux ( $D > 8$  pixels) sur les images saines et diabétiques en utilisant les mesures de discordance standard

Méthode		Sensitivité ( $\mu \pm \sigma$ )	Spécificité ( $\mu \pm \sigma$ )	Précision ( $\mu \pm \sigma$ )
H	La méthode MSLD	0.870 $\pm$ 3.42%	0.977 $\pm$ 0.53%	0.968 $\pm$ 0.60%
	<b>La méthode proposée</b>	<b>0.936<math>\pm</math>2.75%</b>	<b>0.970 <math>\pm</math>0.40%</b>	<b>0.968<math>\pm</math>0.36%</b>
DR	La méthode MSLD	0.886 $\pm$ 2.71%	0.942 $\pm$ 1.32%	0.939 $\pm$ 1.32%
	<b>La méthode proposée</b>	<b>0.944<math>\pm</math>2.24%</b>	<b>0.940 <math>\pm</math>0.79%</b>	<b>0.939<math>\pm</math>0.77%</b>



**Figure. V.9** Exemple de segmentation de grands vaisseaux. (a) une région agrandie à partir d'une image rétinienne; (b) l'image en niveaux de gris de l'entrée (a); (c) une région agrandie de la segmentation manuelle; (d) et (f) sont les résultats de la segmentation MSLD et de la méthode proposée; (e) et (g) sont la fusion entre la segmentation manuelle et le MSLD et les résultats de segmentation de la méthode proposée.

## V.7 Évaluation des performances sur la base de données à basse résolution

Pour les images à basse résolution, l'algorithme proposé a regroupé les échelles en deux groupes:  $L_1 = \{1, 5, 7, 9\}$  et  $L_2 = \{11, 13, 15\}$ , le premier groupe segmenté par le seuil 0.70 et le second par 0.95. Le nombre d'échelles utilisées a été réduit par une échelle par rapport à la méthode MSLD (de 8 à 7 échelles). Pour examiner quelle méthode identifie le plus de pixels de vaisseaux, l'optimisé ou le MSLD, nous avons déterminé une valeur de seuil ( $T > 0.52$ ) pour le MSLD par rapport au taux de vaisseaux identifiés au même niveau de bruit de fond (spécificité), puis nous avons comparé leurs sensibilités.

A partir des tableaux 5 et 6, nous montrons que les performances sur les différentes mesures considérées étaient supérieures pour la version proposée par rapport à la méthode MSLD ( $p < 0,05$ , deux simple t-test). La méthode proposée a amélioré le taux de sensibilité par rapport au MSLD de 4,7% pour DRIVE et de 1,8% pour la base de données STARE, respectivement. Le taux de sensibilité plus élevé dans les deux bases de données indique que la méthode proposée segmente davantage de vaisseaux rétiniens.

**Tableau V.5** Performance de la méthode proposée et la méthode MSLD sur la base de données DRIVE.

Méthode	Sensitivité ( $\mu \pm \sigma$ )	Spécificité ( $\mu \pm \sigma$ )	Précision ( $\mu \pm \sigma$ )	Temps (Sec)
La méthode MSLD	0.698±5.36	0.972±2.02	0.941±1.86	4.31s
<b>La méthode proposée</b>	0.745±4.26	0.971±0.72	0.942±0.57	4.27 s

**Tableau V.6** Performance de la méthode proposée et la méthode MSLD sur la base de données STARE.

Méthode	Sensitivité ( $\mu \pm \sigma$ )	Spécificité ( $\mu \pm \sigma$ )	Précision ( $\mu \pm \sigma$ )	Temps (Sec)
La méthode MSLD	0.836±7.14	0.945±2.58	0.932±1.82	5.42 s
<b>La méthode proposée</b>	0.854±6.91%	0.944±1.23%	0.935±1.53	5.35 s

Le tableau V.7 présente la comparaison des performances par rapport à d'autres approches supervisées et non supervisées existantes. La méthode de segmentation des vaisseaux proposée a surpassé tous les algorithmes de segmentation des vaisseaux métaheuristiques existants dans la littérature [182], [183], [184], [185], et [186], et a obtenu des résultats comparables aux autres méthodes existantes en termes de spécificité et de précision, sauf pour les approches supervisées [161] and [157] sur l'ensemble de données STARE. L'approche de Staal et al. [161] semble être meilleure que notre méthode; cependant, il requiert d'une complexité de calcul plus élevée pour trouver les vaisseaux. De plus, dans la méthode proposée, nous avons utilisé uniquement la base de données d'apprentissage DRIVE pour régler les paramètres, tandis que la plupart des méthodes non supervisées et supervisées existantes utilisaient les deux bases de données DRIVE et STARE pour trouver les meilleurs paramètres.

Pour la comparaison de la complexité de temps, on peut observer à partir des tableaux V.5 et V.6 que le temps d'exécution a été légèrement réduit d'environ 0,03 seconde par rapport à la méthode MSLD [108], parce que le nombre d'échelles utilisées dans la méthode proposée a été réduit par une seule échelle. D'autre part, d'après le tableau V.7, la complexité du temps de la méthode de segmentation des vaisseaux proposée était significativement inférieure à la plupart des méthodes existantes dans la littérature.

**Tableau V.7** Comparaison des performances avec les méthodes de segmentation disponibles sur les bases de données STARE et DRIVE.

Bases de données de test	DRIVE				STARE				Système
	Sen	Spec	Acc	Temps (Sec)	Sen	Spec	Acc	Temps (Sec)	
<b>Supervisée</b>									
Marin et al. [157]	70.6%	98.0%	94.5%	90s	69.4%	98.1%	95.2%	90s	2.13 GHz,2-GB RAM
Staal et al. [161]	71.9%	97.7%	94.4%	900s	69.7%	98.1%	95.2%	900s	1.0 GHz,1-GB RAM
Soares et al. [162]	73.3%	97.8%	94.6%	180s	72.0%	97.5%	94.8%	180s	2.17 GHz,1-GB RAM
Mendonca et al. [97]	73.4%	97.6%	94.5%	150s	69.9%	97.3%	94.4%	180s	3.2 GHz,1-GB RAM
Budai et al. [217]	64.4%	98.7%	95.7%	5s	58.0%	98.2%	93.8%	6s	2.3 GHz,4-GB RAM

<b>Non supervisée</b>										
Hoover et.al [86]	-	-	-	-	65.0%	81.0%	92.8%	300s	2.6 GHz,4-GB RAM	
Miri et al. [98]	71.5%	97.6%	94.3%	50s	-	-	-	-	3 GHz,1-GB RAM	
Emary et al. [184]	62.8%	98.4%	93.8%	-	58.6%	98.7%	94.4%	-	-	
Asad et al. [183]	-	-	-	-	85.3%	92.1%	91.3%	42s	2.53 GHz,3-GB RAM	
Cinsdikici et al. [182]	-	-	92.9%	35s	-	-	-	-	-	
Hassanien et al. [185]	72.1%	97.1%	93.8%	86s	64.9%	98.2%	94.6%	86s	-	
Emary et al. [186]	-	-	93.6%	102s	-	-	-	-	-	
<b>Méthode proposée</b>	<b>74.5%</b>	<b>97.1%</b>	<b>94.2%</b>	<b>4.27s</b>	<b>85.4%</b>	<b>94.4%</b>	93.5%	<b>5.35s</b>	<b>2.6 GHz,4-GB RAM</b>	

En général, pour tout problème, l'application des algorithmes d'optimisation basée sur les métaheuristiques nécessite la définition des deux paramètres suivants: les fonctions objectifs et la représentation de la solution. Dans notre cas, nous avons bien défini ces deux paramètres pour l'algorithme PSO, donc, nous pourrions facilement l'adapter pour un autre algorithme d'optimisation tel que ABC. Cependant, la différence entre ces algorithmes est qu'il serait moins efficace en termes de calcul d'appliquer une autre approche métaheuristique à la place de PSO. Généralement, le schéma d'optimisation proposé pourrait fonctionner pour tous les algorithmes de métaheuristique.

