



HAL
open science

Assistance virtuelle pour la prévention des risques cardiovasculaires

Saifeddine Rjiba

► **To cite this version:**

Saifeddine Rjiba. Assistance virtuelle pour la prévention des risques cardiovasculaires. Cardiologie et système cardiovasculaire. Université de Poitiers, 2022. Français. NNT : 2022POIT2273 . tel-03851979

HAL Id: tel-03851979

<https://theses.hal.science/tel-03851979>

Submitted on 14 Nov 2022

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

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

THÈSE

POUR L'OBTENTION DU GRADE DE

DOCTEUR DE L'UNIVERSITÉ DE POITIERS

FACULTÉ DES SCIENCES FONDAMENTALES ET APPLIQUÉES

DIPLÔME NATIONAL - ARRÊTÉ DU 25 MAI 2016

ECOLE Doctorale : Sciences et Ingénierie des Systèmes, Mathématiques, Informatique – SISMI
Secteur de Recherche : Traitement du Signal et des Images

Présenté par :

Saifeddine RJIBA

Assistance virtuelle pour la prévention des risques cardiovasculaires

Directeurs de Thèse :

Christine FERNANDEZ-MALOIGNE

Roger DELEPAULE

JURY

Fabrice MERIAUDEAU, Professeur des universités, Université de Bourgogne.....Président
Jenny BENOIT PINEAU, Professeur des universités, Université de Bordeaux..... Rapporteur
Sylvain FAISAN, Maître de Conférences, ICUBE Rapporteur
Christine FERNANDEZ-MALOIGNE, Professeur des universités, Université de Poitiers..... Directeur
Roger DELEPAULE, Directeur grands comptes, Canon Medical Systems France.....Directeur
Thierry URRUTY, Maître de Conférences, Université de Poitiers Encadrant

Résumé

Les maladies coronariennes et les attaques cérébrales ont longtemps été la principale cause de décès en France, comme dans de nombreux pays dans le monde. Dans ce travail de thèse, nous proposons d'offrir aux experts médicaux des algorithmes automatiques pour l'analyse de données à caractère biomédical en vue de la prévention des risques cardiovasculaires (sténoses) et les accidents vasculaires cérébraux (anévrismes). Nous déployons pour cela des outils novateurs basés sur les techniques de l'intelligence artificielle permettant d'extraire l'arbre artériel, de détecter les sténoses, de classifier les types des plaques coronaires et de segmenter les anévrismes intracrâniens non rompus. Nous introduisons, également, une nouvelle base de données que nous avons créé à l'aide des efforts des équipes médicales du CHU Poitiers.

Mots clefs : Aide au diagnostic automatique, Intelligence artificielle, CTA, Artères coronaires, Sténose, MRA-TOF, Anévrisme

Abstract

Cardiovascular disease and cerebrovascular accidents have long been the main cause of death in France, as in many countries in the world. In this thesis, we propose to offer medical experts automatic algorithms for the analysis of biomedical data with the aim of preventing cardiovascular risks (stenoses) and strokes (aneurysms). We deploy innovative tools based on artificial intelligence techniques to extract the arterial tree, detect stenoses, classify coronary plaque types and segment unruptured intracranial aneurysms. We are also introducing a new database created with the collaboration of the medical teams of the Poitiers University Hospital.

Keywords : Automatic computer assisted detection, Artificial intelligence, CTA, Coronary arteries, Stenosis, MRA-TOF, Aneurysm

Table des matières

1	Introduction	1
1.1	Contexte général de la thèse	1
1.2	Accidents Vasculaires Cérébraux	3
1.2.1	Anatomie du coeur et des artères coronaires	3
1.2.2	Maladie coronarienne	4
1.2.3	Diagnostic clinique	4
1.3	Risque de rupture d'anévrismes intracrâniens	6
1.3.1	la détection des anévrismes intracrâniens non rompus	6
1.3.2	Diagnostic clinique	7
1.4	Automatisation de la détection	8
1.4.1	Intelligence artificielle	8
1.4.2	Intelligence artificielle pour l'imagerie médicale	9
1.5	Contributions de la thèse	10
1.5.1	La revue de la littérature	11
1.5.2	Extraction des artères coronaires	11

1.5.3	Détection de la sténose et classification des plaques	12
1.5.4	Segmentation des anévrismes intracrâniens non rompus	13
1.5.5	Collecte de la base de données CHU Poitiers	13
1.6	Organisation du manuscrit	14
2	Intelligence Artificielle	17
2.1	Apprentissage machine	18
2.1.1	Les types d'apprentissage machine	19
2.1.2	La formulation mathématique de l'apprentissage supervisé	22
2.1.3	Dilemme biais-variance	23
2.1.4	La répartition des données	24
2.2	Apprentissage profond	26
2.2.1	L'idée du perceptron	26
2.2.2	Réseau de neurones artificiels : ANN	27
2.2.3	Réseau de neurones convolutif : CNN	30
2.3	Exemples des architectures de CNN	36
2.3.1	U-Net	38
2.3.2	ResNet	40
2.3.3	SE-ResNext	40
2.4	Conclusion	42

3	État de l’art	44
3.1	Introduction	44
3.2	Détection des structures vasculaires	47
3.2.1	Les caractéristiques basés sur l’apparence	47
3.2.2	Les caractéristiques basées sur la géométrie	50
3.2.3	Les caractéristiques extraites avec l’apprentissage profond	56
3.3	Détection de la sténose et quantification des plaques	60
3.3.1	La modélisation des vaisseaux sains	61
3.3.2	La modélisation des lésions	63
3.3.3	Détection des lésions à l’aide de l’apprentissage profond	66
3.4	Conclusion	71
4	Matériel et métriques d’évaluation	74
4.1	Introduction	74
4.2	Matériel	75
4.2.1	Défi de suivi des artères coronaires : CAT08	75
4.2.2	Cadre d’évaluation standardisé pour la détection et la quantification de la sténose	76
4.2.3	Segmentation multimodale du cœur entier : MM-WHS 2017	78
4.2.4	Défi de la détection et de la segmentation des anévrismes : ADAM 2020 .	79
4.2.5	CHU Poitiers	80
4.3	Métrique d’évaluations	84

4.3.1	Sensibilité	86
4.3.2	Spécificité	86
4.3.3	Précision	86
4.3.4	Courbe ROC et AUC	87
4.3.5	Coefficient de similarité de Dice : DSC	88
4.3.6	Coefficient de corrélation de Matthews : MCC	88
4.3.7	Distance de Hausdorff : MHD	89
4.3.8	Similarité volumétrique : VS	89
4.4	Conclusion	90
5	Extraction des artères coronaires	92
5.1	Introduction	92
5.2	État de l’art	93
5.3	Méthodologie	96
5.3.1	Pré-traitement	97
5.3.2	CenterlineNet : Architecture	99
5.3.3	Organisation des données	100
5.3.4	Stratégie d’entraînement	101
5.3.5	Post-traitement : Délimitation de la région cardiaque et l’aorte ascendante	103
5.3.6	Résultats et Discussion	105
5.4	Optimisation du Pipeline de la Détection	107

5.4.1	Délimitation de la région cardiaque : segmentation des sous-structures du coeur	109
5.4.2	Analyse intelligente des composants connectés : diminuer le risque des interruptions	114
5.5	Conclusion	118
6	La détection de la sténose et la classification des plaques	122
6.1	Introduction	122
6.2	État de l'art	124
6.3	Reconstruction de l'arbre coronaire extrait	127
6.3.1	cMPR : reformatage multiplanaire incurvé	128
6.3.2	Implémentation du cMPR	130
6.3.3	Résultats de la cMPR sur la base de données de CHU Poitiers	132
6.4	Détection de la sténose	134
6.4.1	Pré-traitement	135
6.4.2	Architecture	140
6.4.3	Résultats	142
6.5	Classification des plaques	145
6.6	Conclusion	149
7	Segmentation des anévrismes intracrâniens non rompus	152
7.1	Introduction	152
7.2	Méthodologie proposée	155

7.2.1	pré-traitement	156
7.2.2	Segmentation des vaisseaux	158
7.2.3	AneurysmNet	160
7.2.4	Post-traitment	162
7.3	Expérimentations	163
7.3.1	Détails de l'implémentation	163
7.3.2	Évaluation	164
7.4	Résultats	165
7.5	Discussion	171
7.6	Conclusion	173
8	Conclusion et perspectives	176
8.1	Conclusion générale	176
8.2	Perspectives	179
	Références	183

Liste des tableaux

2.1	Les fonctions d'activation les plus utilisées : leur formule et leur domaine de définitions	29
4.1	La distribution des patients (pourcentage) par catégorie de score calcique (CCS). Le CCS réfère au score Agatston.	81
4.2	La distribution des examens (pourcentage) par la qualité de l'examen.	81
4.3	La distribution des sujets (pourcentage de la population) par la classe de corpulence d'une personne selon l'IMC.	82
4.4	La distribution du nombre des artères (pourcentage de la totale des segments) par leur état.	83
4.5	La distribution du nombre des plaques (pourcentage du nombre total des lésions) par leur type.	83
5.1	Évaluation des performances de sensibilité de CenterlineNet sur 18 patients issus de l'ensemble d'entraînement du concours de sténose et de quantification des artères coronaires de Rotterdam (2012). Les colonnes considérées comme l'annotation de la vérité du terrain.	105

5.2	Évaluation des performances de CenterlineNet sur 8 patients des jeux de données CAT08. Nous rapportons les résultats de la version du modèle entraînée uniquement sur les données de sténose et une autre version mélangée avec les patches CAT08. [107]	105
5.3	Coefficients de similarité de Dice en % pour la reproduction de travail de Payer et al, les résultats de l’algorithme d’état de l’art de MICCAI WHS 2017 et notre proposition de couplage des résultats de notre modèle CenterlineNet et l’approche de Payer. Les résultats montrent la moyenne de toutes les images de la configuration de validation croisée pour chaque étiquette de segmentation. Abréviations des étiquettes : VG - cavité sanguine du ventricule gauche, Myo - myocarde du ventricule gauche, VD - cavité sanguine du ventricule droit, AG - cavité sanguine de l’oreillette gauche, AD - cavité sanguine de l’oreillette droite, AA - aorte ascendante, AP - artère pulmonaire, WHS - moyenne des sept sous-structures du cœur entier	112
5.4	Comparaison des résultats de l’approche de l’analyse classique de composants connectés avec celle du module intelligent à l’issu des prédictions intracardiaques du modèle CenterlineNet. L’évaluation est faite sur 8 patients qui appartiennent à la base de données de CHU Poitiers en utilisant les métriques : sensibilité (rappel), valeur prédictive positive, précision (accuracy) et la similarité de Dice .	117
6.1	Comparaison des résultats de l’approche à double entrée et à entrée unique (cMPR sans les corrections). L’évaluation est faite sur 8 patients qui appartiennent à la base de données de CHU Poitiers en utilisant les métriques : sensibilité (rappel), précision (valeur prédictive positive), le DSC (coefficient de similarité Dice), AUC (aire sous la courbe) et MCC (coefficient de corrélation de Matthew)	142

7.1	La sensibilité en % et le taux des faux-positifs par cas pour le modèle 2.5 MIP et notre segmentation proposée avec et sans normalisation de toutes les images de l'ensemble de données de validation ADAM que nous avons partitionné localement.	165
7.2	Résultats sur le jeu de données de test du défi ADAM (base de données privée et non publique)[209]	169
7.3	L'évaluation de la deuxième tâche pour les 5 meilleures équipes sur les scans positifs uniquement (patients ayant au moins un anévrisme) et les résultats de l'entraînement par rapport à la sensibilité des tests sur les deux ensembles de données complets.[199]	170

Table des figures

1.1	Aquilion ONE GENESIS Edition : un CT scanner moderne qui utilise l'intelligence artificielle pour la reconstruction des images [3]	2
1.2	Anatomie du sous structures du coeur et de l'arbre artériel coronaire.	2
1.3	Maladie Coronarienne : formation d'une plaque d'athérosclérose [9].	4
1.4	Image CT et Reconstruction 3D	5
1.5	Détection d'un anévrisme intracrânien non rompu à partir d'une IRM en projection à intensité maximale (MIP)	6
2.1	Les types d'apprentissage machine et leurs applications [10].	18
2.2	Le compromis de surapprentissage / sousapprentissage. La figure est adaptée de [12].	23
2.3	Comparaison entre un neurone biologique (à gauche) et le modèle mathématique d'un neurone artificiel (à droite) . La figure est adaptée de [13].	26
2.4	Un réseau de perceptron multicouche : réseau entièrement connecté [13].	28
2.5	Le schéma complet d'un réseau de neurones convolutif. La figure est adaptée de [19].	31

2.6	La distribution des poids pour les neurones de la première couche cachée pour un MLP (à gauche) et un CNN. Le biais est ignoré dans cette représentation. La figure est adaptée de [20].	32
2.7	L'opération de convolution	33
2.8	L'opération de max-pooling	34
2.9	Les cartes de caractéristiques pour la détection des visages. La figure est adaptée de [21].	35
2.10	Les architectures qui ont remporté la compétition de classification des images ILSVRC. La figure est adaptée de [27].	36
2.11	L'architecture de U-Net. La figure est adaptée de [30].	39
2.12	Partie d'un réseau de neurones convolutif. A gauche sans et à droite avec le bloc résiduel. La figure est adaptée de [54].	39
2.13	Comparaison entre le bloc résiduel de ResNet et le bloc de "squeeze and excitation" de SE-ResNet. La figure est adaptée de [55].	41
3.1	Histogramme des valeurs de l'unité de Hounsfield pour les points appartenant à ligne centrale de la base d'entraînement. Les patients sont représentés par des couleurs différentes.	48
3.2	Profil d'intensité de la section du vaisseau. La figure est adaptée de [94].	49
3.3	Ellipsoïde de second ordre de l'espace des formes de Frangi et al [98]. Les prototypes de forme sont définis en fonction des valeurs propres de la matrice hessienne des intensités locales λ_i . La figure est adaptée de [70]	50
3.4	Amélioration des vaisseaux avec deux filtres différents. La figure est adaptée de [101]	52
3.5	Diagrammes montrant les étapes d'un algorithme de suivi [76].	53

3.6	Le modèle géométrique proposé par [106] pour la représentation des artères coronaires.	55
3.7	Présentation de la méthode de [112]. A la position x , un patch P est extrait et utilisé comme entrée d'un CNN. Ce CNN détermine simultanément une distribution de probabilité $p(D P)$ sur un ensemble discret de directions (le nombre de directions est un hyperparamètre) sur la sphère (représentée ici par un cercle bleu), et une estimation r du rayon du vaisseau. La figure est adaptée de [112] .	57
3.8	Vue d'ensemble de la méthode de [113]. Les lignes rouges représentent les entrées données au modèle de classification de la direction et de la bifurcation et au modèle de classification du patch d'arrêt avec les patches multirésolution P1 et P2. La figure est adaptée de [113]	57
3.9	Vue d'ensemble de la méthode de [115]. Les lignes rouges représentent les entrées données au modèle de classification de la direction et de la bifurcation et au modèle de classification du patch d'arrêt avec les patches multirésolution P1 et P2. La figure est adaptée de [115]	58
3.10	Modélisation de l'approche de [122]. Le modèle apprend des paramètres de transformation basé sur des formes tubulaires à priori. La figure est adaptée de [122] .	60
3.11	La maladie des artères coronaires. La figure est adaptée de [125]	60
3.12	Le pipeline général des méthodes de l'état de l'art pour la détection et quantification de la sténoses. Le chemin rouge correspond à l'approche de caractérisation des lésions alors que le chemin vert décrit la détection des lésions à partir des comparaisons avec les vaisseaux sains. La figure est adaptée de [148]	61
3.13	L'approche de Xu et al [142] : Résultats du calcul du diamètre artériel attendu sur une branche artérielle saine. La ligne continue prédit le diamètre attendu à n'importe quel endroit de la branche artérielle. La figure est adaptée de [142] . .	62

- 3.14 L'approche de Wesarg et al [136] : un ensemble de points candidats est sélectionné sur la base d'un seuil calculé automatiquement. Ces points sont ensuite analysés pour déterminer si des valeurs de gris brillantes se trouvent dans leur voisinage. Enfin, les points restants sont décimés à nouveau pour s'assurer qu'un seul point d'entre eux représente la calcification. La figure est adaptée de [136] 64
- 3.15 Pipeline d'extraction et de quantification automatique des lésions coronaires calcifiées par apprentissage automatique : tout d'abord, l'algorithme commence par identifier un ensemble de candidats. Les caractéristiques appropriées sont calculées pour décrire chacun des candidats choisis. Ensuite, un classifieur est entraîné pour distinguer les vraies calcifications des fausses détections. Une étape de révision est proposée (généralement manuelle) afin de valider/supprimer les calcifications suspectes que le classifieur n'a pas pu détecter. La figure est adaptée de [152] 65
- 3.16 Illustration du pipeline proposé par Zreik et al [153]. Le RCNN effectue deux tâches simultanément qui sont : la détection des plaques et la quantification du degré de la sténose. La figure est adaptée de [153] 67
- 3.17 Illustration du pipeline proposé par Tejero et al [153]. Le RCNN effectue deux tâches simultanément qui sont : la détection des plaques et la quantification du degré de la sténose. La figure est adaptée de [154] 68
- 3.18 Aperçu de l'algorithme de Denzinger et al [156] : extraction de deux vues orthogonales de la lésion d'intérêt. Celles-ci sont concaténées et ensuite utilisées comme entrée pour un 2D-CNN (conv = couche de convolution, bn = couche de normalisation par batchs, dense = couche entièrement connectée). La figure est adaptée de [156] 69

3.19	Aperçu de l’algorithme de Candemir et al [158] : après une étape d’extraction des artères coronaires et reconstruction MPR, le CNN effectue la classification des volumes d’entrées entre volume sain ou non sain. Pour créer la carte de saillance en utilisant le gradient de la dernière couche de convolution. La figure est adaptée de [158].	70
3.20	Aperçu de l’algorithme de Denzinger et al [159] : toutes les artères coronaires de l’arbre artériel sont découpées et traitées séparément par le modèle. Par contre, le score final de la calcification et de la CAD-RADS est obtenu par une décision sur tout les prédictions en question. La figure est adaptée de [159].	71
4.1	Un exemple de scan avec l’annotation de référence correspondante : en haut à gauche : vue axiale des données; en haut à droite : vue coronale; en bas à gauche : vue sagittale; en bas à droite : une reconstruction 3D de l’annotation de référence. La figure est adaptée de [107].	75
4.2	Techniques de visualisation utilisées pour interpréter les images CTA : images transaxiales (à gauche) et multiplanaires (vue en coupe en haut à droite, vue longitudinale en bas à droite) de la coronaire droite (CD), la circonflexe (CX) et l’interventriculaire antérieur (IVA). Ce patient présente une plaque mixte modérée dans un segment de l’IVA. La figure est adaptée de [148].	77
4.3	La segmentation des sept sous structures du coeur à partir des images CT. Les structures affichées sont : atrium droit (AD), atrium gauche (AG), ventricule droit (VD), ventricule gauche (VG) et l’aorte ascendante. La figure est adaptée de [176].	78
4.4	Une image TOF-MRA originale et image MR structurale originale du jeu de données d’ADAM. La figure est adaptée de [200].	79
4.5	Le scanner Aquilion One Genesis utilisé dans le CHU Poitiers. La figure est adaptée de [3].	80

4.6	Les catégories de la corpulence d'une personne selon la mesure de l'IMC. La figure est adaptée de [6].	82
4.7	Un exemple de compte rendu de l'équipe médical du Pr. Luc-Philippe Christiaens du CHU de Poitiers. Les données liées au patient ont été masqué.	84
4.8	La matrice de confusion pour une tâche de classification binaire.	85
4.9	La courbe ROC et la surface sous la courbe AUC [164].	87
4.10	La distance de Hausdorff entre la structure X et Y est le maximum de deux distances calculées dans la figure. Cette illustration est adaptée de [165].	89
5.1	Les algorithmes utilisés pour la modélisation des vaisseaux en fonction de leur taille et contraste. La figure est adaptée de [106]	94
5.2	Atlas de l'arbre des artères coronaires	96
5.3	Pipeline de l'extraction des lignes centrales des artères coronaires	97
5.4	Histogramme des valeurs de l'unité de Hounsfield pour les points appartenant à ligne centrale de la base d'entraînement	98
5.5	Architecture de CenterlineNet	99
5.6	Exemple de patches de vaisseaux "vrai" et "faux" : la première ligne affiche les "faux" vaisseaux tandis que la dernière montre les "vrais" vaisseaux.	100
5.7	Détection de l'aorte et la région cardiaque	104
5.8	Modèles 3D des prédictions CenterlineNet ainsi que des segmentations de la vérité terrain. La ligne supérieure représente les résultats de la prédiction tandis que la ligne inférieure affiche la vérité terrain correspondante pour le même patient et à partir de la même vue.	106
5.9	Pipeline mise à niveau pour l'extraction des lignes centrales des artères coronaires	108

5.10	Segmentation de la région du coeur en sept grands structures : aorte, myocarde, atrium droit, atrium gauche, ventricule droit, ventricule gauche et artère pulmonaire.	110
5.11	Vue d'ensemble du pipeline de segmentation en deux étapes, multi-labels et entièrement automatique de Payer et al [178]. La figure est adaptée de [178]. . . .	110
5.12	Évaluation visuelle des résultats de la combinaison de Payer et al [178] reproduit avec l'élimination des artères produits par CenterlineNet. La première ligne affiche les prédictions alors que la deuxième contient les vérités terrain. Ces patients font parti de la configuration de validation croisée.	113
5.13	Perte d'un sous arbre complet (la partie droite de l'arbre coronaire) à cause des interruptions dans la prédiction de CenterlineNet montrées avec les cadres verts dans l'image (a)	115
5.14	Pipeline complet de l'architecture proposé pour l'analyse intelligente des composants connectés.	116
5.15	La perte d'un sous arbre complet (la partie droite de l'arbre coronaire) à cause des interruptions est récupéré grâce à l'analyse intelligente des composants connectés (Les artères sont épaissies pour des raisons d'affichage).	117
6.1	La maladie des artères coronaires. La figure est adaptée de [125]	123
6.2	Affichage de deux artères coronaires avec la projection à intensité maximale (MIP). 128	
6.3	Différentes méthodes de génération de MPR : a) MPR projetée, b) MPR étirée, c) MRP aligné. La figure est adaptée de [147]	129
6.4	L'idée générale de cMPR : alignement des structures contournés. La figure est adaptée de [181]	130
6.5	Extraction des sections transversales d'une artère coronaire à l'aide de cMPR. . .	132
6.6	La représentation cMPR d'un artère coronaire atteint d'une sténose sévère. . . .	133

6.7	Les Résultats de la transformation cMPR sur des artères coronaires. La première ligne affiche la reconstruction MIP alors que la deuxième montre les cMPR . . .	134
6.8	Le pipeline de la détection de la sténose. L'artère est reconstruite par la cMPR puis elle est corrigée et améliorée. Le CNN prend deux entrées : un fenêtrage défini de l'artère reconstruite et l'artère corrigée. L'ensemble des prédictions sur ces patches forme le rapport de la sténose.	135
6.9	Le déroulement de la détection des lésions : l'artère reconstruit par cMPR est traitée par une approche de fenêtrage. Chaque fenêtre est fournie au modèle de la détection de la sténose. La largeur de la fenêtre égale à 36 pixels. Le découpage se fait avec un stride de 4. Nous ne montrons que 4 fenêtres ici pour des fins de visualisation. Le résultat final du découpage est affiché en dessous de l'artère. Le modèle prédit une valeur réelle de 0 à 2 avec 0 : pas de sténose, 1 : sténose non significative et 2 : sténose significative.	137
6.10	Des exemples de la reconstruction cMPR avec des annotations imprécises.	138
6.11	Les étapes de pré-traitement du volume cMPR : d'abord un filtre de Frangi est appliqué pour accentuer les structures vasculaires. Ensuite, nous créons une carte de chaleur à partir du filtrage de Frangi à l'aide de la méthode de ligne de niveau. Finalement, nous appliquons un seuillage des valeurs et un filtrage gaussien. . .	139
6.12	Le résultat du pré-traitement d'un long vaisseau (affichage 3D à gauche et MIP à droite).	139
6.13	Le résultat final après la segmentation grossière des artères et le recalibrage. . .	141
6.14	L'architecture du CNN à double entrée de la détection de la sténose.	141
6.15	Comparaison entre les matrices de confusion du modèle à double entrée en utilisant la régression et la classification	143
6.16	Comparaison entre les cartes de caractéristiques du modèle à double entrée en et celui à une seule entrée.	144

6.17	Les rapports de la sténose prédits par le modèle pour un ensemble des artères.	144
6.18	Les rapports de la sténose prédits par rapport au diagnostic des experts sur l'ensemble de l'arbre artériel d'un patient.	145
6.19	L'architecture du modèle proposé pour la classification des plaques. Le modèle est entraîné via l'apprentissage par transfert à partir du branche de réseau associée à l'entrée cMPR du modèle de la détection de la sténose.	146
6.20	Les entrées de notre modèle (le morceau de lésion identifié par le modèle de la détection de la sténose) en fonction de leur type. A gauche s'affiche la MIP de la lésion alors qu'à droite une section transversale de la partie atteinte est représenté. Le volume de calcification (blanc foncé) est l'indicateur du type de la plaque : douce en absence de calcification, mixte si la calcification occupe moins de 50% de la zone de rétrécissement et calcifiée si elle dépasse le seuil de 50%.	147
6.21	Comparaison entre les matrices de confusion du notre modèle et le modèle de Zreik et al [153]. Chacun a utilisé sa propre base de données. Par conséquent, la comparaison est à des fins approximatives et non concluantes.	148
7.1	Pipeline complet de l'algorithme de segmentation des anévrismes intracrâniens : les données brutes des MRA TOF sont prétraitées afin d'extraire les vaisseaux. Ensuite, le modèle réseau neuronal AneurysmNet prédit les anévrismes présumés et, enfin, un algorithme de post-traitement simple basé sur la taille de la structure prédite est mis en œuvre pour éliminer les petites prédictions bruitées.	156

- 7.2 **Étude de normalisation** : élimination des résidus bruités dus à l'inhibition de l'intensité à l'extérieur des vaisseaux (première ligne). La normalisation du Z-score entraîne un échec de la segmentation des vaisseaux alors que celle sans normalisation conserve une partie crânienne importante en raison de la similarité des intensités (rangée du milieu). La normalisation de Nyul et Udupa aide l'algorithme de segmentation des vaisseaux à trouver l'arbre artériel complet. (dernière ligne) 157
- 7.3 **Pipeline de segmentation des vaisseaux** : Une étape d'extraction des vaisseaux, suivie d'une transformation morphologique puis d'un processus d'élimination des petits vaisseaux, permet une segmentation précise des vaisseaux et de certaines autres structures. L'omission de ces petites réponses permet une extraction complète de l'arbre vasculaire (les figures montrées sont les MIPs du volume entier et les vaisseaux sont intensifiés pour des raisons d'affichage). . . . 159
- 7.4 Modèle à double entrées hybride 3D et 2,5D et à sortie unique 160
- 7.5 **Les types d'entrée** : la première ligne est une représentation d'un vaisseau sain en 3D et MIP, tandis que la deuxième ligne est l'illustration d'un vaisseau contenant un anévrisme intracrânien. 161
- 7.6 Une correspondance entre le rayon de l'anévrisme en mm (à gauche) et la taille de son volume total en coordonnées réelles (en voxel). 163
- 7.7 **Un cas de réduction des faux-positifs** : bien que le modèle proposé ait détecté le véritable anévrisme et éliminé 11 faux positifs, il a détecté un faux anévrisme qui n'a pas été détecté par le modèle 2,5D MIP (les anévrismes sont représentés en noir alors que le fond est en blanc, l'inversion des couleurs est pour des fins d'affichage) 166

7.8	Un cas de 100 % de sensibilité et 0 faux-positif par cas : le modèle proposé élimine les fausses détections produites par le modèle de base à un seul canal tout en gardant les vrais anévrismes (les anévrismes sont représentés en noir et l'arrière-plan en blanc, l'inversion des couleurs est destinée à l'affichage).	166
7.9	Un cas de prédiction de 100% de sensibilité de 2 faux positifs par le modèle proposé. La prédiction complète est illustrée en (a). Les figures (b) et (c) soulignent les faux positifs prédits. La ligne en dessous compare la vérité de terrain, les résultats des modèles MIP et hybride sur le même profondeur (même coupe du volume MRA).	167
7.10	Le rayon en <i>mm</i> des fausses prédictions pour le modèle Double-Entrée Unique-Sortie ainsi que pour le modèle classique	168
7.11	La sensibilité de détection en fonction du diamètre de l'anévrisme pour les 3 équipes les plus performantes du challenge en comparaison avec notre algorithme. Le diamètre de l'anévrisme est divisé en quatre quartiles (principalement les classes petite, modérée, grande et sévère). [199]	171

Liste des acronymes

3D	3 dimensions
2D	2 dimensions
AA	Aorte ascendante
ACD	Artère coronaire droite
ACG	Artère coronaire gauche
ACP	Analyse des composantes principales
AD	Atrium droit
ADAM	Aneurysm detection and segmentation
AG	Atrium gauche
AHA	American heart association
ANN	Artificial neural network
AP	Artère pulmonaire
AUC	Area under curve
BRATS	Multimodal brain tumor segmentation challenge
CAD-RADS	Coronary artery disease – Reporting and data system
CAT08	Coronary artery tracking 2008
CHU	Centre hospitalier universitaire
cMPR	curved Multiplanar reformatting
CNN	Convolutional neural network
CT	Computed tomography
CTA	Computed tomography angiography
DSA	Digital subtraction angiography
DSC	Dice similarity coefficient
ECG	Électrocardiogramme
FCN	Fully connected network
FN	False negative

FP	False positive
FP/c	False positive per case
GPU	Graphics processing unit
GRU	Gated recurrent unit
HOT	High order tensor
HSA	Hémorragie sous-archnoïdienne
HU	Hounsfield unit
IA	Intelligence artificielle
ILSVRC	ImageNet large scale visual recognition challenge
IRM	Imagerie par resonance magnétique
ISBI	International symposium on biomedical imaging
ISLES	Ischemic stroke lesion segmentations
IUA	Intracranial unrupted aneurysms
LAD	Left anterior descending
LCX	Left circumflex
LiTS	Liver tumor segmentation challenge
Lr	Learning rate
MCC	Matthews correlation coefficient
MHD	Modified Hausdorff distance
MICCAI	Medical image computing and computer assisted intervention
MIP	Maximum intensity projection
MLP	Multilayer Perceptrons
MM-WHS	Multi modal whole heart segmentation
MPR	Multiplanar reformatting
MRA	Magnetic resonance angiography
Myo	Myocarde du ventricule gauche
OMS	Organisation mondiale de la santé
PIV	Posterior interventricular vein
RCNN	Recurrent convolutional neural network
ReLU	Rectified linear unit

RNN	Recurrent neural network
ROC	Receiver operating characteristic
SARS-Cov2	Severe acute respiratory syndrome coronavirus 2
SE	Squeeze and excitation
SVM	Support vector machine
Tanh	Tangente hyperbolique
TN	True negative
TOF	Time of flight
TP	True positive
VD	Ventricule droit
VF	Vecteur de Fisher
VG	Ventricule gauche
VGG	Visual geometry group
VS	Volumetric similarity
XOR	Ou exclusive

Chapitre 1

Introduction

1.1 Contexte général de la thèse

Nous sommes à l'aube de l'ère des nouvelles techniques d'acquisition d'images médicales, des modèles médicaux prédictifs et des simulations réalistes d'images. Le suivi des patients en temps réel et les bases de données médicales à grande échelle deviennent omniprésentes et offrent la possibilité et l'occasion d'améliorer encore la santé des patients aussi que notre compréhension de ces maladies. Les données contenues dans ces bases de données n'ont d'utilité que par les questions auxquelles elles peuvent aider à répondre, les idées qu'elles peuvent générer et les décisions qu'elles permettent de prendre. Des études cliniques sont menées sur de grandes populations afin de recommander un traitement, d'ajuster la thérapie en examinant des patients similaires, précédemment traités, en comparant leurs résultats et en prédisant ce qui est susceptible de se reproduire.

L'introduction de la tomодensitométrie (appelé aussi CT scan) dans les années 70, a radicalement changé le cours de la gestion des plusieurs maladies. Le scanner présente plusieurs avantages par rapport à la radiographie médicale bidimensionnelle traditionnelle. D'une part, la tomодensitométrie élimine la superposition d'images de structures situées en dehors de la zone d'intérêt [2]. D'autre part, les scans de tomодensitométrie offrent une plus grande résolution d'image, distinguant des tissus dont la densité radiographique diffère de 1% ou moins



FIGURE 1.1 – Aquilion ONE GENESIS Edition : un CT scanner moderne qui utilise l'intelligence artificielle pour la reconstruction des images [3]

permettant à l'examen d'être plus détaillée. L'utilisation de la tomodensitométrie a augmenté de façon spectaculaire au cours des deux dernières décennies dans de nombreux pays et a valu aux inventeurs de l'appareil (le physicien sud-africain Allan M. Cormack et l'ingénieur électrique britannique Godfrey N. Hounsfield) le prix Nobel de médecine en 1979. On estime que 72 millions de scanners ont été réalisés aux États-Unis en 2007 et plus de 80 millions en 2015 [1]. La tomodensitométrie peut servir à détecter multiple maladies dans des différents parties du corps notamment, différents types de cancers, la propagation des tumeurs, les infections, l'ostéoporose et les douleurs thoraciques ou abdominales.

Nous nous intéressons, durant cette thèse, aux maladies coronariennes. Selon les statistiques les plus récentes de l'organisation mondiale de la santé (OMS), la maladie des artères coronaires est

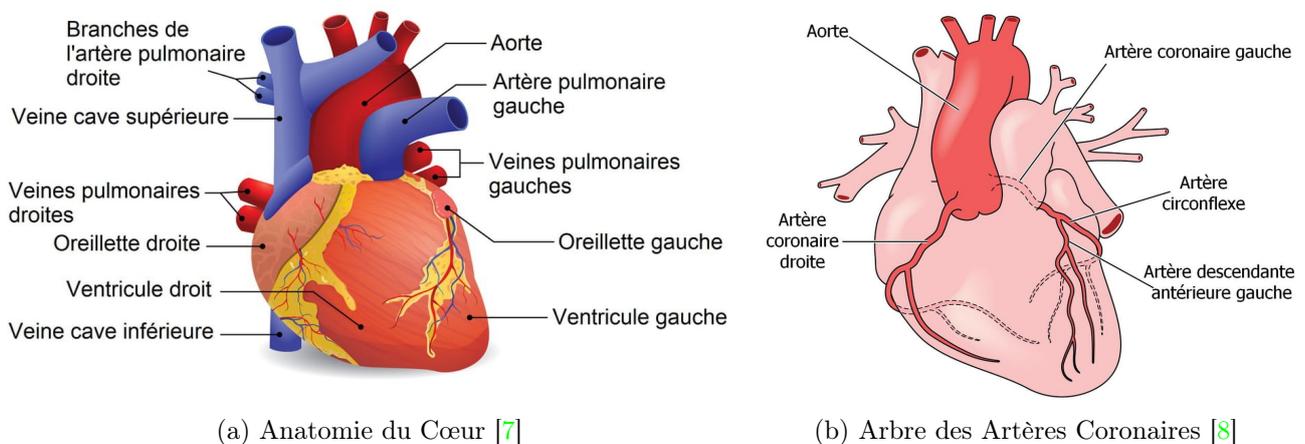


FIGURE 1.2 – Anatomie du sous structures du coeur et de l'arbre artériel coronaire.

l'une des causes de décès les plus répandues dans le monde. Environ 17 millions de morts dues à l'un ou plusieurs types de maladies coronariennes ont été mesurées dans le monde en 2020. Qu'est ce que la coronaropathie alors ? Quelles sont ses causes ? Comment se fait le diagnostic clinique ?

1.2 Accidents Vasculaires Cérébraux

1.2.1 Anatomie du coeur et des artères coronaires

Le cœur, situé dans le médiastin, est le centre du système circulatoire. Il est composé de tissu musculaire cardiaque, qui se contracte et se relâche en permanence et nécessite un apport constant d'oxygène et de nutriments afin de maintenir une circulation sanguine continue. Les artères coronaires sont le réseau de vaisseaux sanguins qui pompent le sang vers le myocarde (le muscle cardiaque) pour l'alimenter en oxygène et en nutriments. Comme l'illustre la Fig 1.2, l'arbre artériel comprend deux branches principales, à savoir l'artère coronaire gauche (ACG) et l'artère coronaire droite (ACD), qui prennent naissance à la racine de l'aorte, près du sommet du cœur. Dans la branche de l'ACG, le segment initial entre l'aorte et la première bifurcation est appelé la coronaire principale gauche (LM). La coronaire LM se ramifie généralement en deux branches : la branche descendante antérieure gauche (LAD) et la branche descendante antérieure gauche (LAD) et l'artère circonflexe gauche (LCX). D'autre part, le ACD prend normalement naissance au niveau de la cuspside coronaire droite et se dirige vers la branche interventriculaire. Dans 85 % des cas, l'ACR est le vaisseau dominant et fournit du sang à la branche descendante postérieure, qui se déplace dans le sillon de la veine interventriculaire postérieure (PIV). Cependant, l'anatomie exacte des artères coronaires peut présenter un large éventail de géométries, en fonction de chaque individu.

1.2.2 Maladie coronarienne

La maladie coronarienne (coronaropathie) se produit lorsque les artères coronaires sont obstruées et se rétrécissent, ce qui entraîne un manque d'oxygène et d'autres nutriments pour le cœur, qui finit par s'arrêter de battre. L'athérosclérose est une condition dans laquelle les plaques, typiquement composées de graisse, cholestérol, de calcium et d'autres substances présentes dans le sang, se bouchent dans les moyennes et grandes artères du cœur. Si ce phénomène n'est pas traité, il va durcir et forcer les artères à rétrécir au fil du temps. En conséquence, la circulation du sang riche en oxygène vers les organes et les différentes parties du corps est réduite, ce qui peut entraîner de graves conséquences, notamment un infarctus du myocarde, voire la mort. La Fig 1.3 ci-dessous illustre une comparaison avant et après la formation d'une plaque dans un vaisseau sanguin.

1.2.3 Diagnostic clinique

Du point de vue du clinicien, il est important d'avoir l'ensemble de l'arbre artériel à sa disposition afin d'évaluer la présence des anomalies coronaires (gravité de la sténose, rétrécissement des artères, etc.) et faciliter le traitement ultérieur. La tomographie assistée par ordinateur (CT) est une modalité d'imagerie médicale invasive, qui offre une alternative pour l'imagerie des artères coronaires. Les progrès récents de la technologie d'imagerie vasculaire utilisant la

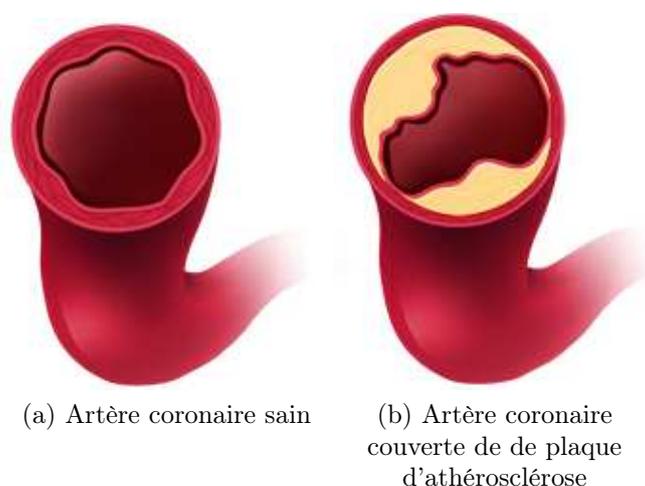


FIGURE 1.3 – Maladie Coronarienne : formation d'une plaque d'athérosclérose [9].

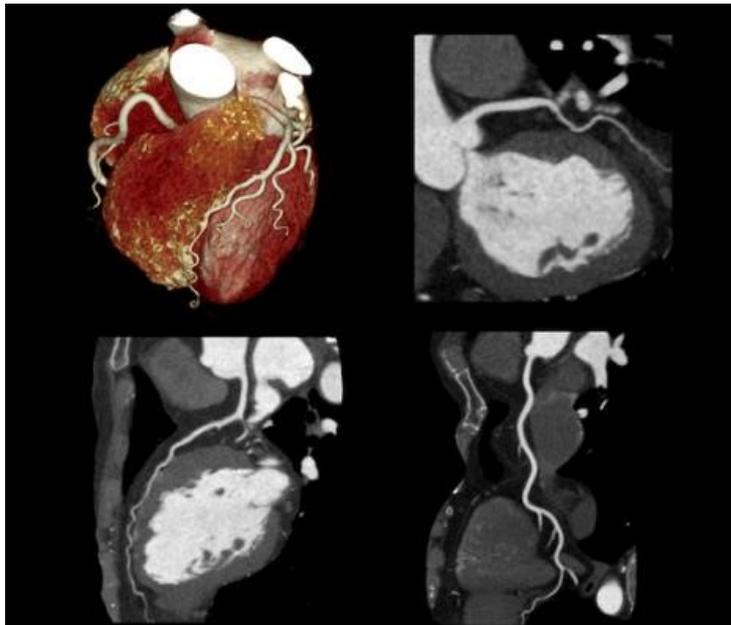


FIGURE 1.4 – Image CT et Reconstruction 3D

tomodensitométrie à coupes multiples permettent de fournir des ensembles de données volumétriques à haute résolution spatiale et temporelle du corps. Les tomodensitomètres les plus modernes, équipés de détecteurs à 320 rangées, sont capables d'imager les artères coronaires en un seul battement de cœur, produisant un ensemble de données d'image 3D avec une résolution spatiale inférieure à un demi-millimètre dans les trois directions. Le scanner est ainsi devenu un examen de routine fiable pour l'évaluation des maladies cardiovasculaires dans la pratique clinique.

Un scanner moderne, en général, consiste en une structure en forme de tunnel avec un tube à rayons X d'un côté et le détecteur de l'autre côté. Avant le scanner, le patient est placé sur la table, et le technicien médical place une ligne intraveineuse dans le bras du patient. En injectant le produit de contraste, il fournit une meilleure visualisation des artères. Pour synchroniser l'acquisition et la reconstruction de l'image avec le mouvement du cœur, le signal de l'électrocardiogramme (ECG) est généralement surveillé. En surveillant en permanence le signal ECG, les images en coupe transversale du cœur sont acquises et reconstruites au cours du même cycle cardiaque, ce qui compense le mouvement du cœur qui bat. Pendant l'examen, l'agent de contraste est automatiquement injecté et il est conseillé au patient de retenir sa respiration pendant 3 à 5 secondes. Le scanner enregistre l'atténuation des rayons X à travers un plan ayant une section transversale d'épaisseur finie du patient et ces mesures d'atténuation sont

ensuite reconstruites à l'aide d'un système informatique dédié pour produire un volume 3D du corps. Ces images permettent au cardiologue de déterminer si des plaques ou des blocages sont présents dans les parois artérielles.

1.3 Risque de rupture d'anévrismes intracrâniens

Malgré la puissance du scanner et son utilité dans la détection de diverses maladies, il reste limité dans les cas où la maladie est suffisamment sensible pour être découverte et pire encore, si dans la plupart des cas la détection est accidentelle. Nous parlons des cas où le diagnostic par scanner arrive en état de confirmation et non pas de prévention. C'est l'exemple de la rupture des anévrismes intracrâniens.

1.3.1 la détection des anévrismes intracrâniens non rompus

Une maladie qui touche le cerveau affecte nécessairement l'identité d'une personne, le sens et l'interprétation de sa vie. Les anévrismes intracrâniens (IUA) se retrouvent chez 2 à 3,5% de la population générale adulte. La prévalence varie en fonction de la charge en facteurs de risque, et peut être supérieure à 20% dans certains sous-groupes. La plupart des anévrismes non rompus sont découverts de manière accidentelle lors d'une IRM de routine. La présence

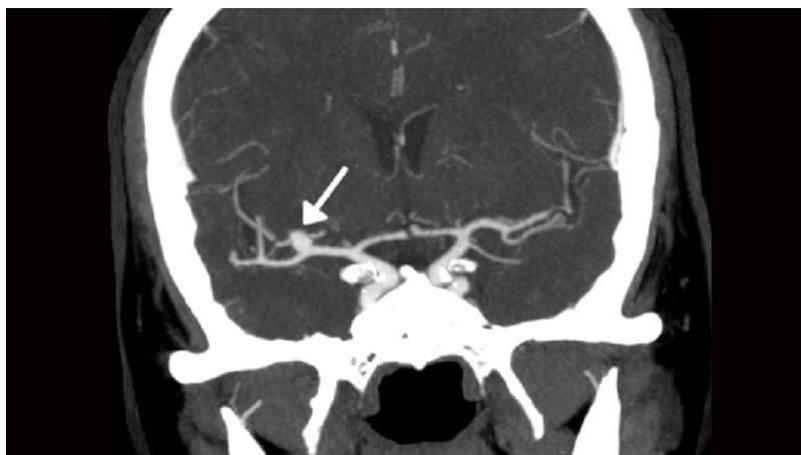


FIGURE 1.5 – Détection d'un anévrisme intracrânien non rompu à partir d'une IRM en projection à intensité maximale (MIP)

d'un anévrisme peut n'être connue que trop tard, lorsqu'il se rompt. Environ un quart des IUA se rompent au cours de la vie du patient et provoquent une hémorragie sous-arachnoïdienne (HSA). L'HSA survient à un âge moyen relativement bas, avec un taux de fatalité de près de 50%, et la moitié des survivants souffrent d'un handicap permanent. Par conséquent, l'HSA est une maladie dévastatrice pour les patients, leurs familles et la société. La disponibilité et l'utilisation accrues de l'imagerie cérébrale ont conduit à un nombre croissant de découvertes fortuites d'HSA non rompues. Le risque de rupture augmente avec la taille de l'anévrisme, mais la majorité des HSA proviennent de petits anévrismes. La gestion des IUA non rompus reste controversée, car le risque de complications liées à un traitement prophylactique doit être mis en balance avec le risque inconnu de rupture pour un anévrisme individuel.

1.3.2 Diagnostic clinique

La détection et la mesure des IUA peuvent être difficiles et il a été rapporté qu'environ 10% de toutes les IUA sont manquées lors de l'acquisition des images. La détection est particulièrement difficile pour les petites IUA et la détection par les radiologues des IUA de diamètre inférieur à 5 mm à partir des images IRM peut avoir une sensibilité aussi faible que 35%. Cependant, la détection par les radiologues s'améliore avec l'augmentation de la résolution des IRMs, en particulier avec des intensités de champs plus élevés. Dans la pratique clinique, la détection des anévrismes est effectuée par un radiologue qui cherche soigneusement les coupes axiales de l'IRM-TOF, souvent combinées à des reconstructions multi-planaires coronales et sagittales, à une projection d'intensité maximale (MIP) ou à une reconstruction volumique 3D, avant d'effectuer des mesures de taille de l'anévrisme en 2D comme indiqué dans la Fig 1.5. Avec le nombre d'individus suivis en augmentation constante, la rapidité du flux de travail clinique pourrait être améliorée grâce à des méthodes automatiques de détection et de quantification des IUA à partir des IRM-TOF. Cependant, il est important que ces méthodes ne compromettent pas la précision de la détection et la mesure des IUA. La segmentation volumétrique automatisée des IUA permettrait la quantification 3D des IUA et pourrait aider à la prédiction du risque de rupture des IUA.

1.4 Automatisation de la détection

Ce n'est que lorsque nous essayons d'écrire un programme pour imiter le raisonnement des experts médicaux sur un ordinateur que nous pouvons commencer à apprécier pleinement la véritable complexité des tâches visuelles effectuées par leur cerveau. La simplicité de l'extraction des informations pertinentes des images est très trompeuse. L'approche de l'apprentissage automatique est très différente. Au lieu de coder manuellement les règles explicites qui imitent l'approche des cardiologues, nous spécifions un modèle d'apprentissage et laissons l'algorithme d'apprentissage déterminer automatiquement un ensemble de règles en examinant les données, c'est-à-dire en entraînant le modèle. Dans le cadre de l'apprentissage supervisé, un ensemble d'exemples ainsi que les résultats souhaités (par exemple, des images et leurs segmentations respectives) sont présentés à l'algorithme d'apprentissage. L'algorithme sélectionne ensuite les règles qui transforment le mieux les entrées en sorties souhaitées. Il est important que le modèle appris soit généralisable, c'est-à-dire qu'il puisse prédire de manière fiable les résultats pour des images non vues auparavant, tout en ignorant les différences d'acquisition non pertinentes.

