

# Segmentation automatique par apprentissage profond des artères coronaires à partir d'angiographie 2D

par

Nouha MEFTAH

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE  
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAÎTRISE  
AVEC MÉMOIRE EN TECHNOLOGIE DE L'INFORMATION

M. Sc. A.

MONTRÉAL, LE 23 FÉVRIER 2024

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE  
UNIVERSITÉ DU QUÉBEC



Nouha MEFTAH, 2024



Cette licence Creative Commons signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette oeuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'oeuvre n'ait pas été modifié.

**PRÉSENTATION DU JURY**

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE:

M. Luc Duong, directeur de mémoire  
Département de génie logiciel et des TI à l'École de technologie supérieure

Mme. Faten M'hiri, codirectrice  
École d'informatique, Faculté des sciences, Université McGill

Mme. Sylvie RATTÉ, présidente du jury  
Département de génie logiciel et des TI à l'École de technologie supérieure

M. Simon DROUIN , membre du jury  
Département de génie logiciel et des TI à l'École de technologie supérieure

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 26 JANVIER 2024

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE



## REMERCIEMENTS

M Luc, je vous remercie du fond du cœur de m'avoir offert cette merveilleuse opportunité de contribuer à un projet si noble et humanitaire. Participer à un projet visant à sauver les vies des enfants est un honneur qui va bien au-delà d'une simple expérience universitaire. Travailler avec un professeur comme vous a été une expérience extrêmement enrichissante pour moi, m'ouvrant de nouveaux horizons dans le monde de la recherche et de la médecine. Cette collaboration m'a appris comment mettre à profit les avancées technologiques pour de bonnes causes. Votre encouragement et votre bienveillance créent un environnement propice à l'épanouissement, et je me sens incroyablement chanceuse de pouvoir bénéficier d'être parmi vos étudiants. Je tiens à souligner que votre impact positif se mesure non seulement par les contributions de ce projet, mais également par la motivation et l'engagement que vous avez créé en moi. Merci pour votre mentorat exceptionnel.

Un grand merci à toi, Faten, pour ta précieuse contribution à ce projet. Tes conseils, instructions et commentaires ont significativement contribué à la réussite de ce projet. J'apprécie profondément l'énergie et le temps que tu aies investi pour faire de ce travail un succès.

Je tiens à exprimer ma profonde gratitude envers tout le personnel dévoué du Centre hospitalier universitaire Sainte-Justine, le plus grand centre mère-enfant au Canada et l'un des quatre centres pédiatriques les plus importants en Amérique du Nord. La collaboration étroite avec cet établissement de renom a été l'essence même de mon projet de maîtrise.

Je tiens à exprimer ma sincère gratitude envers vous, Mme Sylvie, et M Simon pour le temps, la considération et l'expertise que vous avez consacrés à évaluer mon mémoire.

Papa et Maman, je voudrais aujourd'hui exprimer ma plus profonde gratitude pour le don précieux que vous représentez dans ma vie. Votre amour a été mon soutien dans les moments difficiles et ma source de joie dans les moments heureux. Les sacrifices que vous avez consentis, les leçons que vous avez partagées et les encouragements que vous m'avez donnés ont été les pierres angulaires de ma vie. Merci de m'avoir appris à rêver, à persévérer et à aimer sans limites. Je suis toujours reconnaissante pour les valeurs que vous m'avez enseignées, les opportunités que vous m'avez offertes. Je réalise que tout ce que je suis et tout ce que j'accomplis est avant tout le fruit de vos efforts et de votre amour.

Un remerciement très chaleureux à ma petite sœur Cyrine. Tu es la bougie qui illumine ma vie. Merci d'être une merveilleuse sœur qui est toujours à mes côtés pour me combler d'amour. Tu es bien plus qu'une sœur, tu es une amie précieuse, une confidente et une source inépuisable de réconfort.

Je tiens également à remercier toutes les personnes formidables que j'ai eu le plaisir de rencontrer ici à Montréal. Votre convivialité, votre gentillesse et votre diversité ont rendu cette période exceptionnelle. Chacun d'entre vous a contribué à cette expérience particulière.

Je suis vraiment reconnaissante envers Montréal. Pour moi, Montréal est plus qu'une simple ville, elle est une source constante d'inspiration et une mosaïque vivante de culture, d'art et de diversité. Merci, Montréal, pour tous les souvenirs que j'ai créés ici, les amitiés que j'ai nouées et l'amour que tu m'as donné. C'est votre esprit communautaire qui fait de vous un endroit particulier. Il y a quelque chose de magique dans la façon dont nous nous réunissons pour célébrer, nous soutenir mutuellement et faire de Montréal notre maison commune. Je suis très reconnaissante d'appeler Montréal chez moi.

Enfin, je voudrais exprimer ma gratitude à ma Tunisie pour m'avoir donné une base solide en matière d'éducation, éveillant en moi le sens de la découverte et étanchant la soif de connaissances. J'apporte fièrement les enseignements de mon pays d'origine à cette aventure académique internationale. Je considère ce succès comme un hommage rendu à la solide éducation que j'ai reçue en Tunisie présentant ainsi dignement la Tunisie dans ce contexte global, et contribuant à l'enrichissement mutuel des savoirs et des expériences. En cela, chaque réalisation que je réalise ici témoigne de la qualité de l'éducation tunisienne et de l'impact positif qu'elle peut avoir sur le développement intellectuel et professionnel d'un individu, même au-delà de ses frontières.

C'est avec une sincérité profonde que je dédie ce projet à tous les enfants du Centre hospitalier universitaire Sainte-Justine et, par extension, à chaque enfant à travers le monde. Cette recherche, façonnée par le partenariat inestimable avec l'hôpital, transcende les frontières de ma maîtrise. Je fais la promesse solennelle que mon engagement va bien au-delà de ces pages académiques. Je m'engage pleinement à mobiliser mes compétences et mes ressources pour aider les enfants dans le monde entier. Que ce soit à travers le travail acharné, le bénévolat ou toute autre forme d'assistance, je promets de consacrer mes efforts à améliorer la vie de chaque enfant, où qu'il se

trouve sur notre planète.



# Segmentation automatique par apprentissage profond des artères coronaires à partir d'angiographie 2D

Nouha MEFTAH

## RÉSUMÉ

La segmentation automatique précise des artères coronaires joue un rôle crucial dans l'imagerie médicale pour le diagnostic, l'analyse, la prévention et le traitement des pathologies cardiovasculaires. Dans le cadre de ce projet de maîtrise, nous proposons une approche innovatrice basée sur le réseau convolutionnel U-Net pour segmenter les artères coronaires à partir des images angiographiques 2D. Pour optimiser les performances de notre segmentation, nous avons intégré les filtres proposés par Meijering et al. et Sato et al. particulièrement conçus pour l'extraction des caractéristiques des structures tubulaires.

Notre approche expérimentale se décompose en deux étapes distinctes. Tout d'abord, nous avons utilisé le réseau U-Net avec les images de la base de données DCA1 comme données d'entrée. Pour obtenir une segmentation optimale, nous avons choisi d'incorporer les filtres de Meijering et Sato. Cette démarche vise à rehausser la visibilité des vaisseaux et à améliorer la distinction entre les artères coronaires et les tissus environnants. L'incorporation de ces filtres a notablement amélioré les résultats par rapport à ceux obtenus par U-Net sans filtrage. Dans une deuxième phase, la correction gamma a été intégrée dans notre approche afin d'évaluer son impact sur l'amélioration des résultats.

Les résultats obtenus ont été évalués de manière exhaustive à l'aide des métriques d'évaluation tels que l'exactitude, la sensibilité, la spécificité et le coefficient de Dice.

Cette étude contribue à l'avancement des techniques de segmentation des artères coronaires, ouvrant la voie à des applications cliniques plus fiables et précises. Les méthodes présentées dans ce mémoire offrent des perspectives prometteuses pour l'amélioration continue des diagnostics cardiovasculaires et la personnalisation des traitements médicaux.

**Mots-clés:** Artères coronaires, Apprentissage profond, Segmentation, Filtres d'amélioration des vaisseaux, Angiographie 2D.



# **Automatic segmentation through deep learning of coronary arteries from 2D angiography images**

Nouha MEFTAH

## **ABSTRACT**

Accurate automatic segmentation of coronary arteries plays a crucial role in medical imaging for the diagnosis, analysis, prevention and treatment of cardiovascular pathologies. In this master's thesis we propose an innovative approach based on the U-Net convolutional network to segment coronary arteries from 2D angiographic images. To optimize the performance of our segmentation, we have integrated the filters proposed by Meijering et al. and Sato et al. specifically designed for the extraction of tubular structure features.

Our experimental approach is based on two distinct stages. To achieve optimal segmentation, we decided to incorporate the Meijering and Sato filters. This approach aims to enhance vessel visibility and improve the distinction between coronary arteries and surrounding tissue. The incorporation of these filters significantly improved results compared with those obtained by U-Net without filtering. In a second phase, gamma correction was incorporated into our approach to assess its impact on enhancing the results.

The results obtained were comprehensively assessed using evaluation metrics such as accuracy, sensitivity, specificity and Dice coefficient.

This study contributes to the advancement of coronary artery segmentation techniques, paving the way for more reliable and accurate clinical applications. The methods presented in this thesis offer promising prospects for the continuous improvement of cardiovascular diagnostics and the personalization of medical treatments.

**Keywords:** Coronary Arteries, Deep Learning, Segmentation, Vessel Enhancement Filters, 2D Angiography.



## TABLE DES MATIÈRES

	Page
INTRODUCTION .....	1
CHAPITRE 1 CONTEXTE CLINIQUE .....	5
1.1 Anatomie et fonction du système cardiovasculaire .....	5
1.1.1 La circulation sanguine .....	7
1.1.2 Les artères coronaires .....	8
1.1.3 Les pathologies des artères coronaires .....	9
1.1.4 Les interventions coronariennes percutanées (ICP) .....	11
1.1.5 Les angiogrammes des artères coronaires .....	12
CHAPITRE 2 REVUE DE LITTÉRATURE .....	15
2.1 Concepts de base de l'apprentissage profond .....	15
2.1.1 L'algorithme de propagation avant .....	16
2.1.2 L'algorithme de rétropropagation .....	17
2.2 Les réseaux de neurones convolutifs (CNN) .....	18
2.3 La segmentation sémantique des images par CNNs .....	20
2.3.1 Principes des tâches de segmentation sémantique .....	21
2.3.2 Les métriques d'évaluation pour la segmentation sémantique .....	22
2.3.2.1 Indice de Jaccard .....	22
2.3.2.2 Le coefficient de Dice .....	22
2.3.3 U-Net .....	23
2.4 La segmentation des vaisseaux .....	24
2.4.1 Les méthodes classiques d'apprentissage automatique .....	26
2.4.1.1 Les forêts aléatoires .....	26
2.4.1.2 Champ aléatoire de Markov .....	27
2.4.1.3 Kernel support vector machine .....	28
2.4.1.4 Autres méthodes classiques .....	28
2.4.2 Les méthodes d'apprentissage profond .....	30
CHAPITRE 3 MÉTHODOLOGIE .....	33
3.1 Contexte général .....	33
3.1.1 Description de données .....	34
3.1.1.1 Normalisation .....	35
3.1.1.2 Amélioration des vaisseaux : Filtrage .....	35
3.1.2 Le modèle de segmentation .....	41
3.1.2.1 Architecture du modèle .....	41
3.1.2.2 Les métriques d'évaluation .....	42
3.1.2.3 Configuration et optimisation des hyperparamètres .....	43
3.2 Experimentations .....	45

3.2.1	Expérience 1 : Comparaison de différents filtres d'amélioration des vaisseaux .....	45
3.2.2	Expérience 2 : Effet de la correction Gamma sur les filtres d'améliorations des vaisseaux .....	47
3.2.2.1	Choix de la valeur de Gamma .....	48
CHAPITRE 4	RÉSULTATS .....	51
4.1	Expérience 1 : Comparaison de différents filtres d'amélioration des vaisseaux .....	51
4.2	Expérience 2 : Effet de la correction Gamma sur les filtres d'améliorations des vaisseaux .....	56
4.3	Discussion .....	59
CONCLUSION ET RECOMMANDATIONS	.....	69
ANNEXE I	ÉTAT DE L'ART SUR LES MÉTHODES D'APPRENTISSAGE PROFOND POUR LA SEGMENTATION DES CA .....	71
BIBLIOGRAPHIE	.....	81

## LISTE DES TABLEAUX

	Page
Tableau 2.1	Exemples de fonctions d'activation ..... 16
Tableau 3.1	Comparaison entre les filtres de Meijering et Sato ..... 39
Tableau 3.2	Équations des métriques d'évaluation et leurs explications ..... 43
Tableau 4.1	Le résultat de l'application de différents filtres sur le modèle U-Net ..... 51
Tableau 4.2	Le résultat de l'intégration de la correction Gamma ..... 57



## LISTE DES FIGURES

		Page
Figure 1.1	La structure du cœur. Tirée de Santé sur le Net.(2015a). Généralités sur le cœur. Santé sur le Net. <a href="https://www.sante-sur-le-net.com/maladies/cardiologie/generalites-coeur/">https://www.sante-sur-le-net.com/maladies/cardiologie/generalites-coeur/</a> . ....	7
Figure 1.2	La circulation sanguine. Tirée de Santé sur le Net.(2015b). Généralités sur le cœur. Santé sur le Net. <a href="https://www.sante-sur-le-net.com/maladies/cardiologie/generalites-coeur/">https://www.sante-sur-le-net.com/maladies/cardiologie/generalites-coeur/</a> . ....	8
Figure 1.3	Les artères coronaires. Tirée de Citadelle. (s.d.). Mieux comprendre la maladie coronarienne. Citadelle. Récupéré le 1er décembre 2023, de <a href="https://www.citadelle.be/Services/Services-medicaux/Cardiologie/La-maladie-coronarienne/Mieux-comprendre-la-maladie-coronarienne.aspx">https://www.citadelle.be/Services/Services-medicaux/Cardiologie/La-maladie-coronarienne/Mieux-comprendre-la-maladie-coronarienne.aspx</a> . ....	10
Figure 1.4	Intervention percutanée par cathéter : le cathéter (le tube noir) est inséré à partir d'un vaisseau sanguin dans l'aîne et est avancé dans le cœur. Image adaptée de "Cathéter à bout ballonnet" utilisée sous licence Creative Commons par Bruce Blaus (BruceBlaus (2016)). ....	12
Figure 2.1	Le réseau de propagation avant. Image tirée de Databricks. (s.d.). Réseau de neurones. Databricks. Récupéré le 1er décembre 2023, de <a href="https://www.databricks.com/fr/glossary/neural-network">https://www.databricks.com/fr/glossary/neural-network</a> . ....	17
Figure 2.2	L'opération de convolution. Tirée de IndoML. (2018). Notes d'étudiant : Introduction aux réseaux neuronaux convolutionnels (CNN). IndoML. Récupéré le 1er décembre 2023, de <a href="https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/">https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/</a> . ....	19
Figure 2.3	Les opérations de pooling maximum et le pooling moyen. Tirée de ResearchGate. (s.d.). Illustration de Max Pooling et Average Pooling. ResearchGate. Récupéré le 1er décembre 2023, de <a href="https://www.researchgate.net/figure/Illustration-of-Max-Pooling-and-Average-Pooling-Figure-2-above-shows-an-example-of-max_fig2_333593451">https://www.researchgate.net/figure/Illustration-of-Max-Pooling-and-Average-Pooling-Figure-2-above-shows-an-example-of-max_fig2_333593451</a> . ....	21
Figure 2.4	La différence entre le coefficient Dice (DSC) et l'indice de Jaccard (J). ....	23

Figure 2.5	L'architecture U-Net. Tirée de Ronneberger, O., Fischer, P., Brox, T. (2015). .....	25
Figure 3.1	Visualisation de quelques images de la base de données DCA1. ....	34
Figure 3.2	Visualisation de l'effet du filtre sur les images de DCA1. ....	46
Figure 3.3	Le flux du travail de la 1 ère expérience. ....	47
Figure 3.4	Le flux de travail de l'expérience 2. ....	49
Figure 4.1	Dix angiogrammes de l'ensemble de test (a), et leurs vérités de terrain (f). Les lignes (b),(c) et (d) présentent les résultats de segmentation des modèles Standard, Unet-Meijering et Unet-Sato. ....	53
Figure 4.2	Illustration de l'amélioration de la continuité des AC à travers les filtres Meijering et Sato. ....	55
Figure 4.3	Illustration de l'amélioration de détection des bifurcations des AC à travers les filtres Meijering et Sato. ....	55
Figure 4.4	Illustration de réduction de FN à travers les filtres Meijering et Sato. ....	55
Figure 4.5	Dix angiogrammes de l'ensemble de test (a), et (e) leur vérité de terrain respective. Les lignes suivantes présentent les résultats de segmentation des modèles StandardCG(b), MeijeringCG(c), et SatoCG(d). ....	59
Figure 4.6	Illustration de l'amélioration de continuité des AC à travers la correction Gamma sur le modèle original. ....	60
Figure 4.7	Illustration de l'amélioration de détection de bifurcation des AC à tavers la correction Gamma sur le modèle original. ....	60
Figure 4.8	Illustration de réduction de FN à tavers la correction Gamma sur le modèle original. ....	61
Figure 4.9	Illustration de l'amélioration de continuité des AC à tavers la correction Gamma sur le modèle U-Net + Meijering. ....	61
Figure 4.10	Illustration de l'amélioration de détection de bifurcation des AC à tavers la correction Gamma sur le modèle Unet-Meijering. ....	62

Figure 4.11	Illustration de réduction de FN à tavers la correction Gamma sur le modèle Unet- Meijering. ....	62
Figure 4.12	Illustration de réduction de FP à tavers la correction Gamma sur le modèle Unet-Meijering. ....	63
Figure 4.13	Illustration de la dégradation de continuité des AC à tavers la correction Gamma sur le modèle Unet-Sato. ....	63
Figure 4.14	Illustration de la dégradation de détection de bifurcation des AC à tavers la correction Gamma sur le modèle Unet-Sato. ....	64
Figure 4.15	Illustration d'augmentation de FN à tavers la correction Gamma sur le modèle Unet-Sato. ....	64
Figure 4.16	Illustration de l'augmentation de FP à tavers la correction Gamma sur le modèle Unet-Sato. ....	65
Figure 4.17	Diagramme synthétique des performances des différents modèles de notre approche. ....	66
Figure 4.18	Dix angiogrammes de l'ensemble de test (a), et (h) leur vérité de terrain respective. Les lignes suivantes présentent les résultats de segmentation des modèles Standard(b), Unet-Meijering(c), Unet-Sato(d), StandardCG(e), MeijeringCG(f), et SatoCG(g). ....	67



## **LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES**

AC	Artère coronaire
ARG	Adaptive Region Growing
CAM	Champ Aléatoire de Markov
CNN	Convolutional Neural Network
ECG	Électrocardiogramme
EQM	Erreur Quadratique Moyenne
ETS	École de Technologie Supérieure
FA	Forêts Aléatoires
FAV	Filtres d'Amélioration des Vaisseaux
FC	Fully Connected
ICP	Interventions Coronariennes Percutanées
IRM	Imagerie par Résonance Magnétique
KSVM	Kernel Support Vector Machine
LoG	Laplacien du Gaussien
LSTM	Long Short-Term Memory
MBR	Machines de Boltzmann Restreintes
MIoU	Mean Intersection over Union
PGM	Portable Gray Map
RN	Réseaux de Neurones
RNP	Réseaux de Neurones Profonds
SC	Structure Curviligne
SVM	Support Vector Machine
TAO	Tomographie Assistée par Ordinateur
TCO	Tomographie par Cohérence Optique
VA	Valves Auriculo-ventriculaires
VCO	Optimisation de la Correspondance des Vaisseaux
VS	Valves Semi-lunaires
XRA	Séquence Radiographique en Temps Réel



## INTRODUCTION

Les maladies cardiovasculaires restent l'une des principales causes de décès dans le monde, touchant des millions de personnes (Mordor Intelligence,2023). Parmi ces maladies, les maladies coronariennes occupent une place prépondérante, car elles peuvent avoir des conséquences mortelles. La maladie coronarienne se caractérise par un rétrécissement des artères coronaires qui fournissent de l'oxygène et des nutriments essentiels au muscle cardiaque et peut entraîner des affections graves telles que l'infarctus du myocarde, l'angine de poitrine et un dysfonctionnement cardiaque (Ameisen et al.,2008). Cependant, la détection précoce et précise des anomalies des artères coronaires demeure d'une importance cruciale pour faciliter des interventions médicales préventives et améliorer les résultats cliniques. Parmi les méthodes d'évaluation de l'état des artères, la distensibilité émerge comme un paramètre clé. La distensibilité, mesurant la variation de diamètre des artères, offre une perspective unique sur la capacité des vaisseaux à s'adapter aux changements de pression sanguine. Cette mesure va au-delà de l'évaluation de l'élasticité des vaisseaux, en permettant également de sonder leur réactivité aux fluctuations hémodynamiques. Une distensibilité optimale est indicative d'une capacité vasculaire adéquate à répondre aux besoins physiologiques, tandis qu'une diminution de cette caractéristique peut signaler des perturbations dans la fonction vasculaire. La distensibilité revêt une importance particulière dans l'anticipation d'éventuelles complications à long terme, telle que la rigidité artérielle, pouvant potentiellement entraîner une altération de la fonction cardiaque. La mesure automatique de la distensibilité est rendue possible grâce à la segmentation qui permet d'identifier avec précision les subtils changements de l'artère.