## V.8 Conclusion

Dans ce chapitre, une nouvelle méthode pour extraire les vaisseaux sanguins des images rétinienne a été présentée. La méthode proposée exploite la puissance de la technique PSO pour trouver la meilleure disposition des échelles dans la méthode MSLD, et pour gérer le problème de la recombinaison de réponse en échelle. La performance de la méthode proposée a été évaluée sur deux bases de données d'images du fond d'œil à basse résolution (DRIVE, STARE) et à haute résolution. Les données comprenaient des cas de rétinopathie saine et de rétinopathie diabétique. Selon les données à basse résolution, la méthode proposée a obtenu des performances significativement meilleures par rapport à la méthode MSLD et à tous les algorithmes de segmentation des vaisseaux métaheuristiques existants.

De plus, les performances de la méthode proposée ont été évaluées qualitativement et quantitativement sur les images à haute résolution selon deux stratégies: d'une part, lorsque la vascularisation complète a été considérée, et d'autre part en séparant les grands et les petits vaisseaux. Selon les résultats, la méthode proposée a réussi à inclure plus de vaisseaux minces et tortueux par rapport à la méthode MSLD, en utilisant moins d'échelles avec différentes résolutions de pixels, ce qui fait de la méthode proposée un outil approprié par rapport aux méthodes dans la littérature.

## Conclusion et perspectives

Dans cette thèse, nous avons abordé la problématique de la segmentation des images rétiniennes au moyen des métaheuristiques. Car, celles-ci présentent l'avantage de s'adresser à n'importe quel problème d'optimisation, sans connaissance approfondie de ce dernier. De plus, le défi principal de nos travaux est d'avoir une meilleure extraction des vaisseaux rétiniens à partir des images rétiniennes, et de réduire le temps du diagnostic de traitement des maladies de la rétine. De notre étude plusieurs méthodes ont vu le jour: (1) une approche basée sur un algorithme de fourragement bactérien, où la méthode proposée exploite plusieurs critères simultanément pour la segmentation des images diverses, (2) une approche itérative non supervisée basée sur l'algorithme de la colonie d'abeilles, la méthode proposée exploite plusieurs critères de seuillage pour améliorer la précision des résultats de la segmentation des images de la rétine, (3) une approche d'optimisation par essaim de particules pour la détection de petits vaisseaux rétiniens sur l'image du fond d'œil en multi-résolution.

Dans la première et la deuxième approche, nous avons proposé plusieurs solutions pour adapter les métaheuristiques au problème de la segmentation d'image. D'abord, nous avons commencé notre travail par approfondir l'étude des critères de segmentation et de trouver une formalisation plus poussée des relations entre les critères de segmentation et les images à segmenter. Ensuite, nous avons adopté les métaheuristiques d'optimisation pour accélérer le processus de la segmentation d'image. Avant les adapter à la segmentation de la vascularisation rétinienne, nous avons testé la robustesse de nos algorithmes proposés sur différents types d'images.

La première métaheuristique expérimentée a été le fourragement bactérien. Celui-ci a été adapté au problème de segmentation basé sur le seuillage, la méthode proposée exploite simultanément plusieurs critères pour améliorer la précision des résultats de la segmentation, cette approche produit des résultats de segmentation beaucoup plus intéressants, cependant, l'algorithme d'optimisation proposé est pourvu de problème de réglage de paramètres, et cet inconvénient affecte négativement les résultats de la segmentation d'images médicales. Ainsi, un autre algorithme d'optimisation a été proposé, où nous avons l'appliqué la première fois sur la segmentation d'image rétinienne, ce deuxième algorithme proposé est basée sur l'algorithme de la colonie d'abeilles, où plusieurs critères sont exploités simultanément pour améliorer la précision des résultats de la segmentation d'image rétinienne. Une fonction de courbe d'énergie a été utilisée pour calculer les valeurs des critères de seuillage, afin de réduire la réponse au bruit des lésions, et sélectionner les seuils optimaux qui séparent les vaisseaux sanguins de l'arrière-plan. Afin d'accélérer le calcul, une méthode de critère d'arrêt a été utilisée pour ajuster les paramètres de l'algorithme proposé. D'après les résultats trouvés, la deuxième méthode a montrée quel est le plus performant et plus rapide que la plupart des algorithmes basés sur les métaheuristiques pour la segmentation de l'image rétinienne.

Dans la troisième approche développée, l'algorithme PSO a été appliqué pour trouver la meilleure disposition des échelles dans la méthode MSLD, et pour gérer le problème de la recombinaison de réponse multi-échelle. La performance de la méthode proposée a été évaluée sur deux bases de données d'images du fond d'œil à basse résolution (DRIVE, STARE) et à haute résolution. Les données incluent des cas de rétinopathie saine et des cas de rétinopathie diabétique. Basée sur les différents types de bases de données et les méthodes d'évaluation des performances, l'approche proposée a amélioré le taux de sensibilité de 4,7%

pour la base de données DRIVE et de 1,8% pour la base de données STARE. Pour la base de données à haute résolution, l'approche proposée a atteint un taux de sensibilité de 87,09%, en améliorant la sensibilité de 4.49 % au même niveau de spécificité. De plus, nous avons confiné l'analyse sur les petits vaisseaux, ce qui est une nouvelle façon d'examiner les limites des algorithmes de segmentation. La nouvelle méthode a encore amélioré le taux de sensibilité de 11,02% et de 4,42% pour les cas sains et les cas diabétiques, respectivement. Finalement, l'intégration de la méthode proposée dans un système de CAD complet pour le dépistage de la DR permettrait de réduire les faux positifs dus à de petits vaisseaux manqués, mal classés comme des lésions rouges.

À partir de ce travail, de nombreuses perspectives se peuvent être formulées. En effet, les algorithmes développés peuvent être considérés comme des procédures générales de segmentation que nous pouvons utiliser en modifiant les critères, les attributs ou les méthodes d'optimisation, selon le domaine d'application visé. Ainsi, en exploitant diverses combinaisons, plusieurs algorithmes peuvent être mis au point. Comme exemples, les méthodes proposées pourraient être testées sur d'autres modalités d'imagerie 2D / 3D (IRM / radiographie / angioscanner), pathologies, OCT oculaire, OCT interventionnelle pour la microchirurgie rétinienne, imagerie hyperspectrale, fluoroscopie rétinienne, et pour la détection d'autres similaires aux structures anatomiques des vaisseaux comme les neurones dans la microscopie.

Dans les travaux futurs, nous améliorerons ces méthodes en incluant plus de fonctions objectives basées sur les caractéristiques perceptuelles des vaisseaux segmentés. Ces mesures pourraient inclure celles récemment proposées par Gegundez-Arias et al. [219], où trois mesures basées sur la connectivité, l'aire et la longueur (CAL) sont combinées. Le but ultime est d'améliorer les algorithmes proposés afin d'extraire plus de structures tortueuses autour du disque optique, ou d'améliorer la détection des vaisseaux pathologiques liés à des complications menaçant la vue, telles que la néovascularisation.