1.4.1 Intelligence artificielle

Le terme d'intelligence artificielle a été évoqué pour la première fois en 1950 par Alan Turing. Ce mathématicien a élaboré un test permettant de vérifier la capacité d'un système à faire preuve d'intelligence humaine. De nos jours, le test de Turing est toujours utilisé pour mesurer l'intelligence de certaines machines. Depuis, les algorithmes d'intelligence artificielle contemporains s'attaquent principalement à deux types de problèmes : la première catégorie contient les problèmes qui sont facilement décrits à l'aide d'équations et de relations mathématiques sophistiquées, tandis que la seconde catégorie est constituée de problèmes difficiles à formuler. Un exemple de la première catégorie est "Deep Blue". Garry Kasparov, le champion du monde d'échecs, a été battu début 1997 par un algorithme informatique appelé Deep Blue. En effet, le jeu d'échecs est limité à 64 cases et 32 pièces et donc à un nombre maximum de coups. Cependant, pour le cerveau humain, l'exploration de tous les coups possibles semble un processus

difficile et très lent comparé aux algorithmes informatiques effectuant la même tâche. Les problèmes de la deuxième catégorie sont assez différents. Bien qu'ils puissent sembler triviaux pour les humains, ils sont d'une difficulté prohibitive pour être formulés en équations mathématiques simples comme les problèmes de reconnaissance faciale ou d'estimation de l'âge par exemple. La première approche représente tous systèmes dotés de mécanismes de raisonnement capables d'interpréter des données symboliques qui constituent une base de connaissance. Cette approche permet de traiter des questions de logique formelle pour prendre des décisions intelligentes en fonction de règles, faits et raisonnements établis par le savoir humain. La seconde approche, s'inspire du fonctionnement des neurones biologiques. En effet, cette méthode regroupe tous les systèmes composés de sous-élément interconnectés capables de traiter et de communiquer des informations entre eux. En outre, cette intelligence artificielle permet d'extraire des règles implicites contenues dans des bases de données volumineuses. Ces réseaux neuronaux artificiels sont généralement optimisés par des méthodes d'apprentissage afin d'apprendre de leurs erreurs par comparaison statistiques avec les résultats attendus.

Le développement général des volumes de données disponibles et le perfectionnement des nouvelles technologies, plus particulièrement des algorithmes et du matériel informatique, font de la santé un secteur de développement immense et extrêmement diversifié. Le croisement entre l'intelligence artificielle et la médecine permet de concevoir des systèmes plus préventifs et personnalisés, apportant une amélioration du suivi médical des patients et une assistance considérable aux professionnels de santé.

1.4.2 Intelligence artificielle pour l'imagerie médicale

L'intelligence artificielle est devenue un acteur majeur de la médecine du futur en proposant des modèles toujours plus préventifs et personnalisés, offrant une amélioration constante de la qualité des soins et une assistance précieuse aux professionnels de santé. Ses applications ont été conçues et appliquées à des pratiques comme l'aide au diagnostic, les opérations assistées et les traitements personnalisés. L'imagerie médicale, et plus particulièrement l'aide au diagnostic, est le secteur de la santé où les recherches et les enjeux sont les plus importants. Le grand enthousiasme

siasme et le dynamisme du développement des systèmes d'IA en radiologie sont démontrés par l'augmentation des publications sur ce sujet. Il y a seulement 10 ans, le nombre total de publications sur l'IA en radiologie dépassait tout juste 100 par an. Par la suite, nous avons connu une augmentation considérable, avec plus de 700-800 publications par an en 2016-17. Au cours des deux dernières années, la tomographie assistée par ordinateur (CT) et l'imagerie par résonance magnétique (IRM) ont collectivement représenté plus de 50 % des articles, bien que la radiographie, la mammographie et l'échographie soient également représentées. La neuroradiologie (évaluée comme l'imagerie du système nerveux central) est la sous-spécialité la plus impliquée (représentant environ un tiers des articles), suivie de la radiologie musculo-squelettique, cardiovasculaire, mammaire, urogénitale, pulmonaire/thorax et abdominale, chacune représentant entre 6 et 9% du nombre total d'articles. L'IA a actuellement un impact sur le domaine de la radiologie, l'IRM et la neuroradiologie étant les principaux domaines d'innovation.

1.5 Contributions de la thèse

Les principales contributions de cette thèse sont liées au développement de méthodes robuste pour l'extraction des artères coronaires, la détection de la sténose, la quantification des plaques, la segmentation des anévrismes intracrâniens non rompus et la collection d'une base de données des scanners cardiaques propre au CHU Poitiers. La contribution majeure de cette thèse est de développer des méthodes efficaces dans le but principal d'aider les cliniciens dans les études d'images CT en fournissant des analyses plus précises avec des informations qualitatives et quantitatives. Les contributions les plus significatives de cette thèse peuvent être classées en quatre thèmes principaux : l'extraction des artères coronaires, la détection de la sténose et la quantification des plaques, la segmentation des anévrismes intracrâniens non rompus, la collection d'une base de données des scanners cardiaques propre au CHU Poitiers. Ces contributions s'appuient sur une revue de la littérature dans les domaines abordés.

1.5.1 La revue de la littérature

La revue des travaux récents sur les différents sujets liés à l'imagerie médicales (chapitre 2) constitue ainsi une des contributions dérivées de ce travail de thèse. Nous avons d'abord présenté une vue d'ensemble des approches basés sur l'intelligence artificielle qui ont révolutionné le domaine de traitement d'image en général. Nous avons introduit les techniques de l'apprentissage profond, leur formulations mathématiques, leur intérêts ainsi que les travaux les plus reconnus. Nous avons proposé un résumé des applications récentes de l'apprentissage profond dans l'analyse d'images médicales qui impliquent diverses tâches liées à la vision par ordinateur et l'aide au diagnostic.

Nous avons ensuite présenté une étude de la littérature sur le traitement des images CTA cardiaques pour l'extraction des artères coronaires et la détection des maladies coronariennes (sténose). Nous avons organisé les approches, en fonction des caractéristiques à extraire, en trois catégories principales.

Une telle étude nous a permis de mieux appréhender les défis liés à la segmentation des vaisseaux et la détection des lésions. Par conséquent, nous pouvons motiver les choix des techniques que nous utilisons pour les résoudre. Par la suite, à chaque chapitre, nous rappelons les travaux les plus récents relatifs au sujet traité et nous comparons notre approche proposée à celles de l'état de l'art (chapitre 3).

1.5.2 Extraction des artères coronaires

Une partie importante de cette thèse porte sur les outils de traitement d'images CT cardiaques pour une analyse efficace des maladies coronariennes. Dans une première partie (chapitre 5), nous avons implémenté un pipeline complet pour l'extraction des lignes centrales des artères coronaires. Nous avons proposé d'utiliser l'apprentissage profond pour notre approche. Notre pipeline complet ait accès à un ensemble des méthodes analytiques classiques et jouit de la puissance des CNN pour créer une carte de caractéristiques discriminative plus appropriée pour les artères coronaires que pour les formes cylindriques générales. Notre modèle parvient à récupérer l'arbre artériel entier y inclus les branches secondaires.

Dans une deuxième partie du chapitre, nous avons abordé les défis voisins liés à notre étude et fourni des solutions pour la segmentation des sous-structures cardiaques et le clustering des artères coronaires. Nous avons donc fait évoluer cette architecture pour y inclure un modèle de segmentation des sept sous-structures du cœur. Outre la complémentarité qu'il apporte à ce pipeline, il peut être utilisé séparément pour des tâches de mesure des pathologies de ces structures. Nous avons aussi adressé le problème des interruptions des artères coronaires, ce qui est préjudiciable pour la détection de sténose. Nous avons proposé un modèle basé sur l'apprentissage profond dans notre pipeline qui remplace l'analyse classique des composants connectés. Il est capable d'isoler les artères coronaires même en présence de prédictions bruitées et de multiples interruptions et discontinuités.

Finalement, Nous avons montré que cette approche est assez robuste et donne d'excellents résultats sur une base de données diversifiée et difficile, à savoir la base de données Rotterdam [163]. Notre modèle arrive à extraire plus de 95% de l'arbre artériel principal et les branches secondaires également.

1.5.3 Détection de la sténose et classification des plaques

Dans le contexte de la détection et la classification des lésions coronaires, nous proposons deux approches automatisées basées sur l'apprentissage profond. La motivation principale de cette approche est sa capacité de surmonter les limites des techniques basées sur les caractéristiques manuelles pour détecter toutes les pathologies coronaires (en utilisant une seule approche).

Dans une première partie, nous avons proposé d'appliquer la transformation cMPR pour éviter les problématiques de segmentation des artères et s'appuyer sur l'extraction efficace des lignes centrales par notre méthode susmentionnée. L'alignement des artères est un processus fréquent dans l'usage clinique et fournit une visualisation simpliste de ces structures.

Dans une deuxième partie, nous avons proposé un modèle hybride à double entrées 3D pour la détection de la sténose. Nous avons constaté que les méthodes qui se basent sur le cMPR sont très vulnérables à la qualité de l'extraction de la ligne centrale des artères coronaires. C'est pourquoi, nous avons implémenté un module de pré-traitement qui corrige et améliore cette

reconstruction. Nous avons montré qu'en combinant les volumes reconstruits et les volumes corrigés, les performances de notre modèle s'améliorent nettement.

Finalement, peu de méthodes explorent l'apprentissage profond pour la détection des sténoses dans l'état de l'art. Malgré les avancées et les innovations qu'ils proposent, la majorité n'offre pas une classification de la type des plaques. C'est dans ce cadre, que nous avons introduit une méthode qui se rajoute à celle de la détection de sténose pour prédire le type de calcification (doux, calcifiée, mixte).

1.5.4 Segmentation des anévrismes intracrâniens non rompus

¹ Pour renforcer le cadre préventif dans lequel cette thèse s'inscrit, nous avons attaqué le risque de rupture des anévrismes intracrâniens. Malheureusement, les images CT ne permettent pas de détecter au préalable ces structures. C'est pourquoi, nous avons proposé une nouvelle méthode pour la segmentation des anévrismes intracrâniens non rompus à partir des images MRA-TOF. Pour rectifier le manque constaté d'automatisation de quelques approches et l'unidimensionnalité des autres après l'étude approfondie de l'état de l'art, nous avons introduit une nouvelle méthode reposant sur une double entrée de données hybrides (2D MIPs et 3D). Celle-ci a atteint la meilleure sensibilité lors du défi ADAM¹ (Aneurysm Detection And segmentation Challenge) et se compare aux performances de l'inspection visuelle humaine. Le centre de notre pipeline est un modèle d'apprentissage profond qui est associé à un bloc de pré-traitement complet et, ensemble, ils présentent un fort potentiel de généralisation sur des bases de données difficiles.

1.5.5 Collecte de la base de données CHU Poitiers

Une des contributions majeures de notre thèse est la collecte et la création d'une base de données propre au CHU Poitiers. En travaillant avec une équipe d'experts et de cliniciens, nous avons réussi à mettre en place une base de données de plus de 30 patients acquis avec le

1. Aneurysm Detection And segmentation Challenge, <http://adam.isi.uu.nl/>

scanner Acquilon. La population cible est tout patient adulte ayant un CT scan cardiaque avec un risque de sténose potentiel. Certains scans sont négatifs (aucune sténose détectée) afin de refléter le contexte clinique réel.

1.6 Organisation du manuscrit

Après ce chapitre introductif, nous entamons le reste du manuscrit avec le chapitre 2 dédié à l'introduction des techniques de l'intelligence artificielle que nous utilisons tout au long de cette thèse. Nous commençons d'abord par l'explication de la notion d'apprentissage automatique dans la section 2.1. Par la suite, nous introduisons dans la section 2.2 l'apprentissage profond qui est l'une des méthodes d'apprentissage supervisé les plus utilisées. Nous décrivons l'évolution de cette branche d'apprentissage et nous présentons les nouveaux concepts en relation avec cette technique. Avant de conclure, nous détaillons dans la section 2.3, les architectures les plus reconnues avec un intérêt particulier à celles qui font partie de notre travail.

Le chapitre 3 de l'état de l'art aborde les multiples problématiques auxquels nous sommes confrontés. Nous commençons la première section 3.1 en introduisant les domaines d'application des méthodes de l'apprentissage profond ainsi que ses utilisations dans le domaine de l'imagerie médicale. Ensuite, nous explorons dans une deuxième section 3.2 la revue de la littérature des algorithmes d'extraction de structures vasculaires, en nous concentrant sur les images renforcées par contraste, notamment les angiographies par tomographie et par résonance magnétique. Pour combler ce chapitre, la dernière section 3.3 se consacre aux développements récents des méthodes de détection des sténoses et de classification des plaques.

Le chapitre 4 s'intéresse à la description des données utilisées tout au long de cette thèse ainsi qu'aux métriques d'évaluation spécifiques à chacun des défis abordés. Comme convenu, ce chapitre est divisé en deux sections principales : la première, 4.2, présente les cinq différentes bases de données utilisées dans ces travaux, en particulier la base de données de CHU Poitiers qui fait l'une des contributions de cette thèse. La deuxième section, 4.3, précise les métriques choisies pour analyser, comprendre et évaluer les performances des différents modèles proposés.

A compter du chapitre 4, nous abordons la partie des contributions. Les chapitres 5, 6 et 7

ont une structuration similaires avec quelques différences dans des détails mineurs propres à chacun.

L'ensemble du chapitre 5 est dédié à la problématique de l'extraction des artères coronaires. Il s'organise comme suit : tout d'abord, nous commençons par une introduction générale suivi d'un résumé des travaux précédents (sec 5.1 et 5.2) à partir desquels nous justifions la nécessité d'une nouvelle méthode plus générique et précise. Nous expliquons notre méthodologie proposée et nos motivations dans la section suivante (sec 5.3). Nous décrivons les différents composants qui constituent le pipeline proposé et nous évaluons ses performances sur différentes bases de données. Suite à l'analyse de ces résultats, nous identifions les limitations de notre méthode et ses défauts majeurs. Finalement (sec. 5.4), nous proposons une nouvelle version, une mise à niveau du pipeline qui adresse ces lacunes et l'aide à réaliser un excellent niveau de généralisation sur différentes types de données.

Le chapitre 6 présente le point culminant de nos recherches sur le thème de l'aide au diagnostic pour la prévention des risques cardiovasculaires. Les deux premières sections (6.1 et 6.2) annoncent le contexte général suivi d'un résumé de la partie 3.3 de l'état de l'art. Ensuite, nous présentons notre méthodologie, qui commence par l'application de la transformation cMPR dans la section 6.3. Puis, nous mettons en œuvre un pipeline complet décrit qui permet d'abord de détecter les sténoses à partir des images des artères alignées (sec 6.4) et de d'identifier le type des plaques détectées (sec 6.5).

L'avant dernier chapitre 7 traite la problématique de la segmentation des anévrismes intracrâniens non rompus. Après l'introduction générale et le résumé des travaux antécédents (sec 7.1) nous décrivons les techniques que nous proposons pour établir un diagnostic complet de détection et de segmentation des anévrismes, ainsi que leurs rôles dans l'amélioration du pipeline complet dans la section 7.2 qui suit. La quatrième section 7.3 reprend les détails de l'implémentation et présente les résultats de l'évaluation de cette méthode sur le jeu de données ADAM. Avant de conclure, nous consacrons la section 7.5 à la discussion des résultats des onze algorithmes d'extraction d'anévrismes qui ont participé au défi ADAM par rapport au nôtre.

Finalement, le chapitre 8 conclut cette thèse et fournit une liste de recommandations pour les orientations futures possibles et les améliorations du travail existant.

Chapitre 2

Intelligence Artificielle

Il est maintenant reconnu que l'intelligence artificielle (IA) représente un point d'inflexion pour notre société aussi important que l'a été la révolution industrielle. Elle joue un rôle de plus en plus important dans l'industrie, l'éducation, le transport ainsi que dans les sciences et l'ingénierie. En particulier, l'IA est devenue importante tant pour la recherche biomédicale que pour la pratique clinique. Cela s'explique en partie par l'énorme quantité de données que l'ère du tout numérique permet d'obtenir. Nous pouvons également utiliser l'IA pour rechercher des caractéristiques pertinentes dans les données massives déjà collectées. La puissance de l'IA en matière de reconnaissance des formes permet une analyse plus sophistiquée pour la classification des données. Non seulement pour des tâches de classification, mais aussi pour extraire des informations qui ne sont pas évidentes pour un individu limité à des observations directes.

Le but de ce chapitre est d'introduire les techniques d'intelligence artificielle que nous utilisons tout au long de cette thèse. Nous commençons par la notion d'apprentissage automatique dans la section 2.1. Après l'étude des différents types de techniques offertes par l'apprentissage automatique et l'analyse de nos besoins, nous identifions que nos travaux s'inscrivent dans le domaine de l'apprentissage supervisé. Par la suite, nous introduisons dans la section 2.2 la notion de l'apprentissage profond qui est l'une des méthodes d'apprentissage supervisé la plus utilisée récemment. Cette section décrit l'évolution de cette branche d'apprentissage jusqu'à l'arrivée des réseaux de neurones convolutifs. Puis, nous présentons les nouveaux concepts en relation

avec cette technique. Avant de conclure, nous détaillons dans la section 2.3, les architectures qui font partie de notre travail, notamment U-Net, ResNet et finalement SE-ResNext.

2.1 Apprentissage machine

L'apprentissage est un concept permettant de définir l'acquisition de connaissances et leur utilisation. Pour nous, les humains, notre apprentissage se fait tout au long de notre vie. Nous apprenons à partir de la perception de notre environnement, de nos expériences de la vie, de la récurrence des événements avec nos cinq sens, notre mémoire, et notre jugement (libre volonté ou intelligence). Pour les machines, comme elles n'ont pas de sens ou de jugement dynamique, elles suivent les instructions d'un programme avec des données d'entrée et des données de sortie ou de réponses prédéterminées. Arthur Samuel, un pionnier de l'intelligence artificielle et de l'apprentissage automatique, a décrit l'apprentissage automatique comme un domaine qui permet à une machine d'avoir des connaissances sans être formellement programmée ou sans intervention humaine [11]. En tant que discipline, l'apprentissage automatique explore l'analyse et la construction d'algorithmes capables d'apprendre et de faire des prédictions. Grâce à des

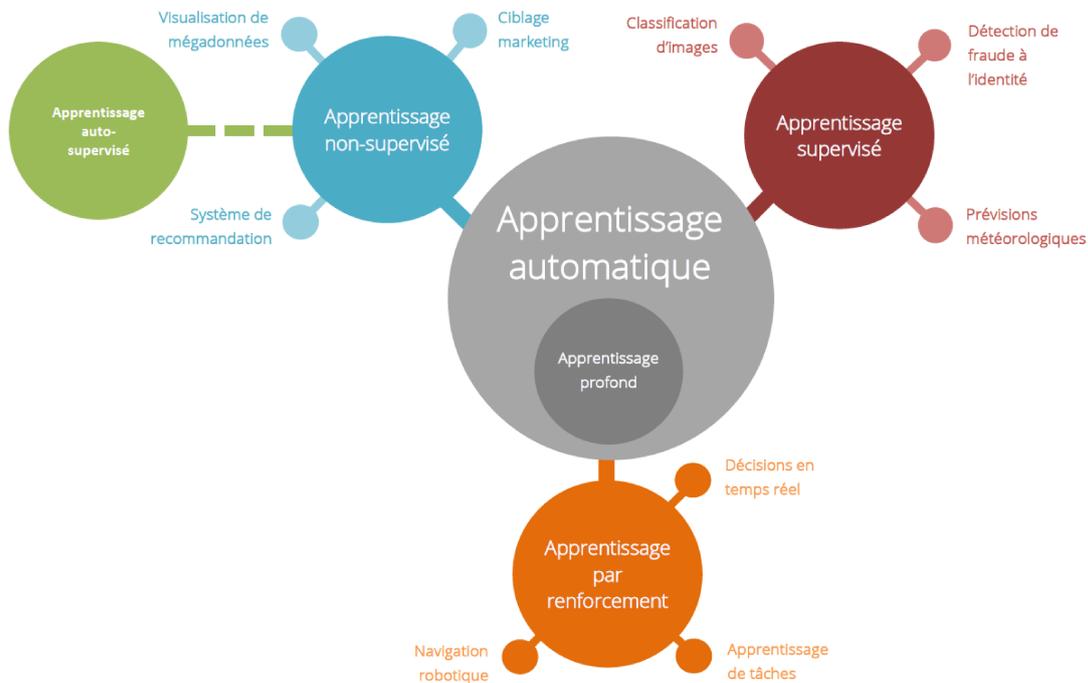


FIGURE 2.1 – Les types d'apprentissage machine et leurs applications [10].

capacités de calcul massives et la disponibilité des données, il permet de résoudre des problèmes à une vitesse et à une échelle qui ne peuvent être reproduites par l'esprit humain seul. Parmi les applications développées par l'apprentissage automatique, nous pouvons citer le diagnostic médical, la recommandation de produits, la détection des spams, la détection de fraude, la reconnaissance vocale, la cyber-sécurité, la prédiction des prix, les prévisions météorologiques, la conduite autonome et bien d'autres.

Comme pour toute méthode, il existe différentes façons de créer des algorithmes d'apprentissage automatique, chacune ayant ses propres avantages et inconvénients. Pour comprendre les avantages et les inconvénients de chaque type d'apprentissage automatique, nous devons d'abord examiner le type de données qu'ils utilisent.

2.1.1 Les types d'apprentissage machine

En apprentissage automatique, il existe deux types de données : les données étiquetées et les données non étiquetées. Si nous avons des données étiquetées, cela signifie que nos données sont marquées, ou annotées, pour montrer la cible, qui est la réponse souhaitée que notre modèle d'apprentissage automatique prédise. La nature de ces données identifie quatre catégories principales d'apprentissage utilisées aujourd'hui : l'apprentissage supervisé, l'apprentissage non supervisé, l'apprentissage semi-supervisé et l'apprentissage par renforcement. Nous détaillerons ces catégories dans les paragraphes suivants.

Apprentissage supervisé

L'apprentissage supervisé traite ou apprend avec des données étiquetées. Cela implique que les données doivent être déjà étiquetées avec les bonnes réponses. L'apprentissage supervisé peut être assimilé à un enseignant qui utilise ses connaissances pour enseigner et corriger les erreurs d'un apprenant. Cette analogie est utilisée par les algorithmes d'apprentissage supervisé pour apprendre à partir des données. Lorsque l'algorithme fait une prédiction sur un exemple, sa fiabilité peut être calculée en connaissant la réponse correcte qui correspond à l'exemple.

L'apprentissage supervisé englobe deux familles d'algorithmes : les algorithmes de classification lorsque la variable de sortie est une catégorie (chat ou chien par exemple) et les algorithmes de régression quand la variable de sortie est une valeur réelle (prix, poids, surface..).

Apprentissage non supervisé

L'apprentissage non supervisé consiste à entraîner un algorithme en utilisant des informations qui ne sont ni classées ni étiquetées et lui permettre d'agir sur ces informations sans aucun guidage. Dans ce cas, sa mission consiste à regrouper des informations non triées en fonction de similitudes, de caractéristiques et de différences. Contrairement à l'apprentissage supervisé, aucun enseignant n'est fourni, ce qui signifie qu'aucune instruction ne sera donnée. Par conséquent, l'algorithme doit trouver les relations implicites dans les données non étiquetées par lui-même. L'apprentissage non supervisé englobe deux familles d'algorithmes : les algorithmes de regroupement (clustering) et les algorithmes d'association. Les premiers consistent à découvrir les regroupements inhérents aux données (par exemple en regroupant les clients par leur comportement d'achat) alors que les derniers consistent à découvrir des règles qui décrivent une grande partie des données (par exemple, les personnes qui achètent X ont également tendance à acheter Y).

Apprentissage semi-supervisé

L'apprentissage semi-supervisé est un problème d'apprentissage qui implique un petit nombre d'exemples étiquetés et un grand nombre d'exemples non étiquetés. Les problèmes d'apprentissage de ce type sont complexes car ni les algorithmes d'apprentissage supervisé ni les algorithmes d'apprentissage non supervisé ne sont capables d'utiliser efficacement les ensembles de données étiquetées et non étiquetées. L'apprentissage supervisé donne plus d'information, mais peut être très coûteux en quantité de données et temps de calcul alors que l'apprentissage non supervisé est plus «automatisé», mais les résultats peuvent être beaucoup moins précis. L'apprentissage semi-supervisé combine quant à lui l'utilisation de données étiquetées et non étiquetées pour obtenir "le meilleur des deux" approches. Son principe est alors de modifier, ou de réorganiser,

les hypothèses effectuées sur le modèle à partir des données d'apprentissage (ensemble en général petit) pour trouver la configuration la plus adaptée la fois aux données d'apprentissage et aux données de test. La plus grande utilité de cette approche est la capacité de labéliser les données non étiquetées en données étiquetées. Les données étiquetées sont comparativement plus coûteuses, difficiles et fastidieuses à acquérir que les données non étiquetées. Une autre utilité est de réduire le nombre de paramètres à apprendre pour prédire les données étiquetées à l'aide de tâches fictives.

Apprentissage par renforcement

L'apprentissage par renforcement consiste à entraîner des modèles d'apprentissage automatique à prendre une séquence de décisions. Le modèle apprend à atteindre un objectif dans un environnement incertain et potentiellement complexe. Dans l'apprentissage par renforcement, il est confronté à une situation semblable à un jeu. Il procède par essais et erreurs pour trouver une solution au problème. Pour amener la machine à faire ce que le programmeur veut, le modèle reçoit des récompenses ou des pénalités pour les actions qu'il réalise. Son objectif est de maximiser la récompense totale. Bien que le développeur définisse la politique de récompense (c'est-à-dire les règles du jeu), il ne donne au modèle aucune indication ou suggestion sur la façon de résoudre le jeu. C'est au modèle de trouver comment accomplir la tâche pour maximiser la récompense, en commençant par des essais totalement aléatoires et en finissant par des tactiques sophistiquées et des compétences supérieures. L'apprentissage par renforcement a été appliqué avec succès à des problèmes variés, tels que le contrôle robotique, le pendule inversé, la planification de tâches, les télécommunications, le backgammon et les échecs.

Durant cette thèse, nous avons fait face à des problématiques de nature segmentation et classification (segmentation des artères, segmentation d'anévrismes, détection des sténoses et classification des plaques). Ces tâches font partie de la discipline de l'apprentissage supervisé car nos modèles apprennent à partir d'un jeu de données annotées par des experts en neurologie et radiologie.

C'est dans ce cadre que nous concentrons les sous-sections suivantes sur l'étude de l'apprentis-

sage supervisé. Nous détaillons sa formulation mathématique, ses principaux défis et les techniques utilisées pour assurer une bonne performance des modèles développés dans ce contexte.

2.1.2 La formulation mathématique de l'apprentissage supervisé

Pour formaliser ce problème, nous devons d'abord établir une modélisation mathématique de la tâche que nous voulons automatiser. Par conséquent, nous définissons un espace des hypothèses Φ dans lequel nous chercherons une solution. Nous devons également choisir une fonction de coût f qui évalue correctement les performances d'une solution $\phi \in \Phi$ pour l'échantillon des données utilisé. Si le coût d'erreur de f est élevé alors les performances sont faibles, et vice versa. Soit D l'ensemble correspondante à toutes les données relatives à la tâche considérée, $d \in D$, alors le but ultime de l'apprentissage automatique est de trouver une fonction ϕ^* telle que

$$\phi^* = \underset{\phi \in \Phi}{\operatorname{argmin}} \mathbb{E}_D[f(d, \phi)] \quad (2.1)$$

En d'autres termes, nous cherchons à trouver une fonction ϕ^* qui minimise le coût de l'erreur sur l'ensemble des données. Ainsi, si nous avons accès à un ensemble infini de données, le problème d'apprentissage automatique se réduit au problème d'optimisation ci-dessus (en plus du problème de modélisation qui est le choix de Φ). En revanche, c'est rarement le cas et les données sont le plus souvent limitées à un ensemble fini D . Par conséquent, nous ne pouvons pas juger avec précision la fiabilité de la fonction choisie car cet ensemble D peut ne pas représenter la vraie distribution des données de la tâche en question. Dans ce cas, nous faisons face à un problème d'estimation où nous ne pouvons évaluer la performance du modèle que sur un ensemble limité et connu de données.

Cet apprentissage se fait alors dans un espace d'hypothèses Φ avec un ensemble de données fini D . En apprenant de cette manière, le système accumule deux erreurs :

- une erreur d'approximation (biais) qui est l'erreur provenant de l'apprentissage sur un espace d'hypothèses différent de l'espace réel,
- une erreur d'estimation (variance) qui est l'erreur résultant de la mauvaise représentation des données par l'hypothèse choisie.

Idéalement, nous cherchons à minimiser ces deux erreurs ensemble (risque empirique). Malheureusement, il est généralement impossible de faire les deux en même temps. Ceci est appelé donc le dilemme biais-variance.

2.1.3 Dilemme biais-variance

Le risque empirique est défini comme la moyenne de la fonction de coût sur D (un ensemble fini de données). L'hypothèse ϕ^* qui le minimise s'écrit alors :

$$\phi^* = \underset{\phi \in \Phi}{\operatorname{argmin}} \frac{1}{|D|} \sum_{d \in D} f(d, \phi) \quad (2.2)$$

où $|D|$ est le cardinal de D .

En élargissant correctement l'espace Φ (augmenter la complexité du modèle), il est possible de minimiser le risque empirique et donc d'obtenir une solution optimale pour l'ensemble D . Cependant, son élargissement excessif entraîne une erreur plus élevée sur les données n'appartenant pas à l'ensemble d'apprentissage. Ce phénomène est appelé surapprentissage (cf fig 2.2). Pour limiter le phénomène de surapprentissage et donc améliorer l'aspect de généralisation du modèle, nous pouvons réduire la complexité du modèle mathématique. Cette procédure est ap-

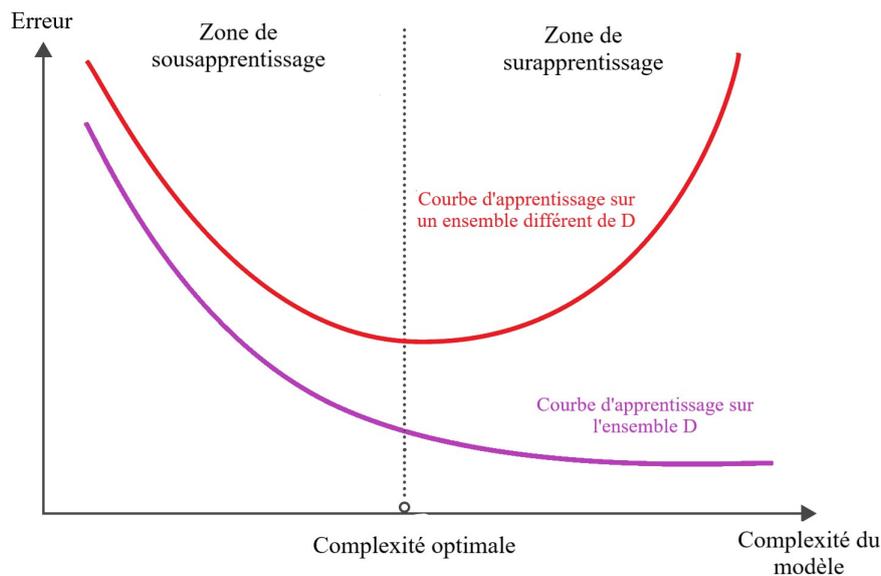


FIGURE 2.2 – Le compromis de surapprentissage / sousapprentissage. La figure est adaptée de [12].

pelée régularisation. Par exemple, il est possible de réduire l'espace des solutions Φ ou d'ajouter une pénalité de régularisation r à la fonction de coût. De ce fait, le modèle est alors associé à un coefficient (hyperparamètre de l'apprentissage) λ fixant les poids de la régularisation lors de l'optimisation (voir éq 2.3)

La régularisation de ces modèles et la simplification de l'espace des hypothèses conduisent à un phénomène inverse, celui du sousapprentissage. Le modèle a alors une complexité trop faible et a plus de difficultés à apprendre correctement la tâche en question. Par ailleurs, l'objectif de l'apprentissage automatique est de trouver un équilibre entre l'étendu de l'espace des solutions Φ , les contraintes apportées au problème d'optimisation par l'ensemble de données et celles apportées par la régularisation. Par ailleurs, le but est de trouver une solution qui se généralise à des exemples qui n'ont jamais été observés par le modèle. Certes l'ensemble D est fini, mais il est nécessaire d'isoler davantage différents sous-ensemble de données. Ils serviront d'une part à alimenter le processus d'apprentissage du modèle et d'autre part à estimer la performance de la solution choisie.

2.1.4 La répartition des données

Pour assurer une représentation et une évaluation correctes de nos données et de notre modèle, nous divisons l'ensemble de données D en trois sous-ensembles disjoints :

- *ensemble d'entraînement* : D_{train} que nous utilisons pour minimiser le risque empirique.

$$\phi_{\Phi,r,\lambda}^* = \underset{\phi \in \Phi}{\operatorname{argmin}} \frac{1}{|D_{train}|} \sum_{d \in D_{train}} [f(d, \phi) + \lambda r(d, \phi)] \quad (2.3)$$

L'idée est de fixer un espace de solutions Φ , une pénalité de régularisation r et un coefficient de régularisation λ puis nous itérons sur toutes les données d'entraînement que nous avons afin d'obtenir les paramètres de la fonction ϕ^* qui minimisent la fonction de coût f ainsi que la pénalité de régularisation λr .

- *ensemble de validation* : D_{val} utilisé pour la sélection du modèle, c'est-à-dire qu'étant donné la fonction optimale ϕ^* , nous ajustons le choix de la pénalité de régularisation r et

les autres hyperparamètres (que nous incluons ici dans λ) en ce qui concerne le compromis surapprentissage / sousapprentissage.

$$[\Phi^*, r^*, \lambda^*] = \underset{[\Phi, r, \lambda]}{\operatorname{argmin}} \frac{1}{|D_{val}|} \sum_{d \in D_{val}} f(d, \phi_{\Phi, r, \lambda}^*) \quad (2.4)$$

— *ensemble de test* : D_{test} , utilisé pour estimer s , la performance générale du modèle

$$s = \frac{1}{|D_{test}|} \sum_{d \in D_{test}} f(d, \phi_{\Phi^*, r^*, \lambda^*}^*) \quad (2.5)$$

L'ensemble de test est utilisé uniquement pour évaluer la performance du modèle choisi, il n'est pas inclus dans le problème d'optimisation.

Finalement, en utilisant des distributions de données similaires pour les ensembles d'entraînement, de validation et de test, nous pouvons minimiser les effets de disparités de données et mieux comprendre les caractéristiques du modèle. Ainsi, après avoir entraîné un modèle en utilisant l'ensemble d'entraînement, nous testons ses performances en faisant des prédictions par rapport à l'ensemble de test.

Après avoir identifié le cadre dans lequel s'inscrit la thèse (apprentissage supervisé), il nous faut maintenant définir les contraintes, notamment la complexité des modèles que nous voulons mettre en place. La nature de nos travaux s'articule autour du traitement d'image. Bien que l'apprentissage machine classique est très efficace pour résoudre ce type de problème, il est généralement basé sur deux étapes cruciales qui sont : l'extraction des caractéristiques et l'algorithme de décision. L'état de l'art nous fournit une multitude de descripteurs visuels qui représente bien nos données mais nous gardons toujours, dans ce cas, l'aspect manuel d'extraction des caractéristiques. Pour cette raison, nous optons pour l'une des méthodes les plus complexes mais qui offre un extracteur de caractéristiques puissant et automatisé : l'apprentissage profond.

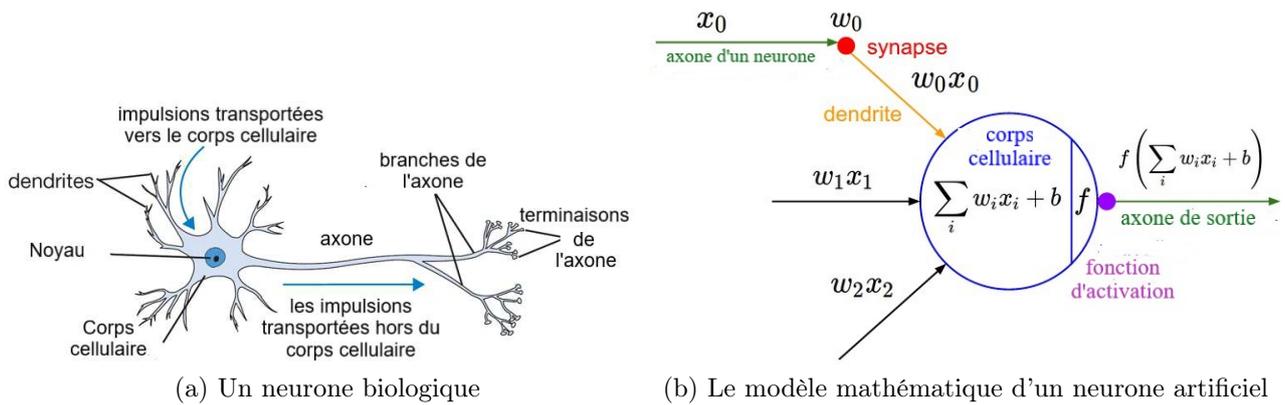


FIGURE 2.3 – Comparaison entre un neurone biologique (à gauche) et le modèle mathématique d'un neurone artificiel (à droite) . La figure est adaptée de [13].

2.2 Apprentissage profond

L'apprentissage profond s'appuie sur les réseaux de neurones artificiels convolutifs, dits profonds. Originellement inspiré par des observations en neurosciences sur le fonctionnement du cerveau, ce type de modélisation existe depuis près de soixante ans, après l'invention du Perceptron [14]. Dans un réseau biologique, les données d'entrée proviennent d'un autre neurone qui passe dans la dendrite, le corps cellulaire effectue les calculs et le résultat sort par l'axone (cf. fig 2.3a). Le fonctionnement d'un neurone artificiel est modélisé sur celui d'un neurone biologique. Il peut réaliser des fonctions logiques, arithmétiques et symboliques complexes. Par contre, sa formulation initiale comportait d'importantes limitations [15], notamment l'impossibilité de résoudre des problèmes non linéaires (surtout l'opération XOR). Il a donc été mis de côté jusqu'à l'invention des réseaux neuronaux multicouches artificiels et la rétropropagation [16].

2.2.1 L'idée du perceptron

La façon la plus simple de construire un réseau neuronal est basée sur l'idée des perceptrons. Ils gèrent des entrées binaires et des sorties binaires. La figure 2.3b présente le processus d'exécution des perceptrons. Il a été initialement conçu pour apprendre les poids automatiquement puisque nous connaissons les entrées et leurs sorties respectives. À chaque valeur d'entrée donnée $x =$

(x_0, x_1, x_2) que nous transmettons à cette structure correspond un poids $w = (w_0, w_1, w_2)$ qui contrôle la décision. La sortie sera calculée en fonction des valeurs d'entrée \mathbf{x} , des poids \mathbf{w} et d'une valeur de biais b suivant l'équation 2.6 ci-dessous.

$$y = \begin{cases} 0, & \text{si } \mathbf{w}\mathbf{x} + b \leq 0 \\ 1, & \text{si } \mathbf{w}\mathbf{x} + b > 0 \end{cases} \quad (2.6)$$

Ce comportement est similaire à l'activité du cerveau, nous pondérons également les conditions, les analysons, comparons les résultats et prenons une décision. Cependant, une décision prise par le cerveau humain est le résultat d'un système profond et complexe et pas seulement d'un neurone unique. Ce qui peut justifier les limitations linéaires du perceptron. Un seul perceptron peut implémenter chacune des fonctions logiques fondamentales : NON, ET et OU. Elles sont dites fondamentales car toute fonction logique, aussi complexe soit-elle, peut être obtenue par une combinaison de ces trois fonctions. Mais est-il possible de trouver des poids pour un seul perceptron afin qu'il résolve tout seul le problème XOR ? La réponse est non car le problème XOR n'est pas linéairement séparable. Il est clair qu'un seul perceptron ne servira pas pour les problèmes qui ne sont pas linéairement séparables. La non-linéarité permet des frontières de décision plus complexes. Ce qui crée la nécessité de combiner multiple perceptrons pour décrire les représentations non linéaire.

2.2.2 Réseau de neurones artificiels : ANN

Le réseau de neurones artificiels (ANN pour Artificial neural network) repose sur la notion perceptrons multicouches (MLP pour Multilayer Perceptrons). Un réseau de perceptrons multicouche (Fig 2.4) peut être vu comme un ensemble d'unités de traitement (neurones), reliées entre elles par des connexions pondérées. Les poids de ces connexions sont les paramètres du modèle. Ces neurones et ces connexions sont organisés par couches : La première couche est appelée couche d'entrée, la dernière couche est appelée couche de sortie et les couches intermédiaires sont appelées couches cachées. Les neurones de ces couches cachées, ainsi que ceux de la couche de sortie, appliquent deux traitements :

- une combinaison linéaire de leurs entrées (dont les poids sont des paramètres du réseau),
- une fonction linéaire ou non linéaire appelée fonction d'activation.

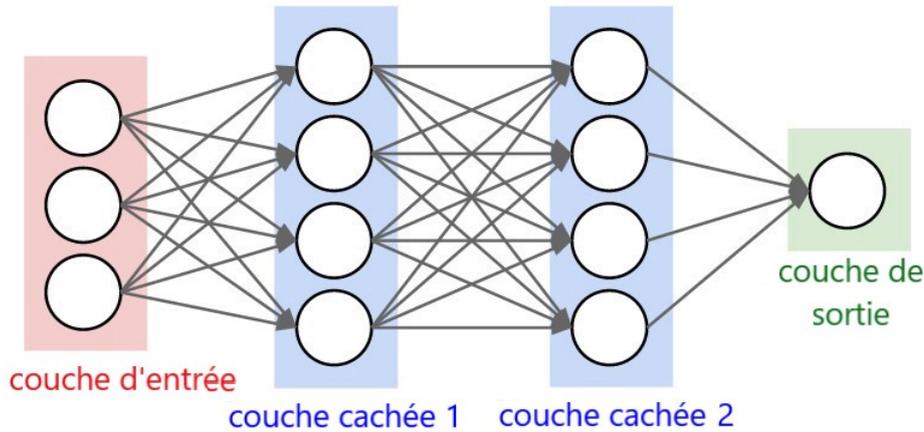


FIGURE 2.4 – Un réseau de perceptron multicouche : réseau entièrement connecté [13].

Si on considère un réseau perceptron multicouche avec N neurones d'entrée, un vecteur d'entrée $\mathbf{x} = [x_1, \dots, x_N]$, et $w_{ij}^{0,1}$ le poids correspondant à la connexion entre le neurone i de la couche 0 et le neurone j de la couche 1, la sortie a_j^1 de chacun des neurones de la première couche cachée sera exprimée par :

$$a_j^1 = g_j\left(\sum_{i=1}^N (w_{ij}^{0,1} \times x_i) + b_j^1\right) \quad (2.7)$$

où b_j^1 est le biais, qui peut être considéré comme le poids d'une entrée constante égale à 1. Son rôle est d'ajouter un degré de liberté supplémentaire en agissant sur la position de la frontière de décision. g_j est la fonction d'activation. Ce même processus exprimé par l'équation 2.7 peut être répété pour les autres couches (couche cachée ou couche de sortie) : chaque sortie d'une couche l ($l \in [0, N]$) joue le rôle d'entrée pour la couche suivante $l + 1$. Ainsi, nous pouvons généraliser l'équation 2.7 à toutes les couches suivantes (y compris la couche de sortie) comme suit :

$$a_j^{l+1} = g_j\left(\sum_{i=1}^N (w_{ij}^{l,l+1} \times x_i) + b_j^{l+1}\right) \quad (2.8)$$

La fonction d'activation g_j sert à introduire une opération non linéaire après l'opération du produit scalaire. Cette non-linéarité permet d'avoir différentes variations de l'état interne sur un objet de même classe. Les fonctions d'activation les plus utilisées sont résumées ci-dessous : Les perceptrons multicouches sont généralement utilisés pour des problèmes supervisés. Cela

Fonction d'activation	Formule mathématique	Domaine de définition
Linéaire	$g(\mathbf{x}) = \mathbf{x}$	$g : \mathbb{R} \mapsto \mathbb{R}$
Tanh	$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$\tanh : \mathbb{R} \mapsto] - 1, 1[$
Sigmoid	$\sigma(x) = \frac{1}{1 + \exp(x)}$	$\sigma : \mathbb{R} \mapsto] 0, 1[$
Rectified Linear Unit	$ReLU(x) = \max(0, x)$	$ReLU : \mathbb{R} \mapsto \mathbb{R}_+$

TABLE 2.1 – Les fonctions d'activation les plus utilisées : leur formule et leur domaine de définitions

implique l'existence d'un ensemble de d'entrées-sorties (base de données d'apprentissage) liées par une certaine relation, que le réseau va "apprendre" en ajustant ses paramètres. L'apprentissage se fait avec l'algorithme de rétropropagation du gradient. Cet algorithme comporte deux étapes :

- le "forward pass" ou propagation vers l'avant, durant lequel les sorties du réseau sont calculées à partir des entrées (comme décrit précédemment dans l'équation 2.8),
- un "backward pass" ou rétropropagation, durant lequel les dérivées partielles d'une certaine fonction de coût C par rapport aux paramètres du réseau sont rétropropagées.

Enfin, les poids du réseau sont mis à jour en fonction de cette dérivée partielle :

$$w_{ij} = w_{ij} + \Delta w_{ij} \quad (2.9)$$

$$\Delta w_{ij} = -\epsilon \frac{\partial C}{\partial w_{ij}} \quad (2.10)$$

où ϵ est le taux d'apprentissage qui détermine l'étape de mise à jour des paramètres du réseau, $w_{ij}^{l,l+1}$ est simplifié en w_{ij} . Le processus décrit précédemment est répété pendant plusieurs itérations (appelées époques) jusqu'à convergence (c'est-à-dire lorsque la fonction de coût se rapproche de zéro). Le nombre d'époques, la valeur du taux d'apprentissage, le nombre de couches cachées, la fonction d'activation etc... sont les hyperparamètres du modèle. Ils sont généralement définis d'une manière manuelle. Par conséquent, de multiples configurations doivent être testés pour bien choisir ses valeurs. Cette procédure est appelée le réglage des hyperpa-

ramètres. Le réseau finalement sélectionné comme le plus performant est celui qui présente l'erreur la plus faible sur une base indépendante de la base d'apprentissage (base de validation ou de test).

A cette étape, nous identifions le réseau de neurones artificiels comme la solution la plus adéquate pour la création d'un extracteur des caractéristiques automatisé grâce à sa procédure d'optimisation des poids. Néanmoins, nous devons être conscients de ses limites qui sont :

- les problèmes liés à la classification d'images deviennent difficiles car les images bidimensionnelles doivent être converties en vecteurs unidimensionnels. Cela augmente le nombre de paramètres entraînaables de façon exponentielle. L'augmentation des paramètres entraînaables exige des capacités de stockage et de traitement importantes ;
- le réseau de neurones profond est mieux approprié vis à vis des données structurés ;
- transformer les images sous forme de vecteurs n'est pas optimal vu que nous perdons les caractéristiques spatiales.

Ce type d'architecture n'est donc pas adapté aux problèmes de segmentation et de classification des images. Pour surmonter ces inconvénients, une amélioration de réseau de neurones artificiels est nécessaire. Il s'agit d'une architecture destinée à la problématique liée au traitement de l'image en principal. Cette nouvelle architecture est le réseau de neurones convolutifs (ou CNN).

2.2.3 Réseau de neurones convolutif : CNN

Ce type de réseau s'inspire du fonctionnement biologique du cortex visuel. Les premières tentatives remontent à 1980 avec le néocognitron de Fukushima [17], ancêtre des réseaux de neurones convolutifs. Lecun et al [18] se sont inspirés de ce dernier pour proposer le premier exemple de réseau de neurones convolutif (appelés aussi CNN ou ConvNet) conçu dans le but de la reconnaissance de l'écriture manuscrite. Ce travail innovant a été appelé LeNet-5 et comprenait sept couches différentes avec deux couches de convolution.

Un réseau de neurones convolutif est un modèle proche d'un réseau de perceptron multicouche. Il repose sur trois principes fondamentaux :

- les champs réceptifs locaux associés à des convolutions permettent de détecter des caractéristiques élémentaires de l'image, formant ainsi une carte de caractéristiques ;
- le partage de poids, qui consiste à apprendre les mêmes paramètres (poids) d'une convolution (et par conséquent à extraire les mêmes caractéristiques) pour toutes les positions sur l'image ;
- les opérations de pooling réduisent la sensibilité aux translations et le coût du traitement de données.