La segmentation manuelle des AC a longtemps été un processus laborieux, sujet à la variabilité interobservateur, et donc sujet aux erreurs humaines. Chaque observateur peut avoir une interprétation unique des données d'image, ce qui peut conduire à des résultats différents. Cette variabilité est encore plus préoccupante dans le domaine des maladies coronariennes, où la précision du diagnostic est essentielle à la gestion clinique. Diverses méthodes semi-automatiques

ont été déployées pour accélérer le processus de segmentation, mais l'intervention d'un expert clinique pour initialiser et/ou contrôler la segmentation est toujours demandée. Cependant, avec l'avènement de la segmentation automatisée des AC, la situation a fondamentalement changé. En effet, la segmentation automatique des AC modifie significativement le diagnostic, la prédiction et le traitement de la maladie coronarienne. En fournissant une visualisation détaillée des AC, elle permet aux médecins de surmonter les limites de la segmentation manuelle, de détecter avec plus de précision un rétrécissement critique (sténose), d'identifier de manière plus fiable les plaques calcifiées et d'évaluer le flux sanguin d'une manière plus objective ce qui contribue efficacement dans la prise des décisions médicales. La segmentation des vaisseaux a considérablement évolué au fil des décennies avec la prolifération de l'intelligence artificielle, de la vision par l'ordinateur et l'apprentissage profond et des techniques d'imagerie médicale. Les réseaux neuronaux convolutifs (CNN) sont les réseaux neuronaux profonds les plus utilisés pour la segmentation des vaisseaux. Contrairement aux méthodes traditionnelles d'apprentissage automatique, les modèles CNN apprennent les caractéristiques de l'image automatiquement plutôt que de les extraire manuellement. La première application des réseaux neuronaux convolutionnels à la segmentation des vaisseaux sanguins a été réalisée par (Liskowski Krawiec, 2016). Depuis, les réseaux neuronaux convolutifs ont été largement utilisés dans plusieurs tâches d'extraction de vaisseaux.

Bien que ces méthodes aient montré une certaine efficacité, elles se heurtent encore à des défis qui limitent leur application généralisée et leur utilité clinique. Le traitement des variations anatomiques et des pathologies complexes est un domaine critique qui nécessite un développement plus poussé. Les AC présentent un large éventail de tailles, de formes et de modèles de ramification, ce qui rend difficile une segmentation précise. En outre, les angiogrammes à rayons X souffrent souvent d'une échelle de gris non uniforme, de faibles rapports de contraste, faible rapport signal/bruit, de la présence d'autres tissus et des mouvements de la caméra, autant de facteurs qui peuvent dégrader la qualité de l'image. Des techniques avancées de prétraitement des données,

tel que le filtrage des vaisseaux, permettent de traiter ces complexités anatomiques tout en réduisant le bruit du signal. Ces filtres se sont révélés prometteurs dans une variété de tâches d'imagerie médicale, permettant l'extraction de caractéristiques et de modèles complexes à partir d'une variété de modalités de données. Nous pouvons améliorer la robustesse et l'exactitude de la segmentation en combinant ces techniques avec des architectures d'apprentissage profond.

Dans cette étude, l'objectif principal est d'étudier l'apport de combiner les filtres d'amélioration des vaisseaux (FAV) à savoir Meijering et Sato avec les nouvelles techniques d'apprentissage profond. L'intégration de l'architecture U-Net avec les FAV constitue le cœur de mon approche. En combinant les forces de l'apprentissage profond et des techniques de filtrage, mon approche vise à améliorer la précision et l'efficacité de la segmentation des AC dans le contexte des interventions de l'AC. Les résultats de cette étude peuvent potentiellement contribuer à aux progrès des interventions par cathéter guidées par ordinateur, à l'amélioration des résultats pour les patients et de faire progresser le domaine de la médecine cardiovasculaire. Le mémoire est constitué de 3 chapitres :

- Le premier chapitre établit le socle contextuel de notre étude en explorant le domaine clinique lié au système cardiovasculaire. Nous débutons par une analyse approfondie de l'anatomie et de la fonction de ce système vital, en mettant en lumière des éléments clés tels que la circulation sanguine, les artères coronaires, les pathologies spécifiques qui les affectent, et enfin, les interventions coronariennes percutanées (ICP).
- Le deuxième chapitre explore les fondements théoriques de l'apprentissage profond appliqué à la segmentation d'images. Après avoir établi ces bases conceptuelles, nous procédons à une analyse approfondie de la littérature, mettant en lumière les différentes méthodes de segmentation des vaisseaux sanguins, avec une attention particulière portée aux artères coronaires. Cette revue de la littérature englobe une diversité de modalités d'imagerie médicale, offrant ainsi une perspective exhaustive des approches adoptées dans la segmentation des

structures vasculaires, et permettant d'identifier les tendances et les avancées significatives dans ce domaine spécifique.

- Le troisième chapitre expose notre méthodologie, fondée sur la segmentation par apprentissage profond, exploitant les FAV (Meijering et Sato). Il fournit une compréhension globale de la méthodologie utilisée, avec des détails spécifiques sur le prétraitement des données et les choix liés aux modèles de segmentation.
- Le quatrième chapitre est une présentation et analyse des résultats obtenus par notre approche. Nous avons effectué une analyse détaillée des résultats des deux expériences menées indépendamment puis les avons comparés. cela nous permet de dégager des tendances, de mettre en évidence les performances spécifiques de chaque expérimentation, et fournir des informations significatives sur la pertinence et l'efficacité de notre approche globale de segmentation des AC.
- La conclusion est une synthèse des points clés de notre méthode et une présentation des futurs aspects de recherche ou mesures de ce projet.

# CHAPITRE 1

## CONTEXTE CLINIQUE

### 1.1 Anatomie et fonction du système cardiovasculaire

La principale fonction du système cardiovasculaire consiste à distribuer de l'oxygène et des nutriments à toutes les parties du corps tout en éliminant le dioxyde de carbone et les déchets indésirables. Il se compose du cœur, qui est la pompe centrale, et d'un réseau de vaisseaux sanguins. Le cœur est le plus gros muscle du système cardiovasculaire, pompant environ 5 litres par minute. Sa taille varie d'une personne à l'autre. Cette variation est due à plusieurs facteurs, à savoir l'âge, le poids, la corpulence, les cardiopathies. En gros, les dimensions du cœur d'un adulte sont environ 12 cm de longueur et 9 cm de largeur. Il pèse généralement entre 250 et 350 grammes et a à peu près la même taille qu'une paire de poings serrés, tandis que le cœur d'un enfant a à peu près la même taille qu'un poing serré (Cleveland Clinic, 2021.Heart, repéré à l'URL : <https://my.clevelandclinic.org/health/body/21704-heart>).

Le cœur est situé entre les deux poumons, au milieu de la poitrine. Il se situe juste au-dessus du diaphragme et derrière le sternum, légèrement à gauche. Environ deux tiers du cœur se trouvent à gauche de la ligne médiane du sternum. Le tiers restant se trouve à droite du sternum. Tout au long de sa vie, le cœur distribue les nutriments et les gaz aux tissus de l'organisme par des canaux spécifiques appelés vaisseaux sanguins. Ces vaisseaux forment deux systèmes fermés de tubes qui commencent et finissent dans le cœur. Le premier système, les vaisseaux pulmonaires acheminent le sang du ventricule droit aux poumons et le ramènent à l'oreillette gauche. Le second système, composé des vaisseaux systémiques, transporte le sang du ventricule gauche vers les tissus de toutes les parties du corps, pour ensuite le ramener à l'oreillette droite. Selon leur structure et leur fonction, ils sont classés en artères, capillaires ou veines : la structure du cœur est composée de :

- **Paroi cardiaque** : La paroi cardiaque est un muscle qui se contracte et se relâche pour fournir du sang à tout le corps. Elle est constituée de trois couches de tissu : l'épicarde est la couche externe où se trouvent les artères coronaires, la couche intermédiaire est le myocarde, et c'est

la couche la plus épaisse du cœur. La couche interne est l'endocarde. Le cœur repose sur un sac fin appelé péricarde, souvent rempli d'une petite quantité de liquide.

- **Les chambres du cœur :** Le cœur est divisé en quatre cavités. Il y a deux chambres supérieures (oreillettes) et deux chambres inférieures (ventricules), une de chaque côté du cœur.
  - Oreillette droite : Deux grosses veines donnent à l'oreillette droite du sang pauvre en oxygène. La veine cave supérieure et la veine cave inférieure transportent respectivement le sang du haut et du bas du corps. L'oreillette droite pompe ensuite le sang vers le ventricule droit.
  - Ventricule droit : La chambre inférieure droite pompe le sang pauvre en oxygène vers les poumons via l'artère pulmonaire. Les poumons rechargent le sang en oxygène.
  - Oreillette gauche : Une fois que les poumons sont remplis d'oxygène, les veines pulmonaires transportent le sang vers l'oreillette gauche. Cette chambre supérieure pompe le sang vers le ventricule gauche.
  - Ventricule gauche : Le ventricule gauche est légèrement plus large que le droit. Il pompe le sang riche en oxygène vers le reste du corps (figure 1.1).
- **Valves cardiaques :** Les valvules cardiaques sont comme des portes entre les chambres du cœur. Elles s'ouvrent et se ferment pour que le sang puisse circuler. La fermeture des valves produit le son familier du battement du cœur. Il existe deux principaux types de valves :
  - Les valves auriculo-ventriculaires (AV) s'ouvrent entre les cavités supérieures et inférieures du cœur. Elles comprennent la valve tricuspide (porte entre l'oreillette droite et le ventricule droit) et la valve mitrale (porte entre l'oreillette gauche et le ventricule gauche).
  - Les valves semi-lunaires (SL) s'ouvrent lorsque le sang s'écoule de vos ventricules. Elles comprennent : la valve aortique, qui s'ouvre lorsque le sang s'écoule de votre ventricule gauche vers votre aorte (artère qui transporte le sang riche en oxygène vers votre corps), et la valve pulmonaire, qui s'ouvre lorsque le sang s'écoule de votre ventricule droit vers vos artères pulmonaires (les seules artères qui transportent le sang pauvre en oxygène vers vos poumons).




Figure 1.1 La structure du cœur. Tirée de Santé sur le Net.(2015a). Généralités sur le cœur. Santé sur le Net. <https://www.sante-sur-le-net.com/maladies/cardiologie/generalites-coeur/>.

### 1.1.1 La circulation sanguine

Comme l'illustre la figure 1.2, le sang pauvre en oxygène revient des tissus de l'organisme et pénètre dans l'oreillette droite via les veines caves inférieures et supérieures pour ensuite circuler à travers la valve tricuspide et entrer dans le ventricule droit. Ainsi, le ventricule droit pompe le sang à travers la valve pulmonaire et le fait sortir du cœur via l'artère pulmonaire primaire. Le sang circule ensuite dans les artères pulmonaires gauche et droite jusqu'aux poumons, qui s'enrichissent en oxygène et éliminent le dioxyde de carbone. Le sang revient ensuite au cœur et se dirige vers l'oreillette gauche via quatre artères pulmonaires. Il passe par la valve mitrale pour entrer dans le ventricule gauche. Ce ventricule pompe le sang à travers la valve aortique jusqu'à l'aorte, cette grande artère (aorte) qui alimente le reste du corps en sang. Les artères coronaires, alimentées par l'aorte, assurent l'approvisionnement en sang riche en oxygène au cœur.




Figure 1.2 La circulation sanguine. Tirée de Santé sur le Net.(2015b). Généralités sur le cœur. Santé sur le Net. <https://www.sante-sur-le-net.com/maladies/cardiologie/generalites-coeur/>.

### 1.1.2 Les artères coronaires

Pour survivre, tous les muscles du corps ont besoin d'un apport régulier en oxygène et en nutriments et doivent évacuer les déchets métaboliques (Barataud, B. (2022). Mieux comprendre le fonctionnement des muscles. MGC Prévention santé). Sans ces besoins, les cellules subissent rapidement des changements irréversibles, ce qui souligne le rôle vital du système cardiovasculaire. En effet, le sang est le transporteur et le cœur est la pompe qui assure son déplacement dans les vaisseaux.

Le cœur lui-même est un muscle qui a besoin d'un apport continu en oxygène et en nutriments pour fonctionner efficacement. C'est pourquoi le muscle cardiaque dispose d'un vaste réseau d'artères coronaires qui fournissent de l'oxygène au cœur et évacuent les déchets.

Ces vaisseaux sont ainsi nommés "artères coronaires" en raison de leur enroulement autour du cœur, similaire à une couronne. L'appellation "coronaire" trouve son origine dans les termes latins

"corona" et grec "koron", signifiant tous deux "couronne". Le cœur humain donne naissance à deux artères coronaires principales : l'artère coronaire principale gauche et l'artère coronaire droite. Comme la figure 1.3 l'illustre, l'artère coronaire principale gauche fournit du sang au ventricule et à l'oreillette gauches. Cette artère se divise en deux branches : l'artère descendante antérieure gauche qui alimente en sang le côté avant gauche du cœur et l'artère circonflexe qui alimente en sang l'extérieur et l'arrière du cœur. Quant à l'artère coronaire droite, elle apporte le sang au côté droit composé du ventricule droit, de l'oreillette droite, du nœud sinusal et du nœud auriculo-ventriculaire.

Comme l'artère coronaire principale gauche, l'artère coronaire droite se divise en deux branches : l'artère descendante postérieure droite et l'artère marginale aiguë. L'artère coronaire droite transporte le sang des poumons vers la partie inférieure du ventricule gauche et le septum. De cette manière, les artères coronaires alimentent le cœur avec le sang dont il a besoin pour remplir efficacement son rôle vital.

Si les artères coronaires ne sont pas en bon état, l'apport sanguin à une partie du myocarde peut être interrompu, ou les besoins énergétiques du cœur peuvent être beaucoup plus importants que son apport sanguin. De tels problèmes peuvent conduire à la crise cardiaque et à plusieurs complications dangereuses.

### **1.1.3 Les pathologies des artères coronaires**

Les cardiopathies coronariennes sont des maladies cardiovasculaires majeures qui touchent toutes les populations du monde entier. Elles sont devenues la principale cause de risques pour la santé humaine et de mortalité (Bache, 2015). À mesure que les facteurs de risque se manifestent, la prévalence de la maladie coronarienne dans le monde augmente également d'année en année. Les facteurs de risque associés au développement de la coronaropathie ont été établis par des recherches épidémiologiques approfondies et ce sont le diabète, l'hypertension, le tabagisme, l'hyperlipidémie, l'obésité, l'homocystinurie et le stress (Malakar et al., 2019). La coronaropathie désigne le rétrécissement ou l'obstruction des artères coronaires, généralement causés par l'athérosclérose. L'athérosclérose est l'accumulation de plaques sur les parois




Figure 1.3 Les artères coronaires. Tirée de Citadelle. (s.d.).  
 Mieux comprendre la maladie coronarienne. Citadelle.  
 Récupéré le 1er décembre 2023, de  
<https://www.citadelle.be/Services/Services-medicaux/Cardiologie/La-maladie-coronarienne/Mieux-comprendre-la-maladie-coronarienne.aspx>.

internes des artères. Ces plaques sont composées de cholestérol, de substances grasses, de déchets, de calcium et de fibrine, substance qui forme des caillots. Au fur et à mesure que les plaques continuent de s'accumuler sur les parois de vos artères, celles-ci se rétrécissent et deviennent rigides. Cette maladie vasculaire est une menace pour tout le monde et son rythme de développement varie d'une personne à l'autre. Au maximum, il commence à un jeune âge. Avant l'âge de 10 ans, les artères coronaires peuvent présenter des plaques de graisse. Comme les plaques se forment sur la paroi interne, le système immunitaire les combat en envoyant des cellules sanguines attaquer le cholestérol, ce qui provoque une plus grande inflammation. Cela déclenche l'arrivée d'autres cellules dans la paroi de l'artère pour former un bouchon mou sur la

plaque. La pression sanguine peut briser ce bouchon de sorte que les plaquettes (fragments de cellules sanguines) se collent à l'endroit de la "blessure", entraînant la formation d'un caillot. Le caillot bloque la circulation sanguine vers le cœur, ce qui augmente le risque d'obstruction artérielle et de nombreuses autres complications dangereuses : une fois que les artères coronaires sont rétrécies, la quantité de sang fournie au myocarde peut être insuffisante par rapport à ses besoins. Cela augmente le risque de douleurs thoraciques (angine de poitrine) ou d'essoufflement. En outre, cette alimentation insuffisante du cœur peut endommager les impulsions électriques du cœur et entraîner des rythmes cardiaques anormaux. En cas de rupture d'une plaque de cholestérol et de caillots sanguins, un blocage complet de l'artère cardiaque peut déclencher une crise cardiaque. Une complication possible de la crise cardiaque est l'insuffisance cardiaque. C'est lorsque le cœur devient trop faible pour pomper suffisamment de sang pour satisfaire les besoins de votre corps.

#### **1.1.4 Les interventions coronariennes percutanées (ICP)**

Afin de diagnostiquer la maladie coronarienne, le cardiologue commence par analyser les symptômes, passe en revue les antécédents médicaux du patient et ses facteurs de risque, puis il effectue quelques tests physiques. Plusieurs options thérapeutiques ont été développées pour traiter les pathologies des artères coronaires : des analyses de sang, un électrocardiogramme (ECG), des tests d'effort, imagerie nucléaire et angiographie. Tous ces tests fournissent des informations importantes sur l'état du système cardiovasculaire. Cependant, ces données demeurent insuffisantes dans quelques situations, donc les cardiologues recourent aux ICP, appelées aussi cathétérisme cardiaque. Au cours des ICP, un tube long et étroit appelé cathéter est inséré dans une gaine d'introduction en plastique (un tube court et creux qui est inséré dans un vaisseau sanguin du bras ou de la jambe du patient). Le cathéter est guidé dans le vaisseau sanguin jusqu'aux artères coronaires à l'aide d'un appareil à rayons X spécial (Figure 1.4). Un produit de contraste est injecté par le cathéter et des films radiographiques sont créés lorsque le produit de contraste se déplace dans les chambres, les valves et les principaux vaisseaux du cœur. Cette partie de l'intervention s'appelle une coronarographie (ou angiographie coronaire). Les

photographies numériques du produit de contraste sont utilisées pour : évaluer ou confirmer la présence du rétrécissement ou de l'obstruction de l'artère coronaire, évaluer la fonction des AC et déterminer la nécessité d'un traitement supplémentaire (tel qu'une procédure interventionnelle ou un pontage aorto-coronarien).

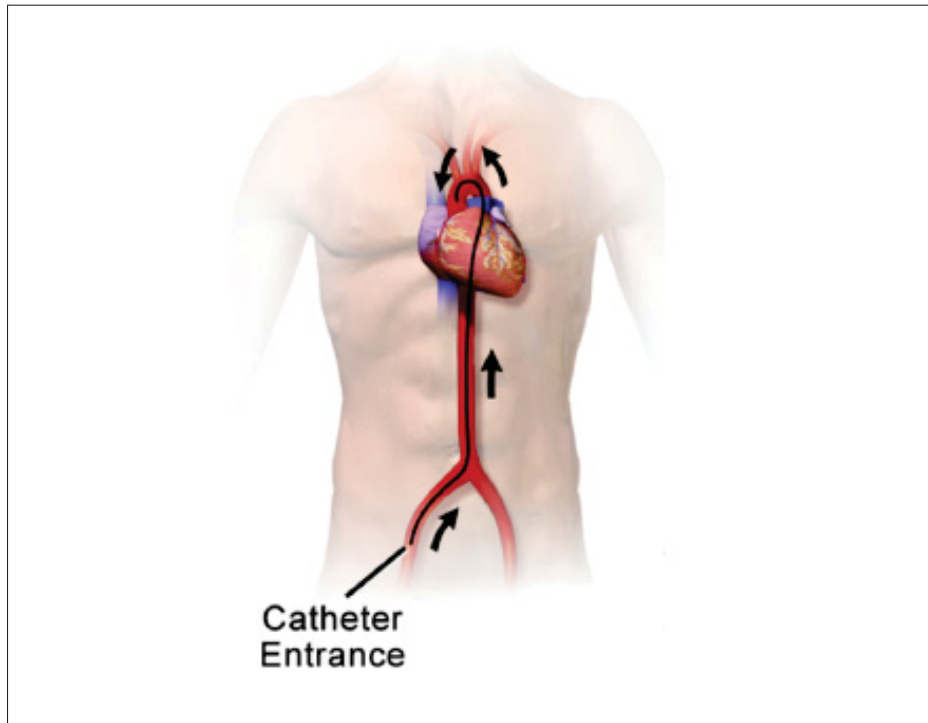


Figure 1.4 Intervention percutanée par cathéter : le cathéter (le tube noir) est inséré à partir d'un vaisseau sanguin dans l'aïne et est avancé dans le cœur. Image adaptée de "Cathéter à bout ballonnet" utilisée sous licence Creative Commons par Bruce Blaus (BruceBlaus (2016)).

### 1.1.5 Les angiogrammes des artères coronaires

Pendant les ICP, les angiogrammes des artères coronaires se distinguent comme la modalité d'imagerie privilégiée pour l'observation et l'évaluation précise de la morphologie des artères coronaires (AC), comme souligné par Liskowski et al. (2016). Grâce à des images radiologiques détaillées en temps réel, ces angiogrammes offrent une représentation visuelle claire de la localisation des AC, de leurs variations anatomiques, ainsi que du degré et de l'étendue des

lésions obstructives. Cette clarté visuelle facilite la détection rapide d'éventuelles anomalies susceptibles d'influencer la circulation sanguine vers le cœur. En tant que modalité invasive, les angiogrammes jouent un rôle essentiel en fournissant un diagnostic précis et en guidant les cardiologues tout au long des ICP, contribuant ainsi de manière cruciale à la prévention des risques cardiovasculaires et à la prise en charge des patients atteints de troubles cardiovasculaires. Ces images jouent un rôle proactif en aidant les médecins à anticiper les risques potentiels, à choisir des interventions appropriées et à déterminer le traitement le plus adapté à des stades avancés, renforçant ainsi les soins personnalisés et la gestion efficace des pathologies cardiovasculaires.