## Références Bibliographiques

- [1] N. R Brigitte Côté, "Dépistage de la rétinopathie diabétique au Québec," *AETMIS*, 2008.
- [2] C. E. Baudoin, B. J. Lay, and J. C. Klein, "Automatic detection of microaneurysms in diabetic fluorescein angiography," *Revue d'épidémiologie et de santé publique*, vol. 32, no. 19850308 DCOM- 19850308, pp. 3-4, 1987.
- [3] M. D. Abramoff, M. Niemeijer, and S. R. Russell, "Automated detection of diabetic retinopathy: barriers to translation into clinical practice," *Expert Rev Med Devices*, vol. 7, no. 287-296, 2010.
- [4] M. D. Abramoff, J. M. Reinhardt, S. R., Folk, J. C. Russell, V. B. Mahajan, and M. Niemeijer, "Automated Early Detection of Diabetic Retinopathy," *Ophthalmology*, vol. 117, pp. 1147-1154, 2010.
- [5] B. Khomri, "Apprentissage et optimisation intelligente pour une segmentation robuste d'image," *2ème Workshop Image Graphique et Vie Artificielle, Biskra (IGVA'2014)*, 08-10 juin, Algérie 2014.
- [6] B. Khomri, "Automatic Histogram Thresholds using Multi-objective Bacterial Foraging Optimization," *the 5th international conference on metaheuristics and nature inspired computing*, 27-30 October 2014.
- [7] Bilal, et al Khomri, "Retinal blood vessel segmentation using the elite-guided multi-objective artificial bee colony algorithm," *IET Image Processing*, vol. 12, no. 12, pp. 2163-2171.
- [8] B. Khomri, A. Christodoulidis, L. Djerou, M. C. Babahenini, and F. Cheriet, "Particle Swarm Optimization Approach for the Segmentation of Retinal Vessels from Fundus Images," *International Conference Image Analysis and Recognition. Springer, Cham*, pp. 551-558, July 2017.
- [9] B. Khomri, A. Christodoulidis, L. Djerou, M. C. Babahenini, and F. Cheriet, "Particle swarm optimization method for small retinal vessels detection on multi-resolution fundus images," *Journal of Biomedical Optics*, vol. 23, 2018.
- [10] C. A Coello, "A short tutorial on evolutionary multiobjective optimization," *In International Conference on Evolutionary Multi-Criterion Optimization*, pp. 21-40, March 2001.
- [11] M. Sezgin and B. Sankur, "Survey over image thresholding techniques and quantitative performance evaluation," *Journal of Electronic imaging*, vol. 13, no. 1, pp. 146-166, 2004.
- [12] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE transactions on systems, man, and cybernetics*, vol. 9, no. 1, pp. 62-66, 1979.
- [13] J. N. Kapur, P. K. Sahoo, and A. K. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram," *Computer vision, graphics, and image processing*, vol. 29, no. 3, pp. 273-28, 1985.
- [14] W. Snyder, G. Bilbro, A. Logenthiran, and S. Rajala, "Optimal thresholding a new approach,"

- Pattern Recognition Letters*, vol. 11, no. 12, pp. 803-809, 1990.
- [15] A., Oulhadj, H., Siarry, P. Nakib, "Image histogram thresholding based on multiobjective optimization," vol. 87, no. 11, pp. 2516-2534, 2007.
- [16] X. Zhao, M. E. Lee, and S. H. Kim, "Improved image thresholding using ant colony optimization algorithm," *International Conference on in Advanced Language Processing and Web Information* , pp. 201-215, July 2008.
- [17] P. D. Sathya and R. Kayalvizhi, "PSO-based Tsallis thresholding selection procedure for image segmentation," *International Journal of Computer Applications*, vol. 5, no. 4, pp. 39-46, 2010.
- [18] L. Djerou, N. Khelil, H. E. Dehimi, and M. Batouche, "Automatic Multilevel Thresholding Using Binary Particle Swarm Optimization for Image Segmentation," *In Proceedings of the 2009 International Conference of Soft Computing and Pattern Recognition, IEEE Computer Society*, pp. 66-71, 2009.
- [19] W. B. Tao, J. W. Tian, and J. Liu, "Image segmentation by three-level thresholding based on maximum fuzzy entropy and genetic algorithm," *Pattern Recognition Letters*, vol. 24, no. 16, pp. 3069-3078, 2003.
- [20] C. G. Z. Hongfu, "2-D maximum entropy method of image segmentation based on genetic algorithm," *Journal of Computer Aided Design & Computer Graphics*, vol. 6, p. 008, 2002.
- [21] A. Alihodzic and M. & Tuba, "Improved bat algorithm applied to multilevel image thresholding," *The Scientific World Journal*, 2014.
- [22] I. Boussaïd, A. Chatterjee, P. Siarry, and M. & Ahmed-Nacer, "Hybrid BBO-DE algorithms for fuzzy entropy-based thresholding," *In Computational Intelligence in Image Processing*, pp. 37-69, 2013.
- [23] D. L. Pham, C. Xu, and J. L. Prince, "Current methods in medical image segmentation," *Annual review of biomedical engineering*, vol. 2, no. 1, pp. 315-337, 2000.
- [24] Y. J. Zhang, "Advances in image and video segmentation," *IGI Global*, 2006.
- [25] I. N. Manousakas, P. E. Undrill, G. G. Cameron, and T. W. Redpath, "Split-and-merge segmentation of magnetic resonance medical images: performance evaluation and extension to three dimensions," *Computers and Biomedical Research*, vol. 31, no. 6, pp. 393-412, 1998.
- [26] S. Geman and D. Geman, "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images," *In Readings in Computer Vision*, pp. 564-584, 1987.
- [27] N. Brunel, "Sur quelques extensions des chaînes de Markov cachées et couples. Applications à la segmentation non-supervisée de signaux radar," *Thèse de doctorat. Université Pierre et Marie Curie-Paris VI*, 2005.
- [28] E. Y. Kim, S. H. Park, and H. J Kim, "A genetic algorithm-based segmentation of Markov random field modeled images," *IEEE Signal processing letters*, vol. 7, no. 11, pp. 301-303, 2000.

- [29] S. Ouadfel and M. Batouche, "Ant colony system with local search for Markov random field image segmentation," *In Image Processing, ICIP 2003.* , Sep. 2003.
- [30] S. Le Hégarat-Masclé, A. Kallel, and Descombes, "Ant colony optimization for image regularization based on a nonstationary Markov modeling," *IEEE Transactions on Image Processing*, vol. 16, no. 3, pp. 865-878, 2007.
- [31] M. Kass, A. Witkin, and D. Terzopoulos, "Snakes: Active contour models," *International journal of computer vision*, vol. 1, no. 4, pp. 321-331.
- [32] T., Terzopoulos, D. McInerney, "T-snakes: Topology adaptive snakes," *Medical image analysis*, vol. 4, no. 2, pp. 73-91, 2000.
- [33] J. A. Sethian, "A fast marching level set method for monotonically advancing fronts," *Proceedings of the National Academy of Sciences*, vol. 93, no. 4, pp. 1591-1595.
- [34] D. Cremers, M. Rousson, and R. Deriche, "A review of statistical approaches to level set segmentation: integrating color, texture, motion and shape," *International journal of computer vision*, vol. 72, no. 2, pp. 195-215, 2007.
- [35] V. Caselles, R. Kimmel, and G. Sapiro, "Geodesic active contours," *International journal of computer vision*, vol. 22, no. 1, pp. 61-79, 1997.
- [36] L. A. MacEachern and T. Manku, "Genetic algorithms for active contour optimization," *In Circuits and Systems, Proceedings of the 1998 IEEE International Symposium on*, vol. 4, pp. 229-232, 1998.
- [37] X. N. Wang, Y. J. Feng, and Z. R & Feng, "Ant colony optimization with active contour models for image segmentation," *Kongzhi Lilun yu Yingyong/ Control Theory & Applications*, vol. 23, no. 4, pp. 515-522, 2006.
- [38] C. C. Tseng, J. G. Hsieh, and J. H. Jeng, "Active contour model via multi-population particle swarm optimization," *Expert Systems with Applications*, vol. 36, no. 3, pp. 5348-5352, 2009.
- [39] M. A. Asl and S. A. Seyedin, "Active contour optimization using particle swarm optimizer," *In Information and Communication Technologies. 2006. ICTTA'06. 2nd. IEEE*, pp. 1522-1523.
- [40] Hau and Chen Chi (Ed), "Handbook of pattern recognition and computer vision," *World Scientific*, 2015.
- [41] M. Friedman and A. Kandel, "Introduction to pattern recognition: statistical, structural, neural and fuzzy logic approaches," *World Scientific Publishing Company*, vol. 32, 1999.
- [42] Y. J. Zhang, "A survey on evaluation methods for image segmentation," *Pattern recognition*, vol. 29, no. 8, pp. 1335-1346, 1996.
- [43] T. Kanungo et al., "An efficient k-means clustering algorithm: Analysis and implementation," *IEEE transactions on pattern analysis and machine intelligence*, vol. 24, no. 7, pp. 881-892, 2002.