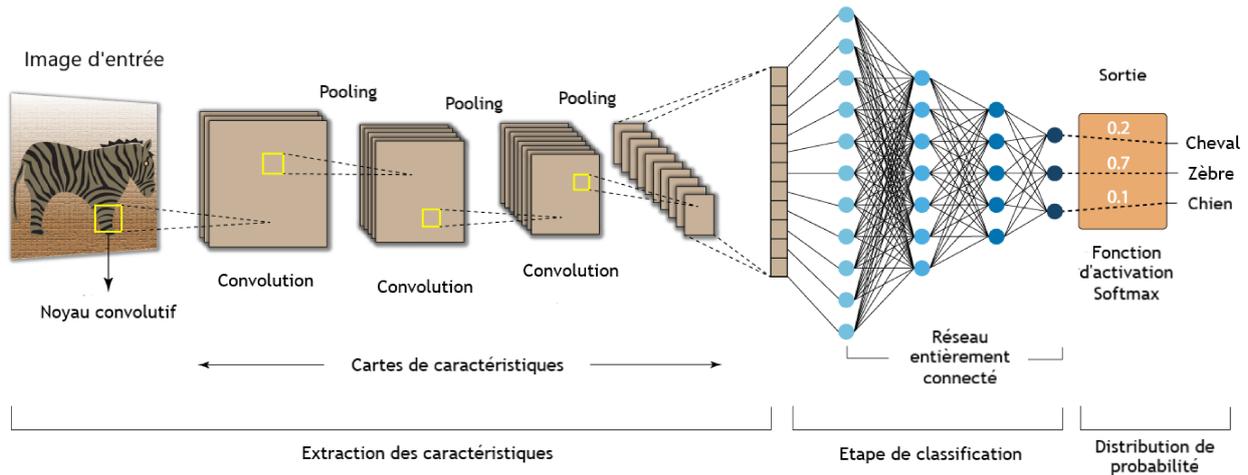


FIGURE 2.5 – Le schéma complet d'un réseau de neurones convolutif. La figure est adaptée de [19].

Le champ réceptif local

Le champ réceptif est défini comme la région de l'image dont un noyau convolutif "regarde". Le champ réceptif est peut-être l'un des concepts les plus importants des CNN. Son avantage est que les unités ou les neurones d'une couche sont directement responsables de la reconnaissance des caractéristiques visuelles dans une petite région des données d'entrée uniquement. En revanche, ce n'est pas le cas pour les MLP. Chaque unité reçoit des données des unités de la couche qui la précède, ce qui l'expose à la totalité de la région d'entrée. Par conséquent, cette approche locale permet aux couches inférieures d'un CNN d'apprendre les caractéristiques de bas niveau de l'image telles que les lignes, les bords, les contours, etc. Les couches supérieures, quant à elles, apprennent les caractéristiques de bas niveau de l'image, telles que les formes, car la région de l'image à laquelle une unité d'une couche supérieure est exposée est plus grande.

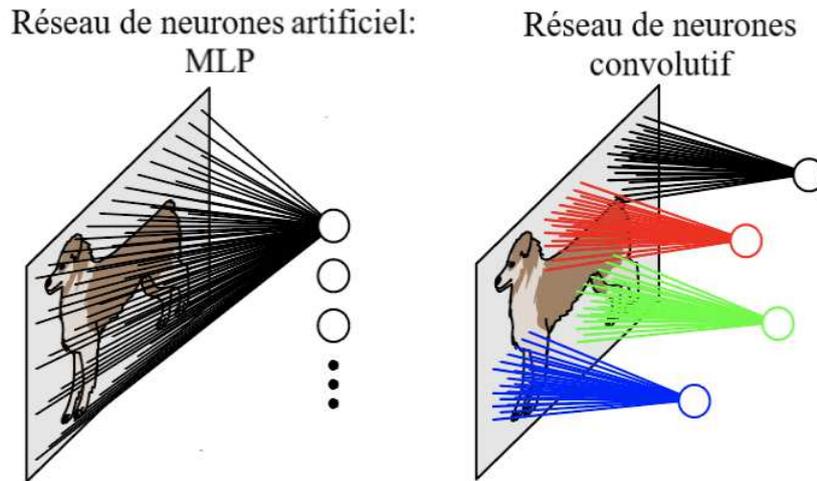


FIGURE 2.6 – La distribution des poids pour les neurones de la première couche cachée pour un MLP (à gauche) et un CNN. Le biais est ignoré dans cette représentation. La figure est adaptée de [20].

Le partage des poids

Le principe de partage des poids représente une des idées clefs des CNN. Il permet de réduire considérablement la complexité en diminuant le nombre de paramètres à apprendre. Le partage des poids se produit lorsqu’une carte de caractéristiques est générée du résultat de la convolution entre un filtre et une unité de la couche de convolution. Toutes les unités d’un même niveau (couche de convolution) partagent les mêmes poids, d’où le terme de partage des poids/paramètres. Nous disposons ainsi d’architectures multicouches qui fonctionnent sur de grandes quantités de données tout en ayant une taille réaliste de modèle. Grâce à ce principe, l’architecture du réseau intègre la structure locale des images et permet également de réduire le nombre de poids à apprendre dans le réseau contrairement au MLP (voir fig 2.6). De plus, le partage des poids améliore les performances en termes de généralisation du réseau, et assure ainsi la cohérence avec les études faites sur le cortex visuel. De ce fait, nous pouvons réécrire l’équation 2.8 qui retourne le vecteur de sortie actuel a de la couche k en prenant en compte le partage des poids :

$$a_{ij}^k = g((\mathbf{w}^k * x)_{ij} + b^k) \quad (2.11)$$

où a^k est la sortie du k^{me} filtre du bloc convolutif, \mathbf{w}^k est la matrice des poids du k^{me} filtre, b^k est le biais et $*$ est l’opérateur de convolution. Pour une entrée \mathbf{x} de taille (H, W, D) , un noyau

convolutif K de taille (H', W', D) , le résultat de sortie y est de taille (H'', W'', D) où H'' et W'' dépendent non seulement de la hauteur et de la largeur du noyau convolutif et de l'image d'entrée mais aussi d'autres hyperparamètres appelés *stride* (S) et *zero padding* (P).

$$\begin{pmatrix} W'' \\ H'' \end{pmatrix} = \begin{pmatrix} \frac{W-W'+2P}{2} + 1 \\ \frac{H-H'+2P}{2} + 1 \end{pmatrix} \quad (2.12)$$

Stride et zero padding

Le stride force la façon dont le filtre convolue autour du volume d'entrée. Il contrôle le chevauchement des convolutions de l'entrée et donc la taille de la sortie. Si le stride est unitaire, le chevauchement est important, ce qui conduit à une grande dimension de la sortie. En l'augmentant, nous réduisons le chevauchement et la taille de la sortie. Le zero padding est réalisé en ajoutant des zéros sur les bords de l'image, pour contrôler la taille à la sortie de chaque couche. Pour l'exemple de la fig 2.7, nous utilisons un stride unitaire ($S = 1$), pas de zero padding ($P = 0$), l'image d'entrée est $(H = 5, W = 5)$ et la taille du noyau est $(H' = 3, W' = 3)$. Ainsi, en appliquant l'équation 2.12, nous retrouvons la taille $(H'' = 3, W'' = 3)$ de l'image de sortie.

Pooling

Après un bloc de convolution, il est fréquent de trouver un bloc de pooling. Paramétré par deux entiers n et m (trois entiers en 3D), il permet d'extraire des sous-matrices de tailles $m \times n$.

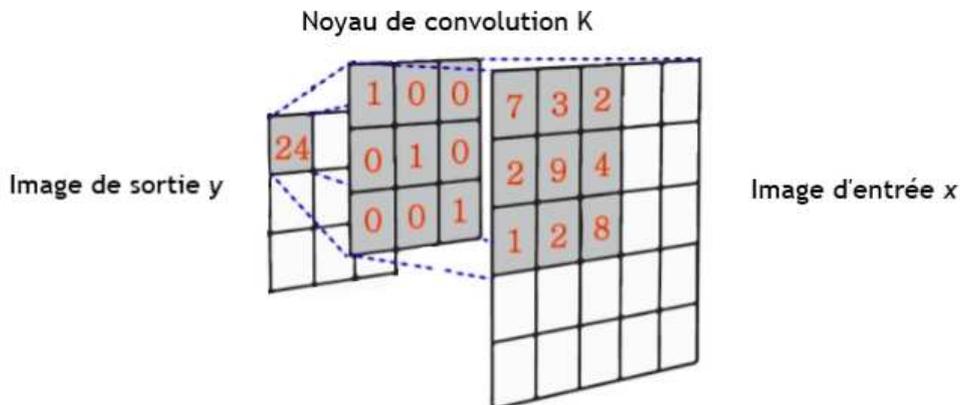


FIGURE 2.7 – L'opération de convolution

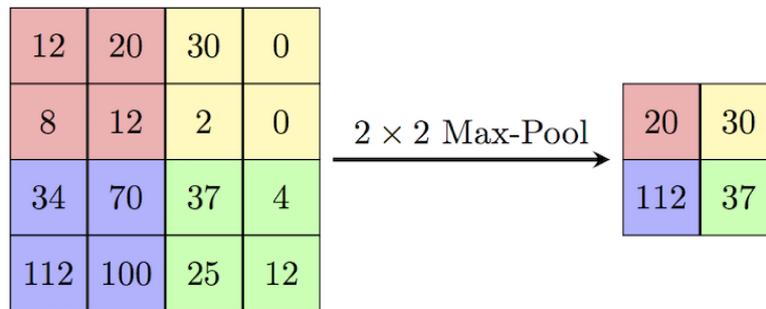


FIGURE 2.8 – L'opération de max-pooling

C'est généralement une opération de max-pooling qui est effectuée (cf fig 2.8). Elle fonctionne en sélectionnant la valeur la plus élevée dans une région définie et en rejetant le reste des valeurs. Ce bloc est particulièrement utile pour trois raisons. Tout d'abord, c'est une transformation non linéaire. De plus, il permet de réduire la dimensionnalité des données à l'intérieur du réseau, et donc de réduire le nombre de paramètres appris, évitant ainsi le surapprentissage. Finalement, cette opération induit une forme d'invariance de la translation des données, rendant les CNNs plus robustes à la détection de motifs particulières dans les données d'entrée.

Nous rappelons que notre objectif est de créer un extracteur de caractéristiques automatisé. Par conséquent, nous décrivons dans la sous section suivante le processus de création des cartes de caractéristiques par les CNN.

Processus d'apprentissage du réseau CNN : l'extraction des caractéristiques

Le résultat de la multiplication du filtre avec les entrées produit un scalaire. Comme le filtre est appliqué plusieurs fois aux entrées, le résultat est un tableau bidimensionnel de valeurs de sortie qui représentent un filtrage de l'entrée. En tant que tel, le tableau de sortie bidimensionnel issu de cette opération est appelé "carte de caractéristiques". Une fois qu'une carte de caractéristiques est créée, nous pouvons appliquer à chaque valeur de la carte de caractéristiques une fonction non-linéaire, telle qu'une ReLU, comme nous le faisons pour les sorties d'une couche entièrement connectée. En résumé, nous avons une entrée, telle qu'une image, et nous avons un filtre, qui est un ensemble de poids, et le filtre est systématiquement appliqué aux données d'entrée pour créer une carte de caractéristiques. Une suite de dizaines, voire de centaines, d'autres petits filtres permet de détecter plusieurs caractéristiques de l'image. Le

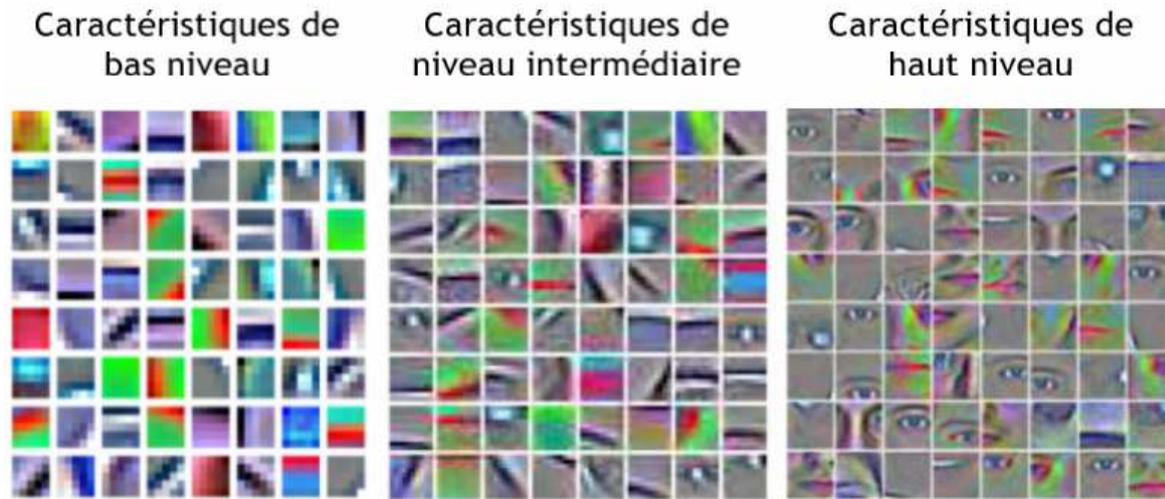


FIGURE 2.9 – Les cartes de caractéristiques pour la détection des visages. La figure est adaptée de [21].

réseau va apprendre quels types de caractéristiques extraire de l'entrée. Plus précisément, dans le cadre d'un apprentissage par descente de gradient stochastique, le réseau est contraint d'apprendre à extraire les caractéristiques de l'image qui minimisent une fonction de coût spécifique (erreur quadratique moyenne, entropie croisée...) à la tâche en question, par exemple extraire les caractéristiques qui sont les plus utiles pour classer les images en chiens ou en chats. Les réseaux de neurones convolutifs n'apprennent pas un seul filtre ; ils apprennent en fait plusieurs caractéristiques en parallèle pour une entrée donnée. Par exemple, pour une couche de convolution, c'est fréquent d'apprendre de 32 à 512 filtres en parallèle. Le modèle dispose ainsi de 32, voire 512 façons différentes "d'apprendre à voir" les données d'entrée. Les couches de convolution ne sont pas seulement appliquées aux données d'entrée, mais elles peuvent également être appliquées à la sortie des autres couches. L'empilement des couches de convolution permet une décomposition hiérarchique de l'entrée. Considérons que les filtres qui opèrent directement sur les valeurs brutes des pixels apprendront à extraire des caractéristiques de bas niveau. Les filtres qui opèrent sur la sortie ces premières couches peuvent extraire des caractéristiques qui sont des combinaisons de caractéristiques de niveau inférieur, telles que des caractéristiques qui expriment des formes. Ce processus se poursuit jusqu'à ce que des couches très profondes extraient des visages, des animaux, des maisons, etc. L'abstraction des caractéristiques vers des ordres de plus en plus élevés dès que la profondeur du réseau augmente comme indiqué dans la figure 2.9.

En résumé, pour construire un réseau, il suffit de connecter les sorties d'un bloc aux entrées d'un autre. Une couche entièrement connectée est généralement ajoutée à la fin du réseau, couplée avec un fonction de décision de classification (dans le cadre d'un problème de classification), ou une régression (dans le cadre d'un problème de régression).

2.3 Exemples des architectures de CNN

Ces dernières années, nous avons assisté à la naissance de nombreuses architectures de CNNs. Nous sommes à quelques mois de fêter les 10 ans du début de la montée en puissance de l'apprentissage profond avec l'introduction d'AlexNet en septembre 2012 par Krizhevsky et al [56]. Ce réseau avait une architecture très similaire à celle de LeNet, mais il était plus profond et comportait des couches de convolution superposées les unes sur les autres avec un nombre de paramètres qui dépasse 60 millions. AlexNet a été le premier réseau CNN à remporter l'ImageNet Large Scale Visual Recognition Challenge (ILSVRC) [27] avec une précision de 85% contre 73%, le record de l'année précédente. En fait, la plupart des architectures renommées, ont acquis leur réputation en remportant la compétition de l'ILSVRC. La figure 2.10 montre les modèles gagnants de chaque année.

Partant de l'idée que l'amélioration des performances des réseaux de neurones profonds passe par l'augmentation de leur nombre de couches, Visual Geometry Group (VGG) a inventé le VGG-16 [28]. Il possède 13 couches de convolutions et 3 couches entièrement connectées, qui utilisent toutes les activations ReLU d'AlexNet. Ce réseau empile plus de couches que le modèle



FIGURE 2.10 – Les architectures qui ont remporté la compétition de classification des images ILSVRC. La figure est adaptée de [27].

AlexNet, utilise des filtres de plus petite taille (2×2 et 3×3) et comprend plus de 138 millions de paramètres. Néanmoins, avec le problème de fuite de gradient, il est devenu difficile de rajouter des couches de convolutions sans nuire aux performances des CNN.

C'est dans ce cadre que Szegedy et al [29] proposent l'architecture Inception. L'idée c'est, au lieu d'empiler des couches de convolution, nous empilons des modules ou des blocs, à l'intérieur desquels se trouvent des couches de convolution d'où le nom d'Inception (en référence au film Inception de 2010 du réalisateur Christopher Nolan).

L'évolution de ces blocs a continué à améliorer les performances des CNN. Particulièrement avec l'introduction du bloc résiduel pour ResNet et le bloc de "squeeze and excitation" pour SE-Net. Nous avons eu recours à ces deux architectures durant cette thèse. Par conséquent, nous décrivons en détail le fonctionnement et la mise en place de ces modèles dans les paragraphes suivants.

La plupart de ces architectures ont été utilisées pour des tâches de classification d'images. En imagerie médicale, un intérêt particulier est porté aux tâches de segmentation. L'un des réseaux de neurones les plus utilisés pour la segmentation d'images est U-Net[30]. Il est lui aussi vainqueur du challenge de segmentation de bioimage de l'ISBI en 2015. A partir de son architecture de base, de multiples variantes ont été développées pour améliorer ses performances, notamment Attention U-Net [31], U-Net++ [32], V-net [33], R2U-U-Net [34], U-Net3+ [35] et bien d'autres. Nous revenons en détail sur les applications médicales qui ont utilisé ces différents types d'architectures dans le prochain chapitre.

L'objectif de cette section est de décrire les architectures des réseaux de neurones que nous avons utilisées dans cette thèse. La littérature est très riche en ce qui concerne la variété des architectures de CNN qui dépassent le cadre de ce travail. Nous orientons les lecteurs vers la thèse [22] et les revues de [23, 24, 26] pour une description détaillée de ces modèles et de leur domaine d'application. Cependant, dans notre thèse, nous nous intéressons à trois architectures majeures qui sont U-Net [30], Resnet [53] et SE-ResNext [180].

2.3.1 U-Net

U-Net est une architecture développée pour la segmentation d'images biomédicales. Elle consiste en plusieurs couches de convolutions, couches max-pooling, activation ReLU, couches de concaténation et des couches de sur-échantillonnage (upsampling) départagées en trois parties : contractante, bottleneck, et une partie d'expansion. La partie d'expansion est plus ou moins symétrique à la partie contractante et donne une architecture en forme de «U» comme indiqué dans la figure 2.11. Ceci permet au réseau de propager les caractéristiques de bas niveau vers des couches de résolution supérieure. Revenons à la structuration de ces différentes parties :

- La section contractante a 4 blocs de contraction. Chacun prend une entrée, applique deux convolutions avec des filtres de taille 3×3 avec des activations ReLU. Ensuite une couche de max-pooling est utilisée pour réduire la taille de sortie de moitié. Le nombre des cartes de caractéristiques (nombre des filtres), par contre, est doublé après chaque pooling ;
- La couche de bottleneck utilise deux couches de convolution avec des filtres de taille 3×3 et une couche up-conv de taille 2×2 ;
- la section d'expansion est symétrique à la section contractante. Elle remplace le max-pooling par une couche de sur-échantillonnage et inclut aussi une couche de concaténation qui correspond à la carte de caractéristiques du même niveau de la partie contractante.

Finalement, une couche de convolution 1×1 est appliquée pour homogénéiser le nombre des cartes des caractéristiques avec le nombre de classes désirées à la sortie. U-net utilise une fonction de coût pour chaque pixel de l'image. Par conséquent, elle facilite l'identification des cellules individuelles dans la carte de segmentation. De plus, c'est la fonction de décision Softmax qui est appliquée à chaque pixel. Ceci convertit le problème de segmentation à un problème de classification dont nous attribuons chaque pixel à l'une des classes.

Comme nous l'avons évoqué dans la section 2.1.3, plus nous optons pour des architectures complexes, plus nous sommes vulnérables au dilemme biais-variance. Dans le cas où une architecture comme celle d'U-Net est incapable de bien représenter les données, une solution consiste à ajouter des couches de convolution. Cependant, nous sommes alors confrontés à un problème majeur qui est la fuite du gradient. Ainsi, avec plus de couches dans le réseau, la performance du

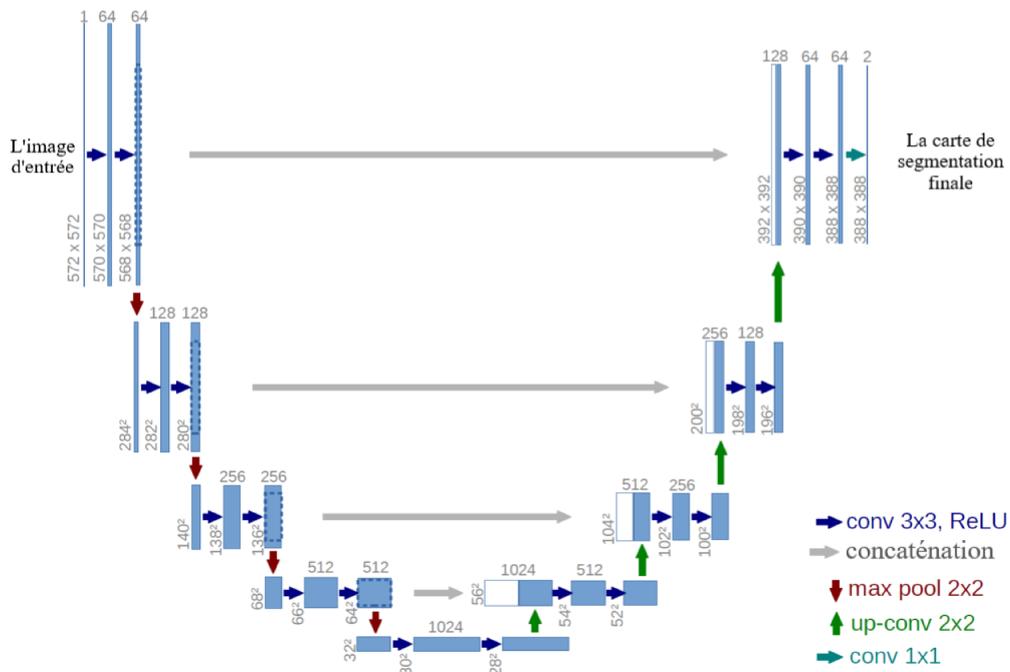


FIGURE 2.11 – L’architecture de U-Net. La figure est adaptée de [30].

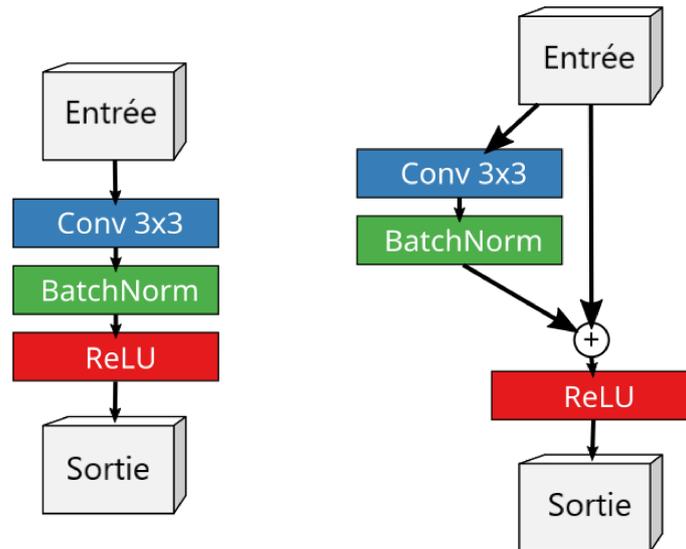


FIGURE 2.12 – Partie d’un réseau de neurones convolutif. A gauche sans et à droite avec le bloc résiduel. La figure est adaptée de [54].

CNN sature et commence à diminuer rapidement. Pour cette raison, nous proposons l’architecture ResNet pour contourner ce problème et avoir plus de liberté pour ajouter de la complexité au modèle.

2.3.2 ResNet

Traditionnellement, un plus grand nombre de couches signifie un meilleur réseau. Mais en raison du problème de fuite du gradient, les poids de la première couche ne seront pas mis à jour correctement par rétropropagation. Comme l'erreur du gradient est rétropropagée vers les couches précédentes, la multiplication répétée rend le gradient assez petit. Ainsi, avec l'augmentation du nombre de couches dans le réseau, ses performances saturent et commencent à diminuer rapidement. ResNet résout ce problème en utilisant la matrice d'identité. Lorsque la rétropropagation est effectuée à l'aide de la fonction d'identité, le gradient ne sera multiplié que par 1, ce qui préserve l'entrée et évite toute perte d'information. Les composants du réseau comprennent des filtres 3×3 , des couches de sous-échantillonnage CNN avec stride de 2, une couche de pooling et une couche entièrement connectée avec une fonction softmax à la fin. ResNet utilise un module résiduel avec une connexion par saut (skip connection) dans laquelle une entrée initiale est également ajoutée à la sortie du bloc de convolution (cf fig 2.12). Cela permet de résoudre le problème de la fuite du gradient en le faisant circuler par un autre chemin. De plus, ce module utilise la fonction d'identité qui aide la couche supérieure à être aussi performante que la couche inférieure. Dans les réseaux de neurones traditionnels, chaque couche alimente la couche suivante. Mais dans un réseau avec des blocs résiduels, chaque couche alimente la couche suivante et directement les couches situées à quelques pas de la couche initiale.

2.3.3 SE-ResNext

Le réseau SE-ResNext fait partie de la famille des réseaux de "squeeze and excitation" (SE-Nets). En introduisant un bloc de construction pour les CNN (cf fig 2.13), ils améliorent les interdépendances des canaux pour un coût de calcul presque nul. Les CNN utilisent leurs filtres convolutifs pour extraire des informations hiérarchiques des images. Les couches inférieures trouvent des éléments de contexte triviaux comme les bords ou les hautes fréquences, tandis que les couches supérieures peuvent détecter des visages, du texte ou d'autres formes géométriques complexes. Ils extraient tout ce qui est nécessaire pour résoudre efficacement une tâche. Tout cela fonctionne en fusionnant les informations spatiales et de canal d'une image. Les dif-

férents filtres trouvent d'abord les caractéristiques spatiales dans chaque canal d'entrée avant d'additionner les informations sur tous les canaux de sortie disponibles. Le réseau pondère chacun de ses canaux de manière égale lors de la création des cartes de caractéristiques de sortie. Les SENets ont pour but de changer cela en ajoutant un mécanisme de prise en compte du contenu pour pondérer chaque canal de manière adaptative. Dans sa forme la plus élémentaire, cela pourrait signifier l'ajout d'un paramètre unique à chaque canal et l'attribution d'un scalaire linéaire à la pertinence de chacun d'eux. Les SENets offrent une plongée plus profonde dans les cartes de caractéristiques, fournissant une compréhension globale de chaque canal en réduisant les cartes de caractéristiques à une seule valeur numérique. Il en résulte un vecteur de taille n , où n est égal au nombre de canaux convolutifs. Ensuite, il passe par un réseau neuronal à deux couches, qui produit un vecteur de la même taille. Ces n valeurs peuvent maintenant être utilisées comme poids sur les cartes de caractéristiques originales, en pondérant chaque canal en fonction de son importance.

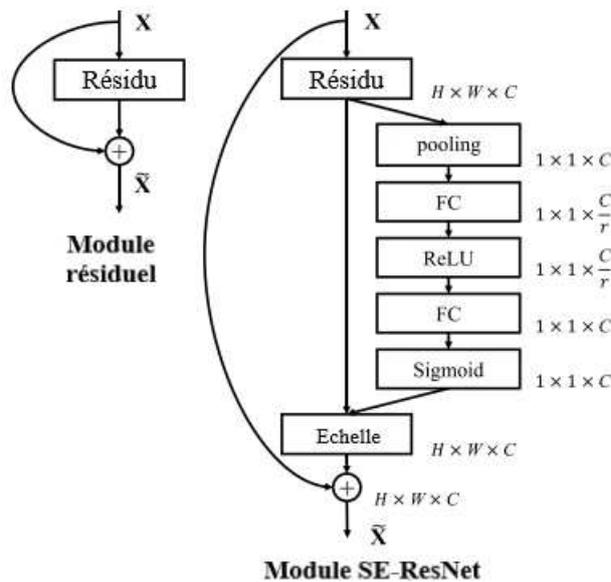


FIGURE 2.13 – Comparaison entre le bloc résiduel de ResNet et le bloc de "squeeze and excitation" de SE-ResNet. La figure est adaptée de [55].

2.4 Conclusion

Dans ce chapitre nous avons introduit les techniques de l'intelligence artificielle que nous utilisons durant cette thèse. Après l'étude de l'évolution des algorithmes d'intelligence artificielle, nous avons identifié que les réseaux de neurones convolutifs sont les plus appropriés à de nos besoins. Les réseaux de neurones convolutifs (CNN) sont utilisés depuis 1980 pour l'analyse d'images. Malgré leur succès initial, leur popularité a diminué jusqu'à la compétition ImageNet en 2012, où un modèle CNN entraîné par Krizhevsky et al [56] a obtenu des résultats d'état de l'art avec une grande marge. Cela a été rendu possible par l'utilisation efficace des GPU, l'augmentation des données et les nouveaux composants des architectures CNN. Les CNN ont été appliqués à l'analyse d'images médicales dès 1993, lorsque Lo et al [57] les ont utilisés pour la détection de nodules pulmonaires. Malheureusement, comme dans le domaine général de la vision par ordinateur, ils n'ont pas connu un grand succès, principalement en raison des durées et des difficultés d'apprentissage. Cette situation a commencé à changer en 2015, lorsque le nombre d'articles documentant l'apprentissage profond dans le domaine de l'analyse d'images médicales a commencé à augmenter rapidement. Depuis lors, l'apprentissage profond est devenu le thème dominant des conférences dans ce domaine [71].

Dans le chapitre suivant, nous explorons les travaux de l'état de pour les problématiques de l'imagerie médicale, et en particulier : segmentation des artères coronaires, la détection de la sténose et la classification des plaques ainsi que la segmentation des anévrismes intracrâniens non rompus.

Chapitre 3

État de l'art

3.1 Introduction

Dans le chapitre précédent nous avons décrit les avancées récentes liées à l'intelligence artificielle et son rôle important dans la résolution de multiples défis liée à l'imagerie en général. Avec le développement rapide de l'intelligence artificielle, l'utilisation de cette technologie pour exploiter les données cliniques est devenue une tendance majeure dans le domaine médical [58, 59]. L'utilisation d'algorithmes d'IA avancés pour l'analyse d'images médicales, l'une des parties critiques du diagnostic clinique et de la prise de décision, est devenue un domaine de recherche actif tant dans l'industrie que dans l'académique [60, 61]. Les applications récentes de l'apprentissage profond dans l'analyse d'images médicales impliquent diverses tâches liées à la vision par ordinateur, telles que la détection, la segmentation et le recalage d'images.

Le recalage d'images, également appelé déformation d'images ou fusion d'images, est un processus de mise en correspondance de deux ou plusieurs images. L'objectif du recalage d'images médicales est d'établir une correspondance optimale entre des images acquises à des périodes différentes, par des modalités d'imagerie différentes (telles que le CT, l'IRM) chez des patients différents. Récemment, des méthodes d'apprentissage profond ont été appliquées au recalage d'images. Nous pouvons citer les travaux de [62, 63] pour le recalage d'images déformables, [64, 65] pour le recalage modèle-image et Xhiang et al [66] pour la correction de l'atténuation

des images PET/IRM (Positron Emission Tomography). Un ensemble des méthodes d'apprentissage non supervisé ont été introduit pour le recalage déformable d'images 2D CT/MR [67], le recalage par paire d'images médicales 3D [68] et le recalage d'images affines et déformables [69].

La détection et la segmentation des lésions est probablement la tâche la plus difficile en imagerie médicale, car les lésions sont plutôt petites dans la plupart des cas. De plus, leurs tailles varient considérablement d'un scan à l'autre, ce qui entraîne des déséquilibres dans les jeux de données d'apprentissage.

L'architecture U-Net [30] est le réseau entièrement connecté le plus populaire pour la segmentation des images médicales (sec 2.3.1). Plusieurs méthodes ont été proposé tirant parti de l'efficacité de cette dernière. En effet, Vnet [33] est la version 3D de U-Net. Cette architecture est entraîné de bout en bout sur des volumes IRM de la prostate, et apprend à prédire la segmentation pour l'ensemble du volume en une seule étape. U-Net++ [32] est essentiellement un réseau d'encodage-décodage profondément supervisé où les sous-réseaux d'encodage et de décodage sont connectés par une série de connexion de saut imbriqués et denses pour de multiples tâches de segmentation d'images médicales notamment, la segmentation de nodules dans les CT à faible dose du thorax, segmentation de noyaux dans les images de microscopie et segmentation du foie dans les CT abdominaux. U-Net 3+ [35] tire parti des connexions de saut à grande échelle et des supervisions profondes pour segmenter les organes qui apparaissent à des échelles variables. Alom et al [34] ont proposé un réseau de neurones convolutifs récurrents (RCNN) basé sur U-Net ainsi qu'un réseau de neurones convolutifs résiduels récurrents (RRCNN), nommés RU-Net et R2U-Net respectivement. Les modèles proposés utilisent la puissance du U-Net, du réseau résiduel et du RCNN pour la segmentation des vaisseaux sanguins dans les images de la rétine, du cancer de la peau et des lésions pulmonaires. Attention U-Net [31] a été entraînée avec des AG (Attention Gates) pour apprendre implicitement à supprimer les régions non pertinentes dans une image d'entrée tout en mettant en évidence les caractéristiques saillantes utiles pour la segmentation multi-classes des images de CT abdominal.

Pour continuer avec les architectures bien connues utilisées en imagerie médicale, Deep Medic [37] est un travail populaire, qui a gagné la compétition ISLES 2015 [36]. Dans DeepMedic,

une architecture CNN 3D a été introduite pour la segmentation automatique des lésions cérébrales, ce qui donne une performance d'état de l'art sur les scans 3D du cerveau. Ce travail a été poursuivi par Kamnitsas et al [38] lors du challenge BRATS 2016 [39] (segmentation de tumeurs cérébrales) où les auteurs ont tiré profit des connexions résiduelles dans les CNN 3D. Dans ce contexte, Zhou et al. [40] ont proposé un CNN 3D (variante 3D de FusionNet [44]) pour la segmentation des tumeurs cérébrales lors du défi BRATS 2018 [41, 42, 43].

L'apprentissage profond a été exploré dans l'oncologie aussi. Le cancer du foie est l'une des principales causes de décès par cancer dans le monde [45]. Dans ce contexte, Vorontsov et al. ont utilisé des CNN pour détecter et segmenter des tumeurs du foie [46]. Mais afin d'améliorer les performances sur les petites lésions, un U-Net modifié (mU-Net) est proposé par Seo et al [47]. Revenons au variante d'U-Net, Li et al [48] ont tiré profit de DenseUnet 2D et l'approche de diagnostic hiérarchique (H-DensNet) pour la segmentation des lésions du foie. Ce réseau a assuré la meilleure performance dans le classement du LiTS 2017 [49].

Finalement, et à l'issue de la pandémie de SARS-COV2, multiple travaux ont été consacré à la détection du COVID-19 à partir des différentes modalités (CT, rayons X) qui est une tâche relativement compliquée. Les revues de [50, 51, 52] décrivent plus d'une centaine de méthodes à base d'apprentissage profond qui ont réussi à relever ce défi.

Nous nous intéressons à l'étude de l'une des tâches qui s'inscrit dans le cadre de la détection des lésions, à savoir la détection de sténoses. Bien que ce problème soit un sujet de recherche indépendant, son succès est fortement lié à l'extraction des artères coronaires, qui est, en soi, une tâche difficile à réaliser.

De ce fait, ce chapitre est consacré à l'étude de l'état de l'art de l'extraction des artères coronaires et la détection de la quantification de la sténose. Dans un premier lieu, nous commençons par l'étude des travaux consacrés à la détection des structures vasculaires dans la section 3.2. Nous décrivons les recherches qui se sont basés sur les méthodes classiques de traitement d'images ainsi que les méthodes basés sur l'apprentissage profond en fournissant les avantages et les inconvénients de chaque famille de ces approches. Dans un second lieu, nous détaillons les travaux qui s'intéressent à la détection de sténose et la classification des plaques. De ce fait, la section 3.3 se départagent en deux parties : les approches basées sur l'estimation des

vaisseaux sains, la modélisation des lésions et les approches basées sur l'apprentissage profond. En guise de conclusion, nous revenons sur les méthodes qui ont influencé notre travail et nous introduisons les chapitres de nos contributions.

3.2 Détection des structures vasculaires

La segmentation des vaisseaux est une problématique compliquée et difficile. En plus des problèmes habituels liés aux protocoles et aux modalités d'acquisition (contraste, résolution, bruit et d'artefacts), la structure des réseaux vasculaires est souvent particulièrement complexe. Les vaisseaux sanguins présentent généralement une grande variabilité de tailles et de courbures. Leur apparence et leur géométrie peuvent être perturbées par des calcifications, des anévrismes et des sténoses. De plus, ils font partie d'un environnement anatomique complexe, entourés souvent par d'autres organes plus grands en taille.

Nous explorons les travaux de l'état de l'art et l'évolution de l'extraction des caractéristiques propres aux artères coronaires au cours de ces deux dernières décennies. Nous basons notre étude sur les revues de [70, 71, 72]. Puisque l'état de l'art est très exhaustif en terme des méthodes, modèles et schémas d'extraction, cette section se concentre sur les différents types de caractéristiques et descripteurs utilisés.

3.2.1 Les caractéristiques basés sur l'apparence

Les modèles se fondent sur un ensemble d'hypothèses qui permettent de refléter la représentation et l'évolution des structures qu'ils ciblent. Ainsi, l'hypothèse la plus simple à exploiter considère que les vaisseaux sont plus lumineux que leur voisinage direct. L'échelle de Hounsfield, une mesure de la radiodensité dans les images CTA (sec 5.3.1), contient l'information sur l'intervalle d'intensité des vaisseaux (fig 3.1). Celle-ci a été incorporée dans plusieurs travaux [73, 74, 75]. Ceux de [76, 79] cherchent à sélectionner un ensemble des points candidats qui devraient se trouver principalement à l'intérieur des vaisseaux. Cette recherche est faite à l'aide d'une analyse des intensités maximales locales pour le premier et une mesure du flux sphérique pour le

deuxième. La première approche assume que les intensités vasculaires sont localement maximales alors que la deuxième mesure la divergence des gradients d'image en mesurant le flux de gradient à travers les frontières des sphères multi-échelles. A son tour, [77] a utilisé un tenseur de second ordre construit à partir de mesures d'intensité directionnelles pour suivre l'ensemble de l'arbre coronaire à partir d'un point de départ unique placé au centre de la section transversale de l'un des vaisseaux. Cette méthode utilise une détection automatique des branches basée sur un regroupement K-moyennes des valeurs d'intensité. Une extension de cette méthode a été proposée par [78]. Elle est basée sur l'utilisation d'un tenseur d'ordre supérieur (HOT) basé sur le flux cylindrique en 4D qui résout également le problème de la détection des branches.

Le problème majeur de ces approches est la non constance de la distribution des valeurs d'intensités dans les images CTA et MRA. Dans la pratique, il est impossible d'obtenir une constance parfaite de la concentration de l'agent de contraste. L'hétérogénéité de ce dernier entraîne une variabilité de l'apparence, même pour des modalités calibrées avec précision comme le CTA.

C'est dans ce cadre que l'attention a basculé vers l'étude de la distribution statistique de l'intensité des vaisseaux au lieu de leur plage de valeurs. Cette distribution a été modélisée par une multitude de modèles. Généralement, ces modèles peuvent être départagés en deux classes : modèles de type gaussien [81, 82, 83, 84, 85] et modèles de type non gaussien [86, 87, 88, 89]. Ces modèles sont fortement utilisés pour la création des filtres adaptés. Le premier type est basé

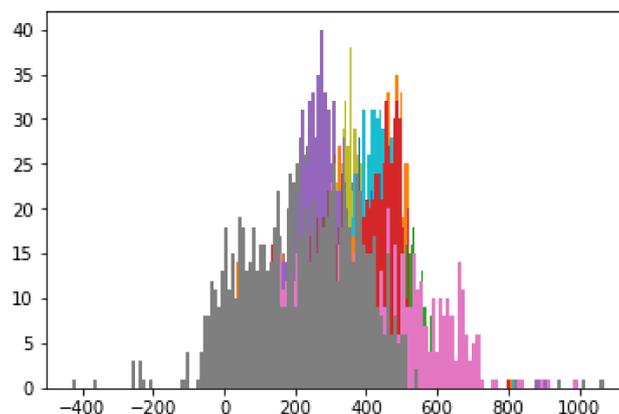


FIGURE 3.1 – Histogramme des valeurs de l'unité de Hounsfield pour les points appartenant à la ligne centrale de la base d'entraînement. Les patients sont représentés par des couleurs différentes.

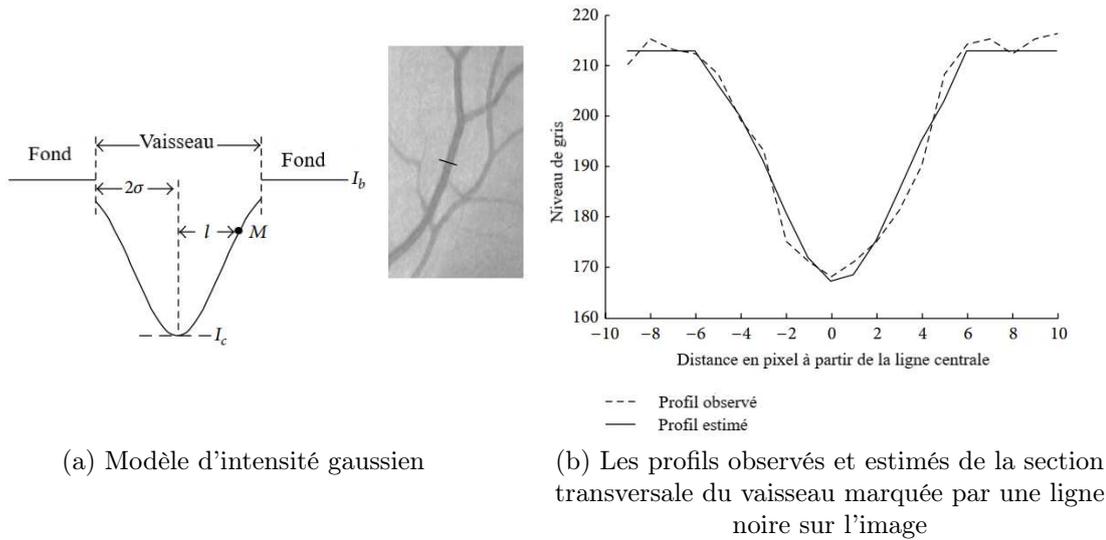


FIGURE 3.2 – Profil d'intensité de la section du vaisseau. La figure est adaptée de [94].

sur la connaissance préalable que la section transversale d'un vaisseau est de forme gaussienne (cf fig 3.2). Par conséquent, s'il existe un vaisseau et que sa largeur correspond à la taille du filtre, une réponse forte est obtenue et le vaisseau est alors détecté. Dans le but de réduire les fausses réponses des vaisseaux au niveau des structures non-vasculaires, différentes variantes ont été proposées pour améliorer les performances de la réponse initiale du filtre adapté [90]. [91] a utilisé un filtrage multi-échelle, [92] a opté pour un seuillage multiple et [93] a basé son filtre sur la dérivée de premier ordre de l'image gaussienne. Ces méthodes restent limitées par l'hypothèse simpliste que le profil d'intensité de la section transversale d'un vaisseau suit la forme d'une gaussienne. Ce qui n'est pas toujours le cas. Les vaisseaux ne sont pas entièrement linéaires et n'ont pas une largeur constante sur une certaine distance. Cette hypothèse rend difficile de s'adapter aux variations de largeur et d'orientation des vaisseaux.

Par conséquent, pour modéliser plus précisément les vaisseaux de petite, moyenne et grande tailles, d'autres travaux proposent différentes distributions. Par exemple, [86] a proposé une distribution de Rice alors que [87] a présenté une analyse de la direction du champ vectoriel du gradient d'intensité qui suit la loi de Cauchy. Une autre méthode qui modélise bien les structures vasculaires est celle de la détection des lignes [88] qui évalue l'intensité moyenne le long des lignes de longueur fixe selon différentes orientations.

La limitation principale de ces méthodes est leur approche locale. De ce fait, pour caractériser

plus précisément les structures vasculaires, certaines méthodes définissent un modèle mixte qui considère les informations sur la structure du vaisseau et les tissus voisins. Des techniques statistique ont été proposées pour modéliser à la fois le vaisseau et son arrière-plan de manière plus précise [95, 96]. Elles se basent sur le fait que ce dernier est homogène et constant. En raison de la présence possible de pathologies vasculaires (calcification, sténose,...), l'hypothèse explicite de l'homogénéité de l'arrière-plan échouerait. C'est pourquoi, [97] a introduit l'idée que les vaisseaux sont plus homogènes que leur fond, ce qui permet d'améliorer les résultats à proximité des régions pathologiques. En raison de leur dépendance à l'égard de la modalité de l'image et de leur incapacité à modéliser correctement les vaisseaux en présence des artefacts (mouvement du patient par exemple), de pathologies (sténose, anévrismes) ou de faible contraste, les modèles d'apparence ne sont pas fiables pour les tâches de segmentation précise des vaisseaux.

3.2.2 Les caractéristiques basées sur la géométrie

Une caractéristique essentielle des vaisseaux sanguins est leur structure spécifique. Leur longueur et forme, en particulier, est une connaissance préalable précieuse qui peut être encodée

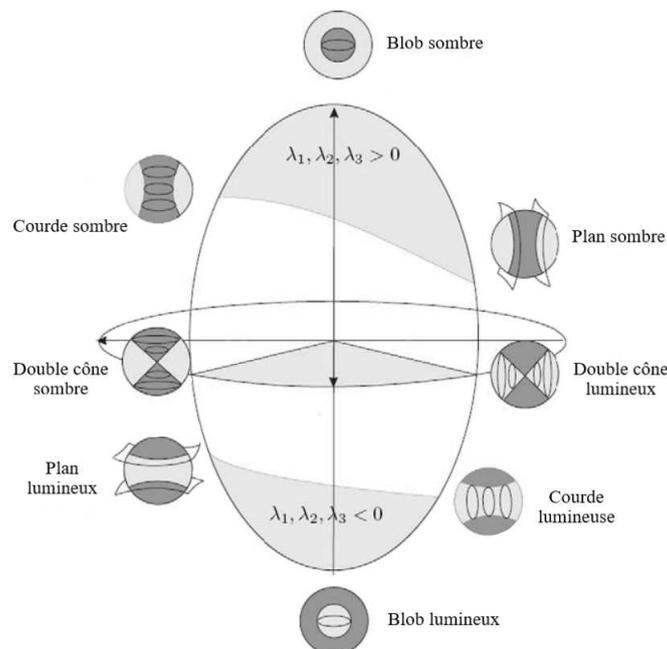


FIGURE 3.3 – Ellipsoïde de second ordre de l'espace des formes de Frangi et al [98]. Les prototypes de forme sont définis en fonction des valeurs propres de la matrice hessienne des intensités locales λ_i . La figure est adaptée de [70]

par des modèles géométriques. La plupart des recherches sur les caractéristiques géométriques se reposent sur des méthodes basées sur le calcul de la matrice hessienne afin de détecter les structures tubulaires. La matrice hessienne est la matrice des dérivées de second ordre de l'intensité de l'image. Pour calculer ses valeurs à chaque voxel, d'abord le volume initial est convolué (éq 3.2) avec un noyau de distribution gaussienne (éq 3.1). Ensuite, l'ensemble est dérivé deux fois pour obtenir les dérivées de second ordre (éq 3.3).