## **CHAPITRE 2**

### **REVUE DE LITTÉRATURE**

L'histoire de l'apprentissage profond remonte aux années 1940, lorsque McCulloch et Pitts décidèrent d'imiter le cerveau humain (Piccinini, 2004). Dans les années 1970 et 1980, des formes modernes de réseaux de neurones artificiels ont commencé à être utilisées. La puissance de calcul accrue et l'existence de grandes quantités de données ont permis aux ordinateurs de progresser dans la compréhension et l'interprétation du contenu visuel, d'une manière qui évoque des similitudes avec la capacité humaine. Celles-ci ont ouvert la voie à de nombreuses applications passionnantes dans des domaines tels que la médecine, l'industrie automobile, l'agriculture et la sécurité.

Cette revue donne un aperçu des techniques d'apprentissage profond pour segmenter les artères coronaires à partir d'angiogrammes. La première section décrit les concepts de base de l'apprentissage profond. La deuxième partie offre un aperçu de la technique des CNN pour la segmentation d'image. Enfin, la troisième partie se penche sur les méthodes de segmentation vasculaire.

#### **2.1 Concepts de base de l'apprentissage profond**

L'apprentissage profond est un ensemble de techniques basées sur des réseaux neuronaux artificiels inspirés du fonctionnement des neurones biologiques du cerveau humain. Les neurones biologiques sont équipés d'un groupe de dendrites d'entrée qui reçoivent des signaux électriques. Lorsque ces signaux dépassent un certain seuil, le neurone se déclenche et le signal est transmis le long de son axone, qui se connecte aux autres neurones via des dendrites. En apprentissage profond, le neurone est symbolisé par un perceptron. Ce perceptron reçoit des entrées  $x_i$ , il les associe à des poids  $w_i$  et ajoute un biais  $b$ . La somme de ces entrées pondérées et la valeur du biais  $b$  sont transmises à la fonction d'activation afin d'obtenir la sortie du neurone. L'objectif de la fonction d'activation est de briser la linéarité en transformant l'entrée linéaire en une sortie non linéaire. Plusieurs fonctions d'activation sont utilisées dans les modèles d'apprentissage profond (tableau 2.1).

Tableau 2.1 Exemples de fonctions d'activation

Fonction d'activation	Formule mathématique	Utilisation
Sigmoid	$\sigma(x) = \frac{1}{1+e^{-x}}$	Utilisée comme couche de sortie pour la classification binaire. Plage de sortie : (0, 1)
tanh	$\tanh(x) = \frac{2}{1+e^{-2x}} - 1 = 2\sigma(2x) - 1$	Utilisée pour les LSTM pour les données continues. Plage de sortie : (-1, 1)
ReLU	$f(x) = \max(0, x)$	Couramment utilisée pour les CNN, les machines de Boltzmann restreintes (MBR) et les réseaux multiperceptrons. Plage de sortie : [0, +∞)
Leaky ReLU	$f(x) = \begin{cases} x & \text{si } x > 0 \\ \alpha x & \text{si } x \leq 0 \end{cases}$	Version améliorée de la fonction ReLU qui inclut une variante pour les nombres négatifs, de sorte que les neurones ne meurent jamais. Plage de sortie : (-∞, +∞)
Softmax	$\sigma(z)_j = \frac{e^{z_j}}{\sum_{n=1}^N e^{z_n}}$	Utilisée pour les problèmes de classification multiclasse en couche de sortie pour prédire la distribution de probabilité. Plage de sortie : (-∞, +∞)

Dans un réseau neuronal artificiel, les perceptrons sont connectés entre eux pour reproduire un comportement similaire, tout comme les vrais neurones humains. Ces réseaux sont représentés comme des systèmes neuronaux interconnectés qui s'envoient des messages.

### 2.1.1 L'algorithme de propagation avant

Les neurones simples sont assemblés pour former un réseau plus profond et plus complexe, le réseau neuronal profond de propagation avant connu "FeedForward". Comme son nom l'indique, dans ces réseaux l'information circule des unités d'entrée à la couche suivante d'unités et jusqu'à la couche de sortie. La sortie de chaque couche est simultanément l'entrée de la couche suivante. Des poids différents sont associés à toutes ces connexions (figure 2.1). Il existe trois types de couches dans un réseau neuronal feed-forward : la couche d'entrée, les couches cachées et la couche de sortie. La couche d'entrée, qui reçoit les données de la base de données et les transmet

au réseau, constitue la première étape du processus. Les couches cachées, qui ne sont pas directement liées au monde extérieur, représentent la profondeur de l'algorithme. Elles traitent progressivement les données pour reconnaître des caractéristiques de plus en plus complexes. En augmentant le nombre de couches cachées, le réseau devient plus profond, ce qui lui permet de reconnaître des motifs plus complexes. Enfin, la couche de sortie produit la réponse finale du modèle, une fois que les données ont traversé l'ensemble du réseau.




Figure 2.1 Le réseau de propagation avant. Image tirée de Databricks. (s.d.). Réseau de neurones. Databricks. Récupéré le 1er décembre 2023, de <https://www.databricks.com/fr/glossary/neural-network>.

### 2.1.2 L'algorithme de rétropropagation

L'idée principale des réseaux neuronaux artificiels est d'attribuer les bons poids aux différentes connexions de manière à ce que : à partir d'un ensemble d'entrées, le réseau neuronal produise les réponses correctes. En fait, l'entraînement d'un réseau neuronal implique l'ajustement de tous ces poids, ce qui est fait par l'algorithme de rétropropagation. Cet algorithme est appelé ainsi parce que, après avoir parcouru un chemin comme expliqué dans le réseau neuronal feed-forward,

l'erreur est propagée de la sortie vers l'entrée en ajustant les poids et les biais. Au début de l'entraînement, tous les poids sont initialisés de manière aléatoire et la sortie du réseau neuronal feed-forward est probablement absurde. L'algorithme de rétropropagation parcourt le réseau et ajuste tous les poids afin que le modèle produise un meilleur résultat lors de l'itération suivante. Une fonction de perte  $L$  est calculée pour connaître l'écart entre les sorties. Il existe différentes fonctions de perte utilisées pour calculer l'erreur entre la sortie souhaitée et la sortie prévue, en fonction de l'objectif du modèle. L'une des fonctions de perte les plus utilisées est l'erreur quadratique moyenne (EQM), qui se présente sous la forme suivante :

$$EQM = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.1)$$

Où  $n$  est le nombre total d'observations dans l'ensemble de données,  $y_i$  est la valeur réelle de la  $i$ -ème observation et  $\hat{y}_i$  est la valeur prédite par le modèle pour la  $i$ -ème observation. L'algorithme de rétropropagation calcule les dérivées partielles  $\frac{\partial L}{\partial w}$  et  $\frac{\partial L}{\partial b}$  de la fonction de perte  $L$  par rapport à n'importe quel poids  $w$  ou biais  $b$  dans le réseau. Il utilise ensuite cette erreur pour revenir dans le réseau en ajustant les poids par descente de gradient afin de minimiser l'erreur. Les nouveaux poids et biais seront mis à jour comme suit :

$$w = w - \alpha \partial L / \partial w \quad (2.2)$$

$$b = b - \alpha \partial L / \partial b \quad (2.3)$$

où  $\alpha$  est le taux d'apprentissage (Héritier Nephtali 2021).

## 2.2 Les réseaux de neurones convolutifs (CNN)

Les CNN s'inspirent du cortex visuel. Ceux-ci se sont révélés très efficaces dans le domaine de la vision par l'ordinateur, car ils extraient automatiquement les caractéristiques des images. L'idée derrière les CNN est de remplacer la multiplication matricielle dans les réseaux de neurones par des opérations de convolution. Contrairement aux réseaux de neurones traditionnels, où chaque

élément de la matrice de poids n'est utilisé qu'une seule fois, les CNN utilisent les mêmes paramètres pour plusieurs fonctions du modèle. La tâche principale des CNN est d'extraire des caractéristiques des images. L'architecture du réseau neuronal convolutif se compose de quatre couches :

- **La couche convolutive** : qui constitue au moins la première couche d'un CNN. Elle détecte la présence de caractéristiques dans l'image d'entrée moyennant l'opération de convolution présentée dans la figure 2.3. Le filtre couvre l'image dans l'espace afin de calculer le produit de points. La convolution de l'image par les K filtres est calculée comme le montre la figure 2.2. Nous appliquons les K filtres sur l'image et nous obtenons comme résultat K cartes d'activation distinctes. Ces filtres sont ensuite empilés pour obtenir l'image de sortie.




Figure 2.2 L'opération de convolution. Tirée de IndoML. (2018). Notes d'étudiant : Introduction aux réseaux neuronaux convolutifs (CNN). IndoML. Récupéré le 1er décembre 2023, de <https://indoml.com/2018/03/07/student-notes-convolutional-neural-networks-cnn-introduction/>.

Il faut définir des hyperparamètres : K est le nombre de filtres, F est la taille du filtre, S est le pas (le pas par lequel le filtre est déplacé sur l'image) et P est la quantité de zéro padding (les étapes utilisées pour faire glisser le filtre sur l'image).

- **La couche de pooling** : généralement placée entre deux couches convolutives. Elle assure un sous-échantillonnage pour réduire la taille de l'image et faciliter sa gestion généralement via

un filtre (2x2) et de pas de 2. Il existe principalement deux opérations de sous-échantillonnage couramment déployées dans les réseaux convolutifs : le pooling maximum (max-pooling) et le pooling moyen (average-pooling). Pour la couche de pooling maximum, elle divise une carte de caractéristiques (features map) en régions qui ne se chevauchent pas (généralement 2x2 ou 3x3) et extrait la valeur maximale de chaque région. Cette opération permet de réduire la taille de la carte des caractéristiques tout en préservant les caractéristiques les plus importantes. Le pooling moyen fonctionne de la même manière que le pooling maximum, mais calcule la valeur moyenne au lieu de la valeur maximale pour chaque région (figure 2.3). Le pooling moyen réduit également la taille des cartes de caractéristiques, mais est généralement moins utilisé en vision par ordinateur que Max Pooling.

- **Les couches entièrement connectées** : souvent désignées par l'acronyme FC (Fully Connected), représentent un élément clé de l'architecture des réseaux de neurones, notamment des CNN. Ceux-ci sont généralement situés à l'extrémité du réseau et sont responsables des tâches de classification. Chaque neurone d'une couche entièrement connectée est connecté à chaque neurone de la couche précédente, créant ainsi une interconnexion globale. Ces couches agissent comme des classificateurs, convertissant les caractéristiques extraites des couches convolutives en sorties représentant les probabilités des entrées appartenant à différentes classes. Une fonction d'activation, telle qu'une fonction softmax, est utilisée pour normaliser ces probabilités et obtenir une distribution de probabilité entre les classes.

### 2.3 La segmentation sémantique des images par CNNs

La segmentation sémantique est un domaine important en vision par ordinateur qui vise à attribuer une catégorie sémantique à chaque pixel d'une image. Fondamentalement, cela consiste à diviser une image en différentes régions et à attribuer chacune à une classe ou une catégorie spécifique. Cette approche permet de comprendre la composition d'une image en détail, d'identifier et de représenter avec exactitude les objets qui composent l'image et de fournir une représentation structurée des informations visuelles. Au cœur de ces tâches se trouve la nécessité d'effectuer cette segmentation automatique à l'aide d'algorithmes avancés et de réseaux de neurones. Ce

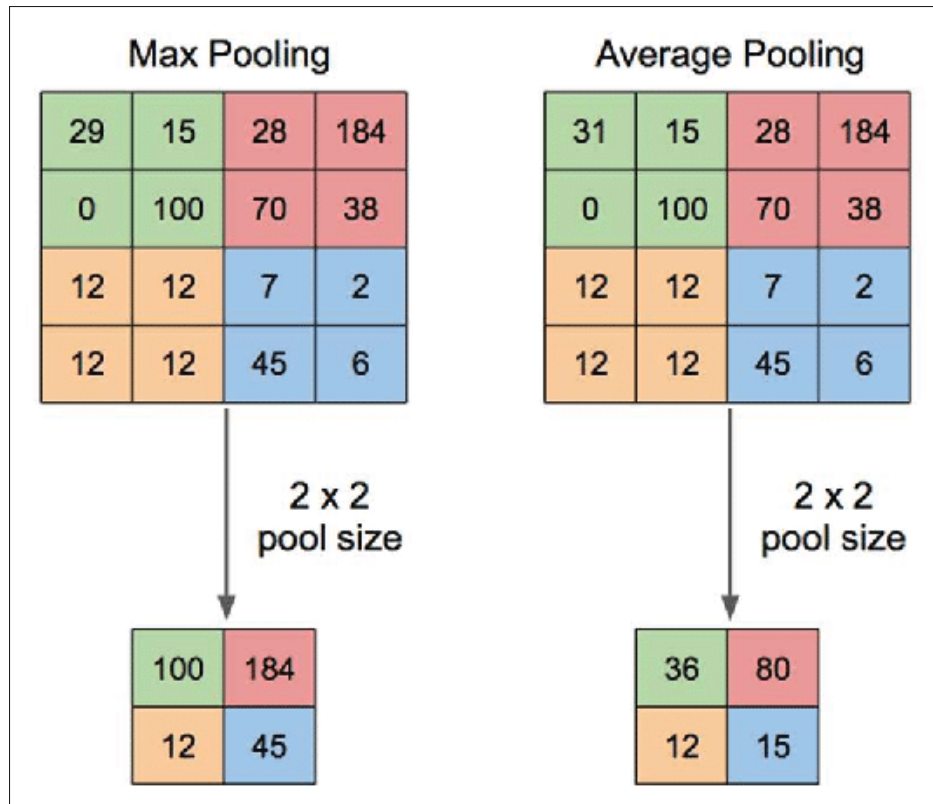


Figure 2.3 Les opérations de pooling maximum et le pooling moyen. Tirée de ResearchGate. (s.d.). Illustration de Max Pooling et Average Pooling. ResearchGate. Récupéré le 1er décembre 2023, de [https://www.researchgate.net/figure/Illustration-of-Max-Pooling-and-Average-Pooling-Figure-2-above-shows-an-example-of-max\\_fig2\\_33593451](https://www.researchgate.net/figure/Illustration-of-Max-Pooling-and-Average-Pooling-Figure-2-above-shows-an-example-of-max_fig2_33593451).

paragraphe passe en revue les concepts, les techniques, et les métriques d'évaluation de la segmentation sémantique et fournit un aperçu complet du modèle U-Net.

### 2.3.1 Principes des tâches de segmentation sémantique

Comme indiqué au début de la section 2.3, la segmentation est l'association d'une classe à chaque pixel présent dans l'image. Cette tâche peut être binaire ou chaque pixel se voit attribuer l'une des deux catégories suivantes : premier plan ou arrière-plan, ou bien peut s'étendre sur plusieurs classes. Généralement la segmentation sémantique se fait par les CNN qui sont spécialement.

conçus pour extraire des caractéristiques visuelles de haut niveau et effectuer une classification par pixel. Ces réseaux sont formés sur de grandes quantités de données annotées, étiquetant chaque pixel de l'image avec sa classe sémantique correspondante. Une fois le modèle entraîné, il peut être utilisé pour segmenter automatiquement de nouvelles images en attribuant une classe sémantique à chaque pixel.

### 2.3.2 Les métriques d'évaluation pour la segmentation sémantique

#### 2.3.2.1 Indice de Jaccard

L'indice de Jaccard appelé aussi MIoU (Mean Intersection over Union) est une métrique de similarité largement utilisée dans la littérature scientifique et les compétitions pour évaluer les performances d'une segmentation (Garcia-Garcia, Orts-Escolano, Oprea, Villena-Martinez, Garcia-Rodriguez, 2017). Cet indice est particulièrement utile pour comparer les similitudes entre deux images. Il est calculé en divisant la taille d'intersection de deux ensembles A et B par la taille de leur union. Mathématiquement, cela s'exprime comme suit :

$$MIoU(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (2.4)$$

Cet indice est la somme des éléments couverts par les deux ensembles. Pour évaluer une segmentation, il mesure la similitude entre les zones segmentées par le modèle et les zones réelles. À mesure que le MIoU se rapproche de 1, la segmentation devient de plus en plus précise et fidèle à la réalité.

#### 2.3.2.2 Le coefficient de Dice

Le coefficient de similarité Dice est une mesure couramment utilisée lors de l'évaluation de la segmentation d'images médicales et d'autres tâches de segmentation. Ce coefficient mesure la similarité entre la segmentation prédite par le modèle et la vérité terrain. Mathématiquement,

cela s'exprime comme suit :

$$Dice(A, B) = \frac{2 \cdot |A \cap B|}{|A| + |B|} \quad (2.5)$$

Un coefficient de Dice égal à 1 indique une correspondance parfaite entre la segmentation et la vérité terrain, et un coefficient de 0 signifie qu'il n'y a aucune similitude entre les deux ensembles.

En comparant ces deux métriques, le coefficient de Jaccard a une tendance plus prononcée à pénaliser les prédictions inexactes par rapport au coefficient de Dice. Cette différence entre ces deux métriques est illustrée par la figure 2.4.

Dans notre projet, la sélection de la métrique d'évaluation est d'une importance primordiale,




Figure 2.4 La différence entre le coefficient Dice (DSC) et l'indice de Jaccard (J).

en particulier compte tenu du contexte médical où une segmentation précise est exigée pour les applications diagnostiques et thérapeutiques. Dans le cas spécifique de la segmentation des vaisseaux, il est courant de choisir le coefficient Dice.

### 2.3.3 U-Net

U-Net comprend deux chemins, à savoir un chemin de contraction et un chemin d'expansion à peu près symétriques qui se rejoignent pour former une forme en « U », comme le montre la figure 2.5. La voie contractante adhère à la structure standard d'un réseau convolutionnel, impliquant l'utilisation répétitive de deux convolutions 2x2 (sans rembourrage). Le terme "rembourrage" (padding en anglais) dans le contexte des réseaux convolutionnels fait référence à l'ajout de pixels supplémentaires autour de l'image d'entrée avant de la soumettre à une opération de

convolution. Dans notre cas, il est mentionné "sans rembourrage", ce qui signifie que lors de l'application des convolutions 2x2, aucune ligne ou colonne supplémentaire de pixels n'est ajoutée autour de l'image.

Ensuite, une unité linéaire rectifiée (ReLU) et une opération de pooling max 2x2 avec un pas de 2 sont utilisées pour le sous-échantillonnage. Le chemin expansif, quant à lui, comprend un sous-échantillonnage de la carte de caractéristiques suivi d'une convolution 2x2, ce qui réduit le nombre de canaux de caractéristiques de moitié. Les deux cartes de caractéristiques, celle du chemin de contraction et du chemin d'expansion seront fusionnés ensuite. En outre, deux convolutions 2x2 sont utilisées, chacune suivie d'une ReLU. Pour compenser la perte de pixels de bordure pendant les convolutions, l'étape de recadrage est nécessaire, une convolution 1x1 est utilisée à la nième couche pour cartographier chaque vecteur de caractéristiques à 64 composantes au nombre de classes souhaité. Dans l'ensemble, le réseau comprend un total de 23 couches de convolution (Ronneberger, Fischer, Brox, 2015). La principale force de l'architecture U-Net réside dans sa capacité à diffuser des informations contextuelles à travers le réseau. La voie contractante capture des caractéristiques de l'image à différentes échelles en réduisant progressivement la résolution spatiale. Ensuite, la voie d'expansion utilise ces caractéristiques pour reconstruire l'image en augmentant la résolution spatiale. En d'autres termes, lors du processus de segmentation, le modèle peut prendre en compte le contexte environnant de la région segmentée, ce qui améliore considérablement la qualité de la segmentation. De plus, U-Net se distingue par sa capacité à effectuer des tâches de segmentation tout en créant des masques de segmentation très précis, même lorsque des données annotées limitées sont disponibles.

## **2.4 La segmentation des vaisseaux**

La segmentation des vaisseaux dans le cadre de l'imagerie médicale est une condition préalable au diagnostic précis des maladies vasculaires. Les résultats de la segmentation peuvent être utilisés pour obtenir d'autres informations de diagnostic telles que : la localisation d'anomalies comme les sténoses, la mesure du volume tissulaire, la simulation de chirurgie virtuelle, la navigation peropératoire. C'est donc un sujet de grand intérêt pour la recherche médicale, comme




Figure 2.5 L'architecture U-Net. Tirée de Ronneberger, O., Fischer, P., Brox, T. (2015).

en témoigne le grand nombre d'articles publiés chaque année dans ce domaine. En effet, la littérature sur la segmentation des vaisseaux est déjà abondante, et diverses revues d'algorithmes de segmentation des vaisseaux ont été publiées ces dernières années. Kirbas et Quek ont passé en revue pour la première fois les techniques d'extraction de vaisseaux en fonction de différentes catégories mathématiques (Kirbas & Quek, 2004). Par la suite, Lesage et al. passent en revue la littérature de pointe sur la segmentation vasculaire, en mettant particulièrement l'accent sur les modalités d'imagerie en 3D avec contraste (MRA et CTA) (Lesage, Angelini, Bloch, Funka-Lea, 2009). Les deux livres sont des références importantes pour les débutants qui se lancent dans la segmentation des vaisseaux. Puis Bibiloni et al. ont étudié la segmentation d'objets curvilignes, y compris les vaisseaux sanguins, et d'autres structures linéaires minces et longues (Bibiloni, González-Hidalgo, Massanet, 2016). Les revues de la littérature susmentionnées ont principalement examiné les méthodes basées sur des règles présumées intuitivement et minutieusement conçues par des experts. En d'autres termes, ces méthodes de segmentation sont basées sur l'expérience humaine plutôt que des machines. Avec de forts développements dans ce domaine, de nouvelles revues sont nécessaires pour analyser et résumer l'état actuel de l'art.