- [44] A. Makropoulos et al., "Automatic tissue and structural segmentation of neonatal brain MRI using Expectation-Maximization," *MICCAI Grand Chall. Neonatal Brain Segmentation*, pp. 9-15, 2012.
- [45] J. C. Bezdek, L. O. Hall, and L. Clarke, "Review of MR image segmentation techniques using pattern recognition," *Medical physics*, vol. 20, no. 4, pp. 1033-1048.
- [46] S. Das, A. Abraham, and A. & Konar, "Metaheuristic clustering," *Springer*, 2009.
- [47] T. Niknam and B. & Amiri, "An efficient hybrid approach based on PSO, ACO and k-means for cluster analysis," *Applied soft computing*, vol. 10, no. 1, pp. 183-197, 2010.
- [48] C., Zhou Liu, Zhang, Q. A., and G. Zhang, "Adaptive image segmentation by using mean-shift and evolutionary optimisation," *IET Image Processing*, vol. 8, no. 6, pp. 327-333, 2014.
- [49] A. Nakib, H. Oulhadj, and P. Siarry, "Image thresholding based on Pareto multiobjective optimization," *Engineering Applications of Artificial Intelligence*, vol. 23, no. 3, pp. 313-320, 2010.
- [50] Y. Collette and P. Siarry, "Optimisation Multiobjectif," *Edition Eyrolles*, Paris, 2002.
- [51] H. Al-Baity, S. Meshoul, and Kaban, "Constrained multi-objective optimization using a quantum behaved particle swarm," *In International Conference on Neural Information Processing*, pp. 456-464, 2012.
- [52] El-ghazali. TALBI, "Métaheuristiques pour l'optimisation combinatoire multi-objectif," *Etat de l'art. Rapport CNET (France Telecom)*, Octobre 1999.
- [53] J. D. Schaffer, "Multiple objective optimization with vector evaluated genetic algorithms," *In Proceedings of the First International Conference on Genetic Algorithms and Their Applications*, 1985. Lawrence Erlbaum Associates. Inc., Publishers, 1985.
- [54] D. E. Goldberg and J. Richardson, "Genetic algorithms with sharing for multimodal function optimization," *n Genetic algorithms and their applications: Proceedings of the Second International Conference on Genetic Algorithms*, pp. 41-49, 1987.
- [55] O. Guenounou, A. Belmehdi, and B. & Dahhou, "Multi-objective optimization of TSK fuzzy models," *Expert systems with applications*, vol. 36, no. 4, pp. 7416-7423, 2009.
- [56] K. A. De Jong, "Analysis of the behavior of a class of genetic adaptive systems," 1975.
- [57] E. Zitzler, K. Deb, and L. Thiele, "Comparison of multiobjective evolutionary algorithms: Empirical results," *Evolutionary computation*, vol. 8, no. 2, pp. 173-195, 2000.
- [58] H. Ishibuchi and T. & Murata, "Multi-objective genetic local search algorithm," *Proceedings of IEEE International Conference on Evolutionary Computation*, pp. 119-124, May 1996.
- [59] E. Zitzler and L. Thiele, "Multiobjective evolutionary algorithms: a comparative case study and the strength Pareto approach," *IEEE transactions on Evolutionary Computation*, vol. 3, no. 4, pp. 257-271, 1999.

- [60] K. Deb, "Multi-objective optimization using evolutionary algorithms," *John Wiley & Sons*, vol. 16, 2001.
- [61] B. Bhanu, S. Lee, S. Das, and , "Adaptive image segmentation using genetic and hybrid search methods," *IEEE Trans.on Aerospace and electronic syst*, vol. 31, no. 4, pp. 1268-1291, 1995.
- [62] Leila Djerou, Naceur Khelil, NH Dehimi, and Mohamed Batouche, "Automatic multi-level thresholding segmentation based on multi-objective optimization," *Journal of Applied Computer Science & Mathematics*, vol. 6, no. 13, pp. 24-31, 2012.
- [63] L. Djerou, N. KHELIL, B. KHOMRI, and M. BATOUCHE, "Image Thresholding Based on Bacterial Foraging and Pareto Multiobjective Optimization," *Journal of Applied Computer Science & Mathematics*, vol. 7, no. 14, pp. 9-15, 2013.
- [64] C. W. Tsai, W. C. Huang, and M. C. Chiang, "Recent development of metaheuristics for clustering," *In Mobile, Ubiquitous, and Intelligent Computing*, pp. 629-636, 2014.
- [65] A. N. Benaichouche, H. Oulhadj, and P. Siarry, "mproved spatial fuzzy c-means clustering for image segmentation using PSO initialization, Mahalanobis distance and post-segmentation correction," *Digital Signal Processing*, vol. 23, no. 5, pp. 1390-1400, 2013.
- [66] P., and Singh, K. Simari, "Multi-objective shape segmentation," *Technical report CSRG-575, Dynamic Graphics Pr oject. Department of Computer Science, University of Toronto*, 2008.
- [67] C. W. Oyster, "The human eye: structure and function," *Sinauer Associates*, 1999.
- [68] C. V. Network, "Developmental Anatomy of the Retinal and Choroidal Vasculature," *The Retina and Its Disorders*, vol. 179, 2011.
- [69] S. S. Hayreh, M. B. Zimmerman, A. Kimura, and A. Sanon, "Central retinal artery occlusion.: Retinal survival time," *Experimental eye research*, vol. 78, no. 3, pp. 723-736, 2004.
- [70] J. J. Kanski and B. Bowling, "Clinical ophthalmology: a systematic approach," *Elsevier Health Sciences*, 2011.
- [71] Larsen et al., "Automated detection of fundus photographic red lesions in diabetic retinopathy," *Investigative ophthalmology & visual science*, vol. 44, no. 2, pp. 761-766, 2003.
- [72] M. Niemeijer, B. Van Ginneken, J. Staal, M. S. Suttorp-Schulten, and M. D. Abràmoff, "Automatic detection of red lesions in digital color fundus photographs," *IEEE Transactions on medical imaging*, vol. 24, no. 5, pp. 584-592, 2005.
- [73] G. K. Matsopoulos, P. A. Asvestas, N. A. Mouravliansky, and K. K. Delibasis, "Multimodal registration of retinal images using self organizing maps," *IEEE Transactions on Medical Imaging*, vol. 23, no. 12, pp. 1557-1563, 2004.
- [74] C. A. Glasbey and G. W. Horgan, "Image analysis for the biological sciences," *Chichester: Wiley*, vol. 1, 1995.
- [75] M. M.,magnino, P. 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, 2012.
- [76] D. Lesage, E. D. Angelini, I. Bloch, and G. Funka-Lea, "A review of 3D vessel lumen segmentation techniques: Models, features and extraction schemes," *Medical image analysis*, vol. 13, no. 6, pp. 819-845, 2009.
- [77] K. Bühler, P. Felkel, and A La Cruz, "Geometric methods for vessel visualization and quantification—a survey," *In Geometric modeling for scientific visualization*, pp. 399-419, 2004.
- [78] A. Christodoulidis, "Segmentation and Characterization of Small Retinal Vessels in Fundus Images Using the Tensor Voting Approach," *Thèse de doctorat. École Polytechnique de Montréal*, 2017.
- [79] W. K. Pratt, "Digital image processing," *New York, London : John Wiley & Sons, Inc*, 2001.
- [80] S. Chaudhuri, S. Chatterjee, N. Katz, M. Nelson, and M. Goldbaum, "Detection of blood vessels in retinal images using two-dimensional matched filters," *IEEE Transactions on medical imaging*, vol. 8, no. 3, pp. 263-269, 1989.
- [81] C. Y. Lin and Y. T. Ching, "Extraction of coronary arterial tree using cine X-ray angiograms," *Biomedical Engineering: Applications, Basis and Communications*, vol. 17, no. 3, pp. 111-120, 2005.
- [82] K. A. Al-Kofahi et al., "Rapid automated three-dimensional tracing of neurons from confocal image stacks," *IEEE Transactions on information technology in biomedicine*, vol. 6, no. 2, pp. 171-187, 2002.
- [83] J. Jan, J. Odstrcilik, J. Gazarek, and R. Kolár, "Retinal image analysis aimed at blood vessel tree segmentation and early detection of neural-layer deterioration," *Computerized Medical Imaging and Graphics*, vol. 36, no. 6, pp. 431-441, 2012.
- [84] R. Annunziata, A. Kheirkhah, S. Aggarwal, P. Hamrah, and E. Trucco, "A fully automated tortuosity quantification system with application to corneal nerve fibres in confocal microscopy images," *Medical image analysis*, vol. 32, pp. 216-232, 2016.
- [85] B. Zhang, L. Zhang, L. Zhang, and F. Karray, "Retinal vessel extraction by matched filter with first-order derivative of Gaussian," *Computers in biology and medicine*, vol. 40, no. 4, pp. 438-445, 2010.
- [86] A. D. Hoover, V. Kouznetsova, and M. Goldbaum, "Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response," *IEEE Transactions on Medical imaging*, vol. 19, no. 3, pp. 203-210, 2000.
- [87] N. X. Lian, V. Zagorodnov, and Y. P. Tan, "Retinal vessel detection using self-matched filtering," *In Image Processing, 2007. ICIP 2007. IEEE International Conference*, vol. 6, pp. VI-33, 2007.
- [88] M. Al-Rawi, M. Qutaishat, and M. Arrar, "An improved matched filter for blood vessel detection of digital retinal images," *Computers in Biology and Medicine*, vol. 37, no. 2, pp. 262-267, 2007.
- [89] L. Gang, O. Chutatape, and S. M. Krishnan, "Detection and measurement of retinal vessels in fundus images using amplitude modified second-order Gaussian filter," *IEEE transactions on*