Soient I_0 le volume initial, p un voxel de coordonnées $p = (x, y, z)$, \otimes représente l'opération de convolution et G_σ un kernel de distribution gaussienne avec un écart type σ .

$$G_\sigma(p) = G_\sigma(x, y, z) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x^2+y^2+z^2)}{2\sigma^2}} \quad (3.1)$$

Le résultat de la convolution du volume initial avec le kernel gaussien est donné par

$$I_\sigma(p) = I_\sigma(x, y, z) = I_0(x, y, z) \otimes G_\sigma(p) \quad (3.2)$$

Finalement, nous obtenons la matrice hessienne à chaque point par :

$$H_\sigma(p) = \begin{pmatrix} \frac{\partial^2 I_\sigma(x, y, z)}{\partial x^2} & \frac{\partial^2 I_\sigma(x, y, z)}{\partial x \partial y} & \frac{\partial^2 I_\sigma(x, y, z)}{\partial x \partial z} \\ \frac{\partial^2 I_\sigma(x, y, z)}{\partial y \partial x} & \frac{\partial^2 I_\sigma(x, y, z)}{\partial y^2} & \frac{\partial^2 I_\sigma(x, y, z)}{\partial y \partial z} \\ \frac{\partial^2 I_\sigma(x, y, z)}{\partial z \partial x} & \frac{\partial^2 I_\sigma(x, y, z)}{\partial z \partial y} & \frac{\partial^2 I_\sigma(x, y, z)}{\partial z^2} \end{pmatrix} \quad (3.3)$$

La matrice hessienne est symétrique, elle a donc trois valeurs propres réelles λ_1, λ_2 et λ_3 et trois vecteurs propres associés (\vec{e}_1, \vec{e}_2 et \vec{e}_3). Les signes ainsi que les amplitudes relatives et absolues des valeurs propres caractérisent la forme locale de l'image. Ces valeurs propres et/ou les vecteurs propres sont souvent utilisés pour proposer une mesure de vascularité qui peut être interprétée comme la probabilité d'appartenance d'un voxel à un vaisseau sanguin. Une analyse des valeurs propres ($|\lambda_1| \leq |\lambda_2| \leq |\lambda_3|$) et les directions principales ($\vec{e}_1, \vec{e}_2, \vec{e}_3$) de la matrice hessienne permet de différencier différents modèles d'orientation comme l'indique la fig 3.3 (blob, tubulaire, plan ou sans direction préférée). Une structure tubulaire idéale implique $|\lambda_1| \approx 0, |\lambda_1| \ll |\lambda_2|, \lambda_2 \approx \lambda_3$, avec \vec{e}_1 est la direction de la courbure minimale (le long du

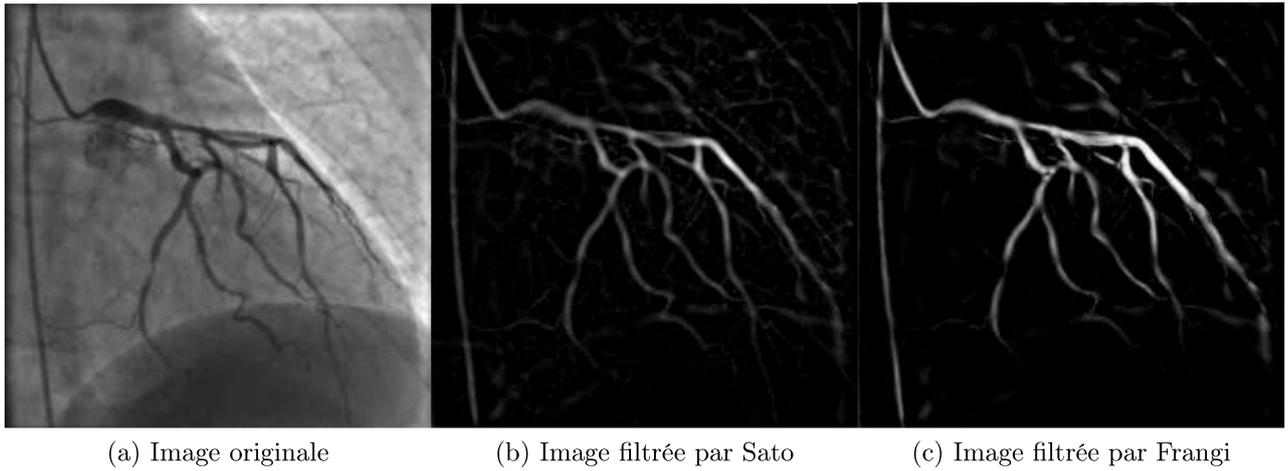


FIGURE 3.4 – Amélioration des vaisseaux avec deux filtres différents. La figure est adaptée de [101]

vaisseau).

La mesure de vascularité produit une réponse maximale à l'échelle σ correspondant au diamètre du vaisseau à détecter. Cette mesure est offerte par plusieurs filtres notamment, le filtre de Sato [99] et le filtre de Frangi [98]. Le principal avantage de ces filtres est leur aspect multi-échelle, détectant ainsi des objets de tailles différentes. Néanmoins, le filtre de Sato est plus sensible au bruit que le filtre de Frangi lorsqu'il est appliqué aux angiographies [100]. La fig 3.4 montre que le bruit de fond est mieux éliminé par le filtre de Frangi que par celui de Sato.

Frangi et al [98] ont conçu une fonction de mesure de vascularité V_F^g pour mesurer la similarité d'une structure à un tube idéal qui se définit comme suit :

$$V_F^\sigma(p) \begin{cases} 0 & \text{Si } \lambda_2 > 0 \text{ ou } \lambda_3 > 0, \\ (1 - \exp(-\frac{R_A}{2\alpha^2}))\exp(-\frac{R_B}{2\beta^2})(1 - \exp(-\frac{S^2}{2c^2})) & \end{cases} \quad (3.4)$$

où α, β, c sont les paramètres qui contrôlent la sensibilité de ce filtre aux mesures de dissimilarité entre les différentes formes de structures. R_A mesure la dissimilarité entre les tubes et les plans, R_B différencie entre les tubes et les blobs alors que S distingue entre les vaisseaux et le fond. Ces mesures sont décrites par les équations suivantes :

$$R_A = \frac{|\lambda_2|}{|\lambda_3|} \quad (3.5)$$

$$R_B = \frac{|\lambda_1|}{\sqrt{|\lambda_2\lambda_3|}} \quad (3.6)$$

$$S = \sqrt{\lambda_1^2 + \lambda_2^2 + \lambda_3^2} \quad (3.7)$$

La mesure finale de la vascularité intègre les réponses du filtre à différentes échelles en prenant la réponse maximale pour chaque échelle selon l'équation ci-dessous :

$$V_F(p) = \max_{\sigma_{min} \leq \sigma \leq \sigma_{max}} V_F^\sigma(p) \quad (3.8)$$

Un facteur de normalisation γ a été introduit par [102] pour normaliser les valeurs d'intensité sur l'ensemble des échelles choisies. Ce paramètre γ peut être ajusté pour donner une préférence à certaines échelles. Il est égal à 1 si aucune échelle n'est privilégiée. En prenant $\gamma < 1$ nous favorisons les petites échelles tandis qu'avec $\gamma > 1$ nous privilégions les plus grandes.

$$V_F(p) = \max_{\sigma_{min} \leq \sigma \leq \sigma_{max}} \sigma^\gamma V_F^\sigma(p) \quad (3.9)$$

Selon l'application, des connaissances supplémentaires (intervalle spécifique de rayons des vaisseaux et bifurcations, par exemple) peuvent être incorporées. En premier temps, Bauer et al. [103] ont basé leur approche de détection des tubes sur le flux de gradient vectoriel et une analyse du champ vectoriel résultant. Contrairement aux filtres de détection de tubes conventionnels, cette approche évite l'analyse multi-échelle avec les problèmes d'espace d'échelle qui y sont liés et est capable d'identifier les objets tubulaires entourés de différents tissus tels que les

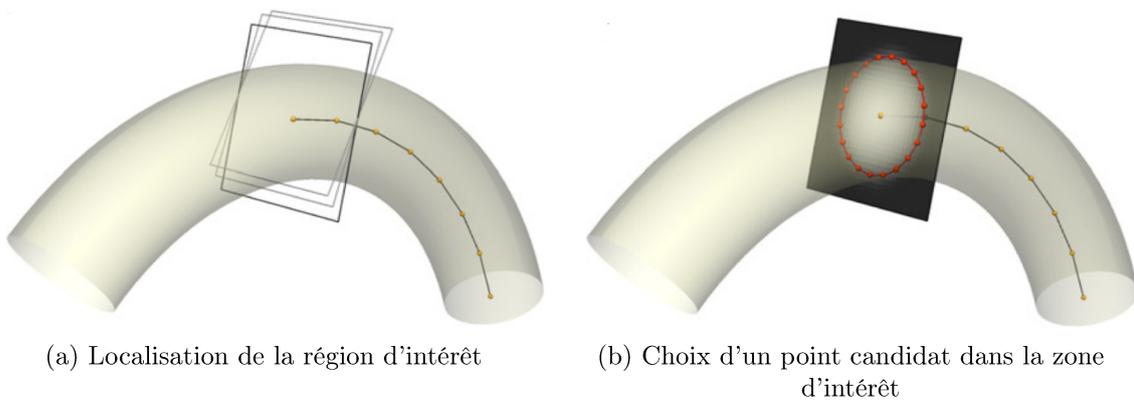


FIGURE 3.5 – Diagrammes montrant les étapes d'un algorithme de suivi [76].

vaisseaux sanguins à proximité de calcifications. Après l'identification des structures tubulaires, leurs lignes centrales sont extraites et regroupées en structures arborescentes complètes. Sur la base des informations de valeur de gris et de la longueur de la ligne centrale des tubes, les structures n'appartenant pas aux artères coronaires sont éliminées.

Par la suite, pour Krissian et al [104] les artères coronaires sont initialement distinguées des vaisseaux plus grand et de la masse sanguine du cœur à l'aide d'un classifieur flou (fuzzy). Une mesure de vascularité est introduite ensuite pour renforcer la séparation des coronaires des autres structures non tubulaires. Cette mesure consiste en une combinaison du produit externe du gradient et du carré de la matrice hessienne. Le point de départ du vaisseau est obtenu automatiquement, tandis que le point d'arrivée est fourni par l'utilisateur. Enfin, la ligne centrale est obtenue comme le chemin de coût minimal entre ces deux points.

A leur tour, Yang et al. [105] ont proposé une modification de la réponse du filtre de Frangi au niveau des bords. Ceci a fait le sujet d'une introduction d'un filtre de vaisseau amélioré en ajoutant des caractéristiques géométriques locales. Ces caractéristiques sont obtenues en effectuant une diffusion de rayons (raycasting) dans des sphères locales. Pour chaque rayon, la diffusion s'arrête lorsqu'il atteint la frontière de la sphère ou lorsqu'il rencontre la limite d'une structure locale. La distribution de ces rayons décrit les caractéristiques géométriques de la forme locale, qui est ensuite mesurée pour discriminer les fausses réponses des cavités cardiaques et les réponses souhaitées des artères coronaires. Par exemple, après la diffusion dans toutes les directions, seuls les rayons dans les tubes et les jonctions de tubes, sont orientés vers les directions des tubes. Alors que, dans les plans et les sphères, les rayons sont dispersés sans donner de direction explicite. Finalement, après l'obtention d'un arbre vasculaire initial, il est affiné par une recherche automatique de branches. Lesage et al. [109] ont à leur tour proposé un modèle bayésien basé sur un algorithme de filtrage particulier.

Comme on peut le comprendre, la différenciation entre les artères coronaires et les autres structures tubulaires est une opération assez sensible que celle de leurs détection. Ceci peut nécessiter une identification plus sophistiquée que prévu. C'est ainsi que Friman et al. [106] ont obtenu le rang le plus élevé dans le défi CAT08 [107]. Leur approche consiste à considérer la tâche d'extraction de la ligne centrale des artères comme un problème de suivi itératif (cf fig 3.5).

Ils ont proposé alors une modélisation explicite de la forme du vaisseau qui est nécessaire pour segmenter les vaisseaux à très faible contraste. Dans leur travail, un profil de vaisseau tubulaire adapté à la segmentation des petits vaisseaux est introduit (fig 3.6a). Ce profil alimente une fonction de correspondance (matching function) (fig 6.2b). Une fonction de correspondance est un modèle idéal de tube de rayon r et de direction \vec{v} . A l'issue de l'identification des structures vasculaires, la création de l'arbre coronaire est faite avec un suiveur d'hypothèse multiple (Multiple Hypothesis Tracker). Par contre, l'un de ses limitations majeure c'est que cette méthode a eu recours à des points de sélection de l'utilisateur et à une étape de correction manuelle en cas d'échec. Lesage et al [109] ont considéré la segmentation des vaisseaux comme un processus de suivi itératif aussi. Ils proposent alors, un algorithme de suivi bayésien basé sur un filtrage particulière pour la délimitation des artères coronaires. Cet algorithme repose sur un modèle géométrique médian (ligne centrale des artères), appris par estimation de la densité du noyau des filtres, et sur MFlux [110] qui exploite le flux de gradient pour la détection de structures allongées avec des sections transversales circulaires. Nous pouvons aussi citer les travaux de Kitamura et al [108] qui ont construit un modèle de forme des vaisseaux coronaires et ont utilisé un classifieur Adaboost afin de distinguer les vaisseaux sains et pathologiques pour l'extraction automatique de la ligne centrale des vaisseaux.

Malgré tous les efforts et les différents descripteurs créés pour l'extraction des caractéristiques

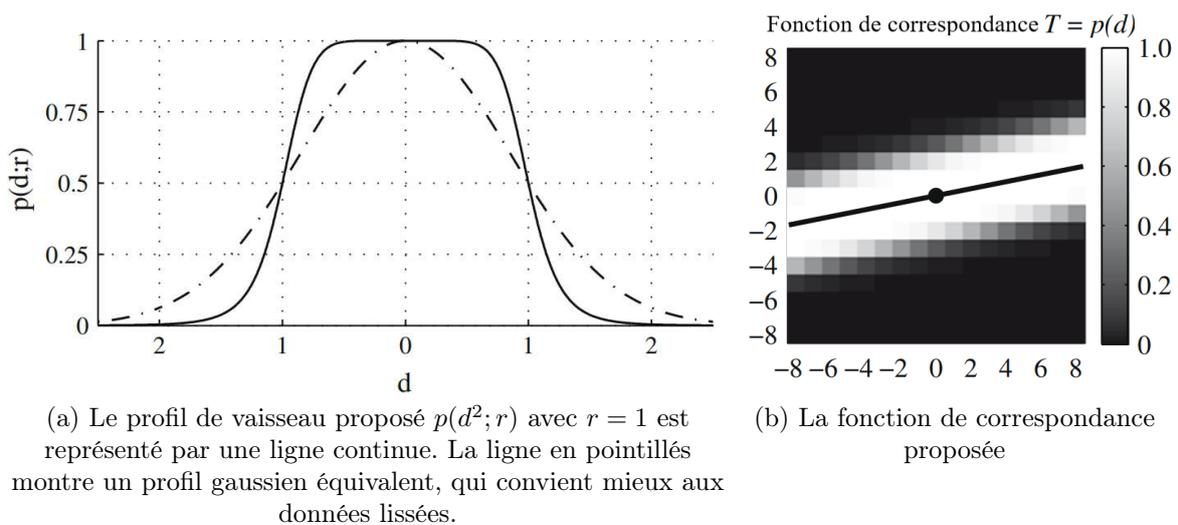


FIGURE 3.6 – Le modèle géométrique proposé par [106] pour la représentation des artères coronaires.

des artères coronaires, ces méthodes restent limitées. En particulier pour les méthodes automatiques qui n'utilisent pas de corrections ou d'interactions avec l'utilisateur. Indépendamment des techniques de pré- et post-traitement qui complètent le pipeline complet de ces algorithmes, les filtres utilisés sont construits manuellement et ils nécessitent des ajustements et des rectifications lorsque leurs hypothèses ne tiennent pas. Les artères coronaires sont des structures complexes à représenter avec un modèle unique. Elles varient en taille (les petits vaisseaux sont difficiles à détecter). Elles varient également dans leur distribution (surtout au niveau des bifurcations) et elles peuvent présenter des maladies qui modifient leurs formes tubulaires (calcification, athérosclérose,...). Ainsi, afin de remplacer l'étape d'extraction manuelle des caractéristiques, les chercheurs se sont tournés vers l'apprentissage profond et notamment vers l'utilisation des réseaux de neurones convolutifs. Ces derniers ont une grande compréhension de la complexité des tâches d'imagerie et une capacité à apprendre les corrélations spatiales et à extraire les caractéristiques visuelles.

3.2.3 Les caractéristiques extraites avec l'apprentissage profond

Les réseaux de neurones profonds ont été progressivement introduits pour automatiser certains modules des pipelines mentionnés précédemment. Gulsun et al. [111] ont exploré l'utilisation de CNN comme technique de post-traitement pour discriminer entre les véritables artères coronaires et les fuites de segmentation. Ils ont d'abord gardé leur modèle de base qui extrait les artères coronaires suite à une analyse de flot optimal (optimal flux). Ensuite, ils ont introduit un CNN à 1D pour la classification des branches. Les entrées de ce CNN consistent de plusieurs caractéristiques comme l'intensité de l'image, la courbure de la ligne centrale, la mesure de la tubularité, les statistiques d'intensité et de gradient (moyenne, écart type) le long d'une branche.

Les approches qui utilisent le suivi itératif ont profité de l'utilisation des CNN dans une multitude de manière. En premier lieu, Wolternik et al [112] ont entraîné un CNN 3D à double sortie à prédire la direction et le rayon les plus probables d'un patch d'image local. Donc, à partir d'un point de départ unique placé manuellement ou automatiquement, un suiveur suit

la ligne centrale du vaisseau dans deux directions en utilisant les prédictions du CNN qui le dirigent. Le suivi est interrompu lorsqu'aucune direction ne peut être identifiée avec une grande certitude (cf fig 3.7). Cependant, cette méthode nécessite au moins un point de départ par vaisseau afin d'extraire sa ligne centrale. Certains vaisseaux nécessitent plus d'un point en raison de l'arrêt prématuré du suiveur. Un CNN supplémentaire pour extraire les points de départ des vaisseaux a également été proposé afin de rendre l'algorithme automatique. Néanmoins, le CNN reste incapable de prendre en compte les bifurcations.

En deuxième lieu, Salahuddin et al propose une amélioration du pipeline de [112] comme montré

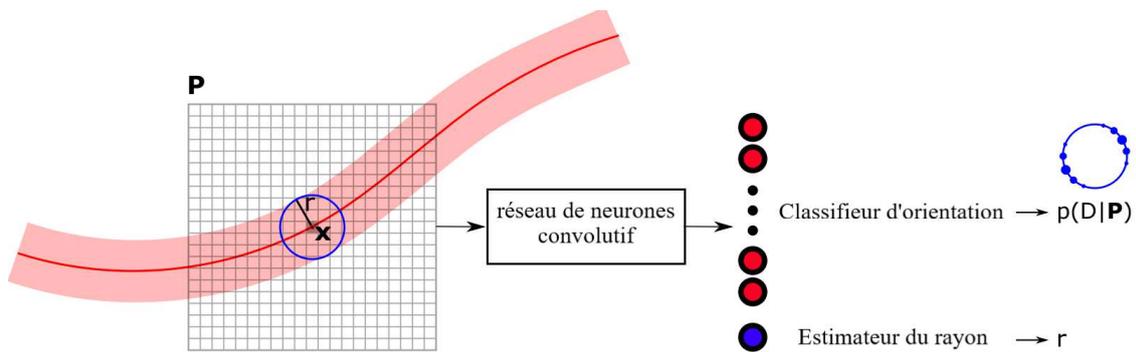


FIGURE 3.7 – Présentation de la méthode de [112]. A la position x , un patch P est extrait et utilisé comme entrée d'un CNN. Ce CNN détermine simultanément une distribution de probabilité $p(D|P)$ sur un ensemble discret de directions (le nombre de directions est un hyperparamètre) sur la sphère (représenté ici par un cercle bleu), et une estimation r du rayon du vaisseau. La figure est adaptée de [112]

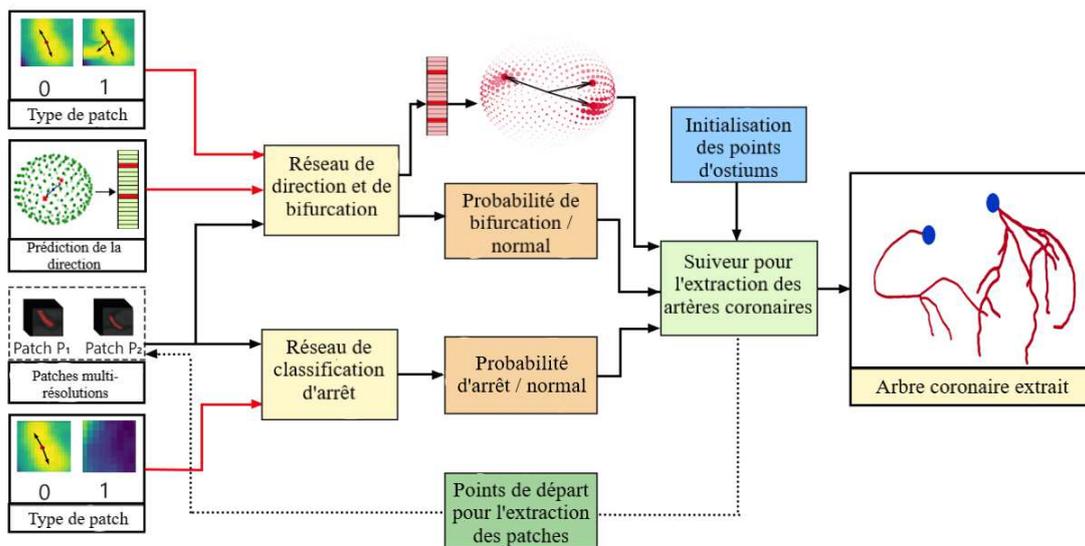


FIGURE 3.8 – Vue d'ensemble de la méthode de [113]. Les lignes rouges représentent les entrées données au modèle de classification de la direction et de la bifurcation et au modèle de classification du patch d'arrêt avec les patches multirésolution P1 et P2. La figure est adaptée de [113]

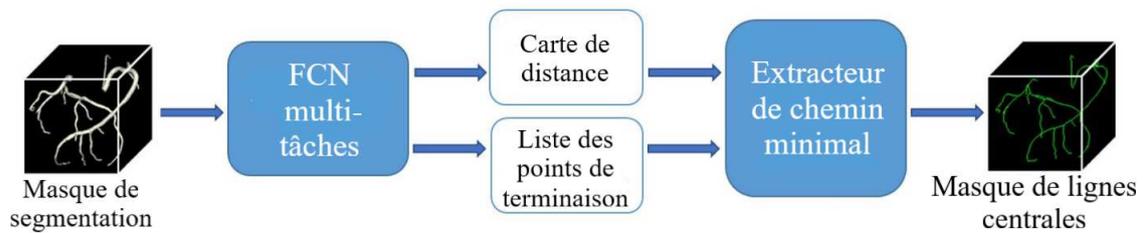


FIGURE 3.9 – Vue d'ensemble de la méthode de [115]. Les lignes rouges représentent les entrées données au modèle de classification de la direction et de la bifurcation et au modèle de classification du patch d'arrêt avec les patches multirésolution P1 et P2. La figure est adaptée de [115]

dans la fig 3.8. Cette fois, en utilisant trois modules différents pour tenir compte du problème de bifurcation et l'arrêt prématuré du suivi. En effet, le premier module est un CNN 3D dont le but est de déterminer la direction ainsi que le type de patch (normal ou bifurcation). Le deuxième module consiste en un autre CNN 3D pour déterminer si le patch contient une artère ou non. Le troisième module appelé "tracker" orchestre l'extraction de la ligne centrale. Le suivi est initialisé à deux points d'ostium obtenus automatiquement. Le "tracker" obtient des prédictions pour les directions et le type de patch du premier module pour chaque patch. Le tracker prend ensuite des étapes en vue de déterminer la ligne centrale des artères. Finalement, le tracker se termine si la sortie du deuxième module signale une condition d'arrêt.

En troisième lieu, Guo et al [115] ont réussi à convertir une carte de segmentation des artères coronaires en un masque des lignes centrales et une liste de points d'extrémité. Ils proposent un FCN multi-tâches à deux sorties qui génère simultanément une carte de distance normalisée de la ligne centrale et une liste des terminaisons du squelette de l'arbre coronaire segmenté (cf fig 3.9). La carte de distance résultante et la liste des points d'extrémité sont introduites dans un extracteur de chemin minimal qui donne les résultats finaux de l'extraction de la ligne centrale.

Une autre méthode de suivi qui a réussi à remplacer le module de l'extraction des caractéristiques par un CNN est celle de Jeon et al [114]. Ils proposent Une méthode de suivi bayésienne combinant un CNN et une méthode de filtrage de particules pour identifier les trajectoires des artères coronaires depuis l'ostium jusqu'aux extrémités distales. Le filtre de particules est un outil de suivi approprié pour des structures aussi minces et allongées. Cependant, la mesure de la vascularité a été faite grâce au CNN pour extraire les lignes centrales des artères coronaires. En outre, ils ont présenté un modèle de détection de bifurcation robuste en regroupant les par-

ticules (issus du filtre particulaire). La méthode proposée permet d'extraire automatiquement toutes les lignes centrales sous forme d'une structure arborescente.

Comme nous pouvons l'observer, l'introduction des CNN n'a pas rendu la tâche de l'extraction des artères coronaires plus simple ou plus facile. En fait, toutes les méthodes que nous venons de décrire comportent au moins deux ou trois modules pour assurer la robustesse de leur modèle. Dans le cas des méthodes basées sur le suivi itératif, elles ont de nombreuses limitations communes dues à la nature de l'approche de suivi. Par exemple, le suiveur peut se terminer plus tôt, ce qui est essentiel pour obtenir une bonne extraction. En outre, les fonctions prédéfinies qui dirigent le suiveur peuvent le conduire à fuir vers d'autres organes. De plus, la détection du point terminal est un défi commun à toutes les méthodes basées sur le suivi car ces méthodes cherchent finalement le chemin maximal local.

D'autres travaux se sont intéressés à la segmentation des artères coronaires et non seulement l'extraction de leurs lignes centrales. Shen et al [121] ont décidé de coupler un CNN pour la segmentation de l'arbre coronaire avec la méthode classique des surfaces de niveaux (level set) qui permet la correction des frontières mal segmentés (sous segmentés ou sur segmentés). Lee et al [122] ont opté pour un réseau de neurones basé qui modélise les déformations de modèles et qui utilise des réseaux de transformation spatiale appelé TETRIS.

TETRIS prend en entrée une image I et une forme à priori U , sous la forme des images, et produit un ensemble de paramètres θ pour une transformation τ_θ . Cette transformation est ensuite appliquée à la forme à priori U . La fonction du coût du modèle final est calculée à partir de la forme à priori déformée (sortie) et la vérité de terrain. La figure 3.10 résume leur pipeline proposé. L'apprentissage profond est assez riche des techniques et permet des représentations diverses des données autres que les CNN. D'une part, Kong et al [116] ont démontré qu'un modèle convGRU (architecture convolutif récurrente profonde) est capable d'apprendre la structure des artères coronaires. D'autre part, Zhang et al [117] ont adopté un apprentissage par renforcement profond. Cette méthode utilise un double Q-learning et conçoit un processus de décision Markovien pour l'extraction des lignes centrales des branches. D'autres méthodes, basés sur les CNN ont été également proposés récemment pour combiner plusieurs tâches avec l'extraction des coronaires comme l'extraction de l'aorte [124] et la segmentation de zones du

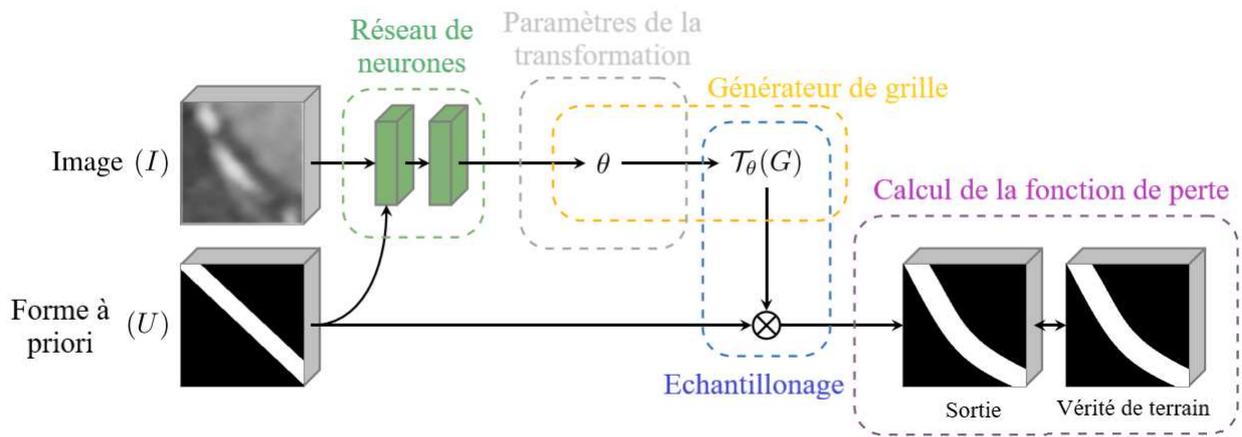


FIGURE 3.10 – Modélisation de l'approche de [122]. Le modèle apprend des paramètres de transformation basé sur des formes tubulaires à priori. La figure est adaptée de [122]

cerveau atteintes lors de maladies cérébrales [120].

Nous pouvons aussi citer les recherches de [118, 119, 123] qui évaluent la robustesse de différents algorithmes d'apprentissage profond en liaison avec l'identification de l'arbre artériel.

3.3 Détection de la sténose et quantification des plaques

La maladie des artères coronaires peut entraîner une crise cardiaque ou une ischémie. Le problème de détection des lésions des artères coronaires fait principalement référence à la localisation des anomalies des vaisseaux causant une limitation du flux sanguin du cœur, comme

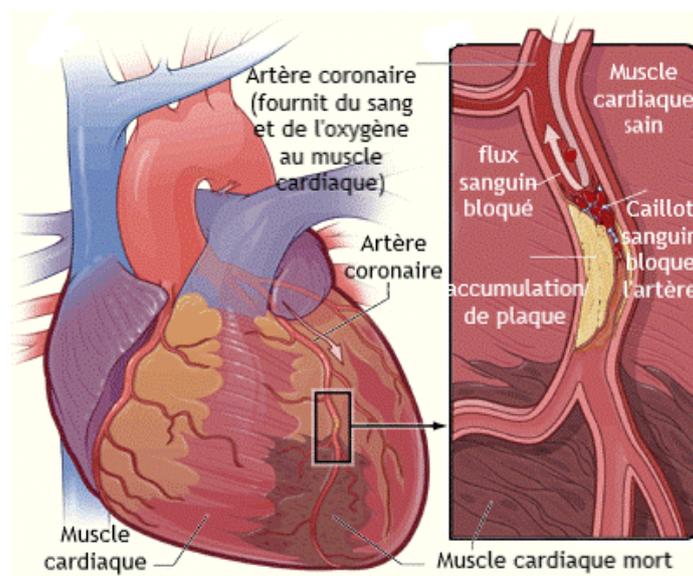


FIGURE 3.11 – La maladie des artères coronaires. La figure est adaptée de [125]

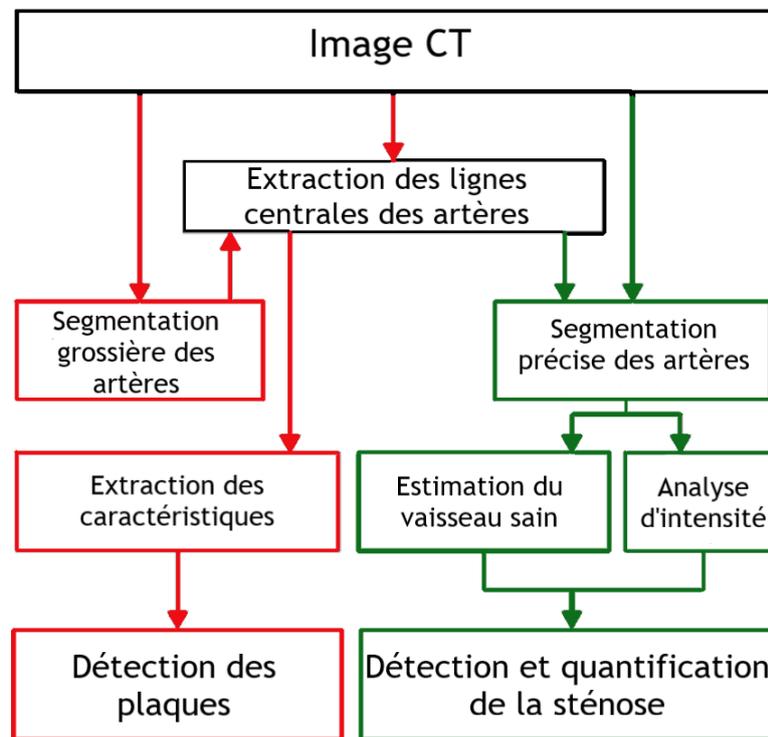


FIGURE 3.12 – Le pipeline général des méthodes de l’état de l’art pour la détection et quantification de la sténoses. Le chemin rouge correspond à l’approche de caractérisation des lésions alors que le chemin vert décrit la détection des lésions à partir des comparaisons avec les vaisseaux sains. La figure est adaptée de [148]

la sténose par exemple. La sténose est un rétrécissement ou un blocage des artères coronaires généralement causé par l’accumulation d’une matière grasse appelée plaque. L’état de l’art est riche en méthodes qui visent à détecter ces lésions à partir des images CT. Nous pouvons dépar- tagées les approches classiques en deux familles : la modélisation des lésions et la modélisation d’un vaisseau sain et la détection des anomalies derrière (cf figure 3.12). Nous ajoutons à ça les approches basées sur l’apprentissage profond.

3.3.1 La modélisation des vaisseaux sains

Généralement, la méthode la plus intuitive et la plus classique est de détecter la sténose comme une diminution soudaine de la valeur du rayon de l’artère après une étape de segmentation robuste des vaisseaux.

Blackmon et al [141] ont présenté un algorithme automatisé d’analyse volumétrique pour mesurer les plaques non calcifiées en utilisant l’identification manuelle des lésions, le seuillage

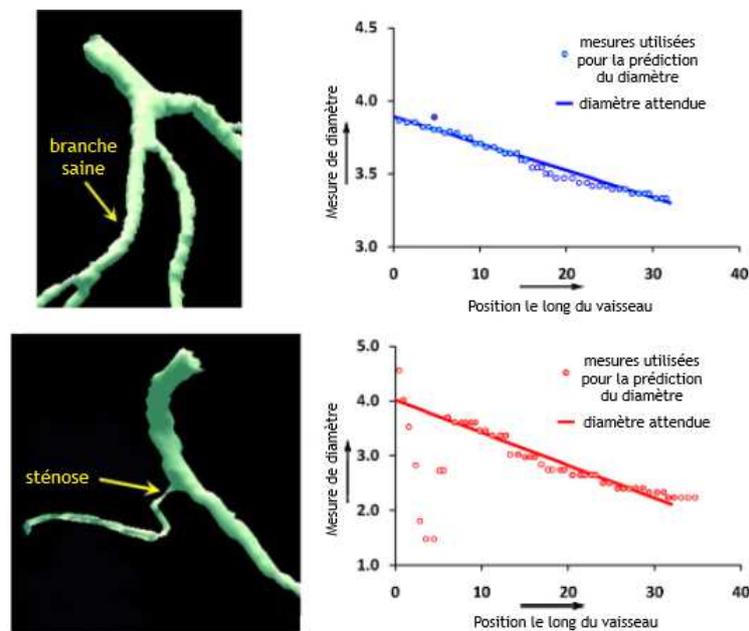


FIGURE 3.13 – L'approche de Xu et al [142] : Résultats du calcul du diamètre artériel attendu sur une branche artérielle saine. La ligne continue prédit le diamètre attendu à n'importe quel endroit de la branche artérielle. La figure est adaptée de [142]

et l'ajustement des diamètres des vaisseaux au-dessus et au-dessous de la lésion. En étudiant seulement les diamètres, Xu et al [142] ont développé une méthode pour estimer le "diamètre attendu" le long d'une branche artérielle donnée. Ils ont effectué une analyse de cohérence des valeurs de diamètre observées le long des branches en utilisant une transformée floue de distance (fuzzy distance transform). Les mesures en dessous du diamètre attendu sont étiquetées comme sténose comme indiqué dans la figure 3.13. Kang et al [128] ont utilisé la méthode des moindres carrés linéaire pour déterminer les diamètres "normaux" à partir des images CT. La régression est effectuée séparément sur chaque segment pour prendre en compte la baisse normale des valeurs de rayon après chaque bifurcation. L'extraction des lésions est réalisée en plusieurs étapes, principalement basées sur le calcul des degrés de sténose par la comparaison des deux profils de diamètres. L'algorithme ne retient que les sténoses dont le degré de rétrécissement est supérieur à 25%. Rinck et al [129] ont opté pour une approche de segmentation basée sur la forme pour extraire les surfaces internes et externes des vaisseaux, puis analyser la déviation entre les deux volumes. Cette méthode peut toutefois nécessiter une interaction supplémentaire avec l'utilisateur pour calculer avec précision les volumes des plaques en plaçant un point de départ avant et après chaque plaque. Blackmon et al [141] ont présenté aussi un algorithme

automatisé d'analyse volumétrique pour mesurer les plaques non calcifiées en utilisant l'identification manuelle des lésions, le seuillage et l'ajustement des diamètres des vaisseaux au-dessus et au-dessous de la lésion. Renard et Yang [130] se basent également sur la segmentation séparée du diamètre intérieur et de la paroi artérielle des artères principales en appliquant une approche de segmentation basée sur un modèle statistique. Les plaques douces sont identifiées en examinant les surfaces de la section transversale effective de l'artère et des surfaces des parois qui l'entourent. Le critère de détection des plaques douces est basé uniquement sur la différence de surface, ce qui rend la méthode sujette à des erreurs.

En résumé, les techniques précédentes sont encore fortement dépendantes de la qualité de la segmentation de l'artère [131, 132, 133, 134, 135]. En effet, toute surestimation ou sous-estimation de la segmentation du vaisseau peut conduire à des détections faussement positives et/ou faussement négatives. L'étape de délimitation du diamètre coronaire (et de la paroi externe) est difficile pour plusieurs raisons : la taille des vaisseaux des artères coronaires, la résolution limitée des images CT et l'effet de partitionnement par volume sont les principales raisons qui rendent la segmentation des artères difficile.

3.3.2 La modélisation des lésions

Cette famille d'approches vise à détecter la sténose à partir de la caractérisation des propriétés de cette lésion. Les plaques sont généralement caractérisées par leur apparence géométrique spécifique correspondant à une zone brillante autour de l'artère dû à la formation des calcifications. Pour détecter et quantifier les plaques non calcifiées, les méthodes proposées ont effectué un seuillage manuel ou semi-automatique sur les valeurs CT dans des régions d'intérêt prédéfinies [126, 127]. Les calcifications sont un stade avancé du processus de développement de la plaque d'athérome. À ce stade, la plaque est principalement composée de calcium, ce qui les fait apparaître comme des structures brillantes collées à la paroi du vaisseau. Sur la base de cette caractéristique d'apparence, l'approche la plus couramment utilisée pour détecter ces structures est l'utilisation de seuils appropriés de valeurs CT combinés à un ensemble d'opérations morphologiques. Wesarg et al [136] ont présenté une méthode pour localiser les calcifications

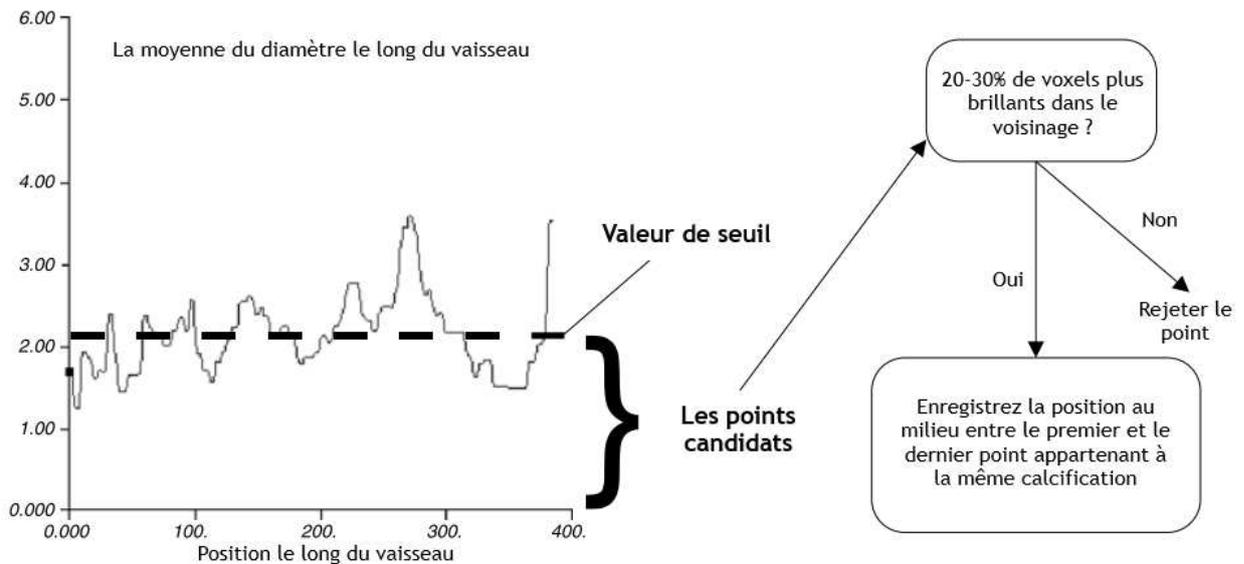


FIGURE 3.14 – L’approche de Wesarg et al [136] : un ensemble de points candidats est sélectionné sur la base d’un seuil calculé automatiquement. Ces points sont ensuite analysés pour déterminer si des valeurs de gris brillantes se trouvent dans leur voisinage. Enfin, les points restants sont décimés à nouveau pour s’assurer qu’un seul point d’entre eux représente la calcification. La figure est adaptée de [136]

en combinant les informations sur le diamètre et l’analyse de la valeur de gris des artères. Leur algorithme fournit suffisamment d’informations pour calculer le diamètre du vaisseau le long du segment extrait (cf figure 3.14). Saur et al [137] ont considéré le fait que les plaques candidates de grande taille avec des valeurs d’intensité élevées sont très susceptibles d’être une vraie détection. Un score d’intensité et un calcul de volume sont ajoutés pour filtrer davantage les fausses prédictions. Wink et al [138] ont proposé une approche de diffusion de rayons 2D pour détecter les plaques calcifiées sur la paroi des vaisseaux en se basant sur un seuil de gradient. Mirunalini et al [149] ont détecté les lésions en analysant les discontinuités de la ligne centrale et de ses voisins. Les calcifications ou le dépôt de graisse présents sur l’artère peuvent maximiser la largeur du contour à cet endroit. Ainsi, en déterminant l’intensité du vaisseau à la largeur maximale, ils ont pu confirmer que les discontinuités correspondantes et la calcification étaient bien des sténoses. Malheureusement, ces méthodes sont limitées par le nombre de caractéristiques réduit qu’ils utilisent. Les lésions sont des structures assez complexes et requièrent plus de descripteurs afin de décrire leur structures.

Dans ce contexte, un grand nombre d’approches (semi-)automatisées se sont basées sur l’extraction de potentielles lésions calcifiées à partir du volume initial, puis un classificateur est

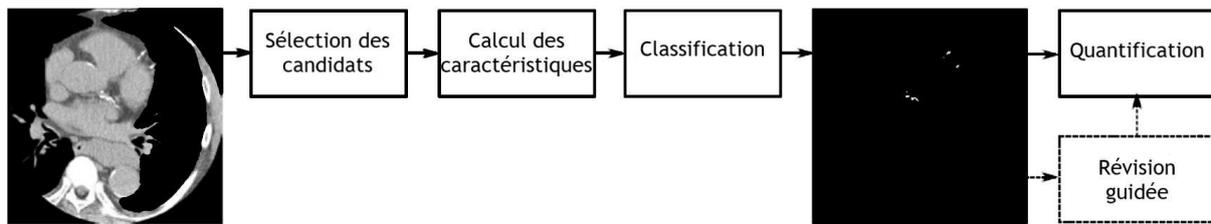


FIGURE 3.15 – Pipeline d’extraction et de quantification automatique des lésions coronaires calcifiées par apprentissage automatique : tout d’abord, l’algorithme commence par identifier un ensemble de candidats. Les caractéristiques appropriées sont calculées pour décrire chacun des candidats choisis. Ensuite, un classifieur est entraîné pour distinguer les vraies calcifications des fausses détections. Une étape de révision est proposée (généralement manuelle) afin de valider/supprimer les calcifications suspectes que le classifieur n’a pas pu détecter. La figure est adaptée de [152]

utilisé pour discriminer les vrais positifs (calcifications coronaires) des faux positifs tels que les os ou les objets métalliques (cf figure 3.15). Mittal et al [140] ont utilisé deux classifieurs (arbre de boosting probabiliste et forêts aléatoires) après avoir extrait neuf caractéristiques, à savoir les intensités moyenne, minimale et maximale, les gradients dans la direction radiale et les gradients dans la direction tangente pour la détection des plaques calcifiées. La détection des formes anormales par l’identification du niveau de densité a été proposée par Zuluaga et al [146]. Ils ont utilisé l’algorithme des machines à vecteurs de support comme méthode d’apprentissage pour séparer les distributions normales et anormales de la section transversale des vaisseaux. Cetin et Unal [145] ont présenté un moyen de détecter les sténoses, y compris les plaques calcifiées et non calcifiées, en utilisant des algorithmes d’arbres de décision, basés sur l’intensité et les caractéristiques géométriques. Halpert et al [143] ainsi que Arnoldi et al [144] ont regroupé plusieurs caractéristiques pour modéliser les lésions calcifiées / non calcifiées autres que le diamètre et l’intensité des vaisseaux. En fait, les lésions calcifiées / non calcifiées se présentent sous la forme d’une zone hyper / hypoatténuante entre le diamètre externe du vaisseau et le diamètre interne. Un ensemble de paramètres est extrait y compris la surface de la section transversale du vaisseau, la présence et la taille de la plaque d’athérosclérose, les bifurcations, le niveau de bruit, la présence et l’étendue des artefacts et la distance à partir de l’ostium. Ils ont proposé ensuite de faire correspondre les caractéristiques extraites aux caractéristiques des lésions qui ont été utilisées pour l’apprentissage de leur algorithme.

En générant des cylindre qui se rapprochent de la forme du vaisseau à multiples échelles, Tess-

mann et al [139] ont réussi à extraire des valeurs de caractéristiques qui décrivent adéquatement les propriétés des lésions sténosées. Cependant, la plupart des caractéristiques locales étaient particulièrement significatives pour les lésions calcifiées, car ces régions ont une valeur d'atténuation élevée. Afin de capturer les plaques douces ayant des valeurs de contraste réduites, des caractéristiques locales de type Haar en combinaison avec des caractéristiques globales, telles que l'intensité moyenne, l'entropie et la variance, sont utilisées. Grâce à leur approche multi-échelles, l'algorithme est capable de gérer la variabilité de la configuration des lésions sténosées. Melki [150] a présenté un algorithme qui pourrait être utilisée comme un premier indicateur d'une sténose sévère dans les segments suspects à forte probabilité. Son algorithme comprend deux étapes : l'utilisation de modèles géométriques pour détecter les régions de suspects et une étape de suppression des faux positifs.

Finissons par l'une des méthode qui utilise les formes géométriques pour détecter la sténose. Nous savons que le filtre de Frangi est capable de détecter les vaisseaux. Cependant, il échoue à proximité des régions sténosées car la forme locale s'écarte de la structure tubulaire saine. Par conséquent, l'approche précédente ne parviendra pas à améliorer les régions sténosées. Pour remédier ces défauts, Lin et al [151], ont proposé un espace de forme en combinant linéairement les paramètres du Frangi avec des coefficients normalisées d'une fonction d'énergie pour créer une conique qui décrit la sténose.

3.3.3 Détection des lésions à l'aide de l'apprentissage profond

L'utilisation de l'apprentissage profond pour la détection de la sténose n'est pas assez développé. Nous comptons moins d'une dizaine d'articles qui ont mis en place cette techniques pour la détection des lésions coronaires. Les différentes approches utilisent deux méthodes de pré-traitement qui sont : l'extraction des artères coronaires et l'application d'une transformation cMPR (nous détaillons cette transformation dans la section 6.3).