Cette revue a pour but d'analyser un large éventail des techniques de segmentation des vaisseaux les plus récentes et les plus innovantes trouvées dans la littérature. En effet, cette section présente l'état de l'art des approches basées sur l'apprentissage automatique en les divisant en deux catégories : les méthodes de segmentation des vaisseaux basées sur des techniques classiques d'apprentissage automatique (section 2.4.1) et celles basées sur l'apprentissage profond (section 2.4.2).

## **2.4.1 Les méthodes classiques d'apprentissage automatique**

### **2.4.1.1 Les forêts aléatoires**

Les forêts aléatoires (FA) ou forêts de décision aléatoire sont une technique d'apprentissage automatique utilisée pour créer des modèles en combinant des décisions à partir d'un ensemble de modèles de base pour produire de meilleurs résultats prédictifs. Il s'agit de construire une forêt entière d'arbres de décision aléatoires non corrélés pour trouver la meilleure réponse possible. Ces méthodes, souvent appelées agrégation bootstrap ou bagging, sont utilisées pour surmonter le problème de compromis biais-variance. Les algorithmes de FA sont faciles à utiliser et ne nécessitent que trois hyperparamètres : le nombre d'arbres, le nombre de caractéristiques utilisées dans les arbres et le taux d'échantillonnage d'ensachage. De plus, bien que la stabilité des résultats soit élevée, son traitement interne s'apparente à une boîte noire comme l'apprentissage en profondeur. (Sankaran et al., 2016) utilisent les FA pour mesurer le diamètre des artères coronaires à partir des tomographies. Les propriétés en aval et en amont du système vasculaire coronarien permettent de détecter la sténose et d'en évaluer le degré. De même, les FA sont utilisés pour segmenter les structures tortueuses (Annunziata, Kheirkhah, Hamrah, Trucco, 2015). Pour détecter ces structures, ils ont conçu un filtre type gaussien appelé "bank filter". Généralement, FA a des performances comparables à l'algorithme Support Vector Machine (SVM) avec un coût de calcul plus faible. Aslani et Sarnel ont déployé l'algorithme de FA pour la segmentation des vaisseaux en utilisant des caractéristiques pour sa supériorité en termes de vitesse, de simplicité et de fusion d'informations (Aslani, Sarnel, 2016). L'utilisation

de ces caractéristiques a amélioré la distinction entre les pixels de vaisseaux et les pixels de non-vaisseaux.

Il va sans dire que la majorité écrasante des approches de segmentation des vaisseaux basées sur les forêts aléatoires nécessitent l'extraction manuelle de caractéristiques, ce qui demande beaucoup du temps et rend la méthode dépendante de l'observateur. Beaucoup de chercheurs ont abordé ce problème en introduisant les techniques de l'apprentissage automatique avancé comme le deep learning. En effet, les réseaux de neurones sont des extracteurs de caractéristiques entraînaibles, capables à apprendre automatiquement des caractéristiques à partir des images.

#### **2.4.1.2 Champ aléatoire de Markov**

Une autre méthode de segmentation qui utilise les principes traditionnels de l'apprentissage automatique est le champ aléatoire de Markov (CAM). CAM lui-même est un modèle probabiliste conditionnel, où la probabilité d'un pixel est affectée par ses voisins. C'est un moyen puissant de connecter la continuité spatiale grâce à des informations contextuelles. Par conséquent, il fournit des informations utiles pour la segmentation. Un bref résumé de la CAM est bien décrit dans (Ibragimov Xing, 2017). Soit  $V$  l'ensemble des nœuds et  $E$  l'ensemble des arêtes donc selon la formulation CAM, l'image cible peut être représentée sous la forme d'un graphe  $G = V, E$ . Les sommets de  $G$  représentent les pixels de l'image et les bords entre deux sommets indiquent que les pixels correspondants sont adjacents. Pour chaque objet  $S$  de l'image, chaque sommet se voit attribuer une étiquette de 1 s'il appartient à  $S$  et une étiquette de 0 s'il n'en fait pas partie. Ensuite, l'étiquette de pixel est finalement déterminée par la similarité (c'est-à-dire la probabilité  $P$ ) avec l'objet  $S$  et la similarité de chaque voisin avec l'objet  $S$ . Un des premiers travaux de segmentation basé sur des algorithmes de CAM est (Held et al., 1997) qui a porté sur la distribution non paramétrique des signaux d'intensité tissulaire, de corrélation de proximité et d'hétérogénéité sur l'Imagerie par résonance magnétique (IRM). Ils ont réussi à segmenter les images IRM simulées en tenant compte du bruit, de l'inhomogénéité, du lissage et de la méthode d'optimisation. En effet, le taux d'erreur obtenu dans la plupart des cas était inférieur à 0.1 %.

### 2.4.1.3 Kernel support vector machine

Un SVM, ou Machine à Vecteurs de Support, constitue un modèle d'apprentissage automatique supervisé visant à définir un hyperplan optimal pour discriminer les données en classes distinctes. L'hyperplan est choisi de manière à maximiser la marge entre les différentes classes, cette dernière étant définie comme la distance entre les points les plus proches de chaque classe et l'hyperplan. En d'autres termes, le SVM s'efforce de trouver la meilleure séparation linéaire entre les classes en maximisant la distance entre les exemples les plus proches de chaque classe. Ces exemples les plus proches sont spécifiquement appelés les vecteurs de support, d'où l'appellation "Machine à Vecteurs de Support". Lorsque les données ne sont pas linéairement séparables, les SVM peuvent recourir à des noyaux (kernels) pour projeter les données dans un espace de dimension supérieure, où une séparation linéaire devient réalisable. Les SVM à noyau constituent des méthodes d'apprentissage automatique efficaces, particulièrement adaptées à l'imagerie médicale où les bases de données peuvent être de petite taille.

(Rodrigues et al., 2013) ont présenté une approche de segmentation des vaisseaux rétiniens à partir d'images de tomographie par cohérence optique (TCO). Cette méthode, à vecteurs de support (SVM) avec le noyau gaussien, montre des performances élevées dans la segmentation des vaisseaux sains ainsi que des vaisseaux pathologiques. (Agurto et al., 2015) ont détecté la néovascularisation dans les disques optiques par une méthode multiéchelle combinant le SVM et la technique de filtrage de marche.

### 2.4.1.4 Autres méthodes classiques

(Zheng et al., 2011) ont utilisé des arbres de stimulation probabilistes pour segmenter les artères coronaires à partir des images de Tomographie assistée par ordinateur. Les caractéristiques géométriques sont utilisées pour décrire les positions des voxels d'image dans un système de coordonnées orienté noyau. De plus, les caractéristiques orientables de l'image sont incluses dans la phase d'amplification, en tenant compte des informations d'intensité et de gradient de l'image. Pour résoudre le problème de la grande variation d'intensité entre les petits et les grands vaisseaux, Buiyan et al. proposent une méthode de segmentation des vaisseaux

basée sur la détection des arêtes. Pour localiser les bords des vaisseaux, cette méthode utilise l'algorithme Adaptive Region Growing (ARG). Cette méthode commence par identifier les bords des vaisseaux à l'aide de points de semences. Ensuite, les bords parallèles sont localisés en fonction de la direction du gradient et de la position des pixels dans chaque zone. Ceux-ci sont considérés comme des vaisseaux primaires. Ensuite, les vaisseaux sanguins sont identifiés en cartographiant l'image rétinienne initiale en fonction des positions des pixels de l'image de gradient segmenté. Cette méthode est fortement dépendante au choix des points de semence, ce qui peut entraîner une segmentation incorrecte ou incomplète de l'image. Cela rend plus difficile son déploiement dans les ICP (Bhuiyan, Nath, Chua, 2007). Fazlali et al. emploient les superpixels pour segmenter les AC. Un superpixel est une région homogène et compacte d'une image, généralement composée de plusieurs pixels adjacents ayant des attributs similaires tels que la couleur, la texture ou la luminosité. Ils ont utilisé un renforcement du contraste, une analyse de la matrice de Hessian et un lissage guidé pour prétraiter les angiogrammes coronaires. Pour commencer, trois échelles de superpixels distinctes sont utilisées pour calculer la probabilité de vaisseau pour chaque superpixel. Une carte de segmentation initiale est ensuite créée en utilisant un vote majoritaire à partir de ces échelles de superpixels différentes. Enfin, la ligne orthogonale sur chaque pixel de crête de la région du vaisseau est trouvée pour affiner cette première segmentation. Cette approche a montré une grande exactitude, mais elle a nécessité des calculs complexes (Fazlali et al., 2018). (Nock Nielsen, 2004) ont proposé pour la première fois la fusion statistique de régions en 2004. Cette méthode utilise les valeurs de gris des pixels de l'image comme modèle statistique pour déterminer la similitude des pixels adjacents. (Un super-pixel est une région compacte et perpétuellement homogène d'une image, formée en regroupant plusieurs pixels similaires. Contrairement aux pixels individuels, les super-pixels sont des unités plus grandes qui capturent les structures visuelles importantes d'une image. L'utilisation de super-pixels est courante dans le domaine de la vision par ordinateur et du traitement d'images pour simplifier la représentation des images tout en préservant les informations significatives.) Cette technique a été combinée à une méthode d'amélioration adaptative multiéchelle basée sur la méthode hessienne pour améliorer la structure complexe des artères coronaires ainsi que la délimitation des vaisseaux fins avant de les segmenter (Wan et al., 2018). Cette méthode

présente toutefois quelques inconvénients, notamment l'incapacité de détecter avec exactitude les vaisseaux fins et de segmenter les structures non vasculaires lorsqu'elles se croisent ou sont très proches d'une branche vasculaire. Quelques techniques ont été proposées pour diviser une angiographie coronaire en plusieurs couches indépendantes comme (Ricciardi et al., 2020) et (Giri et al., 2013). Ces techniques permettent de séparer les artefacts de fond de la couche de vaisseaux, mais certains artefacts subsistent, ce qui rend impossible l'utilisation de ces techniques pour différencier un cathéter d'un vaisseau.

#### **2.4.2 Les méthodes d'apprentissage profond**

À mesure que la puissance de calcul a augmenté, les réseaux de neurones profonds (RNP) ont solidement établi leur présence et ont joué un rôle prépondérant dans les domaines du traitement d'images et de l'apprentissage automatique. Les RNP permettent aux modèles de calcul composés de plusieurs couches de traitement d'apprendre des connaissances représentant des données à travers plusieurs niveaux d'abstraction (LeCun, Bengio, Hinton, 2015). Comparé aux approches classiques d'apprentissage automatique, les RNP se démarquent par leur capacité à former des modèles performants et robustes en exploitant plusieurs fonctions d'activation ainsi qu'une stratégie d'abandon, également connue sous le nom de "drop out" (Srivastava, Hinton, Krizhevsky, Sutskever, Salakhutdinov, 2014). Le "drop out" désigne une technique de régularisation où, pendant l'apprentissage, certains neurones sont aléatoirement désactivés, contribuant ainsi à prévenir le surajustement et à favoriser la généralisation du modèle.

Dans cette section, nous avons passé en revue les méthodes de segmentation des vaisseaux les plus couramment utilisées ces dernières années. Les méthodes d'apprentissage automatique sont capables de traiter une grande quantité de données, ce qui les rend plus coûteuses en termes de calcul comparé aux méthodes classiques d'apprentissage automatique. En revanche, les méthodes d'apprentissage profond, notamment les RNP, ne nécessitent pas d'extraction manuelle des caractéristiques, ce qui rend la segmentation des vaisseaux beaucoup plus précise et robuste. Parmi une variété de RNP, le type de modèle le plus performant pour l'analyse d'images est le CNN. Les CNN présentent deux avantages. Premièrement, les caractéristiques de l'image sont

appriées automatiquement au lieu d'être extraites à la main comme dans les méthodes classiques de l'apprentissage automatique. Deuxièmement, la procédure d'extraction automatique des caractéristiques avec des couches multiples est hiérarchique, de simple à complexe. C'est pourquoi les CNN ont attiré beaucoup d'attention dans de nombreuses applications, notamment dans l'analyse des images médicales. La première application des réseaux de neurones convolutifs à la segmentation des vaisseaux sanguins a été faite par (Liskowski et al., 2016). Ils ont implémenté un modèle CNN qui segmente les vaisseaux sanguins de la rétine. Depuis lors, les CNN ont été exhaustivement utilisés dans de nombreuses applications d'extraction de vaisseaux. Chu et al. (2016) proposent une nouvelle méthode de détection et de suivi des structures curvilignes (SC) dans les séquences dynamiques de rayons X. Elle encode la structure préalable de CS dans le cadre du suivi par approximation tensorielle de rang 1 et utilise également les caractéristiques hiérarchiques apprises via un réseau neuronal convolutif (CNN). (Huang et al., 2018) utilise U-Net 3D pour segmenter la lumière de l'artère coronaire avec et sans ligne médiane à partir des Coronarographies par (CT). Il s'agit d'une série de couches d'échantillons ascendantes combinées à un CNN. Cette méthode surpasse les autres méthodes évaluées par le coefficient Dice (82,91 %) et donne des résultats prometteurs pour la segmentation basée sur la ligne centrale et les images CT originales sans post-traitement. (Cui et al., 2020) ont développé une segmentation de l'artère coronaire entièrement automatisée en utilisant un algorithme croissant qui ne nécessite pas d'interaction homme-ordinateur. Les principaux apports de cette recherche peuvent être résumés de trois manières. Premièrement, la nature entièrement supervisée de l'approche neuronale, qui apprend à partir des données brutes des pixels et ne repose sur aucune connaissance a priori de la structure vasculaire (une méthode de détection des points de racine est utilisée pour remplacer les points de semence sélectionnés manuellement). Deuxièmement, une méthode de segmentation basée sur la croissance et le CNN est utilisée pour extraire des caractéristiques plus représentatives, ce qui prouve que les méthodes basées sur le CNN sont réalisables pour la segmentation d'images médicales. Troisièmement, le réseau proposé ne nécessite qu'un petit ensemble de données d'entraînement : La stratégie de croissance adoptée dans cette étude garantit que le voxel central de chaque bloc est un voxel coronaire, de sorte que nous utilisons des volumes, un nombre relativement faible de données, pour entraîner le

réseau. Dans (Compas, Syeda-Mahmood, McNeillie, Beymer 2014), on étudie les propriétés spatio-temporelles des séquences angiographiques afin de développer une méthode robuste pour segmenter automatiquement l'arbre des artères coronaires. Pour chaque segment d'artère isolé, une surface représentant la largeur de l'artère est générée en mesurant sa largeur le long du segment et en la suivant sur une période de temps dans chaque image. En identifiant le point le plus bas persistant sur cette surface, on détecte un rétrécissement de l'artère.

(Gao & Sundar 2012) modélisent le mouvement de l'artère coronaire en radiographie 2D. Cependant, leur modèle ne prend en compte que le mouvement cardiaque, et pas les déplacements cardiaques et respiratoires. De plus (Moeskops et al., 2016) ont étudié la capacité d'apprentissage par transfert d'un seul CNN dans diverses tâches de segmentation. Ils ont montré que les performances de segmentation d'un CNN formé spécifiquement pour chaque tâche étaient comparables à celles de la formation d'une combinaison de trois tâches (IRM cérébrale, IRM thoracique et CT cardiaque). Cela signifie qu'un CNN formé sur la segmentation tissulaire pourrait potentiellement être utilisé pour la segmentation de l'artère coronaire sans formation spécifique au navire. Hernandez-Vela et al., (2012), décrivent une approche de segmentation de l'angiographie par rayons X, prenant en compte l'apparence des vaisseaux dans le graphique, la continuité de l'arbre artériel et l'apparence des bords.

Nous avons élaboré un tableau complet qui vise à résumer les principales approches examinées dans les articles présentés dans cette revue de littérature. Ce tableau vise à fournir un aperçu consolidé des différentes méthodes et à mettre en évidence les principales contributions et limitations de chaque approche (voir annexe I).

Ce chapitre vise à passer en revue les algorithmes de segmentation vasculaire les plus récents et les plus innovants. Parmi les algorithmes et les approches examinés, nous avons exploré en profondeur les dernières nouveautés en matière de segmentation des vaisseaux.

## **CHAPITRE 3**

### **MÉTHODOLOGIE**

Le cœur de notre méthode repose sur une approche innovante combinant des filtres d'amélioration des vaisseaux et des techniques d'apprentissage profond pour segmenter les artères coronaires. Tout d'abord, nous déployons des filtres d'amélioration des vaisseaux pour mettre en évidence les caractéristiques de l'artère coronaire dans l'image. Ce filtrage représente une technique de prétraitement des données avancée, contribuant à affiner les contours des vaisseaux, à réduire le bruit et à optimiser la visualisation des artères, améliorant ainsi la qualité de données d'entrée pour le réseau neuronal ultérieur. Ensuite, nous effectuons la segmentation proprement dite à l'aide de techniques d'apprentissage profond, en particulier le réseau de neurones convolutifs U-Net. Notre réseau est conçu pour identifier et extraire les artères coronaires à partir de notre base de données et à l'aide d'informations extraites via des filtres d'amélioration des vaisseaux. Pour parvenir à une meilleure segmentation, notre approche s'appuie sur deux expérimentations entraînant plusieurs modèles. Bien que ces modèles aient certaines caractéristiques communes, qui sont discutées dans le paragraphe « Contexte général », leurs principales différences sont détaillées séparément dans le paragraphe « Expériences ».

#### **3.1 Contexte général**

Ce paragraphe vise à fournir un aperçu des éléments communs des différents modèles formés qui constituent l'arrière-plan des solutions de segmentation de l'artère coronaire. Dans les sous-sections suivantes, nous discutons en détail de la description des données, de l'architecture du modèle de segmentation développé, de la configuration expérimentale mise en œuvre et des métriques d'évaluation utilisées pour mesurer la performance et l'efficacité de l'approche. Ce paragraphe important fournit un cadre global pour mieux comprendre l'ensemble du processus et les décisions prises pour mener à bien la tâche de segmentation de l'artère coronaire.

### 3.1.1 Description de données

Durant cette étude, les modèles sont entraînés avec la base de données DCA1 qui est acquise auprès du service de cardiologie de l'Institut mexicain de la sécurité sociale (UMAE T1- León). Elle contient 134 images d'angiographie aux rayons X d'artères coronaires, avec les masques de segmentation validés par un cardiologue expert. Chaque angiogramme de l'ensemble de données est une image pgm (Portable gray map) en niveaux de gris, avec une résolution de 300x300 pixels. La figure 3.1 met en évidence une sélection d'images extraites de l'ensemble de données. Les données ont été divisées de manière aléatoire en données d'entraînement et données de test.

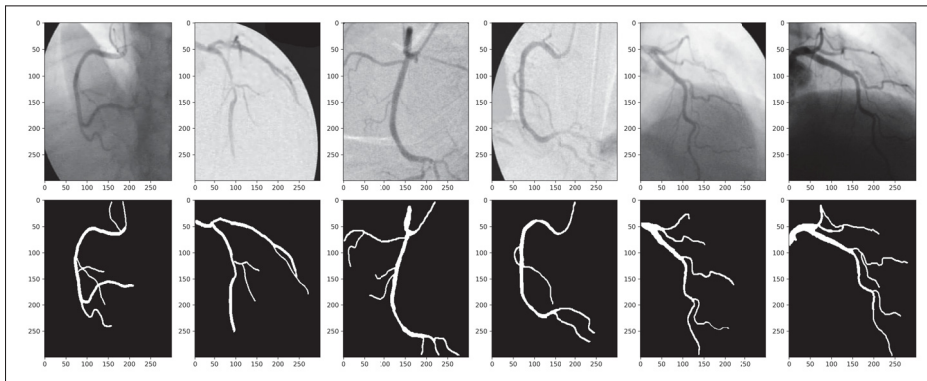


Figure 3.1 Visualisation de quelques images de la base de données DCA1.

107 angiogrammes ont été dédiés pour l'entraînement, tandis que le reste des données, soit 27 angiogrammes, ont été consacrés aux tests. Cela représente une séparation d'environ 20/80 pour l'entraînement et les tests respectivement. Les données doivent subir un prétraitement afin de standardiser certaines de leurs caractéristiques. Cela est nécessaire pour que le réseau neuronal construit ultérieurement puisse apprendre ces caractéristiques et les généraliser à de nouvelles données ayant subi le même prétraitement et possédant les mêmes caractéristiques clés. Nous avons utilisé deux types de prétraitement de données : la normalisation et l'amélioration des vaisseaux par filtrage.

### 3.1.1.1 Normalisation

Avant de soumettre les images au modèle U-Net, nous avons appliqué une étape de normalisation visant à ajuster l'échelle des valeurs dans un ensemble d'images pour garantir que les valeurs des pixels se situent dans une plage spécifique (entre 0 et 1). Cette opération a été réalisée en utilisant la fonction `normalize` de `scikit-learn` : `normalize(np.array(image_dataset), axis=1)` après avoir converti la base de données d'images en un tableau NumPy, nous avons appliqué la fonction `normalize` de `scikit-learn` pour normaliser les valeurs du tableau. L'argument `axis=1` indique que la normalisation est effectuée le long de l'axe des colonnes. Chaque pixel à travers toutes les images est normalisé indépendamment des autres pixels. Plus précisément, pour chaque pixel (ou colonne) dans chaque image, la normalisation est effectuée de manière à ce que la somme de leurs carrés soit égale à 1. Cela permet d'ajuster les valeurs des pixels tout en préservant les relations relatives entre elles. En résumé, la normalisation dans cette commande a pour objectif d'ajuster l'échelle des valeurs de chaque pixel à travers toutes les images, contribuant ainsi à une convergence plus rapide et à une meilleure performance des modèles lors de l'entraînement.