- Biomedical Engineering*, vol. 49, no. 2, pp. 168-172, 2002.
- [90] L. Zhang, Q. Li, J. You, and D Zhang, "A modified matched filter with double-sided thresholding for screening proliferative diabetic retinopathy," *IEEE Transactions on Information Technology in Biomedicine*, vol. 13, no. 4, pp. 528-534, 2009.
- [91] T. Zhu, "Fourier cross-sectional profile for vessel detection on retinal images," *Computerized Medical Imaging and Graphics*, vol. 34, no. 3, pp. 203-212, 2010.
- [92] B. S. Lam, Y. Gao, and A. W. C. Liew, "General retinal vessel segmentation using regularization-based multiconcavity modeling," *IEEE Transactions on Medical Imaging*, vol. 29, no. 7, pp. 1369-1381, 2010.
- [93] B. S. Lam, Y. Gao, and A. W. C. Liew, "General retinal vessel segmentation using regularization-based multiconcavity modeling," *IEEE Transactions on Medical Imaging*, vol. 29, no. 7, pp. 1369-1381, 2010.
- [94] J. Serra, "Image analysis and mathematical morphology," *Academic Press, Inc*, 1983.
- [95] M. E. Martinez-Perez et al., "Geometrical and morphological analysis of vascular branches from fundus retinal images," *In International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 756-765, 2000.
- [96] B. D. Thackray and A. C. Nelson, "Semi-automatic segmentation of vascular network images using a rotating structuring element (ROSE) with mathematical morphology and dual feature thresholding," *IEEE Transactions on Medical Imaging*, vol. 12, no. 3, pp. 385-392, 1993.
- [97] A. M. Mendonca and A. Campilho, "Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction," *IEEE transactions on medical imaging*, vol. 25, no. 9, pp. 1200-1213, 2006.
- [98] M. S. Miri and A. Mahloojifar, "Retinal image analysis using curvelet transform and multistructure elements morphology by reconstruction," *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 5, pp. 1183-1192, 2011.
- [99] F. Zana and J. C. Klein, "A multimodal registration algorithm of eye fundus images using vessels detection and Hough transform," *IEEE transactions on Medical Imaging*, vol. 18, no. 5, pp. 419-428, 1999.
- [100] F. Zana and J. C. Klein, "Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation," *IEEE transactions on image processing*, vol. 10, no. 7, pp. 1010-1019, 2001.
- [101] T. Walter and J. C. Klein, "Segmentation of color fundus images of the human retina: Detection of the optic disc and the vascular tree using morphological techniques," *In International Symposium on Medical Data Analysis*, pp. 282-287, Oct. 2001.
- [102] E. M. Sigurðsson et al., "Automatic retinal vessel extraction based on directional mathematical morphology and fuzzy classification," *Pattern Recognition Letters*, vol. 47, pp. 164-171, 2014.

- [103] B. Yin et al., "Vessel extraction from non-fluorescein fundus images using orientation-aware detector," *Medical image analysis*, vol. 26, no. 1, pp. 232-242, 2015.
- [104] A. Dufour et al., "Filtering and segmentation of 3D angiographic data: Advances based on mathematical morphology," *Medical image analysis*, vol. 17, no. 2, pp. 147-164, 2013.
- [105] S. R. Deans, "Hough transform from the Radon transform," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 2, pp. 185-188, 1981.
- [106] R. Zwigelaar, S. M. Astley, C. R. Boggis, and C. J. Taylor, "Linear structures in mammographic images: detection and classification," *IEEE transactions on medical imaging*, vol. 23, no. 9, pp. 1077-1086.
- [107] E. Ricci and R. Perfetti, "Retinal blood vessel segmentation using line operators and support vector classification," *IEEE transactions on medical imaging*, vol. 26, no. 10, pp. 1357-1365, 2007.
- [108] U. T. Nguyen, A. Bhuiyan, L. A. Park, and K. Ramamohanarao, "An effective retinal blood vessel segmentation method using multi-scale line detection," *Pattern recognition*, vol. 46, no. 3, pp. 703-715, 2013.
- [109] X. You, Q. Peng, Y. Yuan, Y. M. Cheung, and J. Lei, "Segmentation of retinal blood vessels using the radial projection and semi-supervised approach," *Pattern Recognition*, vol. 44, no. 10-11, pp. 2314-2324, 2011.
- [110] J. Chen, Y. Sato, and S. Tamura, "Orientation space filtering for multiple orientation line segmentation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, no. 5, pp. 417-429, 2000.
- [111] S. Lu and J. H. Lim, "Automatic optic disc detection from retinal images by a line operator," *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 1, pp. 88-94, 2011.
- [112] M. M. Orkisz, C. Bresson, I. E. Magnin, O. Champin, and P. C. Douek, "Improved vessel visualization in MR angiography by nonlinear anisotropic filtering," *Magnetic Resonance in Medicine*, vol. 37, no. 6, pp. 914-919, 1997.
- [113] K. Allen, N. Joshi, and J. A. Noble, "Tramline and NP windows estimation for enhanced unsupervised retinal vessel segmentation," *In Biomedical Imaging : From Nano to Macro, 2011 IEEE International Symposium on*, pp. 1387-1390, Mar. 2011.
- [114] Y. J. Jeong, S. Ley, R. Dillmann, and R. Unterhinninghofen, "Vessel centerline extraction in phase-contrast MR images using vector flow information," *n : Medical Imaging 2012: Image Processing. International Society for Optics and Photonics*, vol. 8314, p. 83143H, 2012.
- [115] L. Sukkaewa, B. Uyyanonvarab, and S. Barmanc, "Comparison of edge detection techniques on vessel detection of infant's retinal image," *image*, 2005.
- [116] F. Oloumi, R. M. Rangayyan, P. Casti, and A. L. Ells, "Computer-aided diagnosis of plus disease via measurement of vessel thickness in retinal fundus images of preterm infants," *Computers in biology and medicine*, vol. 66, pp. 316-329, 2015.