Zreik et al [153] ont été les premiers à mettre en place une méthode de détection et de caractérisation automatique du type de plaque coronaire basée sur l'apprentissage profond. En effet, pour effectuer l'analyse automatique complète, un réseau de neurones convolutif récur-

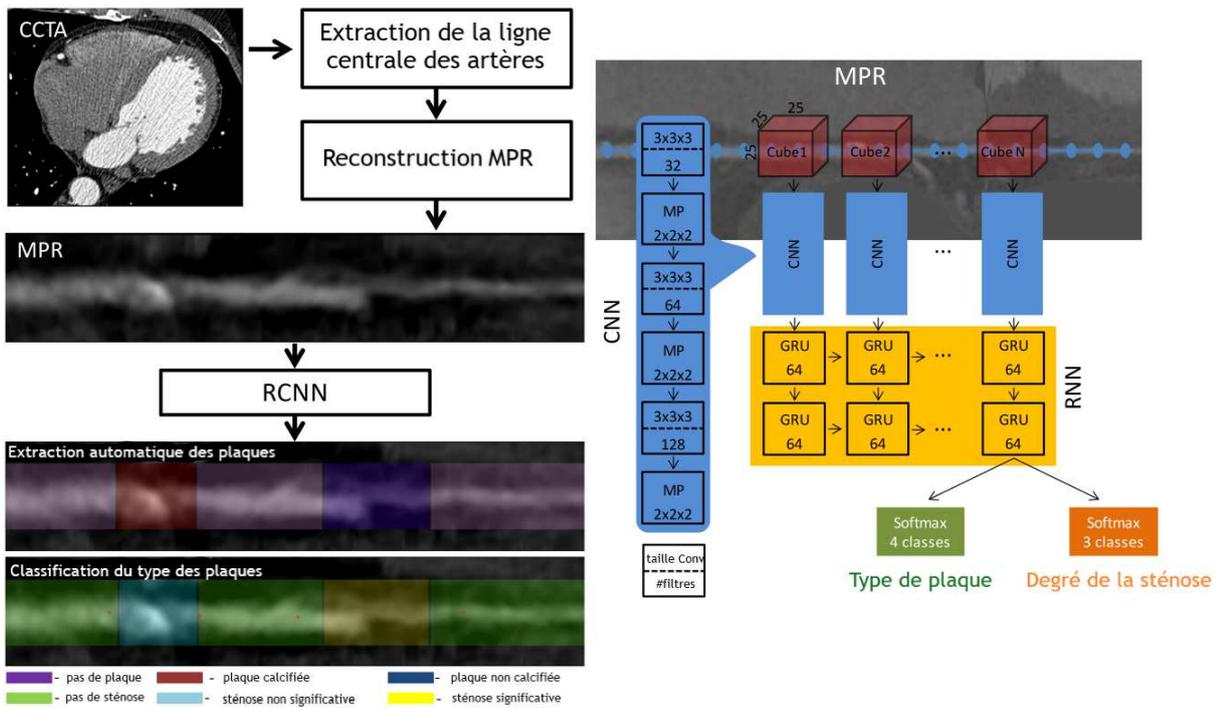


FIGURE 3.16 – Illustration du pipeline proposé par Zreik et al [153]. Le RCNN effectue deux tâches simultanément qui sont : la détection des plaques et la quantification du degré de la sténose. La figure est adaptée de [153]

rent multi-tâches (RCNN) est utilisé pour analyser le voisinage le long de la ligne centrale extraite dans une image cMPR. Ce réseau effectue deux tâches de classification simultanément (cf figure 3.16). Dans la première tâche, le réseau détecte et caractérise le type de plaque coronaire, c'est-à-dire absence de plaque, plaque non calcifiée, mixte ou calcifiée. Dans la deuxième tâche, le réseau détecte et détermine l'importance anatomique de la sténose de l'artère coronaire, c'est-à-dire aucune sténose, sténose non significative (rétrécissement d'artère inférieur à 50%) ou sténose significative (rétrécissement d'artère supérieur à 50%). Le RCNN analyse une séquence de petits volumes du voisinage de la ligne centrale de l'artère. Cette approche permet au RCNN, construit à partir d'un réseau de neurones convolutif 3D (CNN) et d'un réseau de neurones récurrent (RNN) connectés en série, d'extraire les caractéristiques de l'image à partir de petits volumes, quelle que soit la longueur de la plaque, puis d'agrèger toutes les caractéristiques extraites le long de la plaque. Les propriétés de cette architecture sont :

- les données d'entrées : une séquence de cubes extraits le long de l'image cMPR avec une taille de $(25 \times 25 \times 25)$ pour chaque cube et un longueur maximal de séquence de 25 ;
- le CNN contient trois couches de convolution et 3 couches de Max-pooling ;

- le RNN est constitué de deux couches de GRU (gated recurrent units) et des activation ReLu ;
- les cartes de caractéristiques extraites par le CNN sont fournis au RNN ;
- la dernière couche du RNN est attachée à deux classifieurs multi-classes Softmax.

En plus de la nouveauté de cette méthode, Zreik et al ont démontré que l'utilisation d'un réseau à multiple tâches est largement supérieur à un réseau avec une seule tâches (sept classes combinés dans le cas de travail). Par contre, ceci a créer des instances ou la première tâche prédit une absence de plaque alors que la deuxième prédit une existence de sténose. Ce scénario est physiologiquement impossible et induit une manque de correspondance entre les deux tâches. Tejero de Pablos et al [154] ont proposé une méthode hybride basée sur l'utilisation d'un CNN avec des classifieurs SVM pour la prédiction comme indiquée dans la figure 3.17. Le motif derrière cette architecture réside dans l'incapacité de reproduire les travaux de Zreik et al [153] sur un jeu de données réduit à cause de la taille du modèle proposé par ces derniers. Par conséquent, Tejero de pablos et al ont utilisé plusieurs vues du même segment d'artère coronaire pour la classification des sténoses significatives. Ainsi, ils ont proposé une approche multi-vues capable

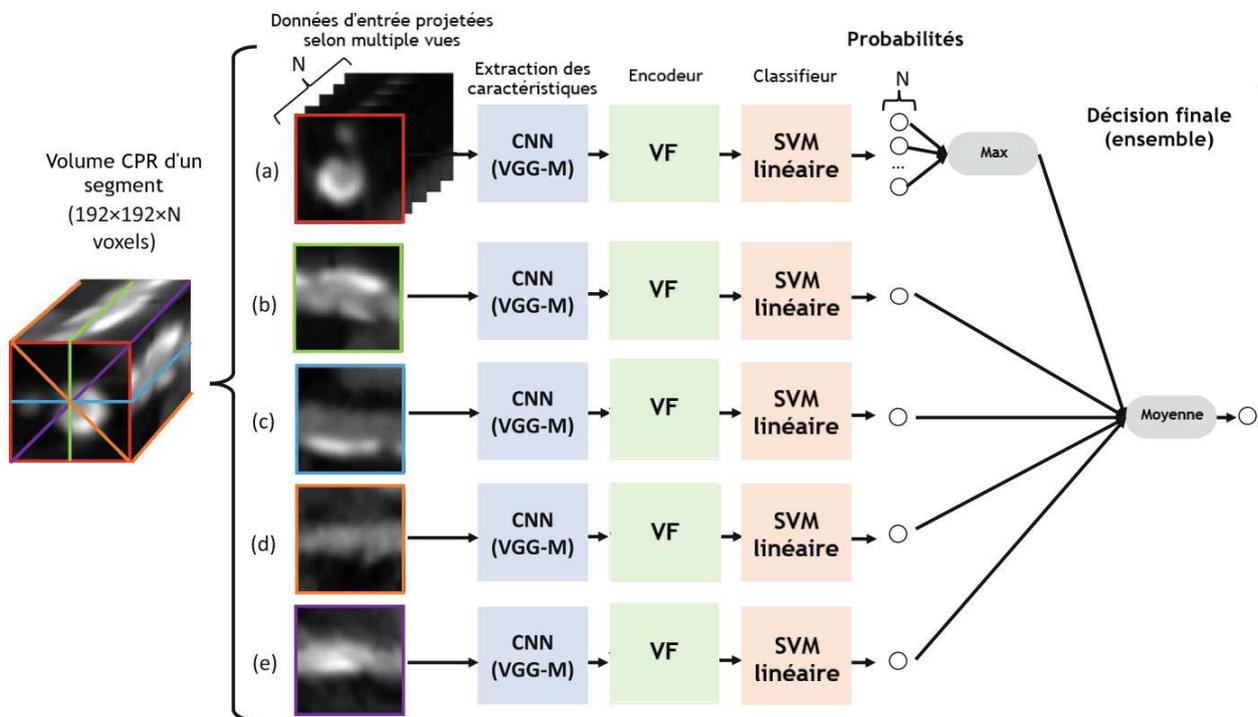


FIGURE 3.17 – Illustration du pipeline proposé par Tejero et al [153]. Le RCNN effectue deux tâches simultanément qui sont : la détection des plaques et la quantification du degré de la sténose. La figure est adaptée de [154]

de fournir une bonne performance avec des jeux de données limités. Dans leur architecture, ils ont utilisé le modèle VGG-M [155]. Ensuite, ils ont appliqué une ACP (analyse des composantes principales), afin de réduire la dimensionnalité et retenir les caractéristiques les plus représentatives. Ces caractéristiques sont encodées à l'aide d'un vecteur de Fisher (VF). L'encodeur VF est entraîné de manière non supervisée, en dédiant un sous-ensemble du jeu d'entraînement pour le faire apprendre la projection ACP et le modèle gaussien des caractéristiques CNN. Ces caractéristiques, finalement encodées, sont utilisées pour entraîner un SVM linéaire. Ce SVM génère la probabilité de la vue d'entrée contenant une sténose significative. Enfin, les probabilités de toutes les vues sont combinées pour une vote finale pour décider si la section d'entrée contient une sténose significative. Malgré les bonnes performances de cette approche, elle est dépendante du choix des projections et ne prend pas en compte la classification du type de la plaque.

Les deux méthodes susmentionnées utilisent une représentation 3D ou une multitude de représentations 2D, dont l'obtention et le traitement peut être coûteux. Pour remédier à ce problème, Denzinger et al [156] ont proposé une approche multi-vues 2,5D, comme le montre la figure 3.18. À partir de la séquence d'images MPR, seules deux tranches orthogonales sont sélectionnées, concaténées et transmises à un réseau 2D-CNN. Ils ont apporté aux travaux de [153, 154] quelques modifications dont nous citons :

- utilisation du VGG16 au lieu du VGG-M ;
- le choix de la longueur maximale de la section MPR est important. En effet, avec un redimensionnement des images d'entrée à la longueur de la section maximale, le modèle

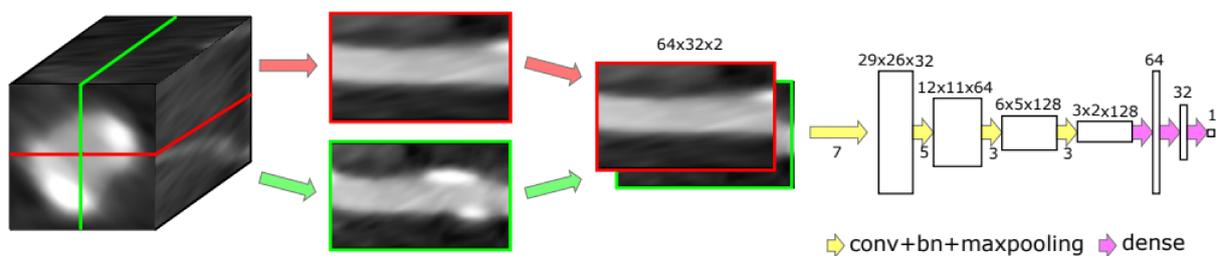


FIGURE 3.18 – Aperçu de l'algorithme de Denzinger et al [156] : extraction de deux vues orthogonales de la lésion d'intérêt. Celles-ci sont concaténées et ensuite utilisées comme entrée pour un 2D-CNN (conv = couche de convolution, bn = couche de normalisation par batches, dense = couche entièrement connectée). La figure est adaptée de [156]

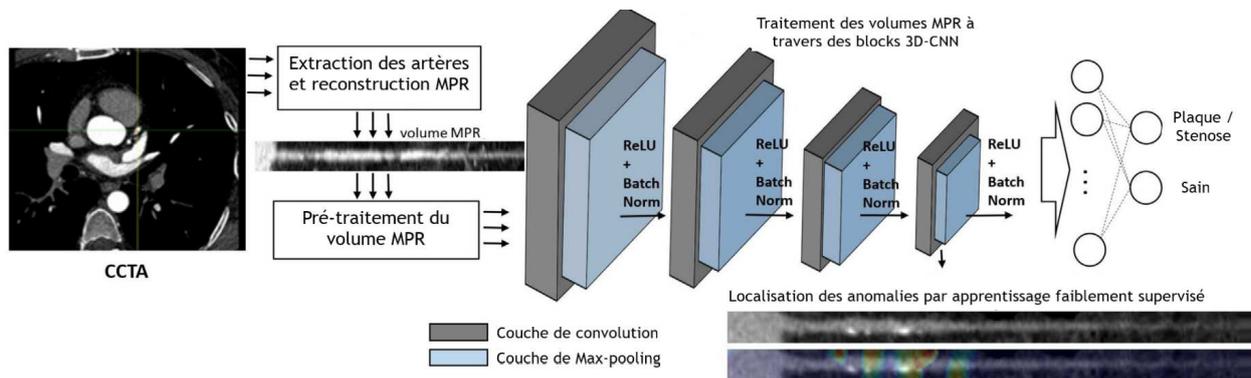


FIGURE 3.19 – Aperçu de l’algorithme de Candemir et al [158] : après une étape d’extraction des artères coronaires et reconstruction MPR, le CNN effectue la classification des volumes d’entrées entre volume sain ou non sain. Pour créer la carte de saillance en utilisant le gradient de la dernière couche de convolution. La figure est adaptée de [158].

de Tejero et al a obtenu de meilleures performances alors que le modèle de Zreik et al a souffert de cette transformation ;

— la concaténation de deux projections est suffisante.

Pour renforcer l’aspect biologique et visuel des cartes de caractéristiques extraites par les CNN, Candemir et al [158] ont utilisé un réseau de neurones convolutif tridimensionnel (3D-CNN) pour modéliser les changements pathologiques (par ex. plaques d’athérome) dans les vaisseaux coronaires. Leur modèle apprend les caractéristiques discriminatoires entre les vaisseaux avec et sans athérosclérose. Les caractéristiques discriminatoires de la couche de convolution finale sont visualisées à l’aide d’une carte de saillance afin de fournir des indices visuels liés à la probabilité et la localisation de l’athérosclérose comme indiqué dans la figure 3.19 Il s’agit de l’une des premières études qui utilisent une architecture CNN 3D et qui étudient le comportement de l’architecture en utilisant des algorithmes de visualisation surtout que les CNN sont annotés comme des boîtes noires. Néanmoins, ce travail ne fournit pas une classification du type de la plaque mais simplement une information sur le fait qu’elle existe ou pas.

Nous finissons cette revue par la description du travail de Denzinger et al [159]. Ce travail présente et évalue la première approche permettant de prédire directement le score CAD-RADS en six classes à l’aide d’un algorithme basé sur l’apprentissage profond. Comme montré dans la figure 3.20, l’ensemble des segments des artères coronaires est découpé en 17 segments selon la norme AHA (American Heart Association). Après avoir effectué la transformation CMPR sur l’ensemble des segments, un extracteur des caractéristiques [156] est appliqué pour

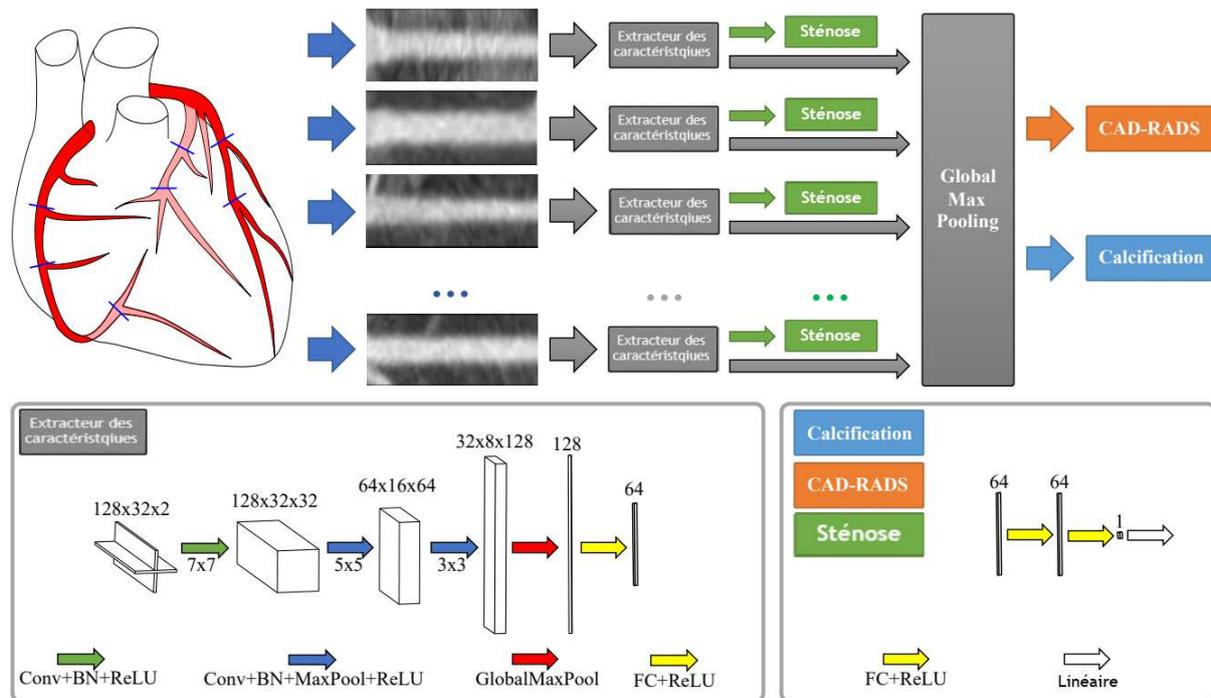


FIGURE 3.20 – Aperçu de l’algorithme de Denzinger et al [159] : toutes les artères coronaires de l’arbre artériel sont découpées et traitées séparément par le modèle. Par contre, le score final de la calcification et de la CAD-RADS est obtenu par une décision sur toutes les prédictions en question. La figure est adaptée de [159].

extraire les caractéristiques spatiales. L’utilisation du Global Max-pooling permet au modèle une indépendance vis à vis l’emplacement de la sténose (toutes les artères ont le même poids, une sténose dans une artère a est équivalente à une sténose dans une artère b). Cet ensemble est ensuite introduit dans deux autres blocs de régression pour la prédiction du score CAD-RADS et de la calcification. Ce travail introduit enfin, une analyse par patient (score CAD-RADS) et une analyse par segment d’artère.

3.4 Conclusion

Dans ce chapitre, nous avons passé en revue une grande partie des techniques proposées pour traiter les problèmes de la détection et de la quantification des lésions des artères coronaires ainsi que l’extraction des structures vasculaires. Nous avons départagé les différentes techniques en nous appuyant sur les caractéristiques qu’elles utilisent pour accomplir ces tâches.

Malgré la diversité des méthodes proposées dans l’état de l’art pour l’aide au diagnostic des

maladies coronariennes, ce domaine n'a pas encore fourni des schémas entièrement automatiques et fiables. Avec l'introduction des techniques d'apprentissage profond, nous constatons une meilleure caractérisation des structures vasculaires et les lésions coronariennes.

Dans la suite de ce manuscrit, nous présenterons nos contributions scientifiques. Nous détaillerons notre méthode d'extraction des artères coronaires et notre approche pour la détection de la sténose et la classification des plaques. Nous serons aussi amenés à tirer profit des multiples méthodes de l'état de l'art que nous avons présenté dans ce chapitre, pour fournir un pipeline complet et automatisé pour la prévention des risques cardiovasculaires.

Chapitre 4

Matériel et métriques d'évaluation

4.1 Introduction

Les chapitres précédents fournissent le contexte de la thèse. Nous avons détaillé les différentes missions ainsi que les verrous scientifiques que nous proposons de relever. Pour continuer à définir l'environnement de nos travaux, nous consacrons ce chapitre à la présentation du matériel et des métriques utilisés pour l'évaluation et la validation des approches proposées.

Dans la première section, nous décrivons l'ensemble des jeux de données dont nous nous sommes servis pour la création et l'apprentissage de nos méthodes et algorithmes. Cet ensemble est constitué de quatre bases de données publiques et une base de données propre à nos travaux construite à l'aide des efforts de l'équipe du Pr. Luc-Philippe Christiaens du CHU de Poitiers. La deuxième section introduit les métriques d'évaluation pour la validation des résultats de nos travaux. Nous énonçons leurs formules mathématiques et nous motivons l'intérêt de nos choix vis à vis des mesures qu'elles offrent.

4.2 Matériel

4.2.1 Défi de suivi des artères coronaires : CAT08

A la recherche d'un jeu de données qui offre un ensemble représentatif de données CTA cardiaque, avec des annotations manuelles des artères coronaire, nous avons travaillé avec le jeu de données de Rotterdam. Nous avons inclus 8 images CCTA provenant d'un cadre d'évaluation accessible au public pour l'extraction de la ligne médiane des artères coronaires coronaire [107]. Le MICCAI 2008 Coronary Artery Tracking Challenge (CAT08) fait partie du cadre d'évaluation des artères coronaires de Rotterdam. Les images de CAT08 ont été acquises sur un scanner à 64 coupes (Sensation 64, Siemens Medical Solutions, Forchheim, Allemagne) ou un scanner à double source (Somatom Definition, Siemens Medical Solutions, Forchheim, Allemagne). Les scans ont été acquis avec 120 kVp et un courant de tube maximal de 900 mA. Les images ont été reconstruites avec une résolution moyenne par voxel de $0,32 \times 0,32 \times 0,4mm^3$. Dans chaque scan, la ligne centrale et le rayon de quatre artères coronaires majeures ont été annotés

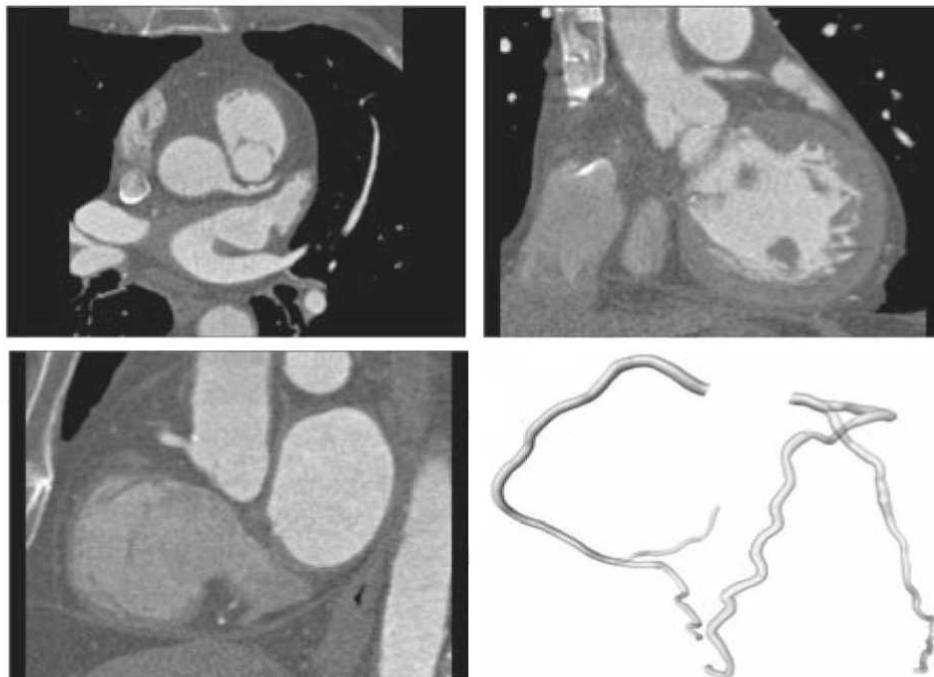


FIGURE 4.1 – Un exemple de scan avec l'annotation de référence correspondante : en haut à gauche : vue axiale des données ; en haut à droite : vue coronale ; en bas à gauche : vue sagittale ; en bas à droite : une reconstruction 3D de l'annotation de référence. La figure est adaptée de [107].

manuellement dans une lecture consensuelle par trois experts. Ces artères étaient la coronaire droite (CD), la circonflexe (CX) et l'interventriculaire antérieur (IVA), ainsi qu'un quatrième vaisseau sélectionné comme branche latérale de la CD, de la CX ou de la IVA. Les organisateurs de CAT08 ont séparé les 32 volumes CCTA en un ensemble d'entraînement et un ensemble de test sur la base de la qualité subjective de l'image (6 mauvaise, 11 modérée, 15 bonne) et de la charge calcique coronaire (12 faible, 16 modérée, 4 grave). L'ensemble d'entraînement comprend 8 images CCTA avec des annotations de référence pour l'emplacement de la ligne centrale et le rayon, et l'ensemble de test comprend 24 images CCTA pour lesquelles aucune annotation de référence n'est fournie.

Une description détaillée de l'acquisition et de la reconstruction du scan, ainsi que le protocole d'annotation de la ligne centrale est fournie dans [107].

4.2.2 Cadre d'évaluation standardisé pour la détection et la quantification de la sténose

Kirişli et al [148] ont introduit en 2012 un cadre d'évaluation d'algorithmes nommé : le cadre d'évaluation de la détection et de la quantification des sténoses de l'artère coronaire. Il fournit un cadre d'évaluation en ligne de différents défis : détection des sténoses, détection et quantification des sténoses sans et avec la segmentation des artères. Le cadre fournit 48 ensembles de données d'angiographie cardiaque des patients symptomatiques âgés de 41 à 80 ans, dont 32 (67%) hommes. Les ensembles de données ont été acquis dans trois centres médicaux différents sur différents tomodensitomètres : (1) le centre médical universitaire Erasmus (Erasmus MC, Rotterdam, Pays-Bas) à l'aide d'un tomodensitomètre à double source (Somatom Definition, Siemens, Forchheim, Allemagne), (2) le centre médical universitaire Utrecht (UMCU, Utrecht, Pays-Bas) sur un scanner à 64 tranches (Brilliance 64, Philips Medical Systems, Best, Pays-Bas), et (3) The Leiden University Medical Center (LUMC, Leiden, Pays-Bas) à l'aide d'un scanner à 320 coupes (Aquilion ONE 320, Toshiba Medical Systems, Tokyo, Japon). Les images de tomodensitométrie améliorée ont été reconstruites à la phase diastolique en utilisant un gating ECG rétrospectif ou prospectif. En outre, pour chaque patient, une tomodensitométrie non

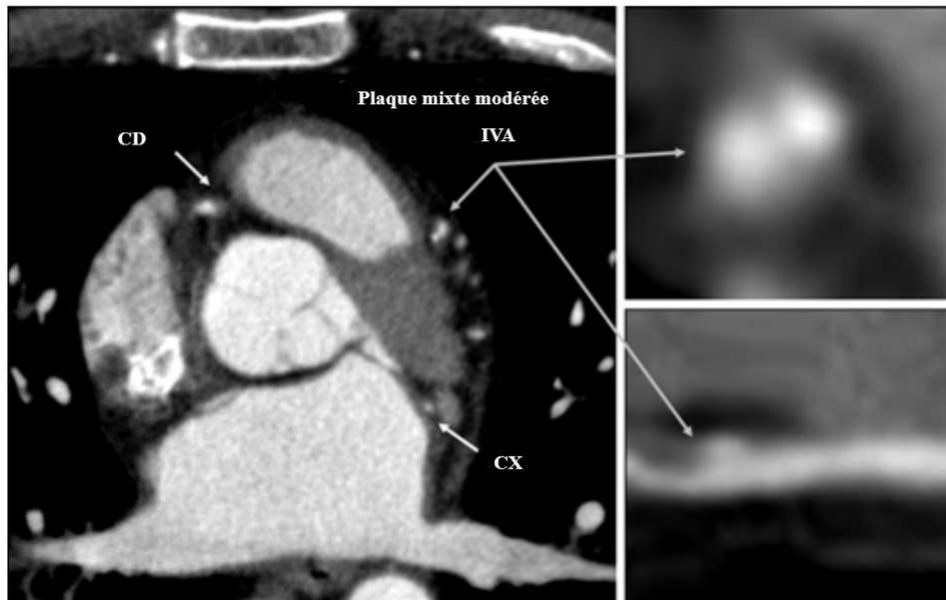


FIGURE 4.2 – Techniques de visualisation utilisées pour interpréter les images CTA : images transaxiales (à gauche) et multiplanaires (vue en coupe en haut à droite, vue longitudinale en bas à droite) de la coronaire droite (CD), la circonflexe (CX) et l'interventriculaire antérieur (IVA). Ce patient présente une plaque mixte modérée dans un segment de l'IVA. La figure est adaptée de [148].

améliorée est réalisée pour évaluer le score calcique coronaire (CCS) à l'aide d'un logiciel dédié. Les patients ont été sélectionnés sur la base de leur CCS (entre 0 et 400) et répartis sur 5 catégories de risque. Seules 18 des 48 images CT ont été mises à disposition avec les annotations des experts médicaux pour former la base d'apprentissage. Pour les 30 patients restants, seules les images CTA étaient disponibles. Ces ensembles de données ont été utilisés pour tester les algorithmes proposés à l'aide du cadre d'évaluation mais les annotations ne sont pas accessibles. Les patients de la base de données d'entraînement et de test ont été sélectionnés de manière à couvrir différentes appareils d'acquisition, catégories de CCS et degrés de sténose.

Pour chaque ensemble de données, les lésions dont le rétrécissement est supérieur à 20% sont signalées. Pour chaque lésion détectée, le type de plaque (calcifiée, douce ou mixte), la localisation de la sténose et le degré de la sténose ont été rapportés par les observateurs. Les degrés de la sténose ont été départagés par le pourcentage de rétrécissement de l'artère en : normal (<20%), léger (20% à 49 %), modéré (50% à 69%), sévère (70% à 99%) ou obstrué (100%). Un segment présentant au moins une sténose significative rapportée (c'est-à-dire avec un rétrécissement supérieur à 50 %) a été notée comme ayant avoir une maladie coronarienne significative. Plus de détails sur la sélection des patients, l'acquisition et la reconstruction des images sont

fournis par [148].

4.2.3 Segmentation multimodale du cœur entier : MM-WHS 2017

Pour un calcul, une modélisation et une analyse précise de l'ensemble des sous-structures du cœur, Zhuang et al [176, 177] ont créé un jeu de données dédié à la segmentation de ces structures. Ils fournissent 120 images multimodales du cœur entier provenant de plusieurs sites, dont 60 CT/CTA cardiaques et 60 IRM cardiaques, qui couvrent l'ensemble des sous-structures du cœur. Les données ont été recueillies dans un environnement clinique in vivo et ont été utilisées dans des cliniques. Les données ont donc une qualité d'image variable, certaines étant de qualité relativement médiocre.

Les données de CT/CTA cardiaque ont été acquises lors d'angiographies cardiaques routine. Toutes les données couvrent l'ensemble du cœur, de la partie supérieure de l'abdomen à l'arc aortique. Les coupes ont été acquises en vue axiale. La résolution en plan est d'environ $0,78 \times 0,78mm$ et l'épaisseur moyenne des tranches est de $1,60mm$. Ils ont divisé les ensembles de données en un jeu de données d'entraînement (20 CT et 20 IRM représentatifs) et de test (40 CT et 40 IRM). Les ensembles de données d'entraînement fournissent une segmentation manuelle des sept sous-structures du cœur entier : la cavité sanguine du ventricule gauche (VG), la cavité sanguine du ventricule droit (VD), la cavité sanguine de l'atrium gauche (AG), la cavité

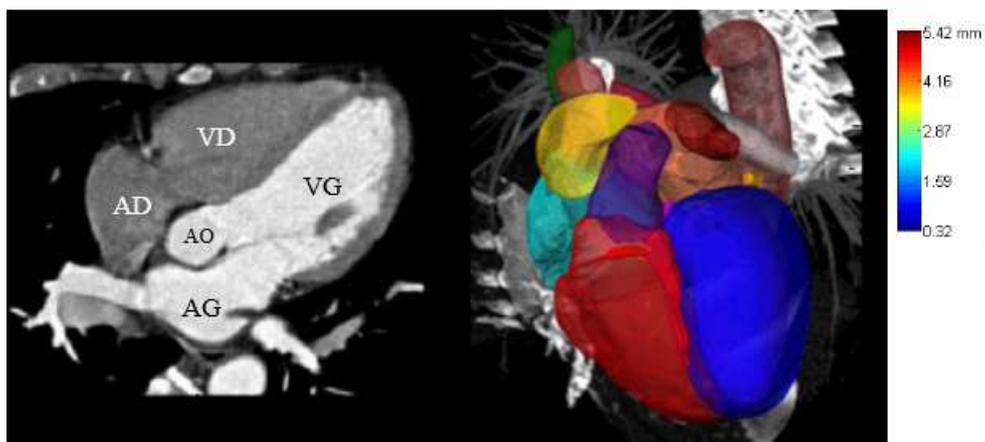


FIGURE 4.3 – La segmentation des sept sous structures du coeur à partir des images CT. Les structures affichées sont : atrium droit (AD), atrium gauche (AG), ventricule droite (VD), ventricule gauche (VG) et l'aorte ascendante. La figure est adaptée de [176].

sanguine de l'atrium droit (AD), le myocarde du ventricule gauche (myo), l'aorte ascendante (AO) et l'artère pulmonaire (AP). Le coefficient de similarité de Dice est la métrique principale pour l'évaluation de l'ensemble des algorithmes participant à ce défi.

4.2.4 Défi de la détection et de la segmentation des anévrismes : ADAM 2020

La prévention des accidents vasculaires cérébraux constitue une partie de cette thèse. Nous nous sommes intéressés à la détection des anévrismes intracrâniens non rompus. Un défi récent nous a offert, ainsi qu'à toute la communauté scientifique, un jeu de données important pour la segmentation des anévrismes à partir des images MRA-TOF. Ce challenge fait partie de la conférence MICCAI 2020 et s'appelle le défi de la détection et de la segmentation des anévrismes (ADAM). Il offre un total de 254 scans TOF-MRA du cerveau avec un ensemble de 282 anévrismes intracrâniens non rompus (UIA) et non traités. L'ensemble de données d'entraînement disponible comprend 113 patients, tandis que l'ensemble de données de test comprend 141 cas (cet ensemble n'est pas disponible au public). Chaque patient a une imagerie TOF-MRA et une image structurale (T1, T2 ou FLAIR). Toutes les MRA ont été réalisées à l'UMC Utrecht, aux Pays-Bas, sur divers scanners Philips avec un champ de 1, 1,5 ou 3T. Les MRA ont un espacement de voxel de $(0,195 - 1,04)mm$ et une épaisseur de tranche de $(0,4 - 0,7)mm$, sans

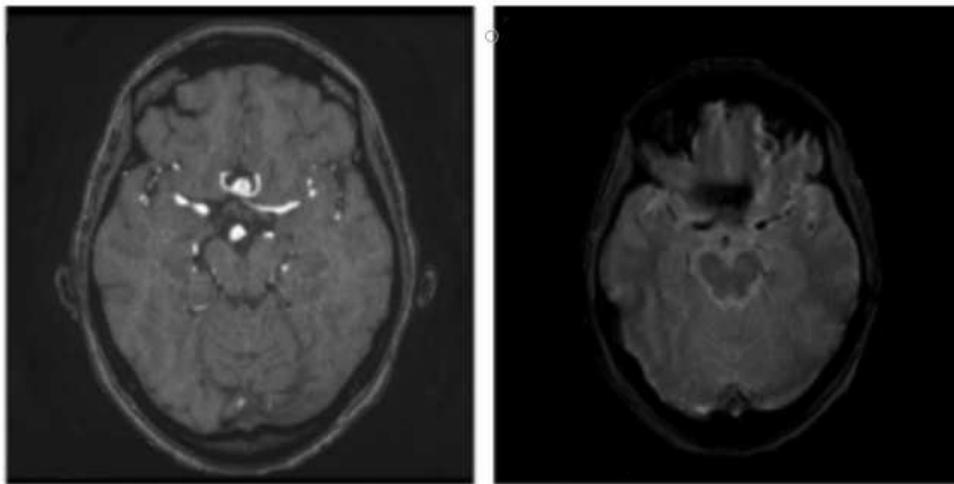


FIGURE 4.4 – Une image TOF-MRA originale et image MR structurale originale du jeu de données d'ADAM. La figure est adaptée de [200].

protocole d'acquisition défini. Les données proviennent de plusieurs études sur une longue période (entre 2001 et 2019). Les UIA sont de taille variable, avec un diamètre maximal médian de $3,6\text{mm}$ et une fourchette de $1,0$ à $15,9\text{mm}$. 25 % des scanners contenaient des UIA multiples et 28 % des scanners contiennent des UIA traités (soit enroulés soit coupés). L'ensemble de données est diversifié, reflétant les différents protocoles cliniques standardisés utilisés entre les scanners MR. Plus de détails sur la collecte et la constitution de ce jeu de données peuvent être trouvés ici [200].

4.2.5 CHU Poitiers

Dans cette sous-section, nous décrivons le processus de la collecte de notre base de données propre au CHU Poitiers et Canon Medical Systems France.

De mai 2019 à avril 2022, les scanners d'un total de 31 patients présentant une suspicion de coronaropathie ont été collectés en collaboration avec l'équipe du Pr. Luc-Philippe Christiaens du CHU de Poitiers. Nous avons totalisé 107 segments d'artères coronaires présentant des lésions confirmées par le diagnostic des experts. Un scanner Aquilion one Genesis, montré dans la figure 4.5, a été utilisé pour l'ensemble de cette étude. Ce scanner est construit par Canon Medical Systems et utilise l'intelligence artificielle dans la numérisation et le traitement. Il a une rotation de $0,275\text{ s}$, une couverture de 16 cm , une résolution spatiale de $0,17\text{ mm}$ et effectue 640 coupes par rotation. Les examens ont été menés avec une synchronisation d'acquisition à l'ECG et avec un produit de contraste IOMERON 400 Bolus IV. Durant les examens, le logiciel Vitrae [4] accompagne les experts dans leur diagnostic. Il permet une analyse grossière automatique

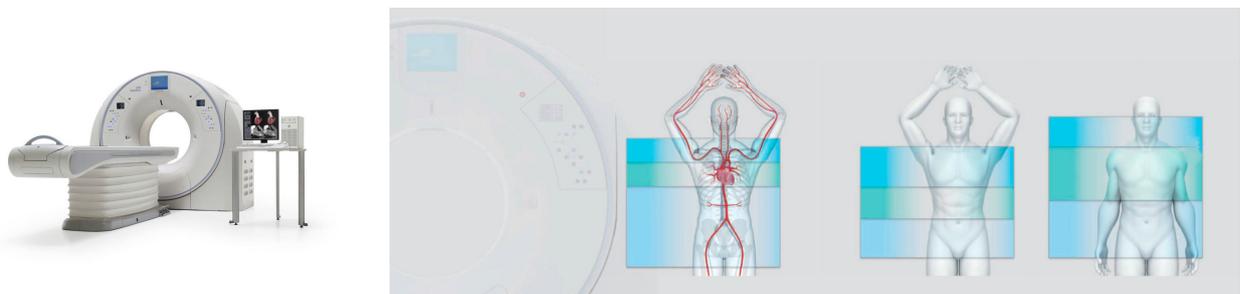


FIGURE 4.5 – Le scanner Aquilion One Genesis utilisé dans le CHU Poitiers. La figure est adaptée de [3].

et semi-automatique des artères coronaires. Les experts corrigent les identifications incorrectes en signalant un ensemble de points qui appartiennent à la région mal prédite. Par la suite, une reconstruction cMPR (curved MultiPlanar Reformatting) est fournie. Finalement, les experts identifient et classent, après l'analyse des images reconstruites, les artères qui présentent des lésions coronaires.

La population choisie est constituée de 16 hommes et 15 femmes. Le choix des patients est motivé par leur score calcique (CCS). Il reflète le contenu en calcium des artères coronaires. Il est généralement corrélé à la probabilité d'une présence d'une maladie coronarienne et peut servir comme dépistage de cette dernière. S'il est supérieur à 400 unités, une plaque d'athérome est constatée avec un rétrécissement significatif d'un segment dans près de la moitié des cas. Un score calcique nul n'élimine pas complètement la présence d'un athérome coronarien mais la probabilité d'une sténose significative est alors très faible [5]. Notre étude couvre les différentes catégories du score calcique comme le montre la table 4.1 ci dessous. La qualité des examens est un des facteurs qui influence le résultat des diagnostics. Nous sommes parvenus à collecter un jeu de données qui prend en considération cette variation de qualité pour refléter la réalité clinique (cf table 4.2).

Notre population a une moyenne d'âge de 57,42 avec un écart type de 11,25. Le sujet le plus jeune a 35 ans alors que le sujet le plus âgé a 75 ans.

TABLE 4.1 – La distribution des patients (pourcentage) par catégorie de score calcique (CCS). Le CCS réfère au score Agatston.

Population	Score Calcique CCS				
	Faible 0	Minimal 0.1-10	Moyenne 11-100	Modéré 101-400	Elevé +400
Nombre de patients (pourcentage de la population totale)	12 (38%)	4 (13%)	4 (13%)	9 (29%)	2 (7%)

TABLE 4.2 – La distribution des examens (pourcentage) par la qualité de l'examen.

Examens	Qualité de l'examen		
	Partiellement interprétable	Moyenne mais interprétable	Bonne
Nombre des examens (pourcentage du total des examens)	3 (10%)	6 (20%)	22 (70%)

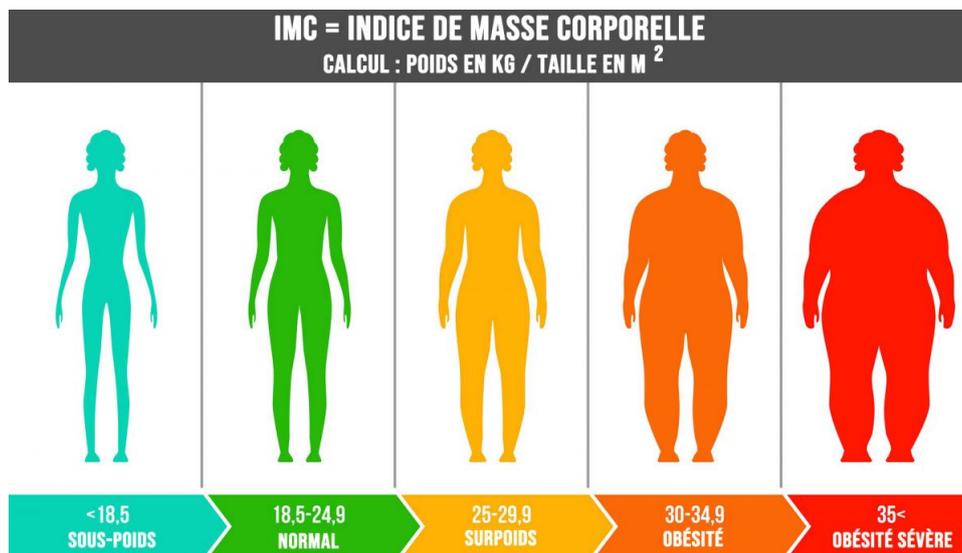


FIGURE 4.6 – Les catégories de la corpulence d'une personne selon la mesure de l'IMC. La figure est adaptée de [6].

Un autre facteur qui constitue l'un des indicateurs de risque des maladies coronariennes est l'IMC (Indice de Masse Corporelle) qui est une mesure de la graisse corporelle basée sur la taille et le poids qui s'applique aux hommes et aux femmes adultes. Il est utilisé pour classer l'insuffisance pondérale, le surpoids et l'obésité chez les adultes (cf figure 4.6). Dans notre étude, nous avons réussi à collecter un ensemble de sujets qui s'inscrivent dans les quatre catégories les plus susceptibles à présenter une maladie coronarienne. La table 4.3 ci-dessous indique la distribution de notre population par rapport à l'IMC.

Notre jeu de données compte un total de 373 artères coronaires analysés par les experts médicaux. Cette ensemble se décompose en artères saines et artères présentant une ou plusieurs

TABLE 4.3 – La distribution des sujets (pourcentage de la population) par la classe de corpulence d'une personne selon l'IMC.

Sujets	Indice de Masse Corporelle (IMC)				
	Sous-poids <18.5	Normal 18.5-24.9	Surpoids 25-29.9	Obésité 30-34.9	Obésité sévère 35<
Nombre de sujet (pourcentage de la population totale)	0 (0%)	5 (16%)	14 (45%)	9 (30%)	3 (9%)

lésions. Nous référons à une artère saine comme une artère présentant un rétrécissement du diamètre allant de 0 % à 20 %. Une artère atteinte d'une sténose non significative présente un rétrécissement de 21% à 49% alors que si elle est atteinte d'une sténose significative, la

TABLE 4.4 – La distribution du nombre des artères (pourcentage de la totale des segments) par leur état.

Artères coronaires	Etat des artères analysées		
	Sain	Lésion (sténose)	
		Non significative	Significative
Nombre des artères (pourcentage de la totale des artères)	276 (73 %)	57 (15%)	40 (12%)

diminution du diamètre dépasse 50 %. La table 4.4 résume la distribution des artères analysées par rapport à leur état.

Nos travaux ne se limitent pas à la détection des lésions. Le type des plaques (lésions) est un sujet d'intérêt pour nous et pour les cliniciens. Par conséquent, nous départageons davantage les artères atteintes de sténose en trois catégories en nous appuyant sur le type de leur plaque comme indiqué dans la table 4.5. Une plaque douce (ou non calcifiée) est une plaque qui présente

TABLE 4.5 – La distribution du nombre des plaques (pourcentage du nombre total des lésions) par leur type.

Lésions	Type de plaque		
	Douce	Mixte	Calcifiée
Nombre des plaques (pourcentage du nombre total des lésions)	32 (32 %)	27 (28%)	38 (40%)

aucune calcification. Par contre, une plaque mixte présente un pourcentage de calcification qui ne dépasse pas la moitié du surface de rétrécissement ($< 50\%$). Si, la calcification couvre la majorité de la surface du rétrécissement alors cette plaque est annotée comme calcifiée.

Les résultats des diagnostics nous ont été délivrés par l'équipe médicale sous forme de fichiers Excel contenant : (1) les paramètres de l'examen (qualité, scanner, agent de contraste,...), (2) les mesures liées aux patients (âge, IMC, sexe,...), (3) l'ensemble des analyses des segments artériels avec le pourcentage de la sténose et le type des plaques, (4) l'existence des valves cardiaques, (5) les mesures de l'aorte (anneau aortique, sinus de Valsalva, jonction sino-tubulaire, aorte ascendante,...). Un exemple de compte rendu des experts peut être visualisé dans la figure 4.7. Nous nous appuyons sur ce jeu de données que nous avons collecté pour la validation de l'ensemble de nos méthodes et, particulièrement les algorithmes de la détection de la sténose et

COMPTE RENDU SCANNER CARDIAQUE				Pontage aortocoronaire	Anast. Prox	Corps	Anast. Dist.	Lit d'aval
MOTIF D'EXAMEN	Suspicion de cardiopathie ischémique							
	Douleur thoracique sans preuve ischémique							
Scanner	Toshiba Aquilion One GENESIS mis en service le 9/1/2017			Ventricule gauche				
Technique	Acquisition synchronisée à l'ECG			Diamètre télédiastolique (mm)				
Agent de contraste	IOMERON 400 Bolus IV 90 cc	Fréq. Card.		Épaisseur SIV (mm)				
Prémédication	Béta-bloquant	Trinitrine		Épaisseur paroi latérale (mm)				
RESEAU CORONAIRE				Hypokinésie segmentaire				
Qualité de l'examen	Moyenne mais interprétable		TA = mmHg	Hypokinésie globale				
Score calcique	358	Probabilité pré-test :		Thrombus				
Dominance	Droite			Anévrisme				
Naissance des coronaires	Normale			Anomalie texture myocarde				
Pont myocardique	Non			Temps tardif effectué				
Stent	0			Autres cavités cardiaques				
Sténose coronaire	Lésions bitronculaires			Thrombus				
Segment sténosé	% sténose	Description		Néof ormation				
	Tronc commun	0 %		Autres				
	Bissectrice			Péricarde				
	IVA prox	30-50%	calcifiée	Epanchement	0			
	IVA moy	30-50%	calcifiée	Épaississement anormal	0			
	IVA dist	0 %		Calcifications	0			
	CX prox	0 %		Valves cardiaques				
	CX moy	<30%	calcifiée	Valve aortique				
	CX dist	<30%	calcifiée	Valve mitrale				
	CD seg 1	<30%	calcifiée	Autres				
	CD seg 2	0 %		Aorte				
	CD seg 3	0 %		Diam. anneau aortique (mm)	26			
	1ère diagonale	0 %		Diam. sinus de Valsalva	41			
	2ème diagonale	0 %		Diam. jonction sino-tubulaire	29			
	Marginale G	>70%	mixte, ostiale	Diam. aorte ascendante (max)	34			
	RVG	0 %		Diam. segment horizontal				
				Diam. aorte descendante	25			
				Plaques	1	*cte en regard de la crosse associée avec diverticu*		
				Dissection	0			
				Hématome pariétal	0			

FIGURE 4.7 – Un exemple de compte rendu de l'équipe médical du Pr. Luc-Philippe Christiaens du CHU de Poitiers. Les données liées au patient ont été masqué.

la classification du type des plaques. La publication de cette base reste un sujet de discussion sensible entre les différentes parties prenantes de cette thèse. Pour le moment, ce jeu de données est confidentiel.

Les bases de données que nous avons présentées nous servent à valider nos travaux de recherche. Il est cependant nécessaire de coupler ces bases avec un ensemble de métriques d'évaluation qui fournit une analyse approfondie des performances des nos modèles proposés, sujet de la section suivante.