### 3.1.1.2 Amélioration des vaisseaux : Filtrage

La deuxième étape de prétraitement qu'on a utilisé est l'amélioration des vaisseaux. Dans l'angiographie par rayons X, les vaisseaux sanguins sont invisibles et l'injection d'un agent de contraste permet de visualiser les vaisseaux sanguins en absorbant les rayons X et en produisant un signal proéminent sur les images. Cependant, l'identification des artères dans ces images peut s'avérer difficile en raison de leur contraste relativement faible ou des variations des conditions d'éclairage. Pour surmonter cette limitation, notre étude s'est concentrée sur l'exploration de l'efficacité des filtres d'amélioration des vaisseaux basés sur la matrice hessienne. Le filtre hessien est une technique largement utilisée en imagerie médicale pour améliorer les structures tubulaires, y compris les vaisseaux, et pour améliorer la qualité de l'image. Il s'appuie sur le concept de la matrice hessienne qui est une matrice composée de dérivées partielles de second ordre, pour identifier les régions de l'image qui présentent d'importantes variations locales

d'intensité indiquant la présence de structures semblables à des vaisseaux. Elle est définie par :

$$H(f) = \begin{bmatrix} \frac{\partial^2 f}{\partial x^2} & \frac{\partial^2 f}{\partial x \partial y} \\ \frac{\partial^2 f}{\partial y \partial x} & \frac{\partial^2 f}{\partial y^2} \end{bmatrix} \quad (3.1)$$

Les valeurs propres et les vecteurs propres issus de la matrice hessienne fournissent une représentation concise des variations exprimées par cette matrice. Les vecteurs propres indiquent les directions principales de la courbure (associées à la matrice hessienne), tandis que les valeurs propres expriment l'intensité de la courbure dans chaque direction. En combinant ces informations, les valeurs et vecteurs propres permettent de quantifier l'orientation, le sens et l'amplitude des variations locales autour d'un point donné.

Soit  $\lambda_1, \lambda_2$  les valeurs propres et  $\mathbf{e}_1, \mathbf{e}_2$  les vecteurs propres correspondants de  $H(f)$ . En triant  $\lambda_1 \leq \lambda_2$ ,  $\mathbf{e}_1$  représente la direction le long de laquelle la seconde dérivée est maximale, c'est-à-dire la direction du vaisseau. Le vecteur propre  $\mathbf{e}_2$  correspond à la direction de la section transversale du vaisseau. Cela est appelé le modèle de tube :

- $\lambda_1 \approx 0$
- $\lambda_1 \ll \lambda_2$

Dans la direction de  $\mathbf{e}_1$  qui correspond à la direction du tube, l'intensité reste relativement constante ( $\lambda_1 \approx 0$ ). Dans le plan de la coupe transversale du tube, l'intensité décroît rapidement au fur et à mesure que l'on s'éloigne du centre du vaisseau ( $\lambda_1 \ll \lambda_2$ ).

Parmi les nombreux filtres hessiens disponibles pour la segmentation artérielle : Sato, Meijering, Hessian, Frangi, OOF, deux ressortent dans la littérature le filtre Sato et le filtre Meijering. Après avoir examiné plusieurs options, nous avons choisi cette dernière en raison de sa prévalence et de sa pertinence reconnue dans cette tâche particulière. Puis, nous avons incorporé la correction Gamma pour améliorer encore les résultats.

- **Filtre de Meijering**

(Meijering et al., 2004) ont introduit une fonction de neurones visant à améliorer la détection des structures tubulaires allongées et minces dans les images de microscopie à fluorescence à des fins de traçage des neurites. Cette méthode ne comporte pas de paramètres et repose

sur la matrice hessienne modifiée comme suit :

$$H(f) = \begin{bmatrix} h_{11} + \alpha^2 & (1 - \alpha^2)h_{12} \\ (1 - \alpha^2)h_{21} & h_{22} + \alpha^2 \end{bmatrix} \quad (3.2)$$

En général,  $\alpha$  est fixé à  $1/3$ . Les valeurs propres sont ensuite calculées, et le filtre de la tubularité est calculé comme suit :

$$F = \begin{cases} \lambda_{\max} & \text{si } \lambda_{\max} < 0 \\ \lambda_{\min} & \text{sinon} \\ 0 & \text{sinon} \end{cases}$$

où  $\lambda_{\max} = \max(\lambda_1, \lambda_2)$  est calculé à chaque pixel, et  $\lambda_{\min}$  est le minimum de tous les  $\lambda_{\max}$  de l'image.

Le filtre de Meijering joue un rôle crucial dans le processus de prétraitement des images médicales, en particulier dans le contexte de l'analyse des vaisseaux sanguins ou d'autres structures tubulaires.

- **Filtre de Sato**

(Sato et al., 1998) introduit un filtre qui vise à améliorer la visibilité des lignes dans les images en utilisant le modèle du tube. La fonction de filtrage dépend des valeurs propres de la matrice hessienne de l'image. Elle s'exprime comme suit :

$$F = \begin{cases} \lambda_1 \cdot \exp\left(-\frac{\lambda_2}{2(1+c)^2}\right) & \text{si } c \neq 0 \text{ et } \lambda_1 \geq 0 \\ c \cdot \exp\left(-\frac{\lambda_2}{2(2c)^2}\right) & \text{si } c \neq 0 \text{ et } \lambda_1 < 0 \\ 0 & \text{si } c = 0 \end{cases}$$

En disposant les valeurs propres  $\lambda_i$  telles que  $\lambda_1 \leq \lambda_2$ , (Sato et al., 1998) ont établi les paramètres  $\alpha_1$  et  $\alpha_2$  pour réguler le niveau d'asymétrie et déterminer la formulation spécifique. La fonction de filtrage  $F$  est définie en deux parties en fonction de la valeur de  $c$  et de la

première valeur propre  $\lambda_1$ . Si  $c$  est différent de zéro, la fonction utilise  $\lambda_1$  et  $\lambda_2$  pour calculer le filtre. Dans ce cas, si  $\lambda_1$  est positif, le filtre amplifie les valeurs des pixels le long des structures linéaires, ce qui renforce leur visibilité. Si  $\lambda_1$  est négatif, le filtre utilise  $c$  pour déterminer l'amplification des valeurs des pixels. Enfin, si  $c$  est nul, le filtre renvoie zéro, ce qui signifie qu'aucun renforcement n'est appliqué.

En résumé, le filtre de Sato joue un rôle crucial dans le prétraitement des images médicales en mettant en évidence les structures tubulaires, en atténuant le bruit et en facilitant la segmentation. Pour optimiser ces avantages, nous avons pris la décision d'intégrer le filtre de Sato en tant que méthode de prétraitement pour les images, avant de les soumettre à UNet. Cette approche vise à tirer pleinement parti des caractéristiques de Sato et de UNet, visant ainsi à améliorer significativement la qualité des images médicales.

Les filtres de Meijering et de Sato sont tous deux des techniques de traitement d'image utilisées dans le contexte de l'analyse d'images médicales pour la détection des structures tubulaires, notamment des vaisseaux sanguins. Bien qu'ils partagent des objectifs similaires, ils diffèrent dans leur approche et leurs caractéristiques. Le tableau 3.1 présente une comparaison entre les deux filtres.

Nous avons intégré les deux filtres pour évaluer l'efficacité de chacun de ces filtres lorsqu'ils sont appliqués individuellement en combinaison avec le modèle UNet. Dans une première expérience, nous examinerons l'impact de chaque filtre, en particulier leur capacité à améliorer la détection des structures tubulaires. Par la suite, nous explorerons également les résultats obtenus en combinant chaque filtre avec la correction gamma, avant d'appliquer le modèle UNet. Cette double approche nous permettra d'analyser de manière approfondie les contributions respectives de ces filtres à l'amélioration des performances de segmentation dans notre contexte d'imagerie médicale.

- **La correction Gamma**

Après l'application des filtres de Meijering et de Sato sur les images originales, nous avons identifié une problématique persistante liée au contraste. Soucieux d'améliorer cette caractéristique cruciale des images médicales, et inspirés par le travail de Survarachakan et al. (2021), nous avons opté pour l'intégration de la correction gamma dans notre processus

Tableau 3.1 Comparaison entre les filtres de Meijering et Sato

	Le filtre de Meijering	Le filtre de Sato
Méthode de détection	Se base sur la réponse du laplacien du gaussien pour détecter les structures tubulaires. Il met en évidence les variations d'intensité liées aux contours des vaisseaux sanguins.	Utilise l'analyse des valeurs propres de la matrice hessienne pour détecter les structures tubulaires. Il prend en compte la direction et l'intensité des gradients dans différentes directions pour identifier les structures linéaires.
Sensibilité à l'orientation	Sensible aux changements d'intensité dans toutes les directions, mais il est particulièrement adapté à la détection des structures tubulaires.	Conçu pour être sensible à des orientations spécifiques en fonction des valeurs propres de la matrice hessienne. Cela lui permet d'ajuster sa réponse en fonction de l'orientation des structures tubulaires.
Sensibilité au bruit	En incorporant un filtre gaussien, le filtre de Meijering contribue à réduire le bruit dans l'image, améliorant ainsi la qualité de la détection.	Le filtre de Sato peut être sensible au bruit, mais il peut également être adapté en ajustant ses paramètres pour améliorer sa robustesse dans des conditions bruitées.
Applicabilité	Souvent utilisé pour la détection de vaisseaux sanguins et d'autres structures tubulaires dans des images médicales.	Souvent utilisé pour la détection de vaisseaux sanguins, mais il peut être étendu à la détection d'autres structures linéaires dans des images médicales.
Paramètres	Peut être ajusté en fonction de l'écart-type du filtre gaussien pour adapter la sensibilité à différentes échelles.	Dépend de paramètres tels que la sensibilité et l'orientation, qui peuvent être ajustés pour optimiser la détection en fonction des caractéristiques spécifiques de l'image.

de traitement d'image.

La correction Gamma est une technique couramment utilisée dans le traitement des images en tant qu'étape de prétraitement. Elle consiste à ajuster les valeurs d'intensité d'une image

pour corriger la relation non linéaire entre les valeurs des pixels et la luminosité perçue. La transformation est basée sur un paramètre appelé valeur de Gamma ( $\gamma$ ), qui contrôle la forme de la courbe de transformation. La valeur Gamma est généralement comprise entre 0 et 1, les valeurs inférieures à 1 présentent un assombrissement et les valeurs supérieures à 1 présentent un éclaircissement. La formule de correction de Gamma peut s'exprimer comme suit :

$$Sortie = A \times Entre^\gamma \quad (3.3)$$

où A est une constante, l'entrée est l'image originale et la sortie est l'image corrigée en fonction du Gamma. Lorsque Gamma est inférieure à 1, la formule assombrit l'image en augmentant les valeurs d'intensité des régions sombres plus que celles des régions claires. Cela permet de révéler les détails dans les zones d'ombre. Inversement, lorsque le Gamma est supérieure à 1, la formule éclaircit l'image en augmentant les valeurs d'intensité des régions claires plus que des régions sombres.

En substance, la correction gamma agit en appliquant une transformation non linéaire aux valeurs des pixels, élevant ces valeurs à une certaine puissance. Cela permet de moduler finement la perception de la luminosité dans l'image, offrant ainsi un contrôle précis sur le contraste en influençant l'équilibre entre les zones sombres et claires.

Dans le contexte spécifique de la segmentation des artères coronaires avec U-Net, l'application de la correction gamma revêt une importance particulière. Cette technique peut jouer un rôle significatif en améliorant la visibilité des vaisseaux sanguins dans les images médicales. En ajustant la représentation des intensités lumineuses, une correction gamma appropriée optimise les données d'entrée pour le modèle U-Net, facilitant ainsi son apprentissage et potentiellement améliorant ses performances de segmentation.

En ce qui concerne l'expérience 2 de notre approche, nous avons entrepris une évaluation approfondie de l'impact de la correction gamma une fois intégrée dans le pipeline du modèle. Nous nous sommes concentrés sur la mesure des performances du modèle à segmenter les artères coronaires, en analysant comment cette technique de correction contribue à une meilleure détection et à une segmentation plus précise des structures vasculaires.

### 3.1.2 Le modèle de segmentation

#### 3.1.2.1 Architecture du modèle

Dans notre approche méthodique dédiée à la segmentation des artères coronaires à l'aide de l'architecture U-Net, décrite de manière exhaustive dans la section 2.2, nous avons consciencieusement affiné chaque aspect du modèle pour garantir une représentation robuste et précise des caractéristiques anatomiques. Initiant le processus par une configuration minutieuse, nous avons opté pour une première couche de convolution avec 16 filtres, accompagnée d'une taille de noyau de (3, 3). Cette configuration initiale vise à favoriser la capture de motifs locaux cruciaux dans les images d'angiographie. La judicieuse extension de cette configuration sur l'ensemble du modèle a impliqué une progression graduelle du nombre de filtres, renforçant ainsi la capacité du réseau à enrichir la représentation des caractéristiques complexes inhérentes aux artères coronaires. Notre méthodologie s'appuie sur l'architecture de réseau neuronal convolutif U-Net, préalablement détaillée dans la section 2.3.3. Le chemin de contraction, qui initie le traitement de l'image d'entrée (s), est composé de couches de convolution (Conv2D) avec des activations ReLU, de couches de régularisation (Dropout) pour prévenir le surajustement du modèle, et de couches de max-pooling (MaxPooling2D) pour réduire progressivement la résolution spatiale de l'image. Pour l'initialisation des filtres de convolution, la méthode "he\_normal" a été sélectionnée, contribuant ainsi à une meilleure convergence du modèle. Cette architecture génère une pyramide de caractéristiques qui capture de manière efficace les informations allant des niveaux les plus bas aux niveaux les plus élevés au fur et à mesure de la progression dans le chemin de contraction.

Le chemin d'expansion comporte des opérations de convolution transposée (Conv2DTranspose) visant à augmenter la résolution spatiale de l'image. La fusion des caractéristiques des couches correspondantes du chemin de contraction (c4, c3, c2, c1) avec celles du chemin d'expansion (u6, u7, u8, u9) est réalisée à l'aide de fonctions de concaténation (concatenate). Cette stratégie ingénieuse permet de connecter de manière cohérente les informations de bas niveau avec celles de haut niveau, favorisant des performances de segmentation optimales. Chaque composant

du modèle, des couches de convolution aux opérations de régularisation, a été soigneusement optimisé pour garantir une segmentation précise des artères coronaires. En fin de parcours, la sortie du modèle prend la forme d'un masque de segmentation, identifiant avec exactitude les artères coronaires dans l'angiographie d'entrée. Cette méthodologie complète reflète notre engagement envers la création d'un modèle U-Net parfaitement ajusté, capable de fournir des résultats de segmentation fiables et de haute qualité.

### **3.1.2.2 Les métriques d'évaluation**

Pour les problèmes de segmentation binaire, l'exactitude est la métrique la plus couramment déployée dans la littérature. Cependant, vu que l'exactitude est très sensible au déséquilibre des classes, nous avons décidé d'évaluer la performance de notre approche par plusieurs métriques d'évaluation comme : la sensibilité, la spécificité, la perte, et le coefficient Dice. Ces mesures appartiennent à l'intervalle  $[0, 1]$ . Une exactitude de 1 signifie une extraction parfaite des caractéristiques d'intérêt, et de 0 dans le cas contraire. L'exactitude de la classe moyenne fournit une mesure qui n'est pas biaisée par la différence de taille entre les classes de pixels de vaisseaux sanguins et le fond de l'image qui sont présents dans une angiographie coronaire. Le pourcentage de pixels caractéristiques correctement classés et de pixels d'arrière-plan correctement classés est mesuré respectivement par la sensibilité et la spécificité. La valeur prédictive positive correspond au pourcentage de pixels d'éléments réels classés par l'élément d'intérêt. Le coefficient de Dice mesure la similarité entre les caractéristiques d'intérêt extraites par une méthode de segmentation et la vérité de terrain, en ignorant les pixels d'arrière-plan correctement classés. Le calcul des six mesures de performance de la classification binaire nécessite d'obtenir le nombre total de pixels de caractéristiques correctement classés comme caractéristiques (TP), de pixels de caractéristiques incorrectement classés comme arrière-plan (FP), de pixels d'arrière-plan correctement classés comme arrière-plan (TN) et de pixels d'arrière-plan incorrectement classés comme caractéristiques (FN). Le tableau 3.1 récapitule les différentes métriques utilisées.

Tableau 3.2 Équations des métriques d'évaluation et leurs explications

Métrique	Équation	Explication
Score Dice	$\frac{2 \cdot TP}{2 \cdot TP + FP + FN}$	Le chevauchement des deux segmentations, divisé par la taille totale.
Exactitude	$\frac{TP + TN}{TP + TN + FP + FN}$	Le nombre de vrais positifs divisé par la somme des vrais positifs et des faux positifs.
Sensibilité	$\frac{TP}{TP + FN}$	Le nombre de vrais positifs divisé par la somme des vrais positifs et des faux négatifs.
Spécificité	$\frac{TN}{TN + FP}$	Le nombre de points de données correctement prédits parmi tous les points de données.

### 3.1.2.3 Configuration et optimisation des hyperparamètres

Nous lançons notre approche en entraînant le modèle U-Net sur les images originales, que nous avons désignées comme le modèle "Standard". Initialement, le modèle présentait des performances modestes, avec un coefficient de Dice aussi bas que 12% et un taux d'erreur dépassant les 46%. Ces résultats mettaient en évidence la nécessité cruciale d'optimiser les paramètres du modèle afin d'améliorer sa capacité de segmentation. Pour remédier à ces lacunes, nous avons entrepris une série d'expérimentations visant à explorer différentes configurations d'hyperparamètres. Parmi les ajustements cruciaux, nous avons focalisé notre attention sur plusieurs aspects clés du modèle. Tout d'abord, nous avons expérimenté différentes fonctions de loss, cherchant celle qui minimisait au mieux la disparité entre les prédictions du modèle et les annotations réelles. Cette étape s'est avérée être un élément pivot dans l'amélioration des performances de segmentation. En parallèle, nous avons ajusté le nombre d'époques d'entraînement, cherchant un équilibre entre un nombre suffisant pour permettre au modèle de converger et éviter le surapprentissage, tout en évitant des coûts computationnels excessifs. Cette approche a permis de trouver le compromis optimal pour garantir une convergence robuste. Le taux de dropout, un mécanisme régulateur crucial pour prévenir le surapprentissage en désactivant aléatoirement certains neurones lors de l'entraînement, a également été finement ajusté. Une exploration minutieuse de différentes valeurs de dropout a conduit à une configuration

optimale qui a renforcé la généralisation du modèle. De plus, le taux d'apprentissage a été ajusté de manière précise. Un taux d'apprentissage approprié est essentiel pour déterminer la taille des pas que le modèle prend lors de l'optimisation. Des ajustements itératifs ont été effectués pour converger vers une valeur qui permettait un entraînement stable et une convergence rapide. La modification des hyperparamètres s'est poursuivie de manière itérative, testant successivement différentes configurations. Chaque ajustement a généré des résultats distincts ; par exemple, le loss a varié de 46% à 6%, et le coefficient de Dice de 12% à 98%. Notre démarche visait à ajuster les hyperparamètres à chaque itération jusqu'à parvenir à des performances optimales. Les paramètres optimaux sont un taux d'apprentissage initial de 0.001, un nombre d'époques fixé à 60, et une taille de lot de 16 avec Adam comme optimiseur et l'entropie binaire croisée comme fonction de perte (binary cross-entropie).

L'entropie croisée binaire est une mesure de divergence entre les prédictions d'un modèle et les vérités de terrain, largement employée dans le contexte de la segmentation, notamment pour des tâches comme la détection des artères coronaires dans des images médicales. Cette fonction de coût est particulièrement pertinente pour des problèmes de classification binaire, où chaque pixel de l'image est associé à une étiquette binaire, généralement représentant la présence ou l'absence de la structure d'intérêt, comme les artères coronaires.

Si  $p$  représente la prédiction du modèle pour le pixel ou voxel et  $y$  est l'étiquette réelle (1 pour la présence de l'artère, 0 pour l'absence), la fonction d'entropie croisée binaire est calculée comme suit :

$$\text{Entropie\_croisée\_binaire}(p, y) = -\frac{1}{N} \sum_{i=1}^N (y_i \log(p_i) + (1 - y_i) \log(1 - p_i)) \quad (3.4)$$

L'objectif est d'ajuster les paramètres du modèle de telle manière que la divergence entre les prédictions et les vérités terrain soit minimale, favorisant une segmentation précise des artères coronaires. L'optimisation de cette entropie croisée binaire guidera le modèle UNet pour apprendre des caractéristiques permettant une segmentation robuste et précise des structures vasculaires dans les images médicales.

Afin de prévenir le surajustement du modèle, des couches de dropout ont été intégrées après

chaque couche de convolution, avec des taux spécifiques soigneusement ajustés. Les taux de dropout, tels que 0.1 et 0.2, ont été choisis pour encourager la généralisation du modèle en éliminant aléatoirement certains neurones pendant l'entraînement. Cette stratégie vise à renforcer la robustesse du modèle face à des données inconnues tout en évitant une dépendance excessive à des caractéristiques spécifiques du jeu de données d'entraînement.

En résumé, l'optimisation des paramètres a été orchestrée avec exactitude pour garantir que le modèle U-Net soit finement ajusté à la tâche complexe de segmentation des artères coronaires. Cette démarche, couvrant des ajustements essentiels tels que le taux d'apprentissage, le nombre d'époques et l'utilisation stratégique du dropout, s'est avérée cruciale pour obtenir des performances maximales dans cette tâche biomédicale spécialisée.

Les mêmes valeurs d'hyperparamètres seront conservées pour l'ensemble des modèles des expériences 1 et 2. Cette uniformité dans les paramètres d'entraînement a instauré une base équitable pour la comparaison entre les différents modèles, permettant ainsi de mettre en évidence la contribution spécifique de chaque approche de prétraitement à l'amélioration de la segmentation des artères coronaires.

## **3.2 Experimentations**

Pour garantir une meilleure segmentation, notre méthode est divisée en deux expériences distinctes.