- [117] V. Mahadevan, H. Narasimha-Iyer, B. Roysam, and H. L. Tanenbaum, "Robust model-based vasculature detection in noisy biomedical images," *IEEE Transactions on Information Technology in Biomedicine*, vol. 8, no. 3, pp. 360-376, 2004.
- [118] P. Perona and J. Malik, "Scale-space and edge detection using anisotropic diffusion," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 12, no. 7, pp. 629-639, 1990.
- [119] H. M. Luu et al., "Evaluation of diffusion filters for 3d cta liver vessel enhancement," *In International MICCAI Workshop on Computational and Clinical Challenges in Abdominal Imaging*, pp. 168-177, Oct. 2012.
- [120] C. Bauer and H. Bischof, "A novel approach for detection of tubular objects and its application to medical image analysis," *In Joint Pattern Recognition Symposium*, pp. 163-172, June 2008.
- [121] F. Benmansour and L. D. Cohen, "Tubular structure segmentation based on minimal path method and anisotropic enhancement," *International Journal of Computer Vision*, vol. 92, no. 2, pp. 192-210, 2011.
- [122] M. Kass, A. Witkin, and D. Terzopoulos, "Snakes: Active contour models," *International journal of computer vision*, vol. 1, no. 4, pp. 321-331, 1988.
- [123] V. Uhlmann, J. Fageot, and M. Unser, "Hermite snakes with control of tangents," *IEEE Transactions on Image Processing*, vol. 25, no. 6, pp. 2803-2816, 2016.
- [124] H. Tek and B. B. Kimia, "Image segmentation by reaction-diffusion bubbles," *In Computer Vision, 1995. Proceedings., Fifth International Conference on*, pp. 156-162, 1995.
- [125] C. Xu and J. L. Prince, "Snakes, shapes, and gradient vector flow," *IEEE Transactions on image processing*, vol. 7, no. 3, pp. 359-369, 1998.
- [126] B. Li and S. T. Acton, "Active contour external force using vector field convolution for image segmentation," *IEEE transactions on image processing*, vol. 16, no. 8, pp. 2096-2106, 2007.
- [127] R. Toledo et al., "Eigensnakes for vessel segmentation in angiography," *In Pattern Recognition, 2000. Proceedings. 15th International Conference on*, vol. 4, pp. 340-343, 2000.
- [128] B. Al-Diri and A. Hunter, "A ribbon of twins for extracting vessel boundaries," *In Medical and Biological Engineering*, 2005.
- [129] B. Al-Diri, A. Hunter, and D. Steel, "An active contour model for segmenting and measuring retinal vessels," *IEEE Transactions on Medical imaging*, vol. 28, no. 9, pp. 1488-1497, 2009.
- [130] T. McInerney and D. Terzopoulos, "T-snakes: Topology adaptive snakes," *Medical image analysis*, vol. 4, no. 2, pp. 73-91, 2000.
- [131] N. Bova, Ó. Ibáñez, and Ó. Cordón, "Extended topological active nets," *Image and Vision Computing*, vol. 31, no. 12, pp. 905-920, 2013.
- [132] O. Wink, W. J. Niessen, and M. A. Viergever, "Fast delineation and visualization of vessels in 3-D angiographic images," *IEEE transactions on medical imaging*, vol. 19, no. 4, pp. 337-346, 2000.

- [133] S. R. Rao, S. E. Shelton, and P. A. Dayton, "The "Fingerprint" of Cancer Extends Beyond Solid Tumor Boundaries: Assessment With a Novel Ultrasound Imaging Approach," *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 5, pp. 1082-1086, 2016.
- [134] O. Chutatape, L. Zheng, and S. M. Krishnan, "Retinal blood vessel detection and tracking by matched Gaussian and Kalman filters," *n Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE*, vol. 6, pp. 3144-3149, 1998.
- [135] A. La Cruz et al., "Non-linear model fitting to parameterize diseased blood vessels," in *Proceedings of the conference on Visualization'04. IEEE Computer Society*, pp. 393-400, 2004.
- [136] H. Shim, D. Kwon, I. D. Yun, and S. U. Lee, "Robust segmentation of cerebral arterial segments by a sequential Monte Carlo method: Particle filtering," *Computer methods and programs in biomedicine*, vol. 84, no. 2-3, pp. 135-145, 206.
- [137] O. Friman, M. Hindennach, C. Kühnel, and H. O. Peitgen, "Multiple hypothesis template tracking of small 3D vessel structures," *Medical image analysis*, vol. 14, no. 2, pp. 160-171, 2010.
- [138] Y. A. Tolias and S. M. Panas, "A fuzzy vessel tracking algorithm for retinal images based on fuzzy clustering," *IEEE Transactions on Medical Imaging* 1998, vol. 17, no. 2, pp. 263-273, 1998.
- [139] K. S. Lin et al., "Retinal vascular tree reconstruction with anatomical realism," *IEEE Transactions on Biomedical Engineering*, vol. 59, no. 12, pp. 3337-3347, 2012.
- [140] D. Lesage, E. D. Angelini, G. Funka-Lea, and I. Bloch, "Adaptive particle filtering for coronary artery segmentation from 3D CT angiograms," *Computer Vision and Image Understanding*, vol. 151, pp. 29-46, 2016.
- [141] J. Zhang, H. Li, Q. Nie, and L. Cheng, "A retinal vessel boundary tracking method based on Bayesian theory and multi-scale line detection," *Computerized Medical Imaging and Graphics*, vol. 38, no. 6, pp. 517-525, 2014.
- [142] C. Boldak, Y. Rolland, C. Toumoulin, and J. L. Coatrieux, "An improved model-based vessel tracking algorithm with application to computed tomography angiography," *Biocybernetics And Biomedical Engineering*, vol. 23, no. 1, pp. 41-64, 2003.
- [143] N. H. Solouma, A. B. Youssef, Y. A. Badr, and Y. M. Kadah, "A new real-time retinal tracking system for image-guided laser treatment," *IEEE Transactions on Biomedical Engineering*, vol. 49, no. 9, pp. 1059-1067, 2002.
- [144] A. Can, H. Shen, J. N. Turner, H. L. Tanenbaum, and B. Roysam, "Rapid automated tracing and feature extraction from retinal fundus images using direct exploratory algorithms," *IEEE Transactions on information Technology in Biomedicine*, vol. 3, no. 2, pp. 125-138, 1999.
- [145] E. W. Dijkstra, "A note on two problems in connexion with graphs," *Numerische mathematik*, vol. 1, no. 1, pp. 269-271, 1959.
- [146] L. D. Cohen and R. Kimmel, "Global minimum for active contour models: A minimal path

- approach," *International journal of computer vision*, vol. 24, no. 1, pp. 57-78, 1997.
- [147] V. S. Joshi, M. K. Garvin, J. M. Reinhardt, and M. D. Abramoff, "Identification and reconnection of interrupted vessels in retinal vessel segmentation," *In Biomedical Imaging: From Nano to Macro, 2011 IEEE International Symposium on*, pp. 1416-1420, 2011.
- [148] O. Wink, A. F. Frangi, B. Verdonck, M. A. Viergever, and W. J. Niessen, "3D MRA coronary axis determination using a minimum cost path approach," *Magnetic Resonance in Medicine*, vol. 47, no. 6, pp. 1169-1175, 2002.
- [149] L. Pedersen et al., "Quantitative measurement of changes in retinal vessel diameter in ocular fundus images," *Pattern Recognition Letters*, vol. 21, no. 13-14, pp. 1215-1223, 2000.
- [150] W. Liao, K. Rohr, and S. Wörz, "Globally optimal curvature-regularized fast marching for vessel segmentation," *In International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 550-557, 2013.
- [151] D. Chen, J. M. Mirebeau, and L. D. Cohen, "A new finler minimal path model with curvature penalization for image segmentation and closed contour detection," *In Computer Vision and Pattern Recognition (CVPR), 2016 IEEE Conference on*, pp. 355-363, 2016.
- [152] O. Wink, W. J. Niessen, and M. A. Viergever, "Minimum cost path determination using a simple heuristic function," *n Pattern Recognition, 2000. Proceedings. 15th International Conference on*, vol. 3, pp. 998-1001, 2000.
- [153] T. Deschamps and L. D. Cohen, "Fast extraction of tubular and tree 3D surfaces with front propagation methods," *In Pattern Recognition, 2002. Proceedings. 16th International Conference*, vol. 1, pp. 731-734, 2002.
- [154] H. Li and A. Yezzi, "Vessels as 4-D curves: Global minimal 4-D paths to extract 3-D tubular surfaces and centerlines," *IEEE transactions on medical imaging*, vol. 26, no. 9, pp. 1213-1223, 2007.
- [155] R. Estrada et al., "Exploratory Dijkstra forest based automatic vessel segmentation: applications in video indirect ophthalmoscopy (VIO)," *Biomedical optics express*, vol. 3, no. 2, pp. 327-339, 2012.
- [156] D. Chen, J. M. Mirebeau, and L. D. Cohen, "essel tree extraction using radius-lifted keypoints searching scheme and anisotropic fast marching method," *Journal of Algorithms & Computational Technology*, vol. 10, no. 4, pp. 224-234.
- [157] D. Marín, A. Aquino, M. E. Gegúndez-Arias, and J. M. Bravo, "A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features," *IEEE transactions on medical imaging*, vol. 30, no. 1, pp. 146-158, 2011.
- [158] S. W. Franklin and S. E. Rajan, "Retinal vessel segmentation employing ANN technique by Gabor and moment invariants-based features," *Applied Soft Computing*, vol. 22, pp. 94-100.
- [159] 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, 2017.