4.3 Métrique d'évaluations

La segmentation et la classification sont deux tâches importantes dans le flux de travail clinique pour l'analyse quantitative des images médicales. Les cliniciens cherchent à intégrer des méthodes automatiques en tant que systèmes d'aide à la décision clinique dans leur routine afin de faciliter le diagnostic, le traitement, l'évaluation des risques et et réduire le temps passé aux processus d'inspection. En raison de leur impact direct sur les décisions de diagnostic et de traitement, une évaluation correcte et robuste de ces algorithmes est cruciale. La performance

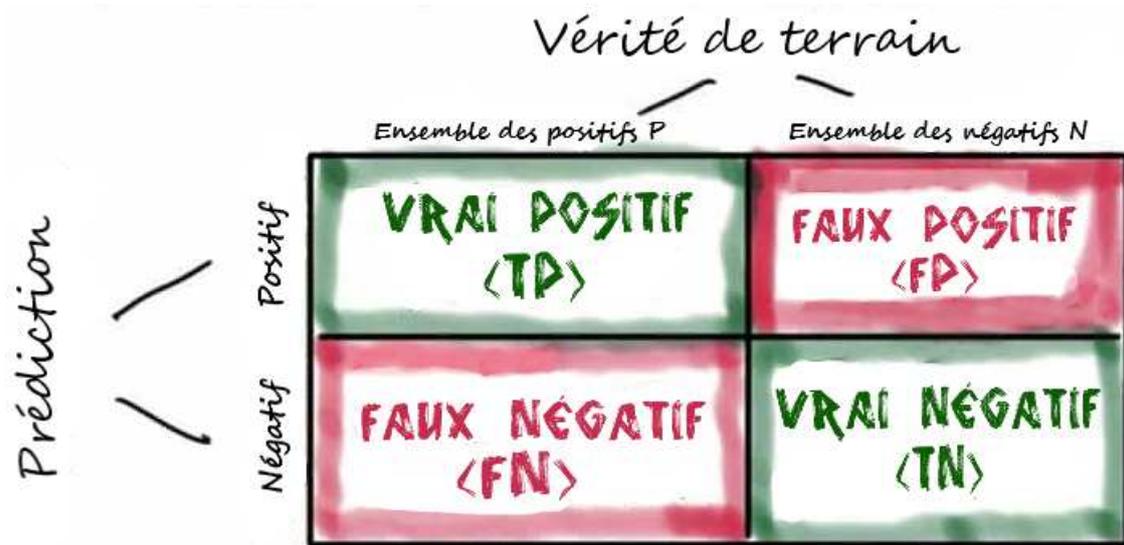


FIGURE 4.8 – La matrice de confusion pour une tâche de classification binaire.

de ces méthodes est généralement évaluée à l'aide des métriques qui mesurent soit les similarités ou les erreurs pour comparer la prédiction des modèles (S) avec une vérité de terrain (V_t), qui est souvent manuellement annotée par les experts. La plupart des métriques peuvent être dérivées en utilisant les quatre cardinalités de base de la matrice de confusion (cf figure 4.8), à savoir les vrais positifs (TP), les vrais négatifs (TN), les faux positifs (FP) et les faux négatifs (FN), qui reflètent l'ensemble des prédictions dans S qui sont classés correctement ou incorrectement par rapport à V_t , selon les définitions suivantes :

$$\left\{ \begin{array}{l} TP = \text{Card}(\{S(\mathbf{x}) = 1 \text{ et } V_t(\mathbf{x}) = 1\}) \\ FN = \text{Card}(\{S(\mathbf{x}) = 0 \text{ et } V_t(\mathbf{x}) = 1\}) \\ P = \text{Card}(\{V_t(\mathbf{x}) = 1\}) \\ FP = \text{Card}(\{S(\mathbf{x}) = 1 \text{ et } V_t(\mathbf{x}) = 0\}) \\ TN = \text{Card}(\{S(\mathbf{x}) = 0 \text{ et } V_t(\mathbf{x}) = 0\}) \\ N = \text{Card}(V_t(\mathbf{x}) = 0) \end{array} \right. \quad (4.1)$$

avec Card , le cardinal de ces ensembles et \mathbf{x} l'entrée du modèle.

4.3.1 Sensibilité

Pour la classification des pixels, la sensibilité (Sens), également appelée rappel ou taux de récupération, se concentre sur la capacité d'un modèle d'identifier les structures cibles. Elle répond à la question : Parmi toutes les structures présentes dans la vérité de terrain, combien le modèle réussit-il à identifier correctement ?

$$\text{Sensibilité} = \frac{TP}{TP + FN} \quad (4.2)$$

4.3.2 Spécificité

La spécificité (Spec) tente de répondre à la question suivante : quelle proportion d'identifications positives était réellement correcte ?

$$\text{Spécificité} = \frac{TN}{TN + FP} \quad (4.3)$$

Pour évaluer correctement l'efficacité d'un modèle, nous devons examiner à la fois la sensibilité et la spécificité. Malheureusement, la spécificité et la sensibilité sont souvent en opposition. En d'autres termes, l'amélioration de la spécificité réduit généralement la sensibilité et vice versa.

4.3.3 Précision

La précision est l'une des mesures permettant d'évaluer les modèles de classification. La précision est la fraction des prédictions que notre modèle a réussi à classer. Elle a la définition suivante :

$$\text{Précision} = \frac{TP + TN}{TP + FP + TN + FN} = \frac{TP + TN}{P + N} \quad (4.4)$$

La précision à elle seule ne suffit pas lorsque nous travaillons avec un jeu de données déséquilibré, où il existe une disparité importante entre le nombre d'échantillons positives et négatives. Il faut alors chercher des métriques qui tiennent en compte cette disparité.

4.3.4 Courbe ROC et AUC

La courbe ROC (receiver operating characteristic) est une courbe qui combine les mesures des sensibilités et spécificités. Précisément, c'est une courbe montrant les performances d'un modèle de classification à tous les seuils de décision. Généralement, le seuil de décision est à une probabilité de 0,5. Plus ce seuil s'approche de 0, plus nous autorisons de faux positifs. Probablement parce que nous avons besoin d'avoir le plus de sensibilité possible. Inversement, plus ce seuil s'approche de 1, moins le modèle prend en compte les faux positifs. La courbe ROC permet de déterminer alors, quel seuil est le mieux adapté à la tâche en question. Une courbe

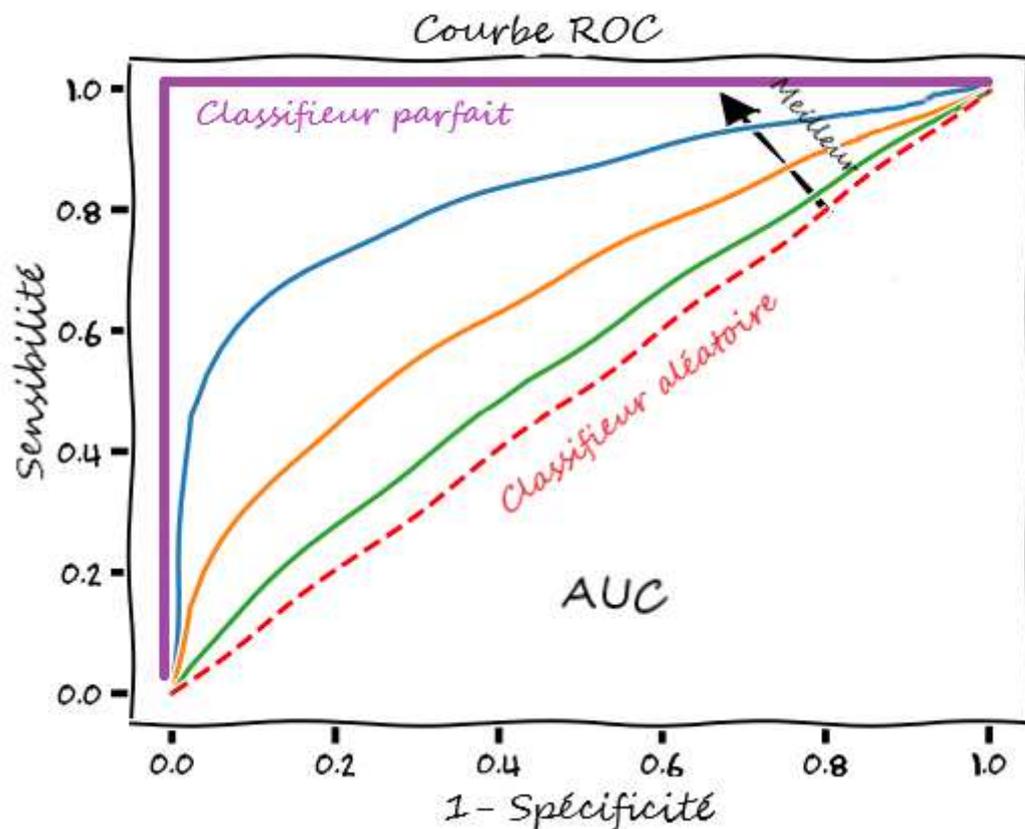


FIGURE 4.9 – La courbe ROC et la surface sous la courbe AUC [164].

ROC idéale s'approche au maximum du coin supérieur gauche (cf figure 4.10). Donc plus l'aire sous la courbe ROC est grande, meilleur est le classifieur. Par conséquent, nous pouvons nous référer à l'AUC (Area under curve) comme une métrique pour choisir le meilleur classifieur.

Elle mesure la qualité des prédictions du modèle, quel que soit le seuil de classification choisi.

$$AUC = \int_0^1 Sens(1 - Spec(h))dh \quad (4.5)$$

4.3.5 Coefficient de similarité de Dice : DSC

Le coefficient de similarité de Dice (DSC), également connu sous le nom d'indice Sørensen-Dice, score du Dice ou coefficient de Dice, est un outil statistique qui mesure la similarité entre deux ensembles de données. Cet indice est devenu sans doute la métrique la plus utilisée dans la validation des algorithmes de segmentation d'images créés avec l'IA. Le DSC combine la sensibilité et la spécificité en une seule métrique en calculant la moyenne harmonique entre les deux. Le DSC équilibre la sensibilité et la spécificité tandis que la précision considère les observations correctement classées, tant positives que négatives. Cela fait une grande différence, surtout pour les problèmes à classes déséquilibrées, car il devient facile d'obtenir un score de précision élevé en classant simplement toutes les observations dans la classe majoritaire. Nous ne devrions donc pas utiliser la précision pour les problèmes déséquilibrés et plutôt favoriser l'utilisation du DSC. Sa formule s'écrit :

$$DSC = \frac{2 \times Spec \times Sens}{(Spec + Sens)} \quad (4.6)$$

$$DSC = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (4.7)$$

4.3.6 Coefficient de corrélation de Matthews : MCC

Pour éviter le problème du déséquilibre des classes, nous ferons appel au coefficient de corrélation de Matthews. Ce coefficient tient compte des vrais et faux positifs et négatifs et est généralement considéré comme une mesure équilibrée qui peut être utilisée même si les classes sont de tailles très différentes. Le MCC est essentiellement un coefficient de corrélation entre les classifications binaires observées et prédites. Il renvoie une valeur entre -1 et $+1$. Un coefficient

de +1 représente une prédiction parfaite, 0 pas mieux qu'une prédiction aléatoire et -1 indique un désaccord total entre la prédiction et l'observation.

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FN)(TP + FN)(TN + FP)(TN + FN)}} \quad (4.8)$$

4.3.7 Distance de Hausdorff : MHD

La distance de Hausdorff est définie comme le maximum de toutes les distances minimales entre deux courbes. Elle mesure principalement la précision de la limite d'une segmentation par rapport à sa vérité terrain. Il s'agit d'une évaluation de la forme de la structure prédite et de sa compatibilité avec la véritable. Soit X le volume prédit, Y la segmentation de la vérité terrain et $d(x, y)$ la fonction de distance euclidienne. La distance de Hausdorff (MHD) est donnée par :

$$MHD(X, Y) = \max \{ \sup_{x \in X} \inf_{y \in Y} d(x, y), \sup_{y \in Y} \inf_{x \in X} d(y, x) \} \quad (4.9)$$

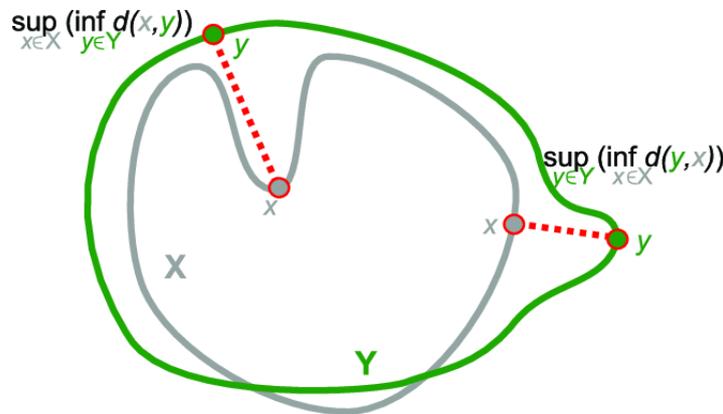


FIGURE 4.10 – La distance de Hausdorff entre la structure X et Y est le maximum de deux distances calculées dans la figure. Cette illustration est adaptée de [165].

4.3.8 Similarité volumétrique : VS

Comme son nom l'indique, la similarité volumétrique (VS) est une mesure qui considère les volumes des structures pour indiquer la similarité. Elle est définie comme $1 - VD$ où VD est

la distance volumétrique (la différence absolue des volumes divisée par la somme des volumes comparés) :

$$VS = 1 - \frac{|FN - FP|}{2TP + FN + FP} \quad (4.10)$$

4.4 Conclusion

Nous avons consacré ce chapitre à la définition de l'environnement de nos recherches. Nous avons détaillé les différents jeux de données et métriques d'évaluation dont nous nous sommes servis. Nous avons décrit le jeu de données du CHU Poitiers que nous avons construit à l'aide des efforts des équipes médicales de l'hôpital. La construction de cette base constitue une contribution importante de cette thèse. Sa publication, par contre, reste un sujet sensible.

Avec la fin de ce chapitre, nous annonçons le début de la partie des contributions scientifiques de cette thèse. Les chapitres suivants aborderont nos contributions dans les domaines de : l'extraction des artères coronaires, la détection de la sténose, la classification des plaques et la segmentation des anévrismes intracrâniens non rompus

Chapitre 5

Extraction des artères coronaires

5.1 Introduction

Dans les chapitres précédents, nous avons exprimé la nécessité d'utiliser des techniques d'intelligence artificielle pour s'attaquer aux problématiques qui requièrent des modélisation complexes des données. L'identification des caractéristiques de haut niveau pour la représentation des structures vasculaires s'inscrit dans ce cadre. Après l'étude de l'état de l'art liée à la détection de la sténose, nous avons montré que l'étape de l'extraction des artères coronaires est primordiale pour isoler ces structures cibles.

Depuis l'invention des scanners, le problème de l'identification des artères coronaires à partir des images d'angiographie par tomographie assistée par ordinateur (CTA) attire l'attention des chercheurs. La tâche d'extraction des structures vasculaires présente de nombreux défis pour la communauté des chercheurs. Tout d'abord, le CTA étant un protocole de renforcement de contraste, les données obtenues dépendent fortement du processus d'acquisition (type de scanner, résolution, bruit, intensité du contraste...) ainsi que de la grande variabilité de la pathologie du patient (réseau d'arbres artériels, taille et courbure des vaisseaux). De plus, la géométrie de ces dernières structures peut être perturbée par la présence anormale de calcifications et de sténoses. Enfin, les dimensions des artères cibles sont relativement petites par rapport aux structures anatomiques voisines et surtout par rapport à l'ensemble du volume.

L'extraction des artères coronaires est une étape cruciale vers l'objectif principal de ma thèse, la détection et classification de la sténose. Ainsi, le but de ce chapitre est la proposition d'un pipeline complet qui traite le problème de l'extraction de l'arbre artériel coronaire. Nous explorons les défis attachés à cette problématique et nous mettons en place différents modèles qui répondent aux plusieurs besoins influençant la robustesse de la performance du pipeline proposé.

L'ensemble du chapitre s'organise comme suit : nous commençons par une section qui fournit un résumé de l'état de l'art (sec. 5.2). Celui-ci justifie la proposition d'une nouvelle méthode plus générique et précise que nous expliquons celle-ci dans la section suivante (sec. 5.3). Nous détaillons les différents composants qui constituent le premier pipeline proposé, à partir des méthodes de pré-traitement, CenterlineNet (le modèle d'apprentissage profond) et de post-traitement. Ensuite nous évaluons les résultats sur deux différentes bases de données. Puis, suite à l'analyse de ces résultats, nous identifions les limitations de notre méthode et ses défauts majeurs. Finalement (sec. 5.4), nous proposons une amélioration du pipeline qui adresse ces défauts et l'aide à réaliser un excellent niveau de généralisation sur différentes types de données à travers une segmentation des sous-structures du coeur et une analyse intelligente des composants connectés.

5.2 État de l'art

Au cours des deux dernières décennies, une pléthore d'algorithmes a été consacrée à l'extraction (semi-) automatique des lignes centrales des structures vasculaires dans le domaine de l'imagerie médicale [70, 71, 72]. Le degré de complexité de la modélisation des vaisseaux impose généralement la méthode à choisir pour l'extraction de l'arbre artériel (cf figure 5.1). Ce niveau de complexité peut être estimé par un ensemble de caractéristiques visuels (diamètre des artères, contraste, qualité de l'image, bruit et bien d'autres).

Certaines méthodes d'extraction sont automatiques alors que d'autres sont interactives et requièrent l'aide d'un expert. Un grand nombre des méthodes interactives [160, 161, 162] se sont basées sur des approches de suivi. Ces approches suivent le développement des vaisseaux à

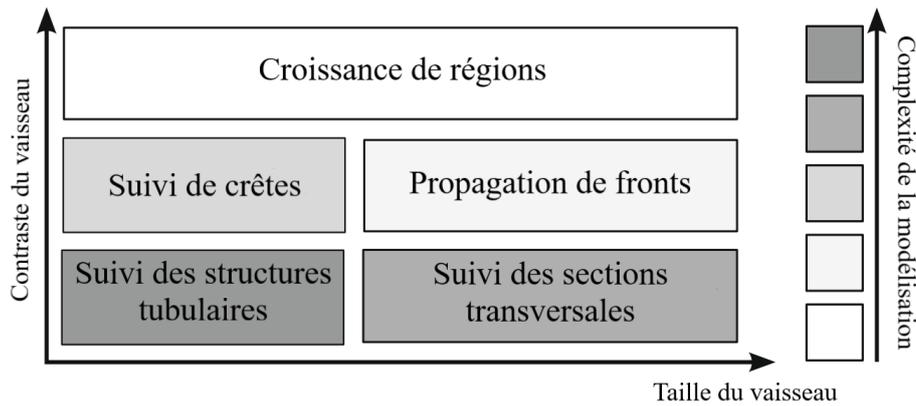


FIGURE 5.1 – Les algorithmes utilisés pour la modélisation des vaisseaux en fonction de leur taille et contraste. La figure est adaptée de [106]

partir d'un point donné par l'expert (utilisateur) ou à partir d'un point de départ et un point d'arrivée. Le processus de suivi est géré par une fonction de coût défini qui cherche à identifier les points qui appartiennent au vaisseau parmi un ensemble des points candidats. La sélection des points candidats et le choix de la fonction de coût constituent la différence entre les travaux qui s'inscrivent dans ce cadre. A ce stade, en plus de l'intervention nécessaire des experts, ces méthodes s'appuient sur ensemble de caractéristiques manuels (caractéristiques basés sur l'apparence et la géométrie). Ceci limite énormément l'aspect de généralisation de ces algorithmes. Les versions entièrement automatiques ont réussi à remplacer les interactions avec les experts par une sélection automatisée des points. Néanmoins, elles continuent à se baser sur des caractéristiques manuelles. De nombreux travaux consistent à appliquer des filtres de détection de tubes comme ceux de Frangi et al [98] et de Sato et al. [99]. Ces derniers offrent une analyse géométrique des structures basées sur les valeurs et vecteurs propres de la matrice hessienne de la distribution locale des voxels. Bauer et al. [103] et Krissian et al. [104] ont basé leur recherche de candidats sur le filtre de Frangi classique tandis que Yang et al. [105] ont introduit une version améliorée du filtre de Frangi qui limite les fausses réponses.

Friman et al. [106] ont eu un succès dans la compétition CAT08 [107] en ayant les meilleurs performances. Sans avoir recours aux filtres de Frangi ou Sato, ils ont proposé un modèle idéal de correspondance de forme tubulaire pour identifier les structures vasculaires. La récupération des points candidats est effectuée à l'aide d'un suiveur à hypothèses multiples (MHT). Néanmoins, l'une des limitations majeure c'est qu'elle a eu recours parfois à l'intervention de

l'utilisateur et à une étape de correction manuelle en cas d'échec. Restons avec les méthodes du suivi itérative, Lesage et al. [109] ont proposé un modèle bayésien basé sur un algorithme de filtrage particulaire. Ils ont exploité le flux de gradient pour estimer la densité des filtres appliqués aux sections transversales de structures tubulaires.

Malgré la diversité des descripteurs proposés dans la littérature, leurs aspects analytiques et manuels limitent les performances des modèles qui les utilisent. De plus, de nombreux ajustements et rectifications sont à envisager si certaines hypothèses de leur application ne se vérifient pas (terminaison prématurée pour les algorithmes de suivi, problème de fuite pour les algorithmes de croissance de régions, la déformation des vaisseaux à cause des sténoses ou calcifications pour les méthodes qui utilisent les sections transversales,...). Ainsi, afin de compenser l'étape d'extraction de caractéristiques manuelles, les chercheurs se sont tournés vers l'apprentissage profond et notamment vers l'utilisation de réseaux de neurones convolutifs. Ces derniers ont une grande capacité pour extraire des caractéristiques de haut niveau à partir des structures complexes. Pour commencer, Gulsun et al. [111] ont exploré l'utilisation du CNN comme technique de post-traitement pour identifier si les structures précédemment détectées font ou non partie de l'arbre artériel. Guo et al. [115] ont utilisé un modèle CNN pour convertir une carte de segmentation en un masque de lignes centrales et une liste de points d'extrémité. Wolternik et al. [112] ont réussi à mettre en place un pipeline de suivi itératif qui bénéficie d'un CNN à double sortie (rayon et une orientation la plus probable) pour identifier les points qui appartiennent à ligne centrale des vaisseaux au lieu d'une extraction classique des caractéristiques. Les CNN ont été utilisés non seulement pour l'extraction de la ligne centrale mais aussi pour la segmentation des vaisseaux, comme le montrent de nombreux travaux de [118, 119, 120, 121, 122].

La manière la plus simple de relever ce défi semble de fournir à un réseau 3D neuronal profond le volume complet de données, mais en raison de la quantité limitée d'échantillons, le modèle sera sûrement sous-apprenti et représentera donc mal les caractéristiques des données. On pourrait dire que les techniques d'augmentation de données peuvent aider à résoudre ces déficiences, mais lorsque la taille réelle des données est relativement faible, leur contribution devient mineure. Pour cela, une nouvelle stratégie de détection des lignes centrales à l'aide de CNN 3D doit être mise en place.

5.3 Méthodologie

Le filtre de Frangi est un détecteur efficace de vaisseaux. Néanmoins, il présente de nombreuses limites en raison de sa dépendance à un nombre relativement important de paramètres. Pour nous, nous recherchons un filtre capable d'extraire des caractéristiques de haut niveau à partir du volume CT. La rareté des données rend le domaine de l'imagerie médicale peu adapté aux techniques d'apprentissage profond. Un petit nombre d'échantillons limite la capacité d'un réseau de neurones à apprendre les caractéristiques représentatives dans une image ou un volume. La nature 3D des scans CTA nécessite un modèle 3D pour apprendre les corrélations les plus importantes entre les différentes structures du volume. Les artères coronaires constituent un arbre vasculaire connecté qui débute de l'aorte ascendante et qui appartient à la région cardiaque (cf figure 5.2, nous nous permettons de réutiliser la figure 1.2b du chapitre 1). Le pipeline proposé à la figure 5.3 traduit cette définition en sous-modèles qui extraient l'arbre complet des artères coronaires. Tout d'abord, une étape de pré-traitement en vue d'amélioration des vaisseaux est utilisée pour atténuer les structures non-vasculaires, puis un modèle CNN 3D est appliqué pour détecter les artères dans le volume CTA. En post-traitement, les limites des structures cibles sont définies en extrayant l'aorte et la région cardiaque grâce au modèle d'extraction des sous-régions du coeur. Enfin, une étape d'auto-correction est proposée par une analyse intelligente des composants connectés pour rectifier les erreurs de détection.

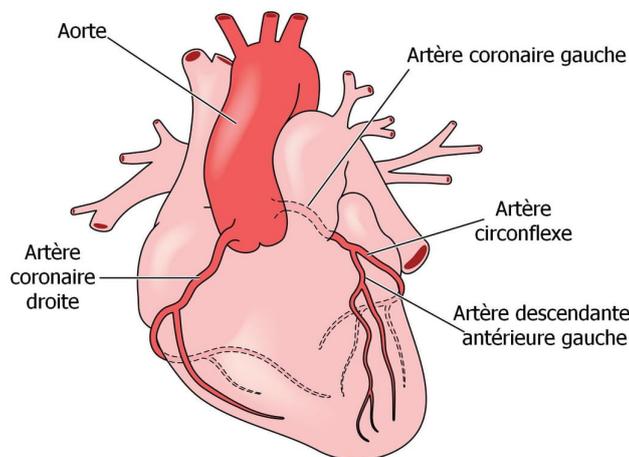


FIGURE 5.2 – Atlas de l'arbre des artères coronaires

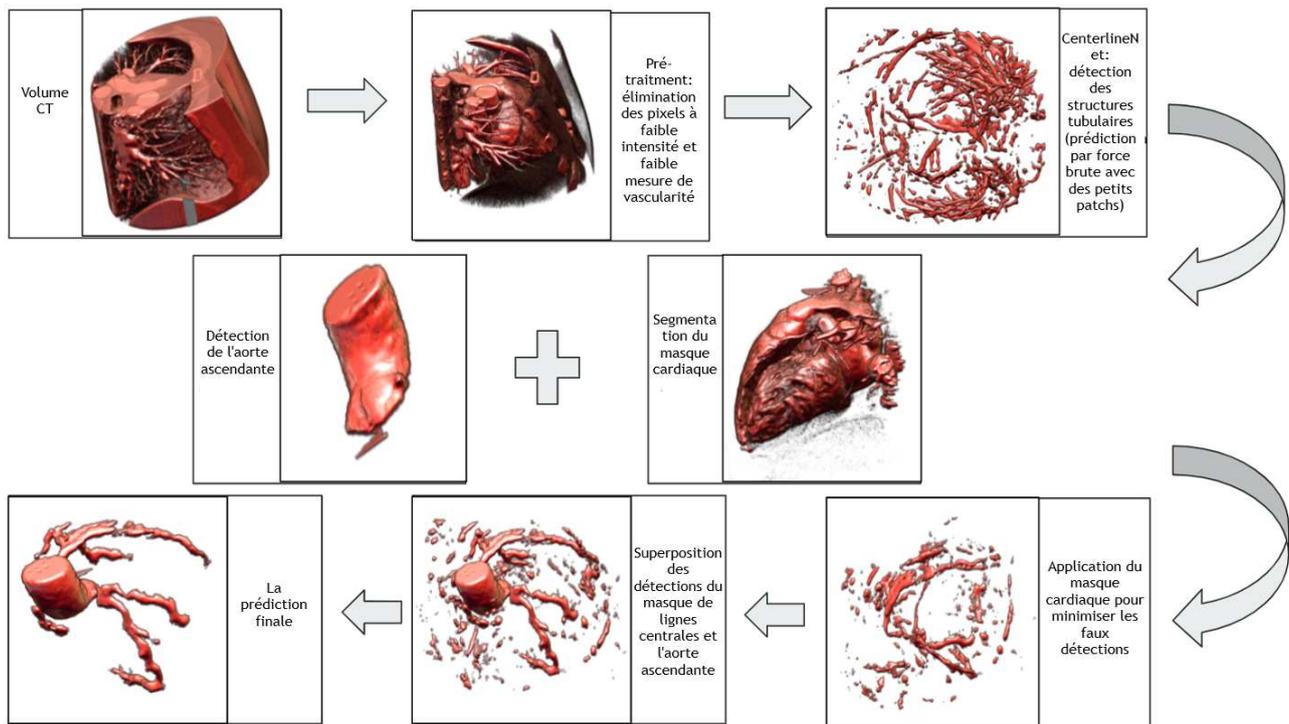


FIGURE 5.3 – Pipeline de l'extraction des lignes centrales des artères coronaires

5.3.1 Pré-traitement

Il n'est pas efficace ou nécessaire de traiter l'ensemble du volume CT, car les artères coronaires n'occupent généralement qu'un petit nombre de voxels. Par conséquent, la définition de la région d'intérêt et la suppression des informations non pertinentes constituent une étape importante et essentielle avant la segmentation proprement dite. D'abord, nous proposons d'améliorer les structures vasculaires contenus dans le volume CT en utilisant des filtres d'amélioration et spécialement le filtre de Frangi. L'objectif du filtre de Frangi est d'améliorer les structures vasculaires dans le but éventuel de les segmenter. Une procédure d'amélioration des vaisseaux en tant qu'étape de prétraitement améliorera la délimitation des petits vaisseaux et réduira la surprojection des organes. C'est une méthode populaire pour détecter les structures vasculaires dans les images médicales. Elle attribue à chaque voxel de l'image CT une mesure de vascularité, indiquant la probabilité que ce voxel ressemble à une structure vasculaire. Pour créer une représentation binaire des artères coronaires, un algorithme de seuillage adaptatif est appliqué aux sorties de ce filtre.

Les valeurs d'intensité des scans CT sont mesurées en unités Hounsfield, une unité définissant

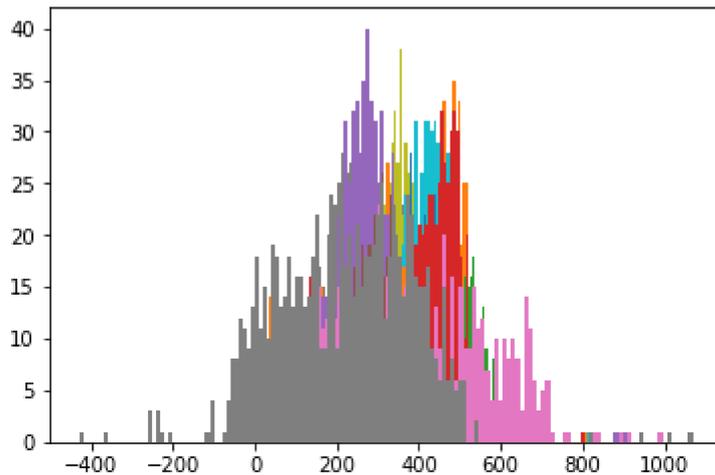


FIGURE 5.4 – Histogramme des valeurs de l'unité de Hounsfield pour les points appartenant à ligne centrale de la base d'entraînement

l'absorption du faisceau de rayons X par les différents tissus qu'il traverse. Les données sont traitées et reconstruites par un ordinateur en une image, selon un calcul matriciel. L'échelle de Hounsfield correspond à des densités qui s'étendent sur 2000 valeurs. Par définition, $HU = 0$ correspond à l'eau pure, $HU = -1000$ à l'air pur, $HU = +1000$ au métal et à l'os compact. La majorité des structures tissulaires ont une densité comprise entre 20 et 80 unités. La densité du sang est comprise entre 50 et 80, celle du calcium est supérieure à 90, celle des graisses varie de -50 à -100 . La densité du tissu cérébral est de 20 dans la matière blanche et de 40 dans la matière grise. Un liquide visqueux riche en protéines peut atteindre une densité de 40 unités. Une large gamme de valeurs peut être écartée lors de l'étape de pré traitement, car ces valeurs correspondent à des structures qu'il n'est pas pertinent de conserver dans cette étude. Afin de choisir la gamme optimale de valeurs à conserver, l'histogramme des valeurs d'intensité des lignes centrales est calculé comme le montre la figure 5.4. D'après le graphique de l'histogramme, on peut affirmer que le seuil de 700 engloberait la grande majorité des points des lignes centrales. Toute valeur qui dépasse 700 sera réduite à 700 et le même processus est répété pour les valeurs inférieures à 0. Les valeurs restantes sont ensuite mises à l'échelle dans l'intervalle $[0, 1]$ selon l'équation suivante Soit \mathbf{X} un coordonnée de voxel, I le volume CTA, I_{pre}

est le volume pré-traité, HU_{min} and HU_{max} le couple des seuils précédemment définies.

$$I_{pre}(X) = \begin{cases} 1.0 & \text{if } I(X) \geq HU_{max} \\ 0 & \text{if } I(X) \leq HU_{min} \\ \frac{I(X) - HU_{min}}{HU_{max} - HU_{min}} & \text{sinon} \end{cases} \quad (5.1)$$

Cette normalisation Min-Max est une transformation linéaire qui maintient les connexions et les corrélations entre les valeurs d'intensité. Elle permet d'éviter les problèmes numériques de convergence en plafonnant les intensités, dans notre cas, aux seuils HU_{min} et HU_{max} . Ceci réduit la quantité de données à traiter, à savoir les structures inutiles dans cette étude et limite donc les détections de faux positifs.

5.3.2 CenterlineNet : Architecture

L'architecture complète du modèle est présentée dans la figure 5.5. Ce réseau a une profondeur de 6 couches et utilise un module de convolution fortement inspiré du module U-net 3D [157]

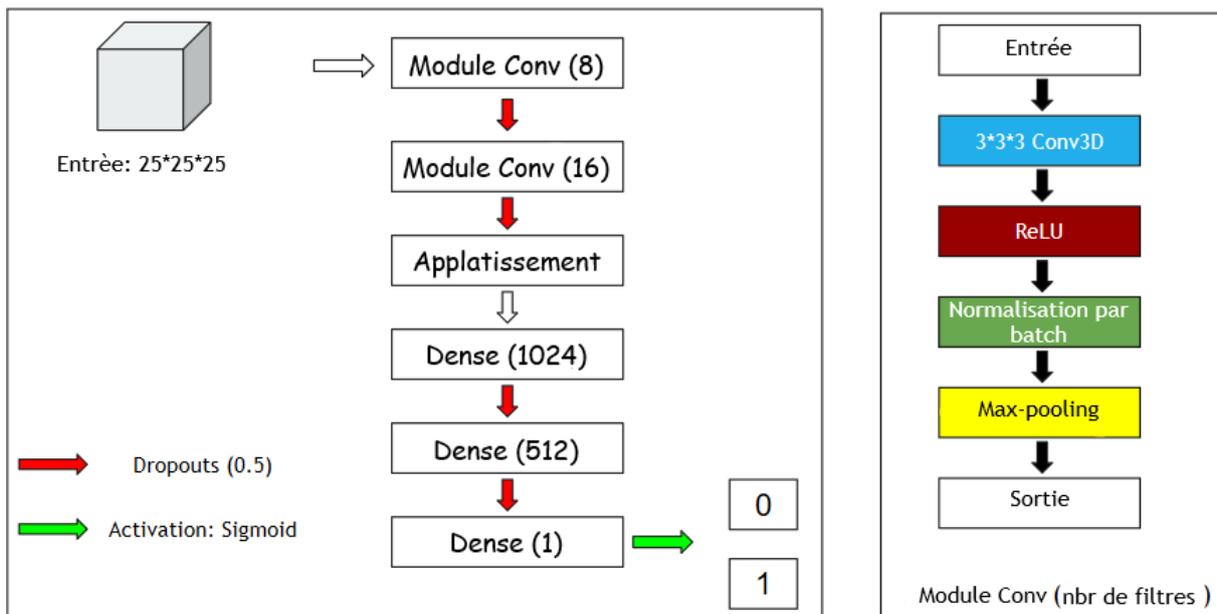


FIGURE 5.5 – Architecture de CenterlineNet

qui effectue des convolutions 3D avec des filtres de $3 \times 3 \times 3$. Chaque opération de convolution est accompagnée d'une activation ReLu pour détecter les non linéarités. Le résultat est ensuite transmis à une couche de normalisation pour ajuster et mettre à l'échelle les données afin d'obtenir une plus grande vitesse de convergence. Après cela, les données se compressent à l'aide d'une couche de Max-pooling qui divise la taille de la carte de caractéristiques résultante par 2 à chaque fois. Les données sont traitées deux fois par le "Module Conv", le nombre de filtres étant doublé à chaque étape (de 8 à 16). Pour minimiser le phénomène de sur-apprentissage, nous ajoutons des couches de Dropout Spatial avec un taux de 25 %. Ensuite, la sortie de la deuxième couche est aplatie (passage de 3 dimensions à une) puis appliquée à trois couches denses consécutives où la dernière couche retourne une valeur scalaire. Au final, le modèle devrait être capable de donner la probabilité qu'un volume d'entrée contienne un vaisseau ou pas en utilisant la fonction d'activation Sigmoid.

5.3.3 Organisation des données

Tous les ensembles de données sont ré-échantillonnés à une taille de voxel de $0.8 \times 0.8 \times 0.8 mm^3$ par interpolation tri-linéaire. Les valeurs des ensembles de données sont restreintes à une plage

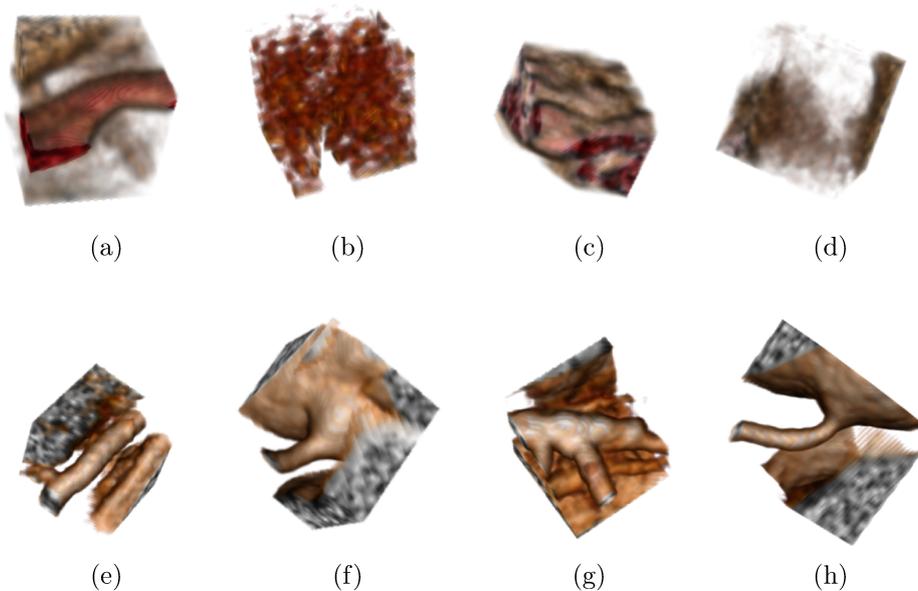


FIGURE 5.6 – Exemple de patches de vaisseaux "vrai" et "faux" : la première ligne affiche les "faux" vaisseaux tandis que la dernière montre les "vrais" vaisseaux.

de $[0, 700]$ puis ramenées à une plage de $[0, 1]$ en utilisant la normalisation Min-Max. Afin de créer un filtre de vaisseaux 3D, le modèle reçoit différents patches de vrais et faux vaisseaux provenant de volumes CTA. Un patch d'entrée a une taille de $(25 \times 25 \times 25)$ afin qu'il puisse contenir la plus grande artère coronaire possible. Un patch est étiqueté comme "vrai" s'il est centré sur un point de la ligne centrale, tandis qu'il est étiqueté comme "faux" si le patch ne contient pas de vaisseau ou contient un vaisseau qui n'est pas centré, comme le montre la figure 5.6.

Pour générer les données d'entraînement, les coordonnées réelles des lignes centrales fournies par les ensembles de données de Rotterdam ont été utilisées. Chaque patch de vaisseau réel est centré sur un point de la ligne centrale. Soit $C = (z_{centerline}, x_{centerline}, y_{centerline}) = (c_0, c_1, c_2)$ un point central. Soit \mathbf{d} un vecteur qui représente la taille du patch en un nombre de voxels.

$$\mathbf{d} = \begin{pmatrix} profondeur_{patch} \\ hauteur_{patch} \\ largeur_{patch} \end{pmatrix} = \begin{pmatrix} d_0 \\ d_1 \\ d_2 \end{pmatrix} \quad (5.2)$$

Soit \mathbf{P} un patch dont la taille est définie par \mathbf{d} et \mathbf{I} est le volume CTA. Le i^{me} coupe du patch qui correspond à la i^{me} couche de profondeur est définie comme suit :

$$P_d(i) = \begin{pmatrix} I(C_0 - \frac{d_0}{2} + i, C_1 - \frac{d_1}{2}, C_2 - \frac{d_2}{2}) & \cdots & I(C_0 - \frac{d_0}{2} + i, C_1 - \frac{d_1}{2}, C_2) & \cdots & I(C_0 - \frac{d_0}{2} + i, C_1 - \frac{d_1}{2}, C_2 + \frac{d_2}{2}) \\ \vdots & \cdots & \vdots & \ddots & \vdots \\ I(C_0 - \frac{d_0}{2} + i, C_1, C_2 - \frac{d_2}{2}) & \cdots & I(C_0 - \frac{d_0}{2} + i, C_1, C_2) & \cdots & I(C_0 - \frac{d_0}{2} + i, C_1, C_2 + \frac{d_2}{2}) \\ \vdots & \cdots & \vdots & \ddots & \vdots \\ I(C_0 - \frac{d_0}{2} + i, C_1 + \frac{d_1}{2}, C_2 - \frac{d_2}{2}) & \cdots & I(C_0 - \frac{d_0}{2} + i, C_1 + \frac{d_1}{2}, C_2) & \cdots & I(C_0 - \frac{d_0}{2} + i, C_1 + \frac{d_1}{2}, C_2 + \frac{d_2}{2}) \end{pmatrix} \quad (5.3)$$

5.3.4 Stratégie d'entraînement

Augmentation des données

Pendant l'entraînement et la validation, des patches de référence annotés manuellement ont été utilisés. Le réseau a été entraîné en utilisant des mini-batchs contenant des fragments étiquetés.

Dans l'ensemble de données, la répartition de "faux" et "vrai" patches est très déséquilibrée. Pour surmonter ce problème, un échantillonnage aléatoire stratifié des données a été effectué pour l'entraînement. Chaque itération d'entraînement (époque) comprend une distribution équilibrée et aléatoirement sélectionnée. En outre, plusieurs techniques d'augmentation des données ont été utilisées pour accroître la taille de l'ensemble d'entraînement. Premièrement, pour rendre le réseau invariant aux rotations autour de la ligne centrale de l'artère, des rotations aléatoires entre 0 et 360 degrés autour de la ligne centrale de l'artère coronaire ont été appliquées à tous les cubes. Deuxièmement, pour rendre le réseau invariant aux légères inexactitudes dans les annotations manuelles des points définissant le fragment, un décalage aléatoire uniforme entre ± 3 voxels le long de la ligne centrale est appliqué. Troisièmement, pour rendre le réseau robuste à d'éventuelles inexactitudes dans l'extraction de la ligne centrale de l'artère coronaire, le centre de chaque cube a été déplacé de façon aléatoire autour de son origine jusqu'à ± 2 voxels, dans n'importe quelle direction.

Paramètres d'entraînement

Les données d'entraînement utilisées étant trop volumineuses, elles n'ont pas pu être chargées directement dans la mémoire. Pour cela, et pour éviter de minimiser ces échantillons, un entraînement avec générateur de données a été utilisé au lieu de l'entraînement normal. L'entraînement avec générateur permet le chargement des données par lots (batch). Cette technique résout une fois pour toutes le problème de surcharge de la mémoire. La taille du lot utilisé est de 256, car il s'agit de la quantité maximale que la machine pouvait traiter en une seule fois. Les couches d'exclusion (dropout) ont été utilisées sur les deux premières couches de convolution et sur les deux dernières couches denses avec une probabilité d'exclusion de 50 %. Cela signifie que chaque nœud a la même chance d'être activé ou arrêté pendant un cycle de mise à jour des poids.

En termes d'initialisation des poids, aucun apprentissage par transfert n'a été utilisé, l'apprentissage a été effectuée à partir de zéro, mais en ce qui concerne les noyaux du CNN, leurs poids ont été initialisés en utilisant *glorot uniform distribution*. [167]. Il s'agit d'une distribution uniforme dont la variance est calculée en fonction des poids pour la passe avant et

la rétropropagation. Pour entraîner ce réseau, l'optimiseur ADAM [168] a été utilisé avec un taux d'apprentissage de $lr = 10^{-4}$, $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 10^{-8}$ et une décroissance de 10^{-6} (ces variables sont propres à l'optimiseur ADAM). Finalement, ces paramètres devraient permettre au modèle d'obtenir de bons résultats dans la période de temps la plus courte possible. Lorsque l'apprentissage commence, le taux d'apprentissage initial est comme mentionné ci-dessus $lr = 10^{-4}$ mais une diminution est programmée si la fonction du coût de validation atteint un plateau. Ainsi, si la métrique de la perte de validation ne s'améliore pas pendant un certain nombre d'époques (20 dans ce cas) alors le lr est réduit d'un facteur 2. Cette réduction profite au modèle si le processus d'apprentissage stagne. Finalement, un moniteur d'arrêt précoce est ajouté. Ainsi, lorsque la perte de validation ne s'améliore pas pendant un certain nombre d'époques (100 époques), l'apprentissage est interrompu.

5.3.5 Post-traitement : Délimitation de la région cardiaque et l'aorte ascendante

Afin de délimiter l'origine et l'étendue de l'arbre artériel coronaire, une extraction de la région cardiaque et de l'aorte ascendante est réalisée. L'aorte ascendante est le plus grand vaisseau sanguin du corps. Elle sort du cœur et pompe le sang à travers l'arc aortique et dans l'aorte descendante. L'aorte ascendante est la première partie la plus proche du cœur et comporte deux petites branches. Ce sont les principales artères coronaires qui fournissent un sang riche en oxygène au muscle cardiaque. Cette connexion biologique permet au modèle de distinguer les vaisseaux parasites des vaisseaux cibles. De plus, et dans le but d'éliminer les fausses réponses, une frontière de la région cardiaque est établie afin d'éliminer les prédictions extra-cardiaques (poumons, pulmonaires,...). Pour cette tâche, un modèle de segmentation U-Net à 3 classes [30] comme indiqué dans la figure 5.7 est utilisé et les échantillons de vérité terrain sont préparés par des cardiologues à l'aide du module d'édition de segments du logiciel 3D Slicer [166]. Nous avons utilisé un ensemble de 10 patients choisis au hasard dans la base de données Rotterdam comme jeu de données d'entraînement. Le choix d'une architecture 2D est dû principalement à la rareté des données, car une approche par coupe fournit plus d'échantillons d'entraîne-

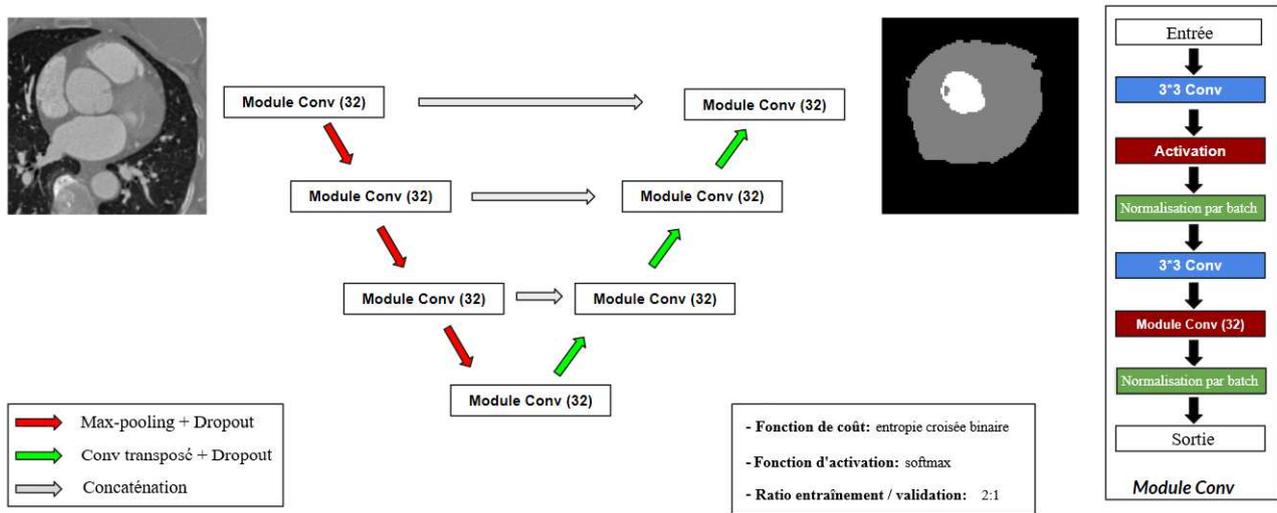


FIGURE 5.7 – Détection de l'aorte et la région cardiaque

ment qu'une segmentation 3D par volume. Le modèle U-Net est largement utilisé dans les algorithmes de vision par ordinateur pour sa segmentation rapide et précise des images. La partie encodeur consiste à compresser les données en une petite carte de caractéristiques tandis que la phase décodeur reprend cette carte de caractéristiques à la taille originale de l'image d'entrée. Cette architecture est finalement suivie d'une couche de segmentation qui décide sur la valeur de chaque pixel et le classe dans l'une des classes suivantes : {0 : Extra Cardiaque, 1 : Région cardiaque, 2 : Aorte ascendante}. Les résultats de segmentation (la sensibilité est la métrique utilisée) obtenus par ce modèle sont légèrement supérieurs à 89,2 %. Finalement, toutes les composantes du pipeline proposé en figure 5.3 sont prêts à être combinés pour une segmentation finale des artères coronaires. L'élimination des régions extra-cardiaques avant la segmentation, crée des effets de bords très néfastes pour les prédictions de CenterlineNet. De ce fait, nous préférons d'utiliser cette composante comme une méthode de post-traitement pour ne pas interférer avec les résultats du filtrage des artères. L'assemblage de ces prédictions se fait à l'aide d'une superposition.