### **3.2.1 Expérience 1 : Comparaison de différents filtres d'amélioration des vaisseaux**

La première étape vise à améliorer la qualité des images angiographiques à l'aide de filtres spéciaux qui mettent en évidence les caractéristiques de l'artère coronaire dans l'angiographie, facilitant ainsi la tâche du modèle U-Net formé au cours de la deuxième étape. Comme déjà mentionnés, nous avons utilisé des filtres Meijering et Sato. La figure 3.2 illustre l'effet de ces filtres sur les images de notre base de données. Comme l'illustre la figure 3.3, nous avons entraîné 3 modèles :

- Standard : U-Net avec les images originales en entrée.

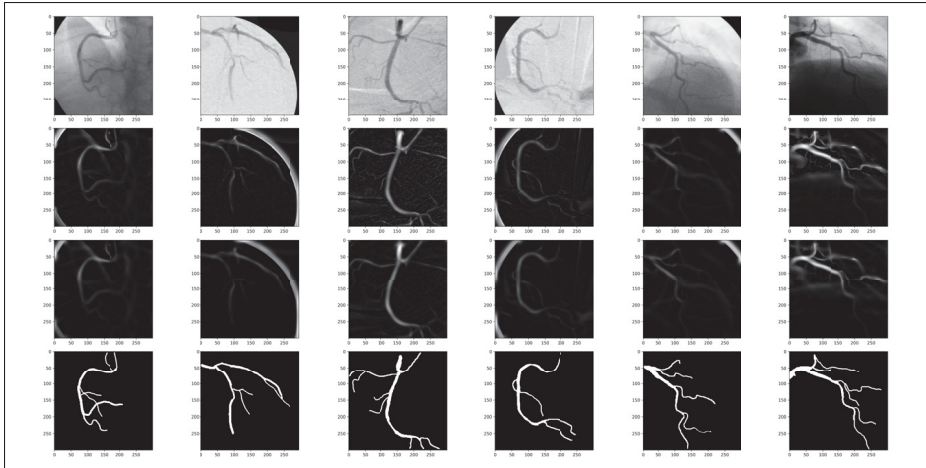


Figure 3.2 Visualisation de l'effet du filtre sur les images de DCA1.

La ligne 1, 2, 3 et 4 représentent respectivement les images originales, les images filtrées par Meijering, les images filtrées par Sato et la vérité de terrain.

- Unet-Meijering : U-Net avec les images filtrées par le filtre de Meijering en entrée.
- Unet-Sato : U-Net avec les images filtrées par le filtre de Sato en entrée.

Dans la figure 3.3, chaque flèche du diagramme symbolise un modèle particulier dans notre approche. Démarrons le processus avec l'image originale. Le Standard utilise ces images originales comme données d'entrée. Pendant ce temps, le modèle Unet-Meijering applique un filtre Meijering aux images originales et les prépare à être utilisées comme des données d'entrée. Le modèle Unet-Sato applique à la place un filtre Sato aux images originales et les transforme en données d'entrée. Il est important de noter que les images utilisées dans l'élaboration des diagrammes ont subi des changements uniformes caractérisés par un ajustement du contraste pour améliorer leur clarté dans les diagrammes. Cependant, il convient de noter qu'il ne s'agit pas de modification transférée aux modèles. Leur utilisation reste uniquement à des fins de visualisation.

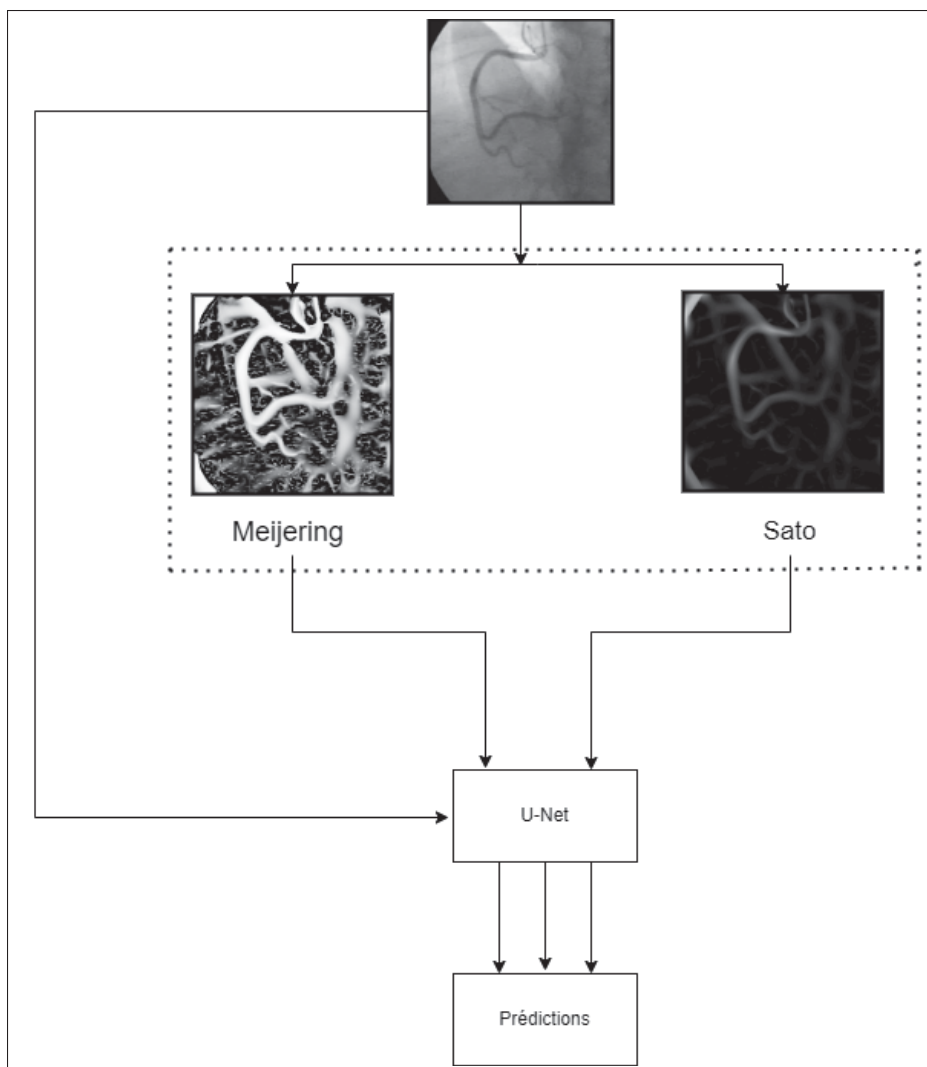


Figure 3.3 Le flux du travail de la 1 ère expérience.

### 3.2.2 Expérience 2 : Effet de la correction Gamma sur les filtres d'améliorations des vaisseaux

Malgré les premiers résultats prometteurs obtenus grâce à l'application de filtres d'amélioration des vaisseaux, il est devenu évident que certaines zones des images présentaient encore des problèmes de contraste persistants. Afin de relever ce défi, une expérience ultérieure a été menée pour évaluer l'efficacité de l'incorporation de la correction Gamma dans le pipeline de prétraitement. Dans cette expérience, la correction Gamma a été introduite dans les images filtrées, et les images modifiées ont ensuite été utilisées comme entrée pour les trois modèles U-Net, comme

le montre la figure 3.4. Il est important de noter que les images utilisées dans l'élaboration des diagrammes ont subi des changements uniformes caractérisés par un ajustement du contraste pour améliorer leur clarté dans les diagrammes. Cependant, il convient de noter qu'il ne s'agit pas de modification transférées aux modèles. Leur utilisation reste uniquement à des fins de visualisation.

### 3.2.2.1 Choix de la valeur de Gamma

La sélection de la valeur Gamma a été une étape importante dans ce processus d'amélioration. Pour chaque valeur Gamma testée de 1 à 5, le coefficient Dice a été calculé en comparant la « vérité terrain » avec l'image corrigée correspondante. Ce processus a été répété pour chaque valeur Gamma afin de déterminer la valeur Gamma optimale. La valeur Gamma qui maximise le coefficient Dice a été sélectionnée comme Gamma optimale pour chaque image.

Avec cette approche, la correction Gamma appliquée maximise la correspondance entre les artères coronaires segmentées par les différents modèles et les structures réelles présentes dans la vérité terrain, optimisant ainsi les performances globales du processus de segmentation.

Comme le montre la figure 3.4, nous avons appliqué une correction Gamma aux images originales, les images filtrées par Sato et Meijering, et avons fini par former trois autres modèles.

- OriginalCG : U-Net avec les images originales corrigées par Gamma en entrée.
- MeijeringCG : U-Net avec les images filtrées par le filtre de Meijering et corrigées par la correction Gamma en entrée.
- SatoCG : U-Net avec les images filtrées par le filtre de Sato et corrigées par la correction Gamma en entrée.

Les résultats de la segmentation obtenus à partir des images corrigées en fonction du Gamma ont été comparés avec ceux obtenus à partir des images filtrées sans correction Gamma.

Les résultats qualitatifs et quantitatifs des deux expériences sont détaillés dans le chapitre suivant.

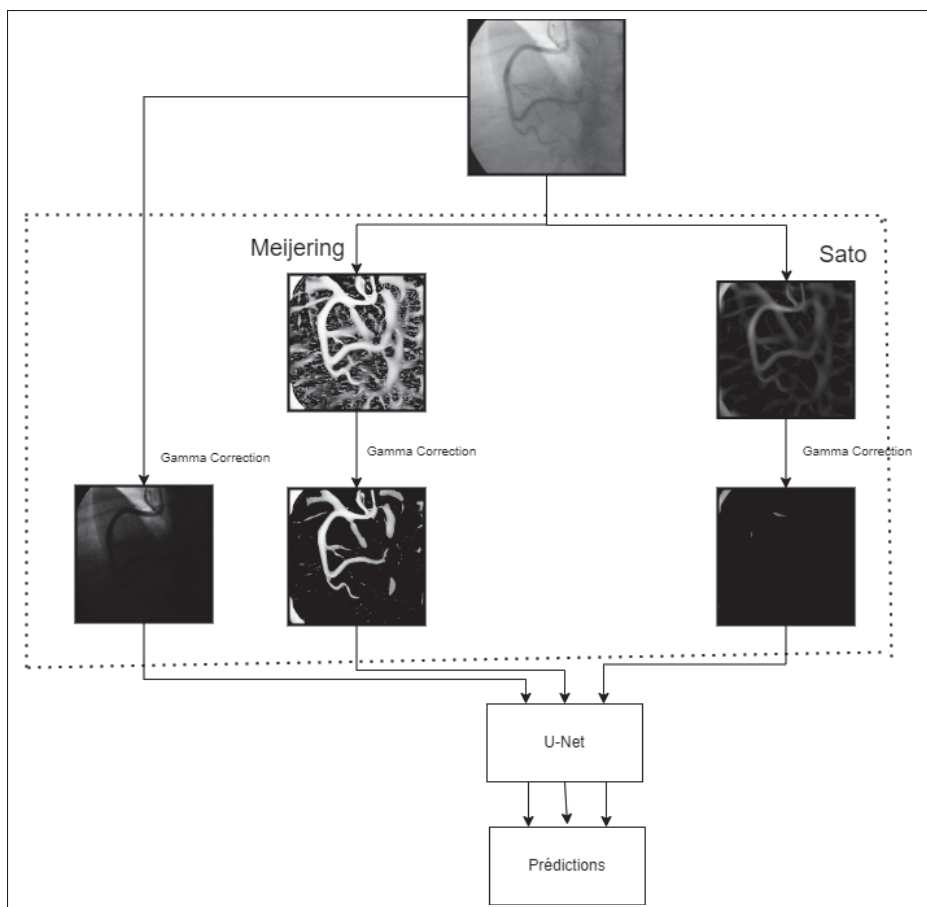


Figure 3.4 Le flux de travail de l'expérience 2.



## CHAPITRE 4

### RÉSULTATS

Ce chapitre est spécifiquement dédié à l'évaluation et à la comparaison de deux filtres d'amélioration des vaisseaux (FAV), à savoir les filtres Meijering et Sato, ainsi qu'à l'application de la correction Gamma. Comme mis en évidence dans la section 3.1.2.2, notre évaluation repose sur un ensemble de métriques clés, comprenant l'exactitude, la perte, la spécificité, la sensibilité et le coefficient Dice. Ces métriques constituent le socle de notre analyse approfondie des résultats obtenus. En outre, nous présentons des visualisations des prédictions générées par les différents modèles au cours des deux expériences. Ces représentations visuelles permettent une compréhension plus approfondie des performances des filtres Meijering et Sato, ainsi que de l'impact de la correction Gamma sur les résultats obtenus. Cette illustration visuelle renforce notre évaluation quantitative en fournissant une perspective complémentaire sur la qualité des améliorations apportées par chaque filtre, contribuant ainsi à une compréhension holistique des performances des méthodes évaluées.

#### 4.1 Expérience 1 : Comparaison de différents filtres d'amélioration des vaisseaux

Dans la première expérience, nous analysons l'impact des filtres Meijering et Sato sur la segmentation effectuée par le réseau U-Net. Nous évaluons dans quelle mesure l'utilisation de ces filtres comme techniques de prétraitement des données peut bénéficier les performances de la segmentation des AC. Le tableau 4.1 ci-dessous quantifie ces bénéfices numériques et donne un aperçu quantitatif des améliorations apportées par l'application des filtres Meijering et Sato au processus de segmentation.

Tableau 4.1 Le résultat de l'application de différents filtres sur le modèle U-Net

Modèle	Ensemble d'entraînement					Ensemble de test				
	acc	loss	dice	spe	sen	acc	loss	dice	spe	sen
Standard	95.73	6.53	98.12	99.16	62.20	94.82	7.46	98.11	99.15	57.45
Meijering	96.12	4.76	98.31	98.96	72.91	95.58	5.84	97.96	98.76	61.18
Sato	96.02	5.12	98.15	98.36	81.62	95.28	6.33	97.69	98.15	66.91

Ce tableau compare les résultats du modèle entraîné sur des images originales aux modèles entraînés sur les images filtrées avec les filtres Meijering et Sato. Comme le montre le tableau, le modèle Standard offre certainement des bonnes performances en termes de coefficient de Dice et de spécificité. Cependant, il devient clair qu'il y a place à l'amélioration, notamment en ce qui concerne l'exactitude, la sensibilité et la minimisation des erreurs. Dans ce contexte, les filtres Meijering et Sato ont été intégrés, engendrant une amélioration par rapport au modèle Standard. En fait, nous observons une amélioration notable des modèles équipés des filtres Meijering et Sato. Plus spécifiquement, l'exactitude initiale de 94.82 % a connu une augmentation à 95.58 % grâce à l'application du filtre Meijering. De même, l'application du filtre Sato a conduit à une exactitude de 95.28 %. Ces résultats mettent en évidence l'impact positif des filtres Meijering et Sato sur la capacité des modèles à effectuer des segmentations plus précises et justes.

En ce qui concerne la sensibilité, l'utilisation du filtre Meijering engendre une augmentation de 3,73 %, et l'utilisation du filtre Sato donne une augmentation encore plus significative de 9,46 %. Ces résultats mettent en valeur le rôle important des filtres de Meijering et de Sato dans l'amélioration de la capacité du modèle à détecter avec exactitude les structures vasculaires, en particulier les cas positifs.

En termes de perte, qui est une mesure importante pour évaluer l'adéquation du modèle, le filtre Meijering présente la perte la plus faible à 5.84 %, suivi de près par le filtre Sato à 6.33 %. À titre de comparaison, le modèle standard sans filtre présente une perte légèrement supérieure de 7.46 %. Ces résultats suggèrent que l'intégration des filtres Meijering et Sato contribue à réduire la perte et améliore l'adaptabilité du modèle aux données de test.

Bien que le coefficient Dice présente une légère diminution en raison de l'intégration du filtre, il reste à un niveau élevé et se situe toujours au-dessus de 97,69 %. Ceci suggère que l'ajout des filtres Meijering et Sato n'a pas affecté significativement la qualité de la segmentation, prouvant ainsi la robustesse du modèle.

La spécificité est restée élevée dans tous les modèles, démontrant une solide capacité à identifier avec exactitude les cas négatifs et à minimiser efficacement les faux positifs. La spécificité varie entre 98,15 % et 99,15 %, mettant en évidence la fiabilité des différents modèles pour différencier les cas négatifs.

En synthèse, l'incorporation des filtres Meijering et Sato a entraîné des améliorations substantielles, particulièrement en ce qui concerne la sensibilité, la perte et l'exactitude. Ces ajustements ont permis de renforcer considérablement la capacité du modèle à détecter avec exactitude les structures vasculaires, tout en préservant une performance solide en termes de coefficient Dice et de spécificité. L'amélioration quantitative que nous observons dans nos résultats traduit une amélioration qualitative, clairement mise en évidence par les masques de prédiction générés par les différents modèles évalués. La figure 4.1 offre un aperçu des prédictions générées par le modèle Standard (b), le modèle Unet-Meijering (c) et le modèle Unet-Sato (d), tandis que (a) et (e) exposent respectivement les images originales et leurs vérités terrain associées. Les




Figure 4.1 Dix angiogrammes de l'ensemble de test (a), et leurs vérités de terrain (f). Les lignes (b),(c) et (d) présentent les résultats de segmentation des modèles Standard, Unet-Meijering et Unet-Sato.

prédictions du modèle Standard dévoilent une segmentation globalement satisfaisante, mais révèlent également certaines limites telles que des discontinuités artérielles (images 2, 5, 6, 7 et 10), des faux positifs (images 1, 4, 5 et 8) et des faux négatifs (images 1, 3, 5, 6, 7, 9 et 10), en plus de négliger certaines bifurcations (images 4, 5 et 8). En revanche, les prédictions des modèles Unet-Meijering et Unet-Sato démontrent une amélioration significative en termes

de continuité, de réduction des faux négatifs. Par exemple, ces deux modèles parviennent à minimiser la discontinuité dans les images 1, 2 et 6, tout en réduisant le taux de faux positif dans les images 3 et 6 ainsi que le taux de faux négatif dans les images 3, 4, 6, 7, 9 et 10. Cette réduction des faux positifs et des faux négatifs se traduit par une augmentation des vrais positifs et des vrais négatifs, améliorant ainsi la qualité globale de la segmentation. De manière significative, l'intégration des filtres de Meijering et Sato a permis au modèle d'identifier plus de bifurcations, comme illustré dans les images 2, 4, 5 et 10.

Les figures 4.2, 4.3 et 4.4 ont été soigneusement sélectionnées pour illustrer de manière exhaustive les différents bénéfices apportés par l'intégration des FAV dans notre processus de segmentation. Ces visuels illustrent l'amélioration de la continuité artérielle, la détection précise des bifurcations, ainsi que la réduction significative des taux de faux négatif (FN). L'image 4.2 met en lumière l'effet des FAV sur la continuité artérielle, illustrant de façon concrète comment ces filtres agissent de manière cohérente pour renforcer la connexion entre les segments artériels. La figure 4.3, quant à elle, encercle visuellement les bifurcations détectées par les filtres Meijering et Sato. En ajoutant ces filtres, le modèle U-Net est maintenant capable de précisément identifier et détecter ces points de bifurcation, enrichissant ainsi la représentation spatiale des structures vasculaires et améliorant significativement l'exactitude des prédictions. L'image 4.4 met en évidence la capacité combinée des filtres Meijering et Sato à réduire les faux négatifs. Le cercle rouge symbolise l'amélioration de la détection des vaisseaux, minimisant ainsi le risque de négliger des structures vasculaires existantes et renforçant la fiabilité globale des prédictions du modèle. Cette analyse visuelle confirme de manière probante les avantages obtenus en combinant le modèle U-Net avec les FAV, renforçant ainsi de manière substantielle les performances globales des modèles dans la segmentation d'images médicales. Ces résultats soulignent l'efficacité de notre approche combinatoire pour obtenir des résultats de segmentation plus précis et fiables.

Les améliorations significatives obtenues grâce à l'incorporation de ces filtres soulignent l'importance de sélectionner des méthodes de prétraitement appropriées. Les filtres Meijering et Sato contribuent à la mise en évidence de la texture des images d'entrée, à la réduction du




Figure 4.2 Illustration de l'amélioration de la continuité des AC à travers les filtres Meijering et Sato.




Figure 4.3 Illustration de l'amélioration de détection des bifurcations des AC à travers les filtres Meijering et Sato.

bruit, l'amélioration de la continuité artérielle, et la détection de bifurcation conduisant à une amélioration globale des performances du modèle U-Net. Cependant, dans notre engagement continu pour affiner davantage les résultats, nous avons décidé d'aller au-delà en intégrant la




Figure 4.4 Illustration de réduction de FN à travers les filtres Meijering et Sato.

correction Gamma. Cette initiative vise à propulser les performances du modèle vers l'excellence en prévoyant des avantages additionnels en termes d'exactitude de la segmentation, tout en préservant les solides performances déjà acquises lors de la première expérience. Cette démarche, en intégrant la correction Gamma, offre le potentiel d'optimiser encore davantage notre approche, ouvrant ainsi la voie à de nouvelles améliorations substantielles dans le domaine de la segmentation des structures vasculaires

#### **4.2 Expérience 2 : Effet de la correction Gamma sur les filtres d'améliorations des vaisseaux**

Cette section est consacrée à une analyse détaillée des résultats de la deuxième expérience, en se concentrant sur les effets provoqués par l'application d'une correction Gamma aux différents modèles de segmentation de l'AC déjà étudiés dans la première expérience. Ces modèles incluent le modèle standard, le modèle Unet-Meijering et le modèle Unet-Sato. Cette expérience évalue les performances de modèles avec correction Gamma améliorée appelés StandardCG, MeijeringCG et SatoCG.