- [160] M. Niemeijer, J. Staal, B. van Ginneken, M. Loog, and M. D. Abramoff, "Comparative study of retinal vessel segmentation methods on a new publicly available database," *In Medical Imaging 2004: Image Processing. International Society for Optics and Photonics*, vol. 5370, pp. 648-657, 2004.
- [161] J. Staal, M. D. Abramoff, M. Niemeijer, M. A. Viergever, and B. Van Ginneken, "Ridge-based vessel segmentation in color images of the retina," *IEEE transactions on medical imaging*, vol. 23, no. 4, pp. 501-509, 2004.
- [162] J. V. Soares, J. J. Leandro, R. M. Cesar, H. F. Jelinek, and M. J. Cree, "Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification," *IEEE Transactions on medical Imaging*, vol. 25, no. 9, pp. 1214-1222, 2006.
- [163] A. Pourmorteza, S. H. R. Tofighi, A. Roodaki, A. Yazdani, and H. Soltanian-Zadeh, "Context-Dependent Segmentation of Retinal Blood Vessels Using Hidden Markov Models," *In Advances in Computer Science and Engineering*, pp. 348-355, 2008.
- [164] F. Sahba, H. R. Tizhoosh, and M. M. Salama, "Increasing object recognition rate using reinforced segmentation," *2006 IEEE International Conference on*, pp. 781-784, 2006.
- [165] L. Wang, K. Lekadir, S. L. Lee, R., Merrifield, and G. Z. Yang, "A general framework for context-specific image segmentation using reinforcement learning," *IEEE transactions on medical imaging*, vol. 32, no. 5, pp. 943-956, 2013.
- [166] P. Komarek, "Logistic regression for data mining and high-dimensional classification," *Robotics Institute*, p. 222, 2004.
- [167] A. Sironi, E. Türetken, V. Lepetit, and P. Fua, "Multiscale centerline detection," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 7, pp. 1327-1341, 2016.
- [168] R. Rigamonti and V. Lepetit, "Accurate and efficient linear structure segmentation by leveraging ad hoc features with learned filters," *In International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 189-197, Oct. 2012.
- [169] V. Estivill-Castro, "Why so many clustering algorithms: a position paper," *ACM SIGKDD explorations newsletter*, vol. 4, no. 1, pp. 65-75, 2002.
- [170] S. S. Kar and S. P. Maity, "Blood vessel extraction and optic disc removal using curvelet transform and kernel fuzzy c-means," *Computers in biology and medicine*, vol. 70, pp. 174-189, 2016.
- [171] D. Relan, T. MacGillivray, L. Ballerini, and E. Trucco, "Retinal vessel classification: sorting arteries and veins," *In Engineering in Medicine and Biology Society. 2013 35th Annual International Conference of the IEEE*, pp. 7396-7399, 2013.
- [172] D. Kaba, A. G. Salazar-Gonzalez, Y. Li, X. Liu, and A. Serag, "Segmentation of retinal blood vessels using gaussian mixture models and expectation maximisation," *In International Conference on Health Information Science*, pp. 105-112, 2013.
- [173] M. R. N. Tagore, G. B. Kande, E. K. Rao, and B. P. Rao, "Segmentation of retinal vasculature

- using phase congruency and hierarchical clustering," *In Advances in Computing, Communications and Informatics (ICACCI)*, pp. 361-366, 2013.
- [174] T. Kohonen, "Self-organization and associative memory," *Springer Science & Business Media*, vol. 8, 2012.
- [175] H. Yin, "The self-organizing maps: background, theories, extensions and applications," *In Computational intelligence: A compendium*, pp. 715-762, 2008.
- [176] J. Zhang, Y. Cui, W. Jiang, and L. Wang, "Blood vessel segmentation of retinal images based on neural network," *In International Conference on Image and Graphics*, pp. 11-17, 2015.
- [177] Q. Li et al., "A cross-modality learning approach for vessel segmentation in retinal images," *IEEE transactions on medical imaging*, vol. 1, p. 35, 2016.
- [178] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *2015*, vol. 521, no. 7553, p. 436.
- [179] R. Annunziata and E. Trucco, "Accelerating convolutional sparse coding for curvilinear structures segmentation by refining SCIRD-TS filter banks," *IEEE transactions on medical imaging*, vol. 35, no. 11, pp. 2381-2392, 2016.
- [180] P. Liskowski and K. Krawiec, "Segmenting retinal blood vessels with deep neural networks," *IEEE transactions on medical imaging*, vol. 11, no. 35, pp. 2369-2380, 2016.
- [181] M. Al-Rawi and H. Karajeh, "Genetic algorithm matched filter optimization for automated detection of blood vessels from digital retinal images," *Computer methods and programs in biomedicine*, vol. 87, no. 3, pp. 248-253, 2007.
- [182] M. G. Cinsdikici and D. Aydın, "Detection of blood vessels in ophthalmoscope images using MF/ant (matched filter/ant colony) algorithm," *Computer methods and programs in biomedicine*, vol. 96, no. 2, pp. 85-95, 2009.
- [183] A. Asad, A. T. Azar, N. El-Bendary, and A. E. Hassanien, "Ant colony based feature selection heuristics for retinal vessel segmentation," *arXiv preprint arXiv*, vol. 1735, p. 1403, 2014.
- [184] E. Emary, H. M. Zawbaa, A. E. Hassanien, G. Schaefer, and A. T. Azar, "Retinal vessel segmentation based on possibilistic fuzzy c-means clustering optimised with cuckoo search," *In Neural Networks (IJCNN), 2014 International Joint Conference on*, pp. 1792-1796, 2014.
- [185] A. E. Hassanien, E. Emary, and H. M. Zawbaa, "Retinal blood vessel localization approach based on bee colony swarm optimization, fuzzy c-means and pattern search," *Journal of Visual Communication and Image Representation*, vol. 31, pp. 186-196, 2015.
- [186] E. Emary, H. M. Zawbaa, A. E. Hassanien, and B. Parv, "Multi-objective retinal vessel localization using flower pollination search algorithm with pattern search," *Advances in data analysis and classification*, vol. 11, no. 3, pp. 611-627, 2017.
- [187] Y. J. Zhang, "A survey on evaluation methods for image segmentation," *Pattern recognition*, vol. 29, no. 8, pp. 1335-1346, 1996.