Nos résultats doivent absolument coller avec la réalité biologique de ces structures. Les artères coronaires se divisent en deux artères coronaires principales droite et gauche, qui sortent de l'aorte ascendante juste au-dessus de la valve aortique (à partir des ostiums coronaires). En s'appuyant sur ces notions, nous concluons qu'une analyse des composants connectés peut extraire l'arbre coronaire artériel du reste des vaisseaux détectés.

TABLE 5.1 – Évaluation des performances de sensibilité de CenterlineNet sur 18 patients issus de l’ensemble d’entraînement du concours de sténose et de quantification des artères coronaires de Rotterdam (2012). Les colonnes considérées comme l’annotation de la vérité du terrain.

Modèles	Données CTA	Prédiction LKEB	LKEB \cup CTA	LKEB \cap CTA
CenterlineNet Prediction	95.48 %	95.18%	94.83%	97.10%
LKEB Prediction	38.33 %	Nan	62.21%	Nan

5.3.6 Résultats et Discussion

Nous avons utilisé les jeux de données de test du Rotterdam Coronary Artery Framework Stenosis and Quantification Challenge (2012). Ces jeux contiennent 30 patients et la vérité de terrain provient de l’algorithme LKEB [105] pour entraîner notre réseau puisque l’annotation manuelle n’est pas fournie pour ces échantillons. La nature locale de notre modèle lui permet de détecter tous les vaisseaux principaux et les branches latérales même s’il a été entraîné sur un modèle qui ne détecte que les branches principales et avec des résultats bruités (pas les annotations des experts). Le test de sensibilité sur 18 patients des jeux de données d’entraînement Stenosis donne les résultats présentés dans la table 5.1. Au niveau du patch, nous démontrons que notre modèle permet d’identifier les points de référence manuels avec une sensibilité de 95,48%, ce qui est largement supérieure à la prédiction LKEB avec 38,33% (aucune marge de rayon n’est considérée pour qu’une prédiction soit étiquetée comme correcte). De manière surprenante, le modèle CenterlineNet reflète davantage les données annotées manuellement (95,48%) que les lignes centrales annotées par LKEB (95,18%), ce qui valide la robustesse et la pertinences des caractéristiques extraites par un modèle CNN. Nous évaluons notre approche sur les jeux de

TABLE 5.2 – Évaluation des performances de CenterlineNet sur 8 patients des jeux de données CAT08. Nous rapportons les résultats de la version du modèle entraînée uniquement sur les données de sténose et une autre version mélangée avec les patches CAT08. [107]

<i>Id du patient</i>	00	01	02	03	04	05	06	07	Total
<i>Avec CAT08</i>	85.51%	95.95%	93.23%	90.08%	98.43%	99.52%	98.21%	89.08%	93.75%
<i>Sans CAT08</i>	78.44%	92.74%	88.92%	85.97%	85.99%	93.02%	95.07%	84.13%	88.03%

données CAT08. Tout d’abord, nous avons remarqué que le modèle est moins performant pour cette application que sur celui de la sténose et de la quantification (88,03% contre 95,48%). Cette baisse peut s’expliquer par le fait que ces deux bases de données n’ont pas la même qua-

lité d'image ni le même protocole de scanner pour les données acquises. Donc la variation entre les deux ensembles d'images est considérable. Pour résoudre ce problème, nous avons fourni des patches CAT08 aux données d'entraînement et nous réentraînons notre modèle en utilisant l'apprentissage par transfert tout en validant par une technique de leave one-out. Les résultats sont présentés dans le tableau 5.2. Nous observons une augmentation de 5 % de la sensibilité et une adaptation du modèle aux nouveaux échantillons. Puisque nous essayons de trouver toutes les branches de l'arbre artériel coronaire, il n'est pas utile de rapporter la spécificité car le cadre de Rotterdam n'extrait que le tronc principal et une branche latérale aléatoire. Néanmoins, l'idée d'avoir des structures connectées est cruciale pour poursuivre avec un tel modèle. Bien qu'il s'agisse d'un modèle orienté localement, la prédiction globale devrait refléter une compréhension des données en produisant un arbre artériel en harmonie avec sa définition biologique. Une telle évaluation ne peut être faite que par la visualisation des prédictions 3D. Ainsi, comme le montre la figure 5.8, le modèle a réussi à reproduire la forme globale de l'arbre central.

L'une des approches les plus explicites de la tâche d'extraction des lignes centrales pourrait être de fournir le volume complet de données à un réseau de neurones. Mais, faute de données, le modèle sera sûrement incapable de représenter les caractéristiques des données. On pourrait penser que les techniques d'augmentation des données peuvent aider à résoudre de telles faiblesses, mais lorsque la taille réelle des données est relativement faible, leur contribution devient

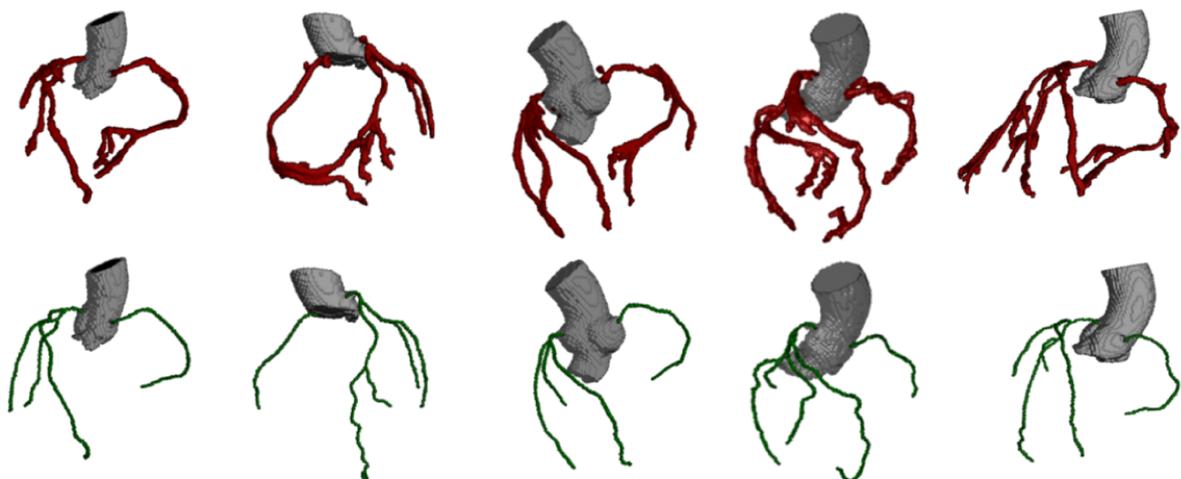


FIGURE 5.8 – Modèles 3D des prédictions CenterlineNet ainsi que des segmentations de la vérité terrain. La ligne supérieure représente les résultats de la prédiction tandis que la ligne inférieure affiche la vérité terrain correspondante pour le même patient et à partir de la même vue.

mineure. Dans cette partie de chapitre, nous avons présenté une nouvelle méthode entièrement automatique pour l'extraction des artères coronaires en utilisant des 3D CNN. Notre approche a utilisé exclusivement le jeu de données limité des cadres de Rotterdam, disponible publiquement, pour l'entraînement et le test. Bien que nous ayons utilisé des prédictions bruitées pour former notre modèle, celui-ci a atteint un taux de récupération élevé de 95,48 % et 93,75 % sur des références annotées manuellement pour les deux ensembles de données. À notre connaissance, il s'agit du premier 3D CNN 3D utilisé uniquement comme détecteur local de la ligne centrale des artères coronaires, en remplacement des filtres et des fonctions de coût manuels utilisés pour l'identification des vaisseaux. Cependant, le pipeline complet assure la détection d'un arbre artériel connecté complet avec des branches principales et latérales provenant de l'aorte ascendante et limitées aux frontières de la région cardiaque.

Néanmoins, il reste de nombreuses améliorations possibles à cette architecture. Chaque composante peut être développée d'avance et surtout automatisée (l'analyse des composantes connectées). Nous observons qu'il manque à l'ensemble une méthode de récupération des artères prédits correctement mais perdu à cause des interruptions. Dans le cas une interruption aura lieu, l'arbre coronaire n'agit plus d'une structure unique mais des bouts de vaisseaux dispersés. Dans ce cas, des améliorations doivent être apportées à l'ensemble du pipeline pour faire face à ces difficultés et éviter le risque de perdre de l'information pertinente à cause des interruptions des artères.

5.4 Optimisation du Pipeline de la Détection

La mise à niveau du pipeline de détection s'inspire de deux principes que nous partageons durant cette thèse qui sont : ajouter de la valeur aux images tout au long de nos recherches et rester fidèle au caractère de généralisation.

L'isolation de la région cardiaque, bien que cruciale dans le but de la détection de la sténose, finalement, ne constitue pas un bénéfice dans la réalité clinique. Les experts métiers sont plus enclins à étudier les différentes sous structures du coeur au lieu de la région cardiaque toute entière. Cette étude nécessite généralement la segmentation des cavités sanguines des quatre

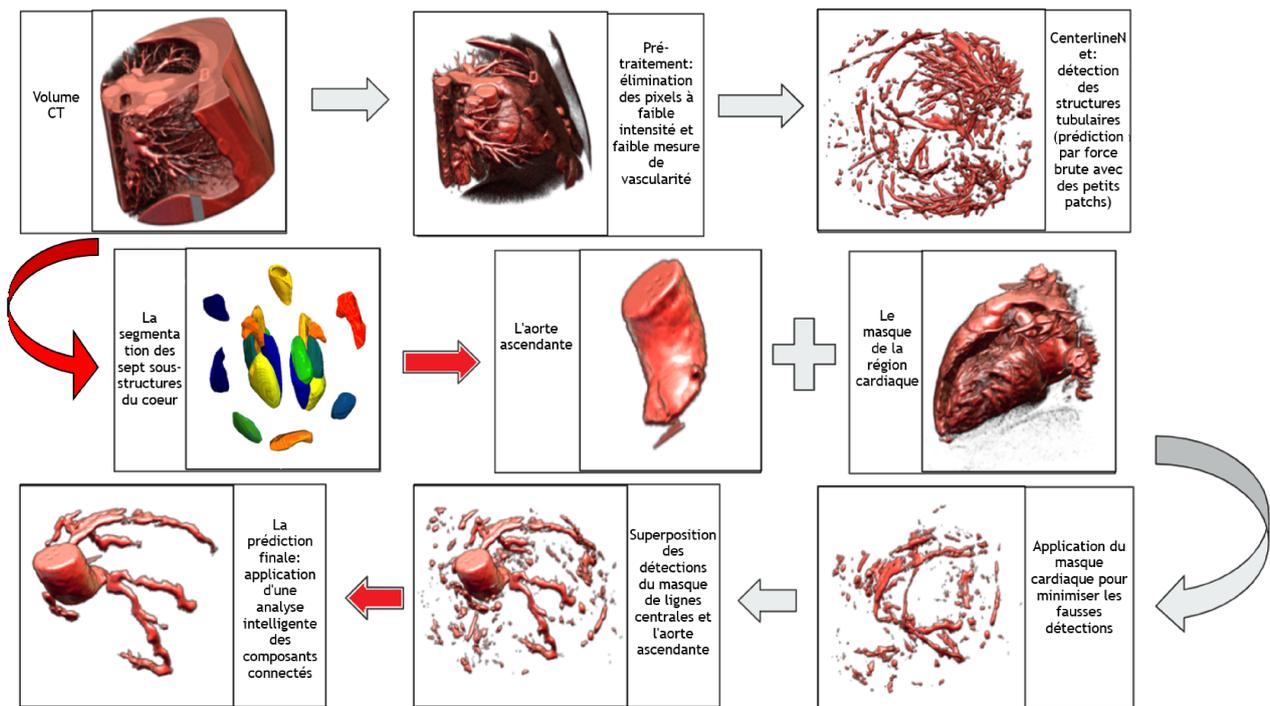


FIGURE 5.9 – Pipeline mise à niveau pour l'extraction des lignes centrales des artères coronaires

chambres et le myocarde du ventricule gauche. Les résultats ont un certain nombre d'applications cliniques potentielles. Par exemple, ils peuvent être directement utilisés pour faire une analyse fonctionnelle du cœur ce qui donne le potentiel de détecter des anomalies subtiles ou des changements de la fonction cardiaque. Ceci est essentiel pour le diagnostic précoce des patients qui présentent par ailleurs une fonction systolique normale des ventricules mais pour lesquelles on soupçonne une fonction anormale dans d'autres régions.

Notre attention s'est ensuite portée sur l'aspect généralisation, important à nos yeux. Notre pipeline original manque de robustesse et de flexibilité passé l'étape de CenterlineNet (cf sous-section 5.3.2). Bien que cette dernière fournisse un excellent filtrage des artères, un mécanisme de confiance, de contrôle et de récupération doit être mis en place pour imposer une garantie de qualité dans des environnements et situations difficiles de prédiction.

Enfin, on agit sur le pipeline original (figure 5.3) en introduisant deux composantes indiquées par les flèches rouges dans la figure 5.9. L'idée de cette amélioration est d'apporter une valeur réelle, biologique et nécessaire à la réalité clinique à travers les modèles et techniques mis en place tout au long de la thèse pour aider à couvrir autant que possible les défis liés à la détection et à la caractérisation de la sténose ainsi que les défis voisins qui partagent les mêmes

structures.

De ce fait, cette section décrit d'abord la revigoration du modèle de l'isolation de la région cardiaque auquel on rajoute la capacité de segmentation des sept sous-structures. Ensuite, nous introduisons une analyse automatisée des composants connectés qui vient compléter les artères correctement détectés mais écartés de la prédiction finale à cause des interruptions et des discontinuités dans les branches de l'arbre artériel prédites.

5.4.1 Délimitation de la région cardiaque : segmentation des sous-structures du coeur

La segmentation précise de la région cardiaque est un problème difficile car le cœur est composé de plusieurs sous-structures. Le cœur humain est un organe complexe composé de quatre chambres, de vaisseaux sanguins et de muscles. L'objectif de ce module, comme indiqué précédemment (sec 5.4) et dans la figure 5.10, est de segmenter précisément les sous-structures, notamment les quatre chambres (ventricule gauche, ventricule droit, oreillette gauche, oreillette droite), les deux artères (aorte ascendante, artère pulmonaire) et le myocarde du ventricule gauche. La principale difficulté de la segmentation des sous-organes cardiaques est l'identification de la limite entre les organes adjacents (par exemple, la limite entre l'oreillette et le ventricule). Cette segmentation complète de ces sous-organes a une multitude de bénéfices notamment :

- fournir une région d'intérêt pour limiter la zone de détection et accélérer les calculs ;
- indiquer les points de naissance des artères coronaires (ostium) ;
- établir un atlas complet pour la région cardiaque indispensable pour les mesures aortique.

Travaux Précédents

En plus de la difficulté de cette tâche dans la réalité clinique, son automatisation présente plus de défis en raison de la grande variation de la forme du cœur et de la qualité des images. Plusieurs méthodes orientées modèle (ajustement de modèle)[169, 170] ou orientées atlas [171, 172]

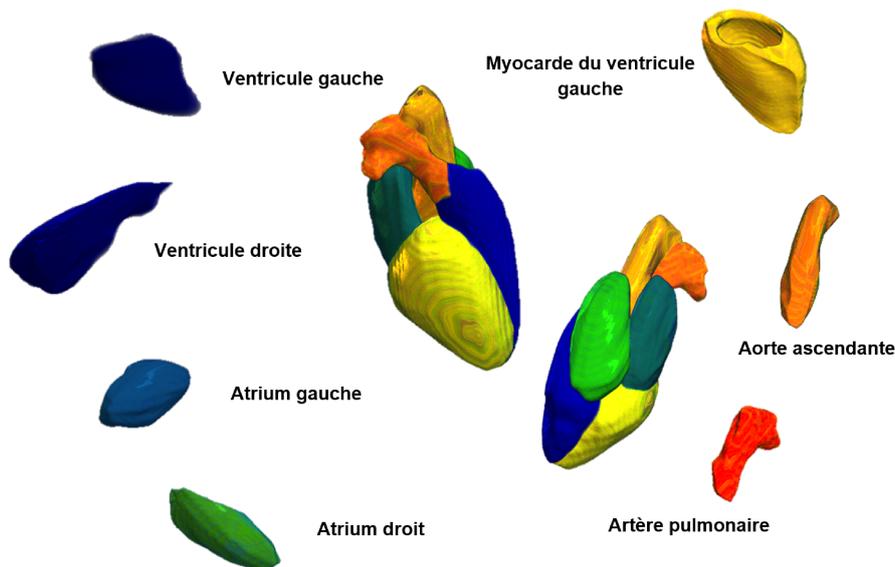


FIGURE 5.10 – Segmentation de la région du coeur en sept grands structures : aorte, myocarde, atrium droit, atrium gauche, ventricule droit, ventricule gauche et artère pulmonaire.

(basées sur les régions, frontières et coupes de graphes) ont été explorées. Depuis 2015, les modèles basés sur l'apprentissage profonds ont devenu l'état de l'art pour la segmentation cardiaque. C'est dans ce contexte que nous utilisons appel à ces méthodes qui démontrent une grande capacité d'analyse de données. Plusieurs algorithmes basés sur l'apprentissage profond ont été proposés pour la segmentation cardiaque [173, 174, 174, 175]. Un réseau multicoupe 2,5D [174], [175] a été utilisé pour la segmentation du ventricule cardiaque. Cependant, les caractéristiques spatiales 3D n'ont pas été pleinement exploitées dans les méthodes 2,5D, qui n'utilisaient que de multiples vues (coronal, saggital et axial) d'images 2D. Des méthodes de segmentation

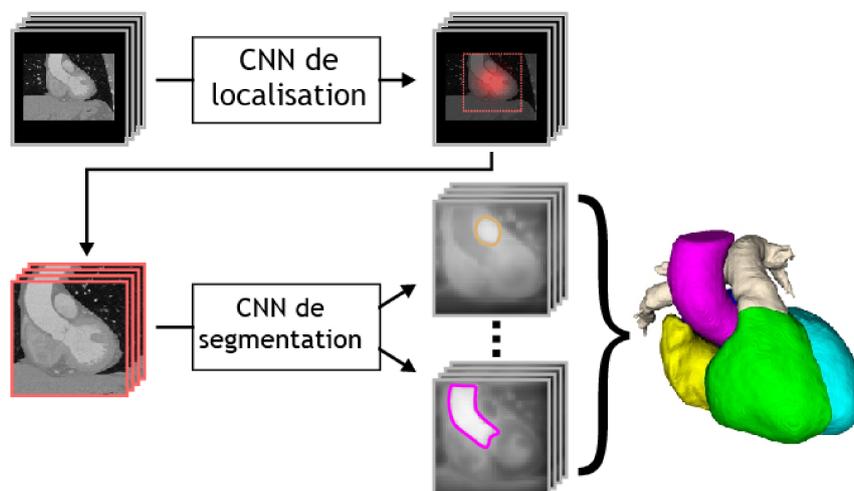


FIGURE 5.11 – Vue d'ensemble du pipeline de segmentation en deux étapes, multi-labels et entièrement automatique de Payer et al [178]. La figure est adaptée de [178].

automatique du cœur entier [173], [174] ont été étudiées sur la base des réseaux de neurones (FCN, U-Net,...). Les résultats de ces méthodes ont montré des performances inférieures parce qu'ils ne parviennent pas à identifier les frontières entre les sous-structures cardiaques précisément. La distinction des frontières d'intensité homogène ne sont pas correctement détectés par les approches 2,5D en raison de la difficulté à préserver les caractéristiques spatiales et de forme.

Modèle Proposé

Pour relever le défi de la segmentation des sous structures du coeur, nous nous inspirons de l'une des méthodes les plus performantes dans le challenge MICCAI WHS 2017 [176, 177] qui est la méthode de Payer et al [178]. C'est un modèle de segmentation de bout en bout, entièrement automatique, basé sur un pipeline de 2 CNNs (comme l'indique la fig 5.11) opérant respectivement depuis une basse, puis une haute résolution. Le premier CNN, appelé "CNN de localisation", localise le centre d'une boîte de délimitation autour du cœur et effectue le recadrage de la région d'intérêt qui englobe toutes les sous-structures. Ce réseau fonctionne en basse résolution, les données d'entrée sont sous-échantillonnées en raison des limites de mémoire, tandis que le deuxième réseau CNN, appelé "CNN de segmentation", prend la région d'intérêt du CNN de localisation comme entrée pour effectuer une segmentation multi-étiquette de chaque pixel.

Cette méthode repose en grande partie sur l'extraction et la localisation de points de repère. Chaque structure extraite permet de localiser l'espace d'existence de la structure adjacente. Une de nos contributions scientifiques s'intéresse à améliorer le modèle de Payer et al [178]. Clairement, grâce au repérage des structures par rapport aux autres que ce modèle apprend et améliore ses performances. Que dire alors si nous apportons à cette équation l'information de l'emplacement d'une structure qui entoure tous ces organes? Ainsi, afin d'améliorer les performances de ce modèle et d'apporter de nouvelles données à interpréter à son extracteur, nous ajoutons les artères détectées comme support pour localiser plus précisément les structures en question. Cette information s'inscrit dans le cadre de notre pipeline. Nous voulons une segmentation précise de la région cardiaque pour définir la région de présence des artères coronaires et

vice versa. Alors comment réussir à garder l'intégrité du modèle de Payer et al en le supportant avec ces données dont il n'a pas eu accès auparavant ?

Nous savons que ce modèle va servir de post-traitement pour ne pas créer des effets de bords pour notre modèle CenterlineNet. Et si CenterlineNet faisait parti du pré-traitement de celui de Payer ? Généralement, les méthodes de pré-traitement sont faite pour standardiser, uniformiser et probablement améliorer des structures cibles. Nous proposons un pré-traitement sophistiqué qui permettra d'éliminer l'arbre artériel qui entoure la région cardiaque. De ce fait, l'approche de Payer et al [179] aura un accès direct aux frontières définissant ces structures. Cette approche aide à obtenir une segmentation précise des sous-structures du coeur à travers la détection des artères. Cette segmentation servira à obtenir une meilleur détection de l'arbre artériel en définissant mieux l'atlas de cette région. Nous créons un effet similaire au cercle vertueux, une amélioration continue de ces deux modèles.

Résultats et Discussion

On commence d'abord par l'évaluation des résultats de reproduction de l'algorithme de Payer et al [178]. Nous avons suivi les instructions des auteurs pour reproduire leur résultat. Malgré cela, les résultats obtenus semblent s'éloigner de ceux décrits dans le travail de [179]. Ceci peut être dû à la migration du modèle de l'environnement Caffe à Tensorflow et aux initialisations aléatoires du modèle. Comme indiqué dans la table 5.3, nos résultats étaient inférieurs à ceux du travail

TABLE 5.3 – Coefficients de similarité de Dice en % pour la reproduction de travail de Payer et al, les résultats de l'algorithme d'état de l'art de MICCAI WHS 2017 et notre proposition de couplage des résultats de notre modèle CenterlineNet et l'approche de Payer. Les résultats montrent la moyenne de toutes les images de la configuration de validation croisée pour chaque étiquette de segmentation. Abréviations des étiquettes : VG - cavité sanguine du ventricule gauche, Myo - myocarde du ventricule gauche, VD - cavité sanguine du ventricule droit, AG - cavité sanguine de l'oreillette gauche, AD - cavité sanguine de l'oreillette droite, AA - aorte ascendante, AP - artère pulmonaire, WHS - moyenne des sept sous-structures du coeur entier

Classes	VG	Myo	VD	AG	AD	AA	AP	WHS
Reproduction de Payer	85.37	84.24	87.07	81.52	81.96	84.52	73.87	82.65
Reproduction de Payer avec élimination des artères	84.2	86.2	90.6	85.86	84.0	87.16	81.7	87.4
Payer	92.4	87.2	87.9	92.4	87.8	91.1	83.3	88.9

original dans toutes les classes. Cependant, en introduisant les résultats de CenterlineNet, qui permettent d'éliminer les artères qui entourent les sous-structures cardiaques et contribuent à brouiller leurs limites, le modèle répliqué montre une amélioration des performances d'environ 5% au total. Bien que cette augmentation puisse être considérée comme une condamnation du modèle répliqué, l'analyse de la classe du ventricule droit prouve le contraire. Cette classe est la seule qui n'a pas souffert d'une diminution significative des performances par rapport à l'algorithme de Payer. L'ajout de notre approche, propulse les résultats de segmentation au-dessus de l'algorithme original. L'apport de notre méthode est donc tangible et une contribution qui peut bénéficier énormément aux modèles de segmentation du coeur.

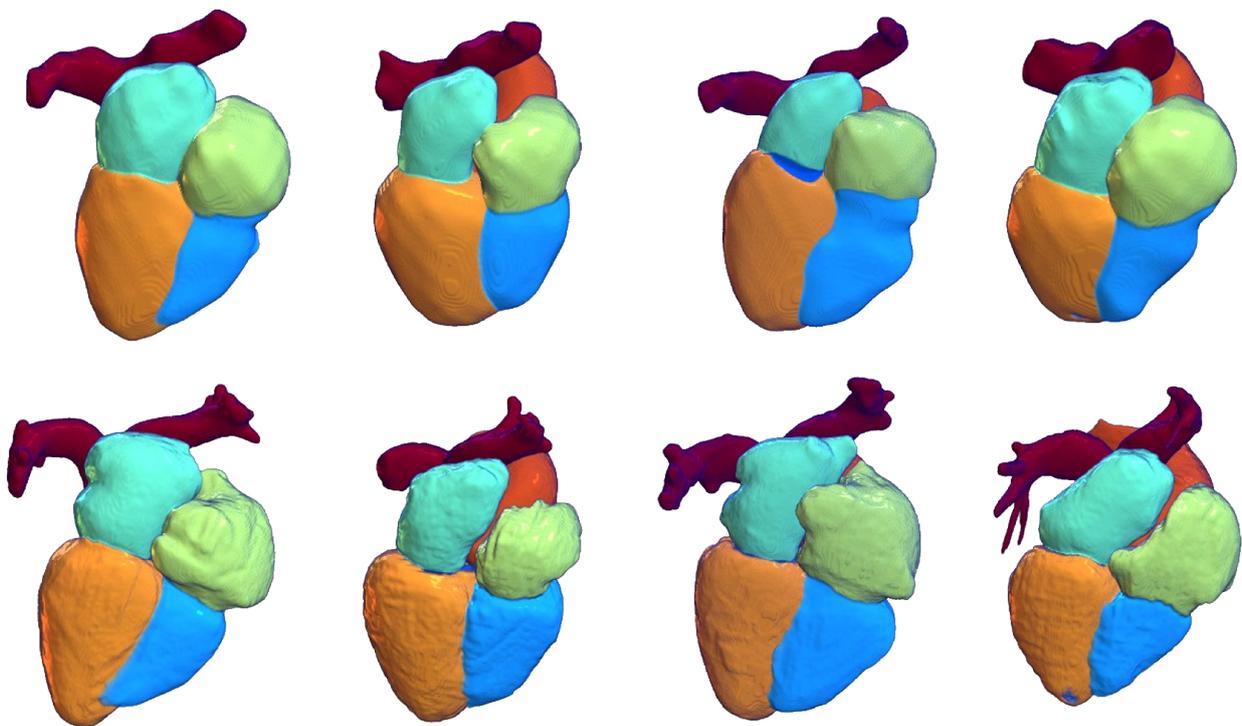


FIGURE 5.12 – Évaluation visuelle des résultats de la combinaison de Payer et al [178] reproduit avec l'élimination des artères produits par CenterlineNet. La première ligne affiche les prédictions alors que la deuxième contient les vérités terrain. Ces patients font parti de la configuration de validation croisée.

5.4.2 Analyse intelligente des composants connectés : diminuer le risque des interruptions

L'approche CenterlineNet utilisée précédemment donne d'excellents résultats si les images scanner sont bien adaptées et de bonne qualité. Cependant, le travail précédent a une limitation importante qui est de perdre complètement, à l'échelle d'un sous-arbre entier, les artères dès qu'elles présentent une interruption même minime du chemin. Cette limitation provient de la nature de l'analyse des composantes connectées. Or, ces interruptions sont fréquentes et peuvent provenir d'erreurs d'acquisition (protocole et équipement) ou à l'anatomie du patient. La taille des artères reste la principale raison d'apparition d'interruptions.

Dans des conditions favorables, ce processus se simplifie en une analyse simple des composantes connectées mais en présence d'éléments perturbateurs et notamment d'interruptions dans le trajet, il permet de conserver et d'isoler les morceaux d'artères après ces discontinuités.

Ces problèmes commencent à apparaître lors de l'utilisation de la base de données du CHU de Poitiers. Cette base de données est plus récente que celle de Rotterdam et la variabilité en terme de la qualité est remarquable. Certaines interruptions, bien que minimes, nous faisaient perdre des sous arbres complets. Commençons d'abord par un cas de figure issu de notre évaluation sur la base de données de Rotterdam. La figure 5.13 présente un cas qui nous a aidé à repenser l'approche de l'analyse classique des composants connectés.

La prédiction de CenterlineNet récupère 95.2% de l'arbre artériel après suppression des régions extra-cardiaques. Cette prédiction souffre de deux ruptures majeures mises en évidence par les cadres verts. Après avoir effectué l'analyse des composants connectés, comme le montre la figure 5.13c, le taux de récupération chute à 61.7% en raison de la perte de l'artère coronaire droite. C'est dans ce contexte que le besoin d'une analyse intelligente pour récupérer l'arbre artériel sans tenir compte des discontinuités est impératif.

Nous avons pour objectif de proposer un module qui permet une analyse intelligente des composants connectés. L'idée est de reconnaître les artères coronaires à partir des structures prédites dans la région cardiaque. Ce modèle doit être capable de reconnaître l'évolution de l'arbre artériel et de fournir l'aspect de généralisation que nous avons manqué à cause de l'approche de

partitionnement en patches utilisé par CenterlineNet. Ainsi, ce module adhère aux contraintes suivantes :

- une approche 3D contenant le volume entier de la prédiction est une nécessité
- les artères intracardiaque prédites par CenterlineNet constituent les données d'entrée
- l'arbre artériel complet est le point culminant de ce module de correction.

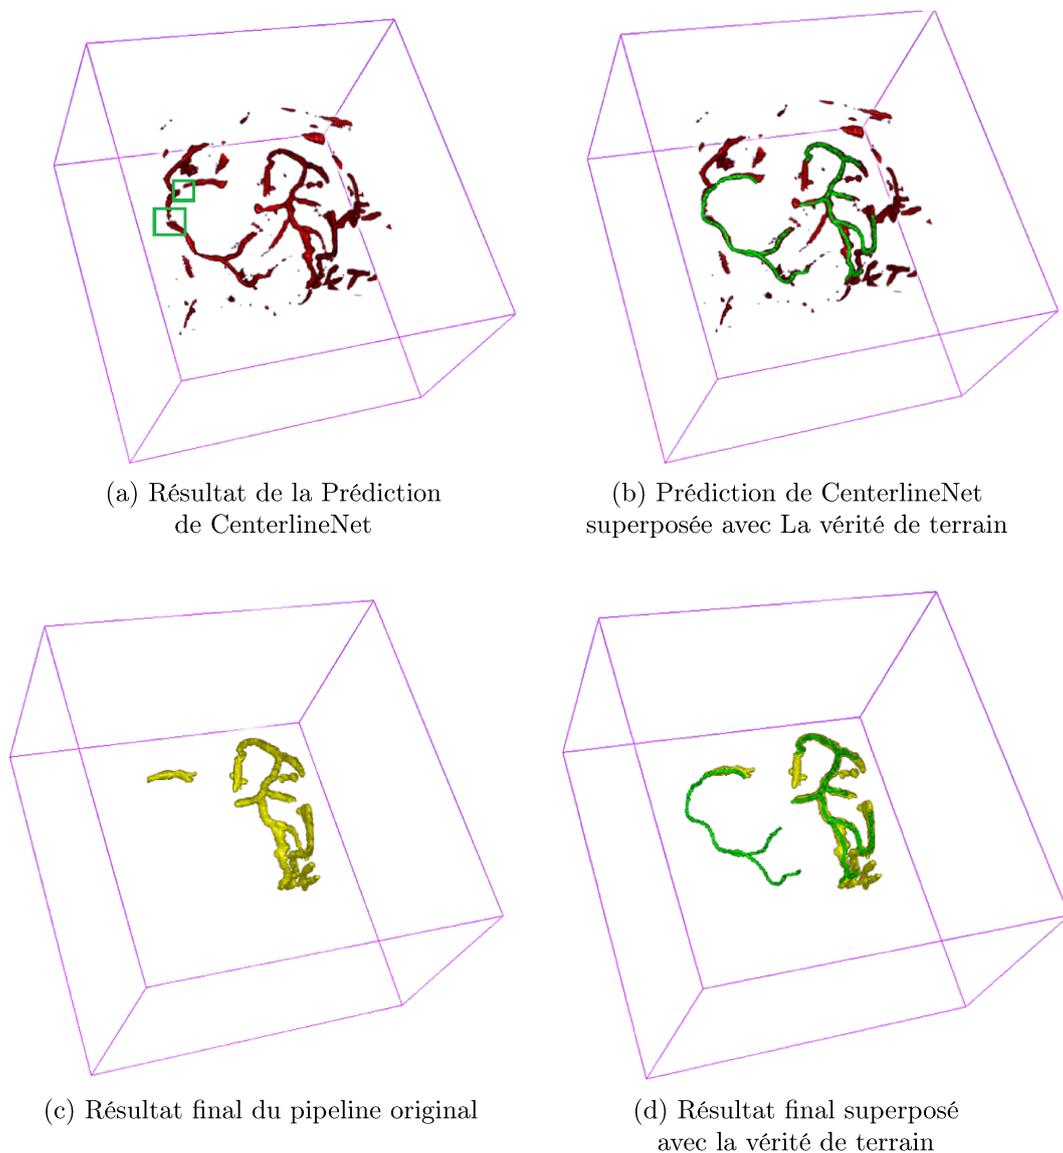


FIGURE 5.13 – Perte d'un sous arbre complet (la partie droite de l'arbre coronaire) à cause des interruptions dans la prédiction de CenterlineNet montrées avec les cadres verts dans l'image (a)

Modèle Proposé

Avec tout ceci en tête, nous proposons l'architecture décrite par figure 5.14. Pour des raisons de coût de calcul et des restrictions de mémoire, les volumes d'entrées subissent un ensemble de transformation en phase de pré-traitement pour réduire leurs dimensionnalités. Ces transformations comprennent des étapes de recadrage et redimensionnement anisotropique. Évidemment, les volumes d'entrées ont différentes résolutions et sont hétérogènes en terme de taille. Ces étapes sont utiles pour normaliser la taille d'entrée des données de $(64 \times 64 \times 64)$. Ce pipeline repose sur le modèle SE-ResNext 101[180] (cf section 2.3.3). Le choix de l'architecture dépend des données disponibles et de la complexité de la tâche. Dans notre cas, comme c'est le cas pour différents défis d'imagerie médicale, les données sont rares. La tâche est cependant complexe car nous recherchons des caractéristiques qui permettent de distinguer les artères coronaires des autres structures tubulaires intracardiaques. Pour cela, nous optons pour une architecture qui offre plus d'interdépendances entre les cartes de caractéristiques et fournit une représentation plus complexe des couches profondes.

Ce modèle a été entraîné avec une taille d'entrée de $(64 \times 64 \times 64)$, des activations ReLu au niveau des couches de convolutions, une activation Sigmoid au niveau de la couche finale, Adam comme optimiseur avec un taux d'apprentissage de 0,01 et un déclin d'apprentissage de 0,1.

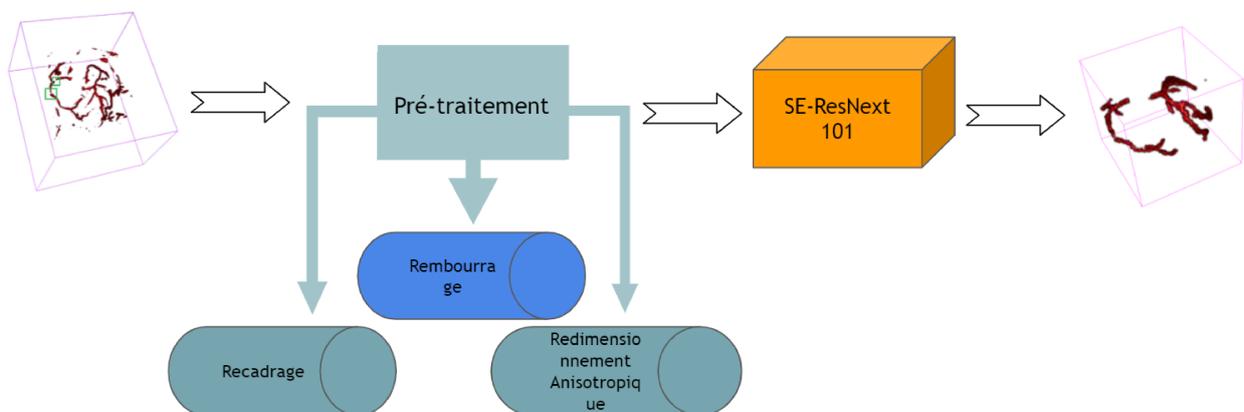


FIGURE 5.14 – Pipeline complet de l'architecture proposé pour l'analyse intelligente des composants connectés.

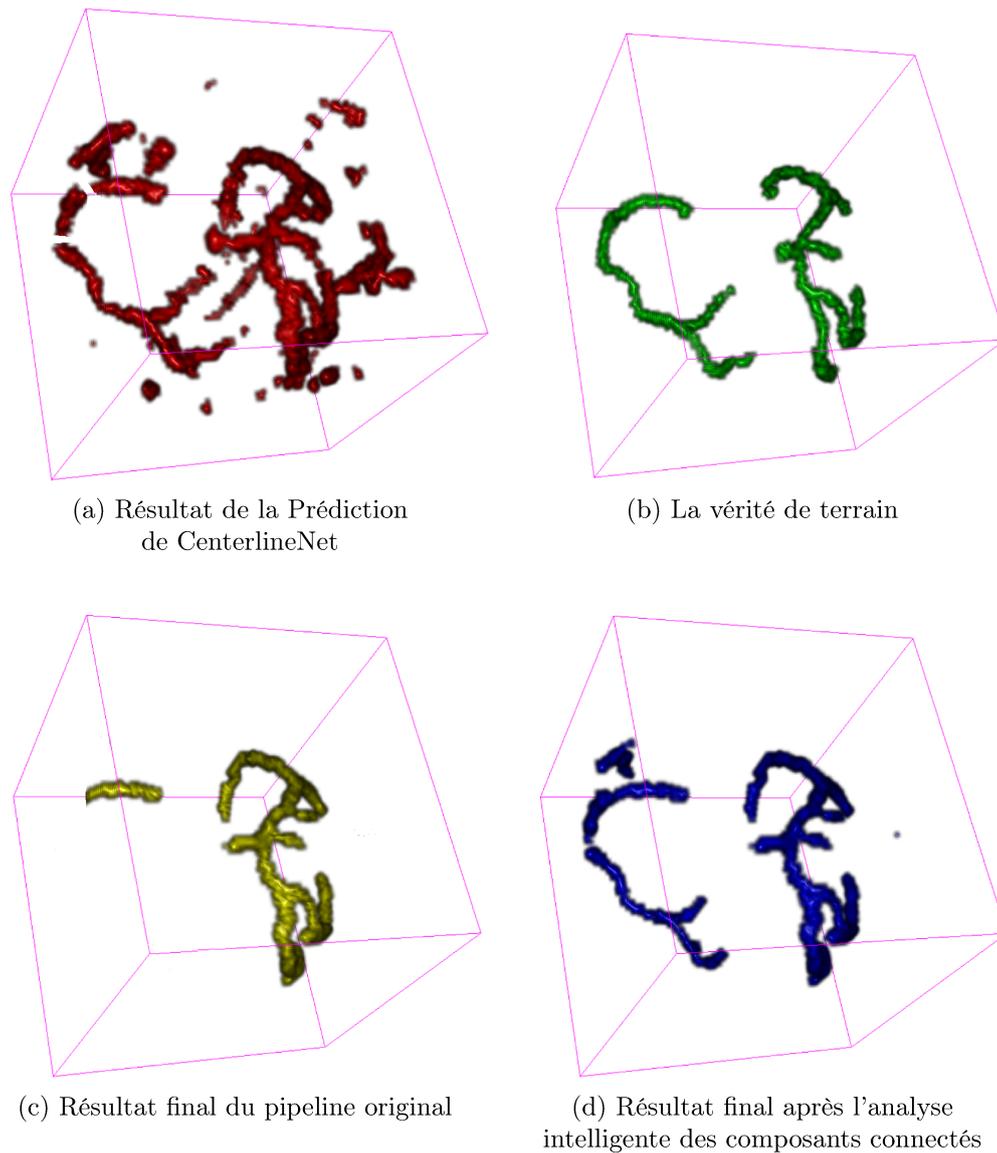


FIGURE 5.15 – La perte d'un sous arbre complet (la partie droite de l'arbre coronaire) à cause des interruptions est récupéré grâce à l'analyse intelligente des composants connectés (Les artères sont épaissies pour des raisons d'affichage).

TABLE 5.4 – Comparaison des résultats de l'approche de l'analyse classique de composants connectés avec celle du module intelligent à l'issu des prédictions intracardiaques du modèle CenterlineNet. L'évaluation est faite sur 8 patients qui appartiennent à la base de données de CHU Poitiers en utilisant les métriques : sensibilité (rappel), valeur prédictive positive, précision (accuracy) et la similarité de Dice

Approche	Sensibilité	Spécificité	Précision	Similarité de Dice
Ancienne	48.4%	81.5%	64.95%	60.73%
<i>Analyse Intelligente</i>	85.75%	83.22%	84.48%	84.46%

Résultats et Discussion

L'approche proposée fonctionne bien mieux que la précédente comme indiqué dans la figure 5.15. Nous pouvons finalement reconnaître les artères qui font partie de l'arbre artériel. Même

si la prédiction (figure 5.15a) présente plus qu'une seule interruption, le module proposé (cf figure 5.15d) garde la continuité de cet arbre en se débarrassant aussi des prédictions bruitées dans son chemin. Il fonctionne bien aussi dans des conditions favorables, en reconstruisant correctement l'arbre artériel, que dans des conditions défavorables où de nombreuses interruptions peuvent intervenir en isolant l'artère des autres structures.

Comme mentionné précédemment, la base de données du CHU Poitiers souffre le plus des petites ruptures de prédiction de CenterlineNet. La table 5.4 met en évidence ces problèmes. Avec l'analyse classique en composantes connectées, la perte est significative (48.4%), en particulier pour la sensibilité qui est la mesure la plus cruciale dans cette analyse. Nous avons besoin de l'arbre artériel complet pour détecter correctement une sténose par la suite. La valeur prédictive positive n'est pas très expressive car, en général, les experts métier se contentent de segmenter les artères principales seulement, ce qui rend cette métrique peu appropriée à notre cas. Mais l'augmentation de cette valeur de 81,5% à 83,22% prouve que le modèle élimine également les structures qui se collent parfois à l'arbre artériel et dont il était impossible de se débarrasser auparavant. Néanmoins, le plus grand succès reste la récupération des bouts d'artères correctement prédits initialement. Le passage de 48.4% à 85.75% résume à la fois, l'inaptitude de l'approche précédente de l'analyse classique des composants connectés pour la base de données de CHU et l'apport de l'analyse intelligente des composants connectés.

5.5 Conclusion

Avant de commencer à traiter les problématiques liées à la détection de la sténose à partir des images CT, nous avons abordé dans ce chapitre une étape essentielle, l'extraction des artères coronaire. Dans une première partie, nous avons présenté les principales méthodes utilisées dans l'état de l'art et expliqué pourquoi elles n'étaient pas adaptées, notamment l'extraction manuelle des caractéristiques et la détections des branches principales de l'arbre artériel seulement.

Nous avons ensuite proposé d'utiliser l'apprentissage profond pour notre approche. Même si ce modèle, CenterlineNet, est aidé par des algorithmes de pré et post-traitement aussi. En

revanche, sa contribution principale réside dans sa capacité à extraire les caractéristiques discriminatives pour filtrer localement les artères. Ce filtre jouit des différentes caractéristiques géométriques et analytiques fourni par une cascade de couches de convolutions.

Tout d'abord, nous avons prévu une étape de prétraitement pour normaliser les données et améliorer les structures cibles avec des filtres utilisés dans l'état de l'art et principalement le filtre de Frangi [98]. Nous voulons que notre modèle CenterlineNet ait accès à l'aspect analytique des filtres tubulaires classiques de sorte que sa carte de caractéristiques soit plus appropriée pour les artères coronaires que pour les formes cylindriques générales.

Nous avons testé les performances de CenterlineNet sur la base de données de Rotterdam. Nous étions principalement intéressés par son taux de récupération (sensibilité). Malgré un apprentissage bruité, l'annotation provenant d'un algorithme offrant simplement les artères principales [105], CenterlineNet arrive à extraire plus de 95% de l'arbre artériel principal et les branches secondaires également. Deux limites sont à noter pour notre méthode. Tout d'abord, nous récupérons toutes les artères du volume CT et non seulement les artères coronaires. Ensuite, de nombreuses portions d'artères sont manquantes, ce qui est préjudiciable pour la détection de sténose.

Nous avons présenté une solution pour la première limitation basée sur la définition biologique de l'arbre artériel. En utilisant une segmentation CNN 2D de la région cardiaque et de l'aorte ascendante, nous avons pu déterminer l'origine et l'étendue de la structure cible. La superposition des résultats avec la prédiction CenterlineNet permet de récupérer l'ensemble de l'arbre artériel. Nous avons montré que cette approche est assez robuste et donne d'excellents résultats sur une base de données diversifiée et difficile, à savoir la base de données Rotterdam.

Suite à cette étude préliminaire, nous avons constaté que l'extraction de la région cardiaque ainsi que de l'aorte ascendante n'était qu'une étape essentielle pour la réussite de l'extraction des artères coronaires. Celle-ci n'apporte aucun bénéfice à la réalité clinique. Ceci est en contraste avec les principes partagés au cours de cette thèse, qui sont principalement basés sur la valeur ajoutée au contexte clinique. Nous avons donc fait évoluer ce module pour y inclure une segmentation des sept sous-structures du cœur. Outre la complémentarité qu'il apporte à

ce pipeline, il peut être utilisé séparément pour des tâches de mesure des pathologies de ces structures.

La migration de ce pipeline vers la base de données de CHU Poitiers a révélé des défauts majeurs dans notre approche et principalement sur la partie de l'analyse des composants connectés. CenterlineNet excelle toujours dans l'extraction des artères mais, les interruptions sont fréquentes. Un module de récupération des bouts d'artère manquants devient une nécessité et la deuxième limite de ce pipeline est alors adressée. Nous avons proposé un troisième module basé sur l'apprentissage profond dans notre pipeline qui remplace l'analyse classique des composants connectés par une analyse intelligente. Il est capable d'isoler les artères coronaires même dans la présence des prédictions bruitées et des multiples interruptions et discontinuités.

Dans ce chapitre, nous avons implémenté un pipeline pour l'extraction des lignes centrales des artères coronaires. Avec les multiples modules proposés, nous avons abordé les défis voisins liés à notre étude et fourni des solutions pour la segmentation des sous-structures cardiaques et le clustering des artères coronaires. Le résultat de ce pipeline devient maintenant le nouveau point de départ de l'approche de détection et de catégorisation des sténoses.