L'objectif central de cette expérience reste d'évaluer l'impact spécifique de la correction Gamma sur la segmentation finale des artères coronaires. Cette évaluation implique une analyse approfondie des diverses mesures clés, telles que l'exactitude, la perte, le coefficient de Dice, la sensibilité et la spécificité dans un premier temps. Par la suite, elle se poursuit par une analyse visuelle des différentes prédictions obtenues. Le tableau 4.2 illustre les performances obtenues par les différents modèles de l'expérience 1 et 2. Lorsque la correction Gamma a été intégrée dans le processus du modèle Standard, des améliorations significatives ont été observées. L'exactitude a augmenté à 95,78%, la perte a diminué de 2,83 %, et le coefficient de Dice et la spécificité ont légèrement diminué, mais sont restés élevés à 97,87 % et 98,58 %, respectivement. Notamment, une augmentation significative de la sensibilité de 6,57 % a été enregistrée. Dans l'ensemble, l'inclusion de la correction Gamma a considérablement amélioré les performances du modèle standard, soulignant son potentiel bénéfique du point de vue de la segmentation des CA.

Les observations préliminaires encourageantes stimulent la poursuite des recherches et motivent

Tableau 4.2 Le résultat de l'intégration de la correction Gamma

	Ensemble d'entraînement					Ensemble de test				
	acc	loss	dice	spe	sen	acc	loss	dice	spe	sen
Standard	95.73	6.53	98.12	99.16	62.20	94.82	7.46	98.11	99.15	57.45
StandardCG	96.24	4.64	98.24	98.88	76.54	95.78	4.63	97.87	98.84	64.02
Meijering	96.12	4.76	98.31	98.96	72.91	95.58	5.84	97.96	98.76	61.18
MeijeringCG	95.74	6.20	97.67	98.59	71.73	95.45	6.20	97.45	98.44	68.81
Sato	96.02	5.12	98.15	98.36	81.62	95.28	6.33	97.69	98.15	66.91
SatoCG	95.29	8.64	97.96	98.61	73.91	94.90	8.64	95.93	97.97	61.81

l'évaluation des effets de la correction Gamma dans des modèles plus spécialisés tels que Unet-Meijering et Unet-Sato.

Des ajustements modérés, mais significatifs ont été trouvés pour le modèle MeijeringCG. Les légères diminutions constatées dans l'exactitude, le coefficient Dice et la spécificité, qui ne dépassent pas 0,51 %, n'ont pas eu d'incidence significative sur ces mesures élevées. L'exactitude demeure à un niveau robuste de 95,45 %, le coefficient Dice maintient une excellente performance à 97,45%, et la spécificité reste élevée à 98,44%. Il est à noter qu'une légère augmentation de la perte, équivalant à 0,36%, a été observée, bien que cette variation demeure non significative. Une note positive émerge toutefois avec une amélioration de 7.36% de la sensibilité, qui atteint désormais 68,81%. Cette amélioration souligne la capacité accrue du modèle à identifier correctement les instances positives.

Dans l'ensemble, ces résultats témoignent de la solidité du modèle tout en mettant en évidence des ajustements positifs dans des aspects clés, soulignant ainsi sa robustesse et sa capacité à s'adapter de manière constructive.

Cependant, l'introduction d'une correction Gamma dans le modèle Unet-Sato ne s'est pas traduite par des améliorations notables, mais plutôt par une légère détérioration de certaines métriques clés. La perte, par exemple, a connu une augmentation, passant de 6.33% dans le modèle Unet-Sato à 8.64% dans le modèle SatoCG. Cette variation indique une augmentation dans les erreurs de prédiction du modèle, soulignant une moindre précision dans l'identification des artères. De manière similaire, la sensibilité a enregistré une diminution de 5.1%, passant de 66.91% dans le modèle Sato à 61.81% dans le modèle SatoCG. Cette baisse suggère que

l'ajout de la correction Gamma a eu un impact négatif sur la capacité de modèle Unet-Sato à correctement segmenter les AC. Il est crucial de noter ces changements, car bien que la correction Gamma puisse être bénéfique dans certains contextes comme le cas du modèle Standard et le modèle Unet-Meijering, elle semble avoir des répercussions défavorables sur ces métriques spécifiques dans ce modèle.

La Figure 4.5 offre une représentation visuelle des prédictions générées par les modèles de la deuxième expérience. Les lignes (a) et (e) présentent respectivement les images originales et leurs vérités terrain, tandis que les lignes (b), (c), et (d) dévoilent les prédictions des modèles StandardCG, MeijeringCG, et SatoCG. Afin d'évaluer l'impact de la correction Gamma, des comparaisons deux à deux ont été réalisées entre les modèles Standard vs StandardCG, Meijering vs MeijeringCG, et Sato vs SatoCG. L'image 4.17 illustre ces prédictions en organisant chaque paire de modèles à comparer sur deux lignes consécutives : ligne (a) pour les images originales, ligne (b) pour les prédictions du modèle Standard, ligne (c) pour les prédictions du modèle StandardCG, (d) pour les prédictions du modèle Meijering, (e) pour les prédictions du modèle MeijeringCG, (f) pour les prédictions du modèle Sato, et (g) pour les prédictions du modèle SatoCG, et (h) pour la vérité de terrain.

L'examen comparatif entre les résultats du modèle Standard (b) et StandardCG (c) révèle des améliorations significatives en termes de continuité artérielle, notamment dans les images 2, 5, 6, 7 et 10. Cette amélioration démontre la capacité de la correction Gamma à détecter plus précisément les structures vasculaires. Les images 4, 8, 9 et 10 témoignent d'une meilleure identification des bifurcations, soulignant ainsi le rôle bénéfique de la correction Gamma dans l'éclairage des vaisseaux de petite taille. En ce qui concerne les faux négatifs, l'utilisation de la correction Gamma a entraîné une réduction de ce taux, notamment dans les images 4, 5, 9 et 10. L'analyse des prédictions des modèles Meijering (d) et MeijeringCG (e) met en lumière une amélioration notable de la continuité, particulièrement dans les images 4, 7 et 10. Cela souligne l'efficacité de la correction Gamma dans le maintien de la continuité des artères. Les images 4, 8 et 9 démontrent une amélioration de la détection des bifurcations artérielles. En termes de faux positif et faux négatif, l'intégration de la correction Gamma a réduit ces taux, notamment




Figure 4.5 Dix angiogrammes de l'ensemble de test (a), et (e) leur vérité de terrain respective. Les lignes suivantes présentent les résultats de segmentation des modèles StandardCG(b), MeijeringCG(c), et SatoCG(d).

dans les images 5, 6 et 5, 6, 8, 10, respectivement ( voir les images 4.9, 4.10, 4.11 et 4.12).

En ce qui concerne les modèles Sato et SatoCG, une dégradation de la continuité est observée, notamment dans les images 7 et 9, et une diminution de la détection des bifurcations dans les images 2, 4, 6, 7, 9 et 10. Les images 3 et 4 montrent une augmentation du taux de faux négatif. De la même manière que dans la section 2.1, nous présentons des figures qui approfondissent l'impact de la correction Gamma sur la continuité artérielle, la détection des bifurcations, et les taux de faux positif (FP) et de faux négatif (FN) pour les différents modèles StandardCG, MeijeirnCG et SatoCG.

### 4.3 Discussion

Dans le cadre de la première expérience, nous avons formé trois itérations de l'architecture U-Net dédiées à la segmentation des artères coronaires (AC) : le modèle Standard, le modèle intégrant le filtre de Meijering, et le modèle exploitant le filtre de Sato. L'objectif fondamental était d'évaluer l'impact discernable de l'utilisation de filtres spécifiques sur les performances de

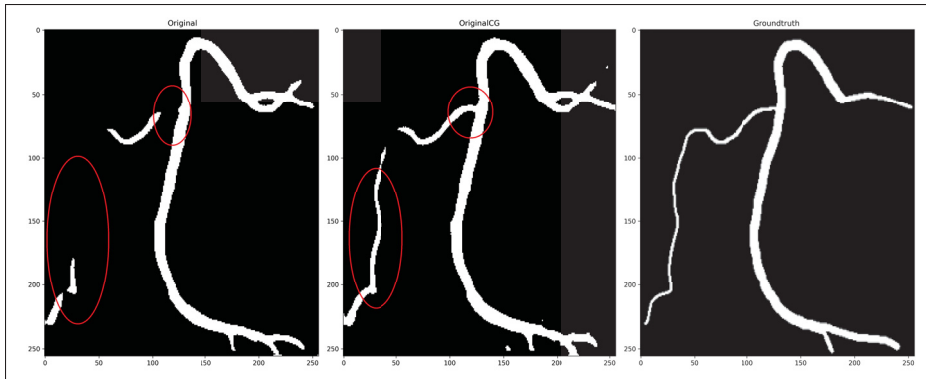


Figure 4.6 Illustration de l'amélioration de continuité des AC à travers la correction Gamma sur le modèle original.




Figure 4.7 Illustration de l'amélioration de détection de bifurcation des AC à travers la correction Gamma sur le modèle original.

segmentation. Les résultats obtenus ont révélé des variations notables dans diverses métriques, notamment l'exactitude (acc), la perte (loss), le coefficient de Dice (dice), la spécificité (spe), et la sensibilité (sen).

Dans la seconde phase de l'expérience, nous avons introduit la correction Gamma pour analyser son influence sur les modèles préexistants. Les résultats issus de cette correction ont mis en évidence des améliorations significatives dans la plupart des métriques évaluées, suggérant ainsi que l'adjonction de la correction Gamma impacte positivement la qualité globale de la segmentation. La figure 4.17 présente un diagramme synthétique illustrant les diverses




Figure 4.8 Illustration de réduction de FN à travers la correction Gamma sur le modèle original.

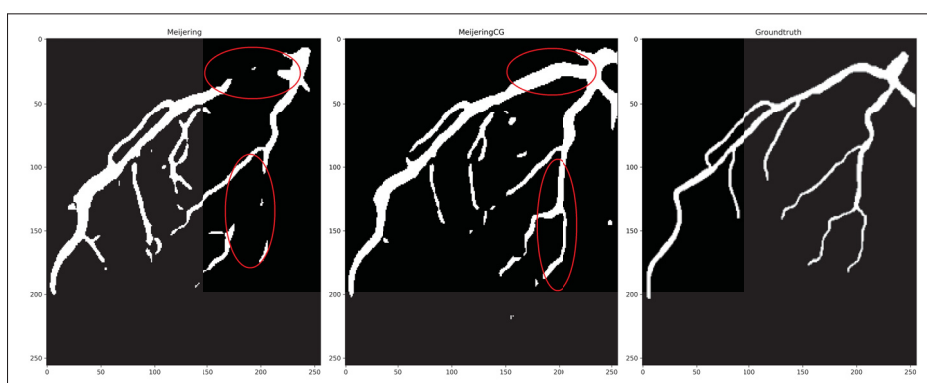


Figure 4.9 Illustration de l'amélioration de continuité des AC à travers la correction Gamma sur le modèle U-Net + Meijering.

performances obtenues par l'ensemble des modèles formés au sein de notre approche, structurée autour de deux expériences distinctes.

Cette représentation graphique offre une vue d'ensemble des performances relatives des modèles à travers les différentes étapes expérimentales, fournissant ainsi une perspective visuelle et concise sur l'évolution de la qualité de la segmentation.

Les résultats obtenus indiquent une amélioration générale des performances de segmentation après l'intégration des filtres et de la correction Gamma par rapport au modèle Standard initial. Le modèle Standard a montré des performances raisonnables, mais son faible niveau de




Figure 4.10 Illustration de l'amélioration de détection de bifurcation des AC à travers la correction Gamma sur le modèle Unet-Meijering.

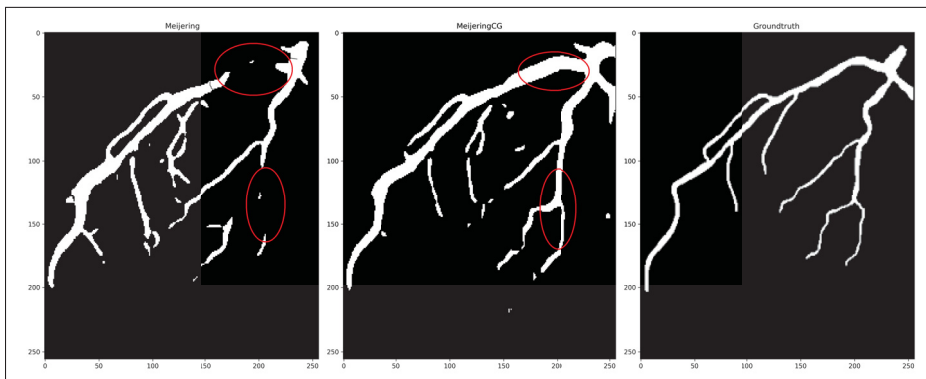


Figure 4.11 Illustration de réduction de FN à travers la correction Gamma sur le modèle Unet- Meijering.

sensibilité suggère une capacité limitée à détecter de manière exhaustive les artères coronaires. L'ajout du filtre de Meijering a conduit à une amélioration de la sensibilité, bien que la spécificité ait également légèrement diminué. En revanche, le modèle avec le filtre de Sato a présenté des performances solides dans toutes les métriques, avec une sensibilité notablement améliorée par rapport au modèle Standard. L'ajout de la correction Gamma a conduit à des améliorations significatives, en particulier en termes de sensibilité, suggérant une meilleure qualité de segmentation.

Ce modèle offre un équilibre exceptionnel entre une sensibilité maximale de 68.81% parmi tous les modèles entraînés dans les deux expériences, un coefficient Dice optimisé à 97.45%, une

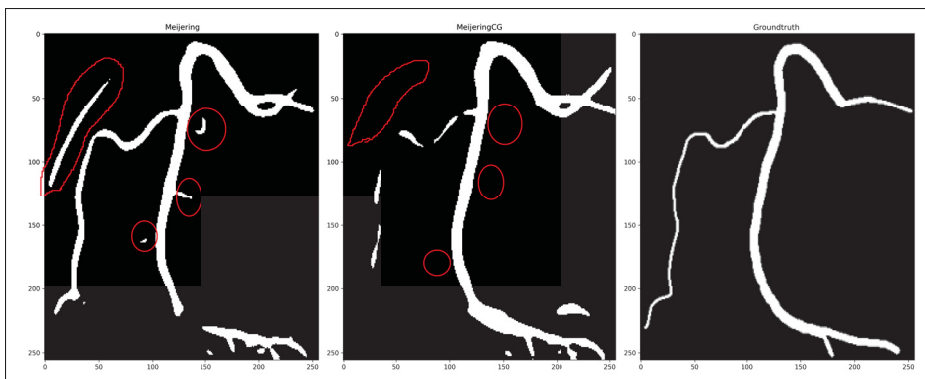


Figure 4.12 Illustration de réduction de FP à travers la correction Gamma sur le modèle Unet-Meijering.

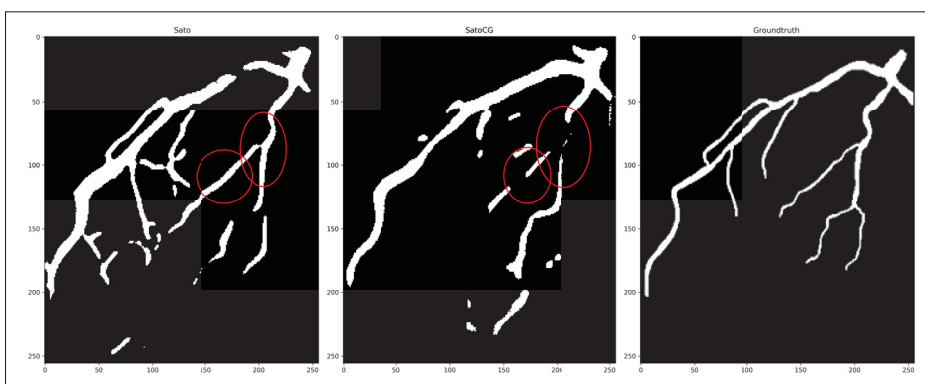


Figure 4.13 Illustration de la dégradation de continuité des AC à travers la correction Gamma sur le modèle Unet-Sato.

perte minimale de 6.2%, une exactitude élevée de 95.45%, et une spécificité de 98.44%. Ces facteurs essentiels garantissent une segmentation précise des artères coronaires. Cette conclusion est étayée par les visualisations, notamment la Figure 4.18, présentant dix images de l'ensemble de test avec les résultats de segmentation obtenus par tous les modèles entraînés au cours des expériences 1 et 2.

En conclusion, notre approche souligne l'importance de considérer attentivement les choix architecturaux et les prétraitements d'image lors de la conception de modèles de segmentation pour les artères coronaires. L'ajout de filtres spécifiques et la correction Gamma peuvent influencer




Figure 4.14 Illustration de la dégradation de détection de bifurcation des AC à travers la correction Gamma sur le modèle Unet-Sato.




Figure 4.15 Illustration d'augmentation de FN à travers la correction Gamma sur le modèle Unet-Sato.

les performances de ces modèles, ouvrant ainsi des perspectives pour des améliorations continues dans la recherche de la meilleure approche de segmentation.




Figure 4.16 Illustration de l'augmentation de FP à travers la correction Gamma sur le modèle Unet-Sato.




Figure 4.17 Diagramme synthétique des performances des différents modèles de notre approche.




Figure 4.18 Dix angiogrammes de l'ensemble de test (a), et (h) leur vérité de terrain respective. Les lignes suivantes présentent les résultats de segmentation des modèles Standard(b), Unet-Meijering(c), Unet-Sato(d), StandardCG(e), MeijeringCG(f), et SatoCG(g).



## CONCLUSION ET RECOMMANDATIONS

Il va sans dire que la segmentation des artères coronaires est un axe de recherche crucial dans la médecine cardiovasculaire vu son potentiel à mesurer divers paramètres hémodynamiques, dont la distensibilité. Cette dernière est un indicateur essentiel de la santé vasculaire, déterminée par les variations de diamètre des vaisseaux en réponse aux changements de pression artérielle. Une segmentation précise permet au cardiologue de quantifier ces variations et, par conséquent, d'évaluer la distensibilité des AC. La distensibilité permet de quantifier objectivement la santé vasculaire d'un individu. Elle offre des informations précieuses sur la compliance artérielle, c'est-à-dire la capacité des vaisseaux sanguins à se dilater et à se contracter en réponse aux variations de pression sanguine. Cette mesure peut aider les cliniciens à évaluer le risque cardiovasculaire global d'un patient, à surveiller l'évolution de la maladie et à ajuster les stratégies de traitement en conséquence. De plus, la segmentation est utilisée pour guider les médecins durant les traitements invasifs tels que l'angioplastie et la pose d'endoprothèses. Cependant, la segmentation manuelle de ces structures anatomiques est une tâche laborieuse qui peut introduire des erreurs interobservatrices et une variabilité par observateur. Par conséquent, de nombreuses études visent à développer des méthodes plus avancées pour segmenter les vaisseaux sanguins de manière plus précise et plus fiable, minimisant ainsi la dépendance à l'égard de l'expertise humaine. Les progrès récents en apprentissage automatique et de vision par ordinateur ouvrent de nouvelles opportunités passionnantes pour améliorer la précision et l'efficacité de la segmentation des vaisseaux, les AC en particulier.

Notre projet s'inscrit dans ce contexte, nous avons proposé une méthode basée sur des techniques d'apprentissage profond en traînant un modèle U-Net et en utilisant les filtres d'amélioration des vaisseaux comme technique de prétraitement de données. Les résultats obtenus démontrent des performances prometteuses et un immense potentiel pour automatiser ce processus complexe. Compte tenu des perspectives d'amélioration, nous prévoyons également d'explorer des approches de segmentation 3D pour capturer pleinement la forme tridimensionnelle des artères coronaires

et d'intégrer des données des patients présentant des anomalies des artères coronaires dans les données d'entraînement.

## **ANNEXE I**

### **ÉTAT DE L'ART SUR LES MÉTHODES D'APPRENTISSAGE PROFOND POUR LA SEGMENTATION DES CA**

Dans ce paragraphe, nous fournirons un tableau récapitulatif des approches de segmentation de l'AC discutées dans le chapitre de revue de la littérature. Chaque modèle sélectionné est soigneusement évalué en fonction de ses méthodes, de ses contributions et de ses limites potentielles. Ce tableau est destiné à servir de référence aux chercheurs, professionnels et à donner un aperçu des dernières avancées dans la segmentation des AC.