- [188] T. Fawcett, "An introduction to ROC analysis," *Pattern recognition letters*, vol. 27, no. 8, pp. 861-874, 2006.
- [189] J. Odstrcilik 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, 2013.
- [190] J., Philipp, S. Cocquerez, "Analyse d'images et segmentation," *Masson*, 1995.
- [191] J. Kittler and J. Illingworth, "Minimum error thresholding," *Pattern recognition*, vol. 19, no. 1, pp. 41-47, 1986.
- [192] S. K. Pal and F. Deravi, "Grey level thresholding using second-order statistics," *Pattern Recognition Letters*, vol. 1, no. 5-6, pp. 417-422, 1983.
- [193] L. J. L. WENQING, "The Automatic thresholding of gray-level pictures via two-dimensional otsu method," *Acta Automatica Sinica*, vol. 1, pp. 0-15, 1993.
- [194] A. S. Abutaleb, "Automatic thresholding of gray-level pictures using two-dimensional entropy," *Computer vision, graphics, and image processing*, vol. 47, no. 1, pp. 22-32, 1989.
- [195] P. S. Liao, T. S. Chen, and P. C. Chung, "A fast algorithm for multilevel thresholding," *J. Inf. Sci. Eng.*, vol. 17, no. 5, pp. 713-727, 2001.
- [196] S. Patra, R. Gautam, and A. Singla, "A novel context sensitive multilevel thresholding for image segmentation. ," *Applied Soft Computing*, vol. 23, pp. 122-127, 2014.
- [197] Berkeley, "University, 2007. The Berkeley Segmentation Dataset and Benchmark.," *Grouping and Ecological Statistics. [Online]* , June 2007.
- [198] W. A. Yasnoff, J. K. Mui, and J. W. Bacus, "Error measures for scene segmentation," *Pattern recognition*, vol. 9, no. 4, pp. 217-231, 1977.
- [199] K. M. Passino, "Biomimicry of bacterial foraging for distributed optimization and control," *IEEE control systems*, vol. 22, no. 3, pp. 52-67, 2002.
- [200] B. Niu, H. Wang, J. Wang, and L. Tan, "Multi-objective bacterial foraging optimization," *Neurocomputing*, vol. 116, pp. 336-345, 2013.
- [201] B. Web, "Simulated brain database. McConnell Brain Imaging Centre," *Montreal Neurological Institute, McGill*, <http://brainweb.bic.mni.mcgill.ca/brainweb>, 2004.
- [202] P. D. Sathya and Kayalvizhi, "Amended bacterial foraging algorithm for multilevel thresholding of magnetic resonance brain images," *Measurement*, vol. 44, no. 10, pp. 1828-1848., 2011.
- [203] M. Sezgin and B. Sankur, "Survey over image thresholding techniques and quantitative performance evaluation," *Journal of Electronic imaging*, vol. 13, no. 1, pp. 146-166, 2004.
- [204] D. Karaboga, "An idea based on honey bee swarm for numerical optimization. Technical report-tr06, ," *Erciyes university, engineering faculty, computer engineering department*, vol. 200,

2005.

- [205] A. K. Bhandari, A. Kumar, and G. K. Singh, "Modified artificial bee colony based computationally efficient multilevel thresholding for satellite image segmentation using Kapur's, Otsu and Tsallis functions," *Expert Systems with Applications*, vol. 42, no. 3, pp. 1573-1601, 2015.
- [206] W. Zou, Y. Zhu, H. Chen, and B. Zhang, "Solving multiobjective optimization problems using artificial bee colony algorithm," *Discrete dynamics in nature and society*, 2011.
- [207] R. Akbari, R. Hedayatzadeh, K. Ziarati, and B. Hassanizadeh, "A multi-objective artificial bee colony algorithm," *Swarm and Evolutionary Computation*, vol. 2, pp. 39-52, 2012.
- [208] Y. Huo, Y. Zhuang, J. Gu, and S. Ni, "Elite-guided multi-objective artificial bee colony algorithm," *Applied Soft Computing*, vol. 32, pp. 199-210, 2015.
- [209] A. M. Mendonca and A. Campilho, "Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction," *IEEE transactions on medical imaging*, vol. 25, no. 9, pp. 1200-1213., 2006.
- [210] 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, 2015.
- [211] R. Eberhart and J. Kennedy, "A new optimizer using particle swarm theory," *In Micro Machine and Human Science, 1995. MHS'95., Proceedings of the Sixth International Symposium on*, pp. 39-43, Oct. 1995.
- [212] Y. Del Valle, G. K. Venayagamoorthy, S. Mohagheghi, J. C. Hernandez, and R. G. Harley, "Particle swarm optimization: basic concepts, variants and applications in power systems," *IEEE Transactions on evolutionary computation*, vol. 12, no. 2, pp. 171-195, 2008.
- [213] J. Hannink, R. Duits, and E. Bekkers, "Crossing-preserving multi-scale vesselness," *In International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 603-610, 2014.
- [214] A. Christodoulidis, T. Hurtut, H. B. Tahar, and F. Cheriet, "A multi-scale tensor voting approach for small retinal vessel segmentation in high resolution fundus images," *Computerized Medical Imaging and Graphics*, vol. 52, pp. 28-43, 2016.
- [215] A. F. Frangi, W. J. Niessen, K. L. Vincken, and M. A. Viergever, "Multiscale vessel enhancement filtering," *In International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 130-137, 1998.
- [216] H. Yu et al., "Fast vessel segmentation in retinal images using multi-scale enhancement and second-order local entropy," *In Medical Imaging 2012: Computer-Aided Diagnosis. International Society for Optics and Photonics.*, vol. 83151, p. 8315, 2012.
- [217] A. Budai, R. Bock, A. Maier, J. Hornegger, and G. Michelson, "Robust vessel segmentation in fundus images," *International journal of biomedical imaging*, 2013.
- [218] 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, 2016.
- [219] M. E. Gegúndez-Arias, A. Aquino, J. M. Bravo, and D. Marin, "A function for quality evaluation of retinal vessel segmentations," *IEEE transactions on medical imaging*, vol. 31, no. 2, pp. 231-239, 2012.
- [220] E. Zitzler and L. Thiele, "An evolutionary algorithm for multiobjective optimization: The strength pareto approach," *TIK-report*, vol. 43, 1998.
- [221] A. Berro, "Optimisation multiobjectifs et stratégies d'évolution en environnement dynamique," *Thèse de doctorat. ANRT*, 2001.
- [222] C. A. Coello Coello, "An empirical study of evolutionary techniques for multiobjective optimization in engineering design," 1996.
- [223] Y. Collette and P. Siarry, "Optimisation multiobjectif," *Algorithmes. Editions Eyrolles*, 2011.
- [224] K. Deb, S. Agrawal, A. Pratap, and T. Meyarivan, "A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II," *In International Conference on Parallel Problem Solving From Nature*, pp. 849-858, 2000.
- [225] M. A. Guzmán, A. Delgado, and J. De Carvalho, "A novel multiobjective optimization algorithm based on bacterial chemotaxis," *Engineering Applications of Artificial Intelligence*, vol. 23, no. 3, pp. 292-301, 2010.
- [226] J. H. Holland and D. Goldberg, "Genetic algorithms in search, optimization and machine learning," *Massachusetts: Addison-Wesley*, 1989.
- [227] H. Ishibuchi and T. Murata, "A multi-objective genetic local search algorithm and its application to flowshop scheduling," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 28, no. 3, pp. 392-403, 1998.
- [228] M. S. Lechuga and E. A. E. Coello, "A proposal for multiple objective particle swarm optimization," *In Proceedings of the 2002 Congress on Evolutionary Computation, Part of the 2002 IEEE World Congress on Computational Intelligence*, pp. 2051-11056, 2002.
- [229] A. Nakib, "Conception de métaheuristiques d'optimisation pour la segmentation d'images. Application aux images biomédicales," *Thèse de doctorat. Université Paris XII Val de Marne.*, 2007.
- [230] V. Pareto and C. D. E. & Politique, "I and II, F. Rouge, Lausanne," pp. 1776-1960, 1896.
- [231] Á. Rubio-Largo, M. A. Vega-Rodríguez, J. A. Gómez-Pulido, and J. M. Sánchez-Pérez, "A multiobjective approach based on artificial bee colony for the static routing and wavelength assignment problem," *Soft computing*, vol. 17, no. 2, pp. 199-211, 2013.
- [232] P. D. Sathya and R. Kayalvizhi, "Optimal segmentation of brain MRI based on adaptive bacterial foraging algorithm," *Neurocomputing*, vol. 74, no. 14-15, pp. 2299-2313, 2011.

[233] N. Srinivas and K. Deb, "Multiobjective optimization using nondominated sorting in genetic algorithms," *Evolutionary computation*, vol. 2, no. 3, pp. 221-248, 1994.