Publication	Méthode	Contributions	Limites
<p><b>A graph-based approach for spatiotemporal segmentation of coronary arteries in X-ray angiographic sequences. (M'hiri, F., Duong, L., Desrosiers, C., Leye, M., Miró, J., et Cheriet, M. (2016))</b></p>	<p>L'algorithme présenté repose sur la méthode de segmentation Temporal Vessel Walker (TVW), qui combine une formulation basée sur les graphes avec des priors temporels.</p>	<p>Le développement d'un algorithme pour la segmentation et le suivi d'un CA spécifique dans une séquence radiographique en mouvement.</p> <ul style="list-style-type: none"> <li>- L'incorporation des superpixels comme primitives d'image.</li> <li>- L'utilisation de la méthode SP-TVW dans un pipeline de superpixels à plusieurs échelles, plutôt que d'appliquer la méthode à différentes échelles de l'image. Cette méthode s'est avérée plus efficace que l'utilisation d'un cadre multiéchelle.</li> <li>- Aucune étape de post-traitement n'est utilisée, contrairement aux travaux précédents.</li> </ul>	<ul style="list-style-type: none"> <li>- Il serait préférable que le paramètre de cette méthode puisse être sélectionné automatiquement en fonction du niveau de contraste de la séquence radiographique.</li> <li>- Des caractéristiques supplémentaires sont nécessaires, comme la direction du vaisseau, pour résoudre le problème des vaisseaux qui se chevauchent.</li> <li>- D'autres tests avec des séquences plus longues à différents cycles cardiaques permettront d'évaluer la répétabilité de la méthode proposée.</li> </ul>

<p><b>Automatic evaluation of vessel diameter variation from 2D X-ray angiography.(M'hiri, F., Duong, L., Desrosiers, C., Dahdah, N., Miró, J., et Cheriet, M. (2017))</b></p>	<p>Une méthode automatique pour mesurer la distensibilité des artères à partir de séquences radiologiques 2D monoplane.</p>	<ul style="list-style-type: none"> <li>-Elle est entièrement automatique : la segmentation du ROI, le suivi du ROI et la mesure du diamètre de l'artère.</li> <li>-Cette méthode segmente et suit une partie spécifique d'une artère.</li> <li>-Elle traite à la fois les petits et les grands artères.</li> <li>- Donne des mesures précises pour calculer le diamètre des vaisseaux, qu'ils soient gros ou fins.</li> <li>-Il pourrait devenir un outil essentiel pour aider les médecins à détecter les variations de la rigidité artérielle associées aux stades précoces de diverses vasculopathies.</li> </ul>	<p>La robustesse de cette approche peut-être améliorée par :</p> <ul style="list-style-type: none"> <li>-L'ajout d'un terme de longueur et d'un terme de courbure au modèle pour renforcer le fait que la méthode suit le segment de la même longueur dans la séquence.</li> <li>-En envisageant d'autres approches de mesure du diamètre pour améliorer la précision des calculs.</li> </ul>
--	---	--	---

<p><b>Automated coronary artery tree segmentation in X-ray angiography using improved Hessian based enhancement and statistical region merging.</b>(Wan, T., Shang, X., Yang, W., Chen, J., Li, D., et Qin, Z. (2018))</p>	<p>Cette approche présente la combinaison d'une méthode d'amélioration adaptative hessienne basée sur plusieurs échelles et d'une technique de fusion de régions statistiques afin d'améliorer les structures complexes des vaisseaux ainsi que la délimitation des vaisseaux fins, souvent manqués par les autres méthodes de segmentation.</p>	<p>-Introduction d'un nouvel algorithme de segmentation des vaisseaux qui intègre des techniques de réduction du bruit, d'homogénéisation de fond, d'amélioration de la structure des vaisseaux et de fusion de régions statistiques pour l'extraction automatique des vaisseaux en angiographie coronarienne.</p> <p>-La méthode est facile à mettre en œuvre.</p> <p>- Comparée ux approches traditionnelles basées sur la matrice Hessienne,elle permet une meilleure identification des branches et des connexions vasculaires.</p> <p>-Elle peut être directement appliquée à l'analyse des vaisseaux sanguins assistée par ordinateur et permet une évaluation automatisée de la gravité de la sténose dans les angiographies coronariennes.</p>	<p>- Risque de segmentation incorrecte des structures non vasculaires lors du croisement ou de la proximité d'une branche vasculaire.</p> <p>-Les structures tubulaires des artefacts d'image peuvent être amplifiées, conduisant à un nombre élevé de faux positif.</p> <p>-Détection inexacte des limites fines des vaisseaux.</p> <p>-Temps d'exécution plus long par rapport aux autres méthodes (moyenne 2,57 s).</p> <p>-La méthode suit l'ensemble de l'arbre vasculaire plutôt qu'une artère spécifique, ce qui peut être moins efficace pour la détection dans des cas particuliers, tels que les patients pédiatriques, où l'arbre entier ne peut pas être capturé dans une seule image.</p>
--	--	--	--

<p><b>Structure-Aware Rank-1 Tensor Approximation for Curvilinear Structure Tracking Using Learned Hierarchical Features.</b>(Chu, P., Pang, Y., Cheng, E., Zhu, Y., Zheng, Y., et Ling, H. (2016))</p>	<p>La méthode détecte et suit les SC dans les séquences de rayons X. Il intègre la structure antérieure de ces SC en utilisant une approche tensorielle de rang 1 pour le suivi et exploite les caractéristiques hiérarchiques apprises d'un CNN.</p>	<p>-Présentation d'un cadre d'approximation tensorielle pour le suivi des CS qui intègre l'interaction spatiale entre ses composants réduisant ainsi l'ambiguïté de l'association et améliorant la robustesse du suivi.</p> <p>-Utilisation d'un détecteur discriminant basé sur les réseaux de CNN pour détecter les candidats de CS.</p>	<p>- Le calcul de la carte de probabilité par pixel doit être accéléré.</p>
---	---	--	---

<p><b>Extraction of Coronary Vessels in Fluoroscopic X-Ray Sequences Using Vessel Correspondence Optimization. (Shin, S. Y., Lee, S., Noh, K. J., Yun, I. D., et Lee, K. M. (2016))</b></p>	<p>Cette méthode permet d'extraire les artères coronaires des séquences radiographiques par fluoroscopie. Elle estime en détail la correspondance optimale des points des vaisseaux dans l'image source.</p>	<p>-Développement d'une méthode d'optimisation CAM pour un enregistrement optimal de la structure vasculaire, combinée à une méthode d'extraction précise des vaisseaux dans des séquences de rayons X en temps réel (XRA) grâce à une estimation minutieuse du mouvement.</p> <p>-Cette approche fournit aux médecins des informations d'analyse visuelle sans avoir besoin de CTA et peut être appliquée à l'enregistrement automatisé des vaisseaux entre les séquences XRA 2D et CTA 3D.</p> <p>-Elle robuste face aux structures vasculaires complexes et aux mouvements brusques.</p>	<p>Un post-traitement est nécessaire pour éliminer les nouvelles branches vasculaires créées par l'injection du produit de contraste. Cependant, VCO a des limites dans la gestion des changements de topologie dus au chevauchement des vaisseaux.</p>
---	--	---	---

<p><b>Coronary Artery Segmentation by Deep Learning Neural Networks on Computed Tomographic Coronary Angiographic Images.</b>(Huang, W., Huang, L., Lin, Z., Huang, S., Chi, Y., Zhou, J., ... et Zhong, L. (2018, July))</p>	<p>L'article utilise un réseau 3D U-Net pour segmenter la lumière de l'artère coronaire dans les données CTCA, qu'elles contiennent ou non une ligne centrale.</p>	<ul style="list-style-type: none"> <li>- Cette méthode surpasse les autres avec un coefficient de Dice évalué à 0,8291.</li> <li>- Elle ne nécessite aucun post-traitement.</li> <li>- Elle retourne des résultats prometteurs tant pour la segmentation de la lumière basée sur la ligne centrale que pour les images CTCA originales.</li> </ul>	<ul style="list-style-type: none"> <li>- Les datasets sont relativement petits.</li> <li>- La méthode segmente la lumière de l'artère et fonctionne mieux avec l'annotation de la ligne centrale.</li> </ul>
<p><b>Fully-automatic segmentation of coronary artery using growing algorithm.</b>(Cui, J., Guo, H., Wang, H., Chen, F., Shu, L., et Li, L. C. (2020))</p>	<p>Il s'agit d'une segmentation entièrement automatique de l'artère coronaire à l'aide d'un algorithme de croissance qui ne nécessite aucune interaction homme-machine.</p>	<ul style="list-style-type: none"> <li>- L'approche choisie est entièrement supervisée et apprise directement à partir des données brutes des pixels.</li> <li>- Aucune connaissance préalable de la structure vasculaire n'est requise.</li> <li>- Une méthode de détection du point racine remplace la sélection manuelle du point de départ.</li> <li>- Elle fonctionne efficacement avec un petit ensemble de données de formation.</li> </ul>	<ul style="list-style-type: none"> <li>- Les variations de densité entre les ATAO de différents patients en raison de différentes doses d'agent de contraste et de différents appareils d'enregistrement peuvent affecter les performances de segmentation.</li> <li>- L'architecture du réseau n'est pas optimale pour segmenter les petites artères coronaires.</li> <li>- L'architecture du réseau n'a pas montré une grande performance dans la segmentation des petites artères coronaires.</li> </ul>

<p><b>Learning tree-structured representation for 3D coronary artery segmentation.(Kong, B., Wang, X., Bai, J., Lu, Y., Gao, F., Cao, K., ... et Yin, Y. (2020))</b></p>	<p>Ce travail modélise explicitement la structure anatomique de l'artère coronaire avec un réseau unifié. Il se compose d'un modèle de FCN pour extraire les caractéristiques discriminantes du jeu de données CCTA et d'une couche ConvGRU arborescente pour modéliser la structure anatomique des artères coronaires.</p>	<p>-Un cadre complet basé sur l'apprentissage en profondeur combine une couche ConvGRU arborescente avec un réseau entièrement convolutif (FCN), représentant la première intégration d'un réseau récurrent arborescent dans la segmentation de l'artère coronaire pour la modélisation de la structure topologique.</p> <p>-Les résultats montrent que ce framework surpasse les méthodes classiques en termes de performances.</p>	<p>Les variations de densité entre les ATA0 de différents patients peuvent affecter les performances de segmentation.</p> <p>Le suivi de l'ensemble de l'arbre vasculaire plutôt que d'une artère spécifique peut ne pas être efficace pour les patients pédiatriques où un arbre complet ne peut pas être capturé dans une seule image.</p> <p>Il serait préférable de concevoir un réseau unifié de segmentation des artères coronaires permettant une interaction mutuelle entre le réseau de reconstruction d'arbre et le réseau de segmentation d'arbre pendant le processus de formation de bout en bout.</p>
--	---	--	---

<p><b>Optimal polyline tracking for artery motion compensation in coronary angiography.</b></p>	<p>Cette méthode modélise la ligne centrale de l'artère comme un contour polygonale (polyligne) et la suit tout au long de la séquence d'images au fur et à mesure qu'elle se déplace et se déforme en fonction des battements du cœur.</p>	<p>-Pas besoin de sélectionner un point d'intérêt à une caractéristique très distinctive dans l'arbre. -Le problème d'ouverture créé par le suivi d'une fenêtre autour d'un point a été éliminé en suivant une artère 1D qui contient de nombreuses caractéristiques.</p>	<p>-Les calculs peuvent être gourmands en mémoire et en temps de calcul car la solution repose sur la recherche du chemin le plus court dans un grand graphe où chaque nœud représente un segment de ligne possible du centre. -La représentation polyligne d'un vaisseau peut entraîner la perte d'informations sur la courbure.</p>
<p><b>Coronary arteries motion modeling on 2D x-ray images</b></p>	<p>Cette approche modélise le mouvement qui reconstruit l'arbre des artères pour chaque phase cardiaque en ajustant un ensemble de points de contrôle. Les positions de ces points sont suivies pendant un cycle cardiaque afin de collecter des informations sur la forme des vaisseaux cardiaques dans toutes les phases cardiaques.</p>	<p>- La vitesse en temps réel : Après avoir construit le modèle en suivant les points de contrôle dans un cycle cardiaque, la mise en phase du cycle cardiaque peut être effectuée en temps réel.</p>	<p>Cette approche ne prend en compte que le mouvement cardiaque, et non pas les déplacements cardiaques et respiratoires.</p>

<p><b>Automatic detection of coronary stenosis in X-ray angiography through spatio-temporal tracking</b></p>	<p>Cette méthode exploite la nature spatio-temporelle des séquences d'angiographie pour présenter une méthode robuste d'isolation automatique de l'arbre coronaire.</p>	<ul style="list-style-type: none"> <li>- L'introduction de l'idée de la persistance des minima dans les surfaces de largeur artérielle pour détecter les sténoses. Cette représentation de surface des séquences d'angiographie à rayons X en 2D donne une indication beaucoup plus claire de la sténose que l'analyse conventionnelle d'une seule image.</li> <li>-L'utilisation d'un algorithme de détection robuste de l'arbre coronaire en utilisant l'information spatio-temporelle.</li> <li>- Il s'agit du premier système de bout en bout en détectant sténoses dans les artères coronaires en imagerie radiographique.</li> </ul>	<ul style="list-style-type: none"> <li>-La méthode suit l'arbre entier, et pas seulement une artère en particulier. Il est admis que le suivi d'une artère est plus difficile parce que toutes les artères de la séquence partagent des caractéristiques similaires et qu'il est difficile de distinguer automatiquement une artère des autres, tout en tenant compte du mouvement de l'artère dans le temps.</li> <li>-La lumière du vaisseau est extraite à chaque point de la ligne centrale individuellement et ne calcule pas un optimum global.</li> </ul>
--	---	--	--

Tableau-A I-1 État de l'art sur les méthodes d'apprentissage profond pour la segmentation des CA.

## BIBLIOGRAPHIE

- Agurto, C., Yu, H., Murray, V., Pattichis, M. S., Nemeth, S., Barriga, S. & Soliz, P. (2015). A multiscale decomposition approach to detect abnormal vasculature in the optic disc. *Computerized Medical Imaging and Graphics*, 43, 137-149.
- Ameisen, J. C., Cambien, F., Dervaux, B., Douay, S., Gaudillière, J. P., Julian-Reynier, C. & Versuyft, C. (2008). *Tests génétiques. Questions scientifiques, médicales et sociétales.* (Thèse de doctorat, Institut national de la santé et de la recherche médicale (INSERM)).
- Annunziata, R., Kheirkhah, A., Hamrah, P. & Trucco, E. (2015). Scale and curvature invariant ridge detector for tortuous and fragmented structures. *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015 : 18th International Conference*, pp. 588-595.
- Aslani, S. & Sarnel, H. (2016). A new supervised retinal vessel segmentation method based on robust hybrid features. *Biomedical Signal Processing and Control*, 30, 1-12.
- Bache, R. J. (2015). Coronary artery disease : regulation of coronary blood flow. Dans *Coronary Artery Disease* (pp. 57-67). Berlin, Germany : Springer.
- Barataud, B. (2022). Mieux comprendre le fonctionnement des muscles. Repéré à [https://www.mgc-prevention.fr/mieux-comprendre-le-fonctionnement-des-muscles/#:~:text=Pour%20bien%20fonctionner%2C%20les%20muscles,l'alimentation%20\(sucres\).](https://www.mgc-prevention.fr/mieux-comprendre-le-fonctionnement-des-muscles/#:~:text=Pour%20bien%20fonctionner%2C%20les%20muscles,l'alimentation%20(sucres).)
- Bhuiyan, M. A., Nath, B. & Chua, J. (2007). An adaptive region growing segmentation for blood vessel detection from retinal images. *International Conference on Computer Vision Theory and Applications*, 2, 404-409.
- Bibiloni, P., González-Hidalgo, M. & Massanet, S. (2016). A survey on curvilinear object segmentation in multiple applications. *Pattern Recognition*, 60, 949-970.
- Blaus, B. [Récupéré le 1er décembre 2023, de <https://www.bruceblaus.com>]. (2016). Cathéter à bout ballonnet utilisé sous licence Creative Commons. Repéré à BruceBlaus.
- Chu, P., Pang, Y., Cheng, E., Zhu, Y., Zheng, Y. & Ling, H. (2016). Structure-aware rank-1 tensor approximation for curvilinear structure tracking using learned hierarchical features. *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2016 : 19th International Conference*, pp. 413-421.

- Citadelle. [Récupéré le 1er décembre 2023, de <https://www.citadelle.be/Services/Servicesmedicaux/Cardiologie/La-maladie-coronarienne/Mieuxcomprendre-la-maladie-coronarienne.aspx>]. (s.d.). Mieux comprendre la maladie coronarienne. Repéré à Citadelle.
- Clinic, C. (2021). Heart. Repéré à <https://my.clevelandclinic.org/health/body/21704-heart>.
- Compas, C. B., Syeda-Mahmood, T., McNeillie, P. & Beymer, D. (2014). Automatic detection of coronary stenosis in X-ray angiography through spatio-temporal tracking. *2014 IEEE 11th international symposium on biomedical imaging (ISBI)*, pp. 1299-1302.
- Cui, J., Guo, H., Wang, H., Chen, F., Shu, L. & Li, L. C. (2020). Fully-automatic segmentation of coronary artery using growing algorithm. *Journal of X-ray Science and Technology*, 28(6), 1171-1186.
- Databricks. [Récupéré le 1er décembre 2023, de <https://www.databricks.com/fr/glossary/neural-network>]. (s.d.). Réseau de neurones. Repéré à Databricks.
- Fazlali, H. R., Karimi, N., Soroushmehr, S. R., Shirani, S., Nallamotheu, B. K., Ward, K. R. & Najarian, K. (2018). Vessel segmentation and catheter detection in X-ray angiograms using superpixels. *Medical & biological engineering & computing*, 56, 1515-1530.
- Gao, Y. & Sundar, H. (2012). Coronary arteries motion modeling on 2D X-ray images. *Medical Imaging 2012 : Image-Guided Procedures, Robotic Interventions, and Modeling*, 8316, 403-408.
- Garcia-Garcia, A., Orts-Escolano, S., Oprea, S., Villena-Martinez, V. & Garcia-Rodriguez, J. (2017). A review on deep learning techniques applied to semantic segmentation. *arXiv preprint arXiv :1704.06857*.
- Giri, D., Acharya, U. R., Martis, R. J., Sree, S. V., Lim, T. C., VI, T. A. & Suri, J. S. (2013). Automated diagnosis of coronary artery disease affected patients using LDA, PCA, ICA and discrete wavelet transform. *Knowledge-based systems*, 37, 274-282.
- Hanaoka, S., Nomura, Y., Nemoto, M., Miki, S., Yoshikawa, T., Hayashi, N. & Shimizu, A. (2015). HoTPiG : a novel geometrical feature for vessel morphometry and its application to cerebral aneurysm detection. *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015 : 18th International Conference*, 18, 103-110.
- Held, K., Kops, E. R., Krause, B. J., Wells, W. M., Kikinis, R. & Muller-Gartner, H. W. (1997). Markov random field segmentation of brain MR images. *IEEE transactions on medical imaging*, 16(6), 878-886.

- Heritier, N. M. & Nephtali, I. B. (2021). L'Algorithme de rétro-propagation de gradient dans le perceptron multicouche : Bases et étude de cas. *International Journal of Innovation and Applied Studies*, 32(2), 271-290.
- Hernandez-Vela, A., Gatta, C., Escalera, S., Igual, L., Martin-Yuste, V., Sabate, M. & Radeva, P. (2012). Accurate coronary centerline extraction, caliber estimation, and catheter detection in angiographies. *IEEE Transactions on Information Technology in Biomedicine*, 16(6), 1332-1340.
- Huang, W., Huang, L., Lin, Z., Huang, S., Chi, Y., Zhou, J. & Zhong, L. (2018). Coronary artery segmentation by deep learning neural networks on computed tomographic coronary angiographic images. *2018 40th Annual international conference of the IEEE engineering in medicine and biology society (EMBC)*, pp. 608-611.
- Ibragimov, B. & Xing, L. (2017). Segmentation of organs-at-risks in head and neck CT images using convolutional neural networks. *Medical physics*, 44(2), 547-557.
- IndoML. [Récupéré le 1er décembre 2023, de <https://indoml.com/2018/03/07/student-notes-convolutionalneural-networks-cnn-introduction/>]. (2018). Notes d'étudiant : Introduction aux réseaux neuronaux convolutionnels (CNN). Repéré à IndoML.
- Intelligence, M. (2023). Analyse de la taille et de la part du marché de la surveillance cardiaque - tendances et prévisions de croissance (2023 - 2028). Repéré à <https://www.mordorintelligence.com/fr/industry-reports/global-cardiac-monitoring-market-industry>.
- international institute, N. Physiology of the Heart. Repéré à <https://training.seer.cancer.gov/anatomy/cardiovascular/heart/physiology.html>.
- Jiang, L., Li, Y., Pan, J., Zhu, D., Tong, J. & Shu, T. (2020). A new method for segmentation of the coronary arteries of interest and diameter measurement. *IEEE Access*, 8, 122975-122985.
- Kirbas, C. & Quek, F. (2004). A review of vessel extraction techniques and algorithms. *ACM Computing Surveys (CSUR)*, 36(2), 81-121.
- LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lesage, D., Angelini, E. D., Bloch, I. & Funka-Lea, G. (2009). A review of 3D vessel lumen segmentation techniques : Models, features and extraction schemes. *Medical image analysis*, 13(6), 819-845.
- Liskowski, P. & Krawiec, K. (2016). Segmenting retinal blood vessels with deep neural networks. *IEEE transactions on medical imaging*, 35(11), 2369-2380.

- Malakar, A. K., Choudhury, D., Halder, B., Paul, P., Uddin, A. & Chakraborty, S. (2019). A Review on Coronary Artery Disease, its Risk Factors, and Therapeutics. *Journal of Cellular Physiology*, 234(10), 16812-16823.
- Meijering, E., Jacob, M., Sarria, J. C., Steiner, P., Hirling, H. & Unser, M. (2004, April). Neurite tracing in fluorescence microscopy images using ridge filtering and graph searching : principles and validation. *2004 2nd IEEE International Symposium on Biomedical Imaging : Nano to Macro (IEEE Cat No. 04EX821)*, pp. 1219-1222.
- ResearchGate. [Récupéré le 1er décembre 2023, de <https://www.researchgate.net/figure/Illustration-of-Max-Poolingand-Average-Pooling-Figure-2-above-shows-an-example-ofmax-2333593451>]. (s.d.). Illustration de Max Pooling et Average Pooling. Repéré à ResearchGate.
- Santé Sur Le Net. [Récupéré le 1er décembre 2023, de <https://www.santesur-le-net.com/maladies/cardiologie/generalites-coeur/>]. (2015a). Généralités sur le cœur. Repéré à SantéSurleNet.
- Santé Sur Le Net. [Récupéré le 1er décembre 2023, de <https://www.santesur-le-net.com/maladies/cardiologie/generalites-coeur/>]. (2015b). Généralités sur le cœur. Repéré à SantéSurleNet.
- Sato, Y., Nakajima, S., Shiraga, N., Atsumi, H., Yoshida, S., Koller, T., Gerig, G. & Kikinis, R. (1998). Three-dimensional multi-scale line filter for segmentation and visualization of curvilinear structures in medical images. *Medical Image Analysis*, 2, 143-168.
- Survarachakan, S., Pelanis, E., Khan, Z. A., Kumar, R. P., Edwin, B. & Lindseth, F. (2021). Effects of enhancement on deep learning based hepatic vessel segmentation. *Electronics*, 10(10), 1165.