Chapitre 6

La détection de la sténose et la classification des plaques

6.1 Introduction

Après avoir effectué avec succès l'extraction de l'arbre artériel dans le chapitre précédent, nous nous concentrons maintenant sur l'un des défis majeurs de la thèse qui est la détection automatique des causes de la maladie coronarienne pour la prévention des risques cardiovasculaires. La crise cardiaque et l'angine de poitrine sont les deux principales conséquences de la maladie coronarienne. Leur cause principale est la formation de l'athérosclérose. Il s'agit de l'accumulation progressive de cholestérol, de graisse, de calcium et de tissu fibreux, appelée aussi plaque, sur la paroi interne des artères coronaires, généralement sur plusieurs décennies. Dans un premier temps, la paroi du vaisseau s'élargit pour inclure la présence de la plaque (dilatation du vaisseau), tout en gardant une section transversale de taille normale (garde la forme tubulaire). L'athérosclérose est une maladie chronique qui reste asymptomatique pendant des décennies jusqu'à ce qu'un rétrécissement, également appelé sténose, limite la circulation du sang riche en oxygène vers les organes. Ce rétrécissement de l'artère se manifeste généralement par des irrégularités des vaisseaux sanguins visibles généralement sur une angiographie par tomodensitométrie (CTA). Lorsque la sténose est suffisamment grave, elle peut avoir des conséquences sur

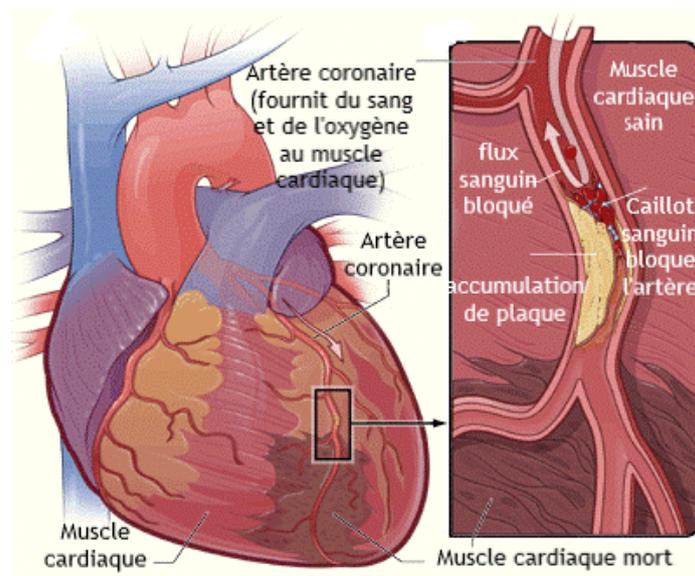


FIGURE 6.1 – La maladie des artères coronaires. La figure est adaptée de [125]

l'apport sanguin à la partie du muscle cardiaque concernée, entraînant une douleur thoracique intense due à l'ischémie (un manque de sang, donc un manque d'apport en oxygène). C'est ce qu'on appelle l'angine de poitrine.

D'un point de vue quantitatif, une sténose est considérée comme significative si le rétrécissement obstrue plus de 70% du diamètre de l'artère et non significative en dessous de 50%. Pour les cas intermédiaires, un diagnostic et des informations supplémentaires sont nécessaires pour quantifier l'impact de la sténose. À un stade plus sévère, les plaques peuvent devenir instables, se rompre et favoriser en outre la formation d'un thrombus (caillot de sang) qui obstrue l'artère. Si un thrombus bouche complètement une artère, toute une partie du myocarde est privée de toute ressource, cela conduit à un infarctus du myocarde, connu sous le nom de crise cardiaque (cf figure 6.1). Les cellules cardiaques non irriguées finissent par mourir si le flux sanguin n'est pas rétabli suffisamment tôt, créant des cicatrices de collagène dans le muscle qui peuvent induire des complications cliniques graves mettant en danger la vie du patient. Ce chapitre 6 se consacre à la description de nos recherches sur le thème de l'aide au diagnostic pour la prévention des risques cardiovasculaires. La section suivante 6.2 présente un résumé de la partie 3.3 de l'état de l'art. À l'issue de l'analyse de la littérature, nous concluons que tirer profit de l'excellente extraction des artères coronaires peut simplifier davantage la représentation des vaisseaux sanguins. Par conséquent, nous proposons d'appliquer la transformation cMPR pour

aligner ces structures (sec 6.3). Puis, nous mettons en œuvre un pipeline complet qui permet à la fois de détecter la sténose (sec 6.4) et d'identifier le type des plaques détectées (sec 6.5).

6.2 État de l'art

Les lésions sont des anomalies à structures et représentations assez complexes. Nombreux sont les travaux qui ont été consacré à l'étude de leurs caractéristiques et attributs. Comme nous avons discuté dans la section 3.3, l'ambiguïté et le manque de descripteurs propres à ces lésions, ont poussé les chercheurs vers de multiples approches dans le but de bien les caractériser.

Une famille d'approches [142, 141, 128, 129, 130] est basée sur la définition biologique de la sténose, "un rétrécissement du diamètre de l'artère", pour proposer une méthodologie basé sur les étapes suivantes :

1. construire un modèle idéal d'un vaisseau sain ;
2. faire la segmentation de l'artère en question ;
3. comparer l'évolution du diamètre de l'artère réel au diamètre du profil idéal ;
4. identifier un seuil de rétrécissement au dessus duquel une lésion est signalée.

Dès le premier aperçu de ces étapes, nous pouvons directement identifier les défauts de ces méthodes. D'une part, la création d'un profil idéal d'un vaisseau sain est loin d'être trivial en raison de la complexité de la structure du vaisseau. D'autre part, le suivi de l'évolution du diamètre de l'artère est une source de fausses détections. En effet, le diamètre du vaisseau subit des diminutions brusques au niveau des bifurcations ou en distale sans que cela soit identifié comme une lésion dans la réalité clinique.

Une partie de ces approches [131, 132, 133, 134, 135] remplace la construction d'un profil idéal par la sélection d'une région saine de l'artère et le calcul du "diamètre attendu" à partir de là. Encore une fois, le choix de cette région est problématique et peut induire des fausses détections si on tombe sur une zone malsaine ou anormale. Certaines méthodes se sont orientées vers l'identification semi- automatique de la région saine grâce à l'interactivité avec les experts médicaux

Pour la classification des plaques, cette famille d'approches repose encore sur un principe simple : une fois la lésion détectée, on extrait la zone de rétrécissement (la région entre le diamètre attendu et le diamètre réel). L'extraction de cette zone permet la classification de la nature des plaques (douce, calcifiée ou mixte). Cependant, pour des raisons liées à la précision de la segmentation, cette tâche est assez compliquée. En effet, la délimitation de ces deux surfaces en question doit être suffisamment précise, ce qui constitue un problème en soi, en raison de la résolution limitée du scanner par rapport à la taille des plaques.

Une deuxième famille d'approches s'est plutôt intéressée à la caractérisation des lésions. Les plaques sont généralement identifiées par leur apparence géométrique spécifique correspondant à une zone brillante autour de l'artère dû à la formation des calcifications. Les premiers travaux [126, 127, 136, 137, 149] ont proposés d'effectuer un seuillage manuel ou semi-automatique sur les valeurs d'intensité des scans CT dans des régions d'intérêt prédéfinies. Malheureusement, Les lésions sont des structures assez complexes et requièrent plus de descripteurs afin de décrire leur structures. C'est dans ce cadre que les chercheurs se sont intéressés à l'identification d'un ensemble des caractéristiques autres que l'intensité et le volume des plaques [152, 140, 146, 145, 143, 144, 139, 150]. Avec l'utilisation de l'apprentissage machine, il est devenu plus simple de combiner multiples mesures et descripteurs dont : circularité, excentricité, la présence et l'étendue des artefacts, les caractéristiques locales de type Haar, l'entropie, la variance et les gradients d'intensité et bien d'autres.

Les résultats prometteurs de ces méthodes ont démontré que les lésions sont bel et bien descriptibles par des caractéristiques de niveau bas et intermédiaire. Mais, ces caractéristiques restent un ensemble fini de descripteurs manuellement choisi, ce qui limite les méthodes susmentionnées.

Nous savons que les récentes méthodes basées sur l'apprentissage profond permettent d'obtenir de très bonnes performances pour l'extraction des caractéristiques automatiques et de haut niveau est celle de l'apprentissage profond. Sa première utilisation, à notre connaissance, pour la détection de la sténose est récente. En effet, Zreik et al [153] ont démontré en 2018 qu'un réseau de neurones convolutif récurrent multi-tâches (RCNN) parvient à obtenir des performances faisant référence dans l'état de l'art. Leur réseau effectue deux tâches de classification

simultanément pour la détection de la sténose et la classification des plaques. Comme entrée, Zreik et al fournissent à leur modèle des images reconstruites des vaisseaux par la cMPR. En fait, à notre connaissance, toutes les méthodes qui utilisent l'apprentissage profond réalisent la reconstruction cMPR au préalable. La méthode de Zreik et al souffre de deux limitations :

- due à son architecture complexe, l'apprentissage de cette méthode sur un jeu de données limité (c'est le cas pour la plupart des problématiques de l'imagerie médicale) est quasi impossible ;
- à cause de la double classification en sortie, le modèle prédit des scénarios physiologiquement impossible (par exemple : pas de sténose comme résultat de la première tâche, plaque calcifiée comme résultat de la seconde).

Tejero de Pablos et al [154] ont proposé l'utilisation d'un CNN, des vecteurs de Fisher et des classifieurs SVM pour la détection de la sténose uniquement. Ce travail est plus approprié aux jeux de données de taille réduite. Tejero de pablos et al ont utilisé un ensemble de six projections différentes du volume cMPR d'un segment. Ce nombre de projections a été réduit par Denzinger et al [156] qui ont démontré qu'un réseau CNN 2.5D à deux projections uniquement parvient à surpasser les performances de [154]. Finalement, dans leur dernier travail, Denzinger et al [159] ont présenté la première approche permettant de prédire directement le score CAD-RADS en six classes à l'aide d'un algorithme basé sur l'apprentissage profond. L'ensemble des segments des artères coronaires est découpé en 17 segments selon la norme AHA (American Heart Association) et reconstruit à l'aide de la cMPR . Leur extracteur de caractéristiques utilisé est le CNN 2.5D présenté dans [156].

Comme nous pouvons le constater, en se basant uniquement sur la représentation 2,5D, il est facile d'omettre certaines informations 3D qui peuvent être pertinentes. De plus, toutes ces méthodes qui utilisent l'apprentissage profond sont fortement dépendantes d'une excellente extraction des artères et d'une reconstruction cMPR correcte. Néanmoins, aucune de ces méthodes ne propose un algorithme de vérification et de correction des artères mal reconstruites.

Dans notre travail, nous proposons deux modèles séparés pour la détection de la sténose et la classification des plaques. Cette séparation est largement motivée par l'importance de l'interprétation biologique des résultats. Le modèle de la classification n'agit que sur les lésions

détectées par le modèle de l'identification de la sténose. De plus, nous proposons deux architectures 3D ce qui permet d'exploiter toutes les informations et corrélations spatiales. Finalement, pour le modèle de la détection de la sténose, nous introduisons un algorithme de pré-traitement pour la correction des artères mal reconstruites (problème de placement des points de la ligne centrale). Ainsi, nous améliorons la robustesse et la fiabilité des prédictions.

6.3 Reconstruction de l'arbre coronaire extrait

L'utilisation de la projection à intensité maximale (MIP) permet d'obtenir une vue plus complète de l'ensemble du volume du vaisseau. MIP est une technique de projection, selon laquelle seul le pixel de plus haute valeur dans la direction de la projection est représenté pour reconstruire les images bidimensionnelles. L'image MIP permet de différencier les structures vasculaires des structures non vasculaires comme indiqué dans la figure 6.2, car le résultat est une projection de la plus haute intensité. Cette technique est largement utilisée car elle fournit une vue globale du vaisseau avec une interaction minimale de l'utilisateur. Cependant, l'un des principaux inconvénients de l'utilisation de ce type d'affichage est la perte d'informations sur la dimension de profondeur et également le manque de détails sur la section transversale du vaisseau qui sont pertinents pour l'analyse de la sténose. En outre, la qualité de l'interprétation dépend du nombre de sections à projeter. Par exemple, une valeur élevée de ce paramètre peut conduire à la dissimulation de certaines sténoses car elles seront masquées par des structures adjacentes plus brillantes. A l'inverse, le choix d'une valeur faible peut empêcher l'utilisateur de visualiser des calcifications importantes. Ainsi, la MIP doit être utilisée en complément d'autres techniques de visualisation pour assurer une meilleure analyse du vaisseau. Les techniques de visualisation basiques ne peuvent pas être utilisées seules pour l'analyse des artères coronaires car elles ne sont pas en capacité d'offrir une vision complète de la structure vasculaire complexe. Des méthodes de reconstruction avancées sont aujourd'hui disponibles grâce aux progrès réalisés dans le domaine des logiciels et du matériel, rendant possible des techniques de visualisation plus sophistiquées en temps réel. Les approches de visualisation (cMPR, rendu volumique direct, coupes transversales) sont des outils précieux pour une investigation rapide et fiable de la

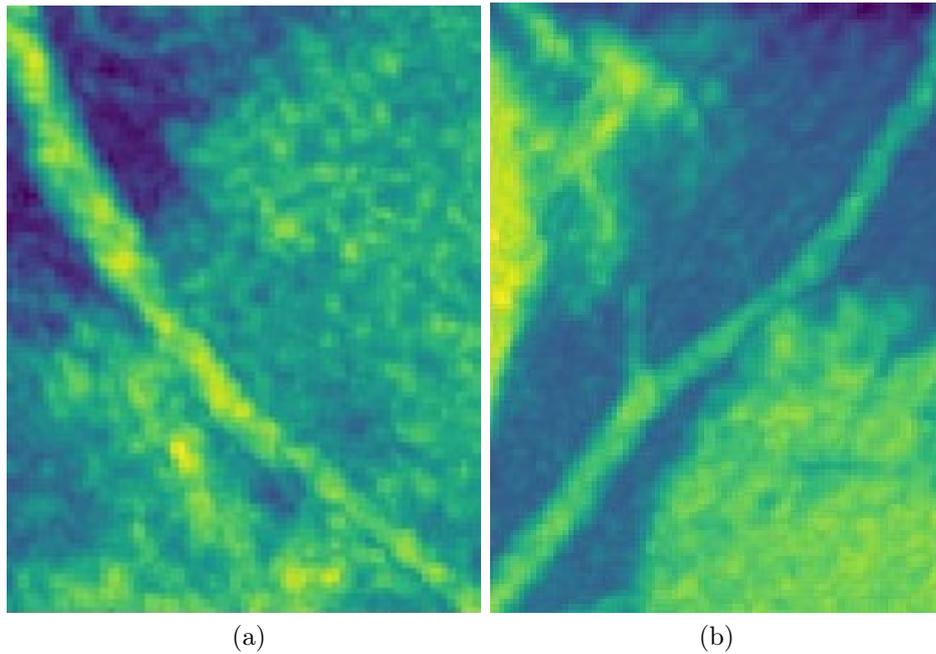


FIGURE 6.2 – Affichage de deux artères coronaires avec la projection à intensité maximale (MIP).

sténose. Néanmoins, étant donné le nombre croissant d'images CT à examiner par jour par les experts, mettre en place des outils plus automatisés aidera à économiser le temps et le coût du diagnostic. Par conséquent, tirant parti du potentiel de l'un des outils de reconstruction les plus performants, nous proposons une analyse de sténose par cMPR.

6.3.1 cMPR : reformatage multiplanaire incurvé

Dans la réalité clinique, la visualisation des structures de petit diamètre se fait à l'aide de reformatage multiplanaire (MPR). Ce processus permet de ré-échantillonner et de visualiser l'ensemble des données en fonction des informations de haut niveau obtenues via la détection de la ligne centrale des structures cibles. Cette technique permet d'afficher toute la longueur de la structure tubulaire dans une seule image. L'expert peut alors faire tourner le vaisseau sur son axe longitudinal permettant de visualiser tout le volume du vaisseau. De plus, il peut parcourir la séquence de coupes transversales de l'artère (vues coronaires transaxiales), ce qui lui permet une visualisation précise du vaisseau ainsi que de la plaque d'athérosclérose. Généralement, l'expert dispose d'un ensemble d'outils pour délimiter manuellement la plaque et quantifier la

sténose sur un ensemble de vues. Dans la figure 6.3, nous pouvons identifier trois types de vues MPR : MPR projetée, MPR étirée et MPR alignée (cMPR).

La MPR projetée peut être vue comme une MIP, donc une projection d'un ensemble de données selon un vecteur d'intérêt colinéaire avec les vecteurs de base (x, y, z) . Un inconvénient de cette méthode qui se rajoute à ceux de la MIP est la distorsion de la longueur de l'axe central des artères coronaires due à cette projection parallèle. Par conséquent, l'isométrie des structures n'est pas conservée. La MPR étirée, par contre, préserve l'isométrie. C'est une transformation qui permet de suivre l'évolution d'une structure selon son axe "incurvé". La projection permet ainsi d'obtenir l'artère coronaire étirée dans un seul plan comme indiqué dans la figure 6.3b.

Le troisième type du MPR est le plus intéressant pour notre étude. La MPR alignée crée non seulement un ensemble des coupes transversales de chaque segment artériel coronaire mais génère une représentation linéaire du vaisseau. Toutes les autres structures avoisinantes qui sont à une distance près de la ligne centrale sont automatiquement éliminées. Cette méthode permet de réduire les problèmes de tortuosité et de chevauchement observés avec d'autres méthodes de reconstruction. Comme indiqué précédemment dans la section 3.3, la sténose est définie comme un rétrécissement d'artère. Par conséquent, l'un des moyens les plus pertinents pour la détection de la sténose est le suivi de l'évolution du diamètre de l'artère coronaire. L'avantage le plus pertinent qu'offre la cMPR est une représentation où la seule variable de l'image résultante est le diamètre. La figure 6.4 permet une visualisation plus claire de l'importance de la cMPR. L'image résultante est plus simple à interpréter que la structure complexe des artères. Par

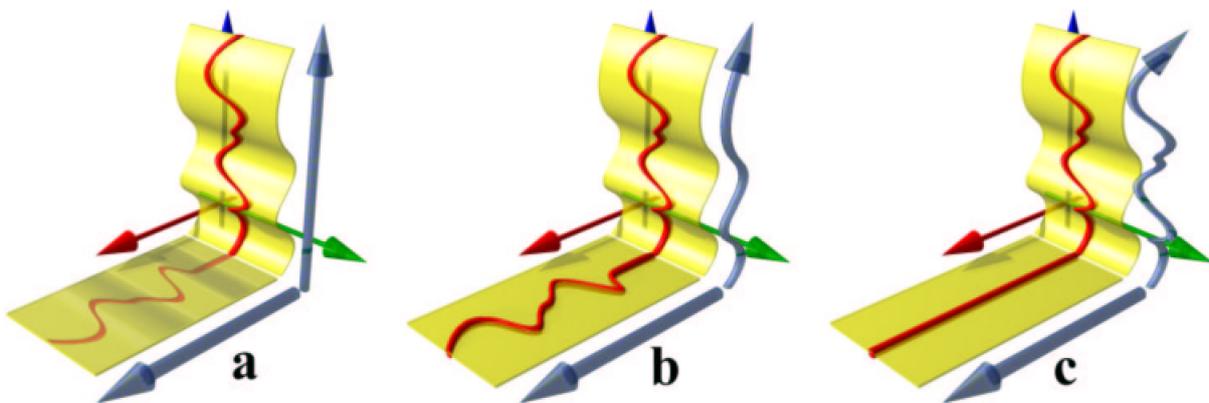


FIGURE 6.3 – Différentes méthodes de génération de MPR : a) MPR projetée, b) MPR étirée, c) MPR aligné. La figure est adaptée de [147]

contre, l'inconvénient le plus apparent de cette méthode est la nécessité de faire une analyse par segment d'artère. Nous ne pouvons plus traiter l'arbre coronaire comme une entité mais nous devons le découper en sous-segments. Cet inconvénient est plutôt un avantage dans notre cas. Dans la réalité clinique, les experts fournissent les résultats de leur diagnostic sous forme d'un bilan qui contient les analyses individuelles de chaque segment.

Dans les sous-sections suivantes, nous décrivons les étapes d'implémentation de la cMPR ainsi que les résultats obtenus sur la base de données du CHU Poitiers.

6.3.2 Implémentation du cMPR

Pour créer une cMPR, il faut suivre l'évolution de l'artère et extraire chaque section transversale perpendiculairement à son vecteur d'orientation (vecteur directeur). Deux méthodes peuvent être utilisées pour atteindre cet objectif qui sont les rotations successives à l'aide des angles d'Euler et les changements de référentiels à l'aide des matrices de passage. Au début, nous favorisons la méthodes des rotations successives. Notre idée se reposait sur trois étapes :

- premièrement, réorienter le vecteur normal dans la direction de l'un des axes principaux en utilisant une rotation 3D ;
- deuxièmement, utiliser une rotation le long d'un axe personnalisé avec un angle de rotation

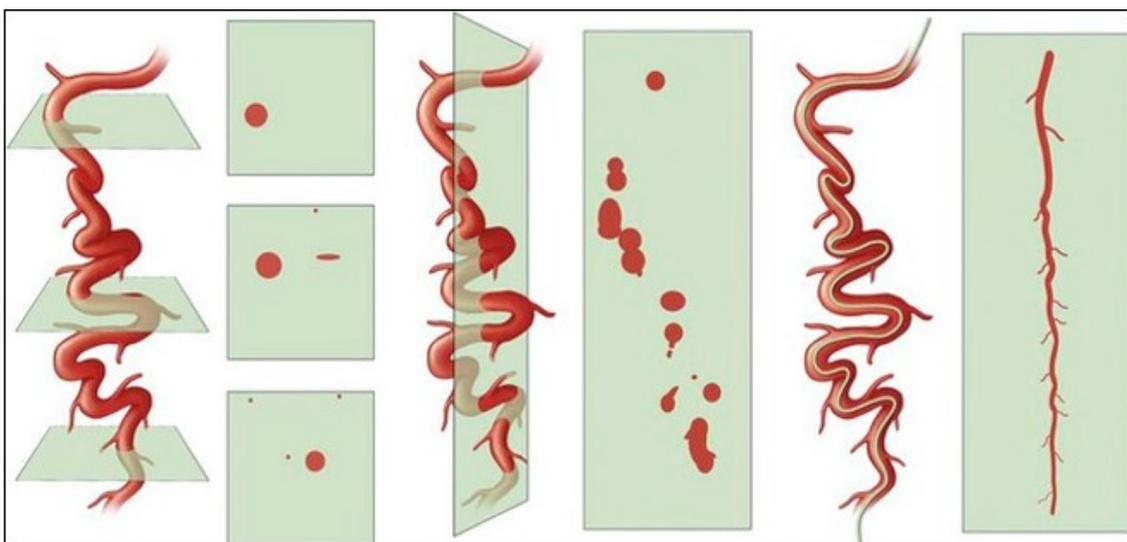


FIGURE 6.4 – L'idée générale de cMPR : alignement des structures contournés. La figure est adaptée de [181]

personnalisée ;

— troisièmement, créer la matrice de rotation 3D.

Le problème de cette approche est que les rotations successives sont très sensibles à l'inexactitude des calculs. L'imprécision des estimations rend l'utilisation des angles d'Euler pratiquement impossible. Par conséquent, nous avons opté pour l'approche utilisant les matrices de passage. Cette méthode se base sur le vecteur normal de la section transversale à traiter. Ce vecteur normal \vec{n} est facilement obtenu à partir de deux points de la ligne centrale de l'artère. Soient p_{i-1} , p_i et p_{i+1} trois points successifs appartenant à la ligne centrale. Le vecteur normal \vec{n} est donné par :

$$\vec{u} = \frac{\overrightarrow{p_{i-1}p_{i+1}}}{\|\overrightarrow{p_{i-1}p_{i+1}}\|} \quad (6.1)$$

Pour obtenir la section transversale au point p_i , il est nécessaire de calculer le plan perpendiculaire à \vec{n} et passant par p_i à l'aide de l'équation suivante :

$$ax + bx + cz + d = 0 \quad (6.2)$$

avec a,b et c sont les composantes du vecteur normal à ce plan \vec{u} . A partir de là, l'identification de deux vecteurs perpendiculaires à \vec{u} est faite. Le premier vecteur \vec{u}_1 appartient au plan de la section transversale tandis que le deuxième vecteur \vec{u}_2 est perpendiculaire à \vec{u} et \vec{u}_1 à la fois en utilisant l'équation ci dessous.

$$\vec{u}_2 = \vec{n} \wedge \vec{u}_1 \quad (6.3)$$

avec \wedge , l'opérateur du produit vectoriel. Ainsi, la matrice de passage M de la base $B1 = (\vec{i}, \vec{j}, \vec{k})$ à la base $B2 = (\vec{n}, \vec{u}_1, \vec{u}_2)$ est donnée par

$$M = (nu_1u_2) \quad (6.4)$$

Finalement, les coordonnées du point p appartenant à la section transversale sont récupérées via l'équation suivante :

$$p^{B2} = {}^t M(p^{B1} - p_i^{B1}) \quad (6.5)$$

où p^{B2} sont les coordonnées dans la nouvelle base de la section transversale, p^{B1} les coordonnées

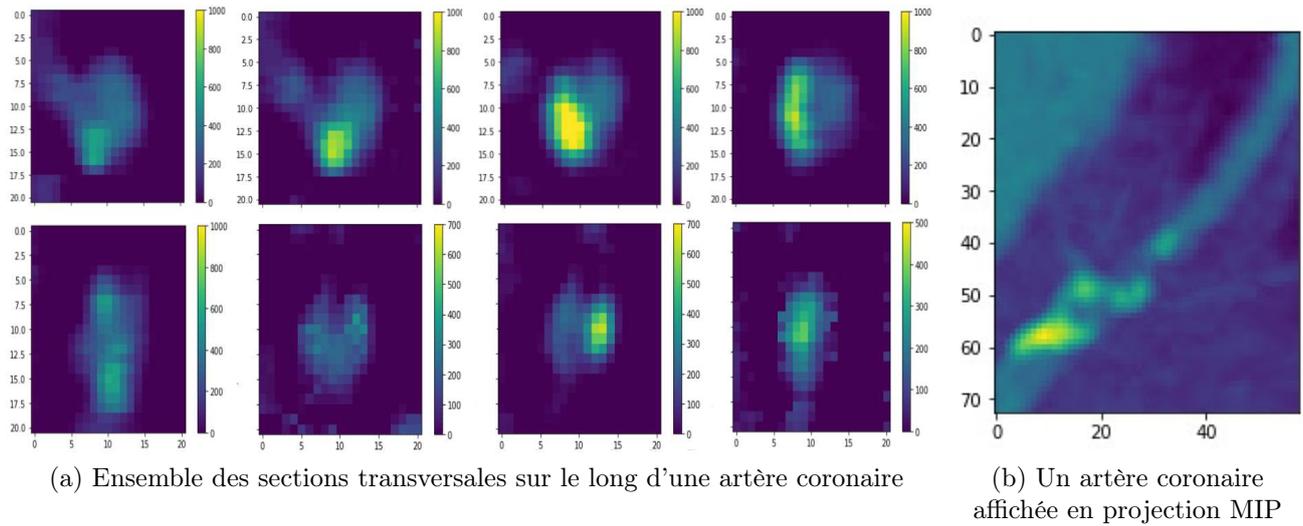


FIGURE 6.5 – Extraction des sections transversales d'une artère coronaire à l'aide de cMPR.

dans la base d'origine et p_i^{B1} les coordonnées du centre du nouveau repère dans la base d'origine. Ces coordonnées sont exprimées dans la base $B2$ donc pour obtenir la projection le long du vecteur normal, il suffit d'éliminer la première coordonnée.

6.3.3 Résultats de la cMPR sur la base de données de CHU Poitiers

Nous consacrons cette sous section à l'analyse visuelle de la reconstruction cMPR que nous venons de développer. Le premier test réalisé permet de valider l'extraction correcte de la section transversale de chaque point appartenant à la ligne centrale d'un artère coronaire. Pour cela, nous proposons d'étudier l'exemple affiché par la figure 6.5. L'artère coronaire choisi est montré dans la figure 6.6b. Il présente une sténose sévère (occlusion de 60 à 80% du diamètre total) dans sa partie proximale. Nous pouvons aussi voir que l'évolution de cette artère se fait selon un axe distinct différent de ceux qui représentent la base $B1$. Après avoir effectué la reconstruction cMPR, nous évaluons la capacité de l'extraction des sections transversales de cette artère montrée dans la figure 6.5a. Clairement, nous pouvons d'abord confirmer la forme circulaire des sections dans les images résultantes ce qui est en concordance avec nos connaissances. Aussi, nous pouvons affirmer que cette reconstruction préserve la distribution des valeurs de voxels puisque les calcifications sont assez brillants dans les images des sections que dans l'image de la MIP. Une fois le premier test validé, nous passons au deuxième test qui

est l'alignement de la structure résultante. La cMPR est extrêmement dépendant d'une bonne extraction de la ligne centrale des artères. La largeur de l'image résultante correspond au nombre de sections transversales reconstruites tandis que sa hauteur est définie par une fenêtre choisie par l'utilisateur (un hyperparamètre de la reconstruction). Dans notre cas, nous choisissons une fenêtre de 20 pixels (10 mm) qui est suffisante pour contenir les artères (diamètres de 2 à 6 mm en réalité). La cMPR peut alors, à l'inverse, être un indicateur de la robustesse de l'algorithme d'extraction de la ligne centrale. Ainsi, la figure 6.6 nous fournit le résultat de la cMPR sur l'artère précédemment choisie. Nous constatons l'alignement et l'homogénéité de l'image résultante. La reconstruction est extrêmement fidèle à l'image MIP (fig 6.6b) et la partie sténotique est bien plus mise en évidence. Pour évaluer davantage la qualité de la transformation, nous présentons dans la figure 6.7 différents exemples de reconstruction. Nous pouvons alors déduire que :

- le modèle de l'extraction des artères coronaires décrit dans le chapitre précédent est assez robuste même pour les données issues du CHU Poitiers,
- l'algorithme du cMPR détaillé dans cette section est capable de produire des structures isométriques et alignées.

Finalement, après une extraction des artères coronaires, nous proposons de reconstruire ces structures selon la forme la plus simple à analyser (linéaire). La cMPR permet de fournir une représentation moins complexe et ainsi nous offre une flexibilité dans les choix des modèles que

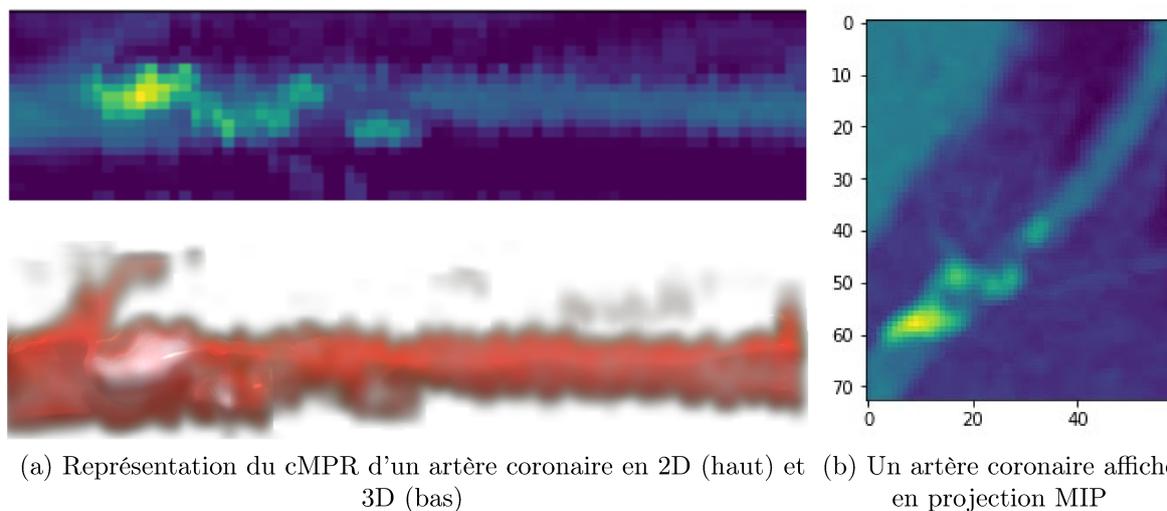


FIGURE 6.6 – La représentation cMPR d'un artère coronaire atteint d'une sténose sévère.

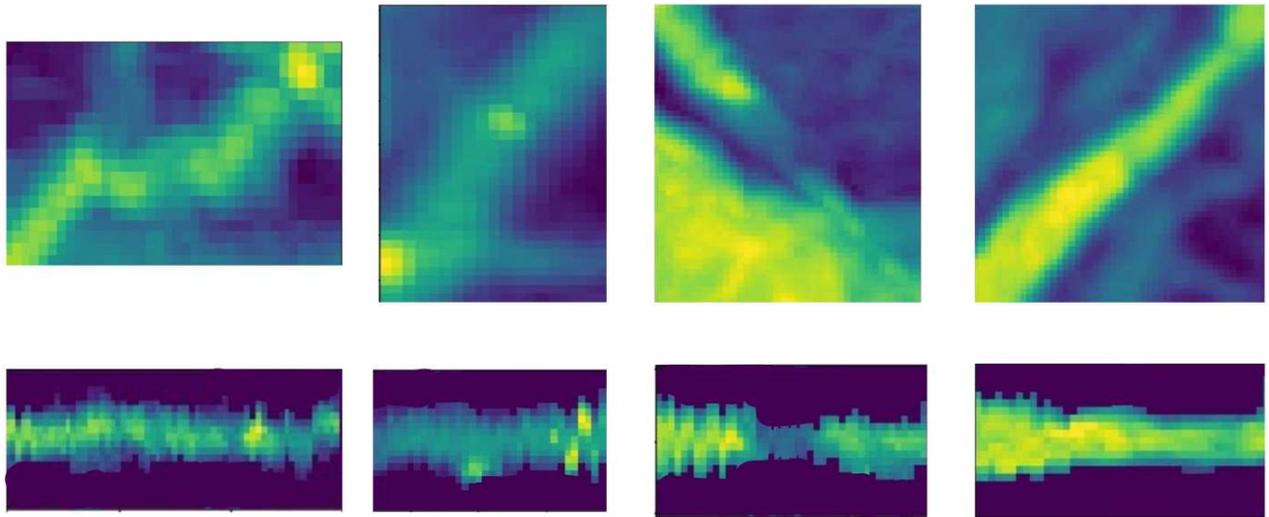


FIGURE 6.7 – Les Résultats de la transformation cMPR sur des artères coronaires. La première ligne affiche la reconstruction MIP alors que la deuxième montre les cMPR

nous mettrons en place.

Dans la section suivante, nous introduisons le pipeline complet de la détection de la sténose et la classification des plaques. Nous revenons à la description des architectures ainsi que les méthodes de pré et post-traitement qui assurent la robustesse des modèles. Nous discutons aussi les résultats obtenus sur la base de données de CHU Poitiers et nous offrons des propositions pour l'amélioration de la version actuelle du modèle.

6.4 Détection de la sténose

Dans cette section, nous proposons un pipeline complet pour la détection de la sténose à partir des volumes cMPR comme indiqué dans la figure 6.8. Nous introduisons un algorithme correctif des volumes cMPR comme pré-traitement pour l'élimination des structures adjacentes et le recalibrage des sections décalées. Nous introduisons un modèle d'apprentissage profond à double entrées qui permet de classifier ces entrées en trois classes : absence de sténose, sténose non significative et sténose significative. Nous détaillons les étapes de pré-traitement, l'architecture du modèle et les résultats dans les sous sections qui suivent.

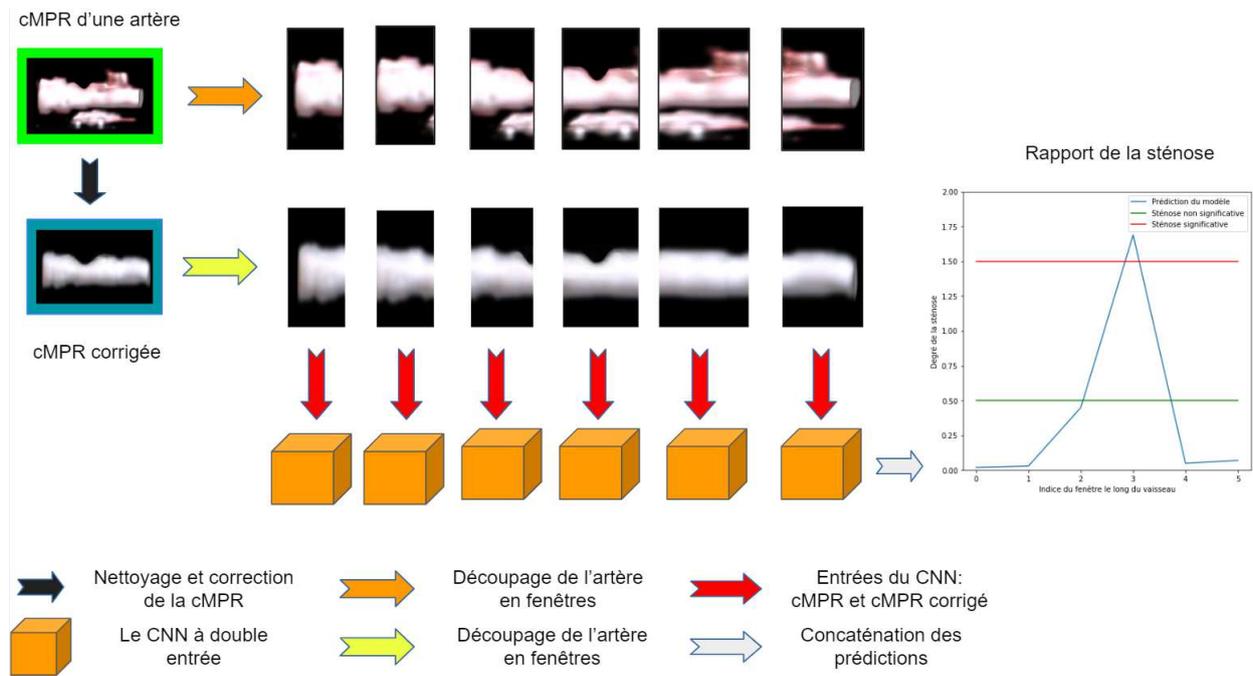


FIGURE 6.8 – Le pipeline de la détection de la sténose. L'artère est reconstruite par la cMPR puis elle est corrigée et améliorée. Le CNN prend deux entrées : un fenêtrage défini de l'artère reconstruite et l'artère corrigée. L'ensemble des prédictions sur ces patches forme le rapport de la sténose.

6.4.1 Pré-traitement

Après l'extraction des branches coronaires et la construction des volumes MPR, nous appliquons des techniques de pré-traitement aux volumes artériels afin d'augmenter les performances de classification et de localisation du système. Nous utilisons d'abord une technique de Min-Max qui restreint l'intensité dans une plage prédéterminée. Avec $I(x, y, z)$ représentant la valeur d'intensité du scanner à la position (x, y, z) , nous limitons les intensités du volume MPR comme suit :

$$I(x, y, z) = \begin{cases} 0 & \text{si } I(x, y, z) \leq 0 \\ I(x, y, z) & \text{si } 0 < I(x, y, z) < 900 \\ 900 & \text{si } I(x, y, z) \geq 900 \end{cases} \quad (6.6)$$

Cette plage de valeur est élargie par rapport à celle utilisée dans 5.3 parce que les calcifications font partie des structures cibles maintenant.

Les artères coronaires extraites ont des longueurs différentes et par conséquent leurs reconstructions cMPR ont des longueurs différentes. Les modèles d'apprentissage profond requièrent

des entrées de taille fixe. De ce fait, trois solutions se présentent :

- faire une interpolation pour homogénéiser la résolution d'entrée ;
- identifier l'artère la plus longue et effectuer du padding (ajouter des sections vides) pour les artères moins longues ;
- choisir une approche par fenêtrage en choisissant les dimensions de la fenêtre de manière à inclure une quantité suffisantes d'information pour discriminer les structures.

Étudions alors ces options. Premièrement, l'interpolation agit sur la structure des artères pour faire le redimensionnement. Or, la forme des bords du vaisseau est l'indice visuel le plus significatif de la sténose. De plus, le travail de Denzinger et al [156] a prouvé que l'interpolation avait un effet aléatoire sur les différentes architectures utilisées. Par exemple, elle a amélioré les performances de [153] et détérioré celles de [154]. De ce fait, nous n'opterons pas pour cette option.

La deuxième solution est celle du padding, ce qui résout les problèmes d'interpolation. Néanmoins, cette option a des effets néfastes sur les paramètres du modèle d'apprentissage ainsi que le processus d'apprentissage en total. Dans notre cas, l'artère la plus grande a une longueur de 247 pixels alors que l'artère la plus petite fait une longueur de 20 pixel (généralement cette artère est le tronc commun). La moyenne des longueurs des artères est d'environ 121 pixels. Donc, nous pouvons déduire que si nous optons pour cette solution, la majorité des données d'entrées sera à moitié nulle ou vide. Pour les zones dont les pixels sont nuls, le résultat de l'opération de convolution est nul. Il en va de même avec le max-pooling. De plus, nous pouvons prouver que les poids ne sont pas mis à jour après la rétropropagation si l'entrée associée à ces poids est nulle sous certaines fonctions d'activation (par exemple, relu, sigmoïde). Du coup, l'apprentissage n'est plus optimal et nous risquons de créer une carte de caractéristiques diluée. Nous n'opterons pas non plus pour cette solution.

Finalement, nous décidons de choisir une approche par fenêtrage qui n'agit pas sur les données d'entrée et garantit un apprentissage optimal de notre modèle. Dans la figure 6.9, nous pouvons constater le découpage d'une artère en multiple fenêtres. Nous avons choisi une largeur de fenêtre de 36 pixels après une série de tests. Cette largeur est la plus appropriée à l'architecture de notre CNN. Nous avons aussi opté pour un "stride" de 4. Donc, entre deux fenêtrages

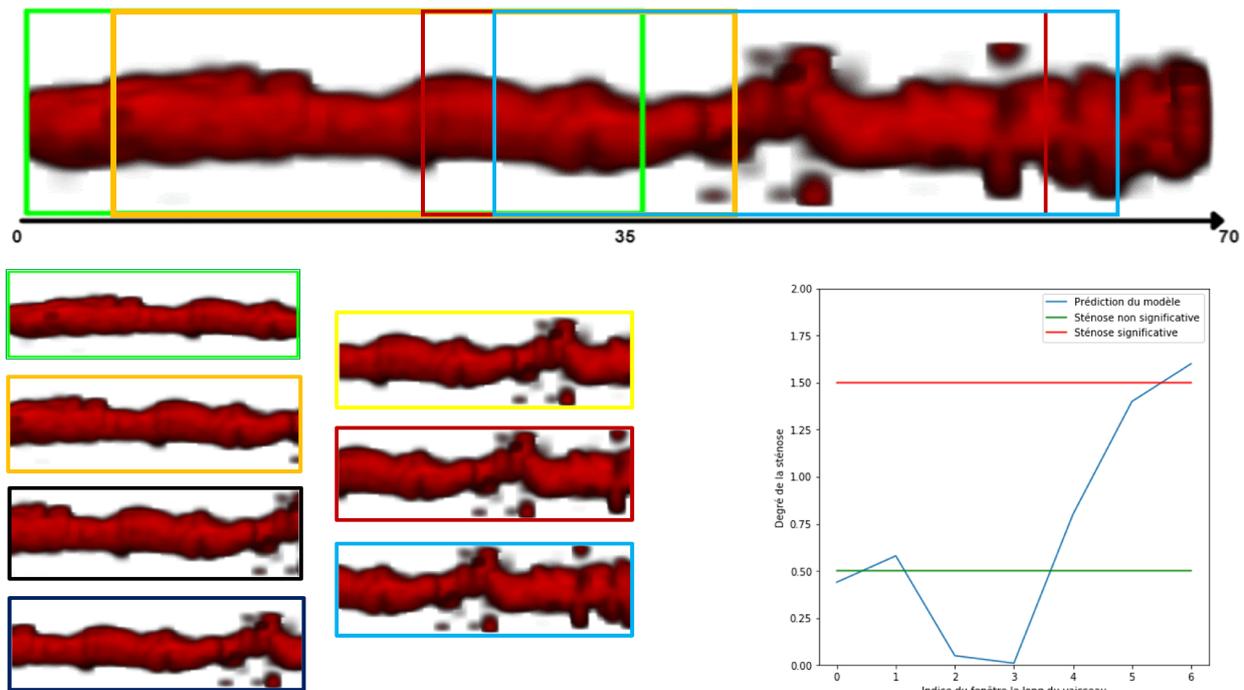


FIGURE 6.9 – Le déroulement de la détection des lésions : l'artère reconstruit par cMPR est traitée par une approche de fenêtrage. Chaque fenêtre est fournie au modèle de la détection de la sténose. La largeur de la fenêtre égale à 36 pixels. Le découpage se fait avec un stride de 4. Nous ne montrons que 4 fenêtres ici pour des fins de visualisation. Le résultat final du découpage est affiché en dessous de l'artère. Le modèle prédit une valeur réelle de 0 à 2 avec 0 : pas de sténose, 1 : sténose non significative et 2 : sténose significative.

successives, on saute de 4 positions.

Comme nous en avons discuté précédemment, les méthodes basées sur la cMPR sont très dépendantes d'une extraction précise des lignes centrales des artères. Nous avons remarqué que même les annotations des experts médicaux pouvaient ne pas être centrées. Ce décalage peut perturber la reconstruction cMPR. De plus, les artères peuvent être rattachées à des structures adjacentes (muscle cardiaque) comme indiqué dans la figure 6.10. Par conséquent, nous proposons un algorithme de pré-traitement qui permet de rectifier ces problèmes (figure 6.11). Cet algorithme est constitué de deux méthodes que ont été utilisés et validé dans la littérature (section 3.2) : le filtre de Frangi et la méthode de ligne de niveau. Nous rappelons que le filtre de Frangi est un bon détecteur de forme tubulaire. Après avoir effectué la cMPR, nous fournissons à ce filtre un volume dont la forme tubulaire est beaucoup plus simple à identifier que celle de CTA brut. En identifiant les artères dans cette forme, nous pouvons éliminer au maximum les structures adjacentes ainsi que les calcifications présente dans le cMPR. Nous

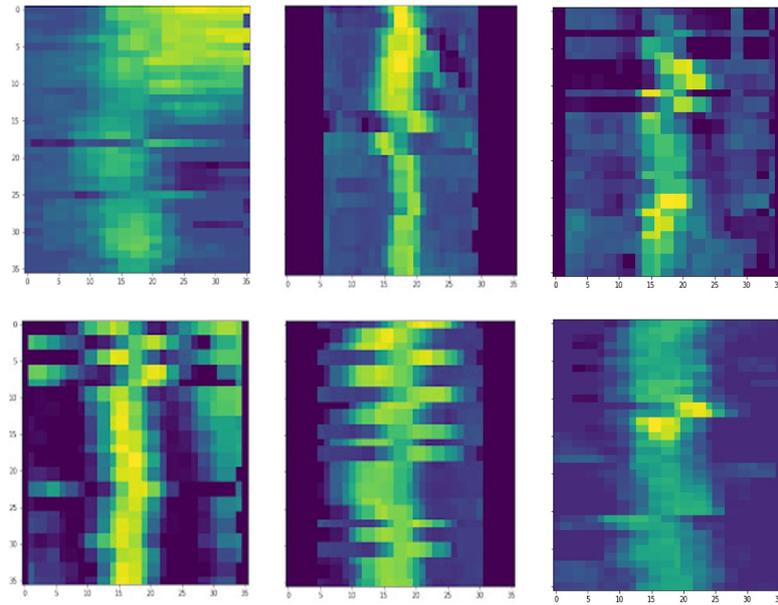


FIGURE 6.10 – Des exemples de la reconstruction cMPR avec des annotations imprécises.

voulons que la deuxième entrée de notre modèle joue le rôle d'une segmentation grossière de l'artère. Nous estimons qu'une délimitation approximative de la paroi de l'artère est suffisante pour aider le CNN à récupérer plus d'information sur l'évolution du vaisseau (nous favorisons la surestimation).

Pour délimiter la paroi, nous fournissons le résultat du filtrage à un algorithme de ligne de niveau. La méthode de ligne de niveau permet de faire évoluer une ligne au lieu d'un contour pour faire la segmentation. Elle est positive à l'intérieur, négative à l'extérieur et égale à zéro au niveau du contour. Nous nous sommes inspirés des recherches de Yang et al [182] qui utilise la combinaison du filtre de Frangi et la ligne de niveau pour obtenir une segmentation performante des vaisseaux de rétines. Comme le montre la figure 6.11, nous pouvons visiblement observer la distribution de la fonction de ligne de niveau qui améliore davantage la forme tubulaire du vaisseau et aide à l'élimination des structures à l'extérieur de la paroi de l'artère. Finalement, nous effectuons une normalisation Min-Max à la sortie de la transformation de la méthode de ligne de niveau pour réduire les valeurs dans l'intervalle $[\frac{M_{min}}{Max(|M_{min}|, M_{max})}, \frac{M_{max}}{Max(|M_{min}|, M_{max})}]$, avec M_{min} et M_{max} les deux bornes de l'intervalle de valeurs du volume transformé.

Finalement, nous multiplions cette carte de chaleur avec le volume initial et nous retenons que les valeurs positifs (à l'intérieur du vaisseau). La figure 6.12 montre le résultat de ce module de pré-traitement sur un long vaisseau. Comme nous pouvons le constater, les structures ad-

jaçantes sont éliminées et la paroi artérielle est intacte. Même si la segmentation est grossière, les performances du CNN seront améliorées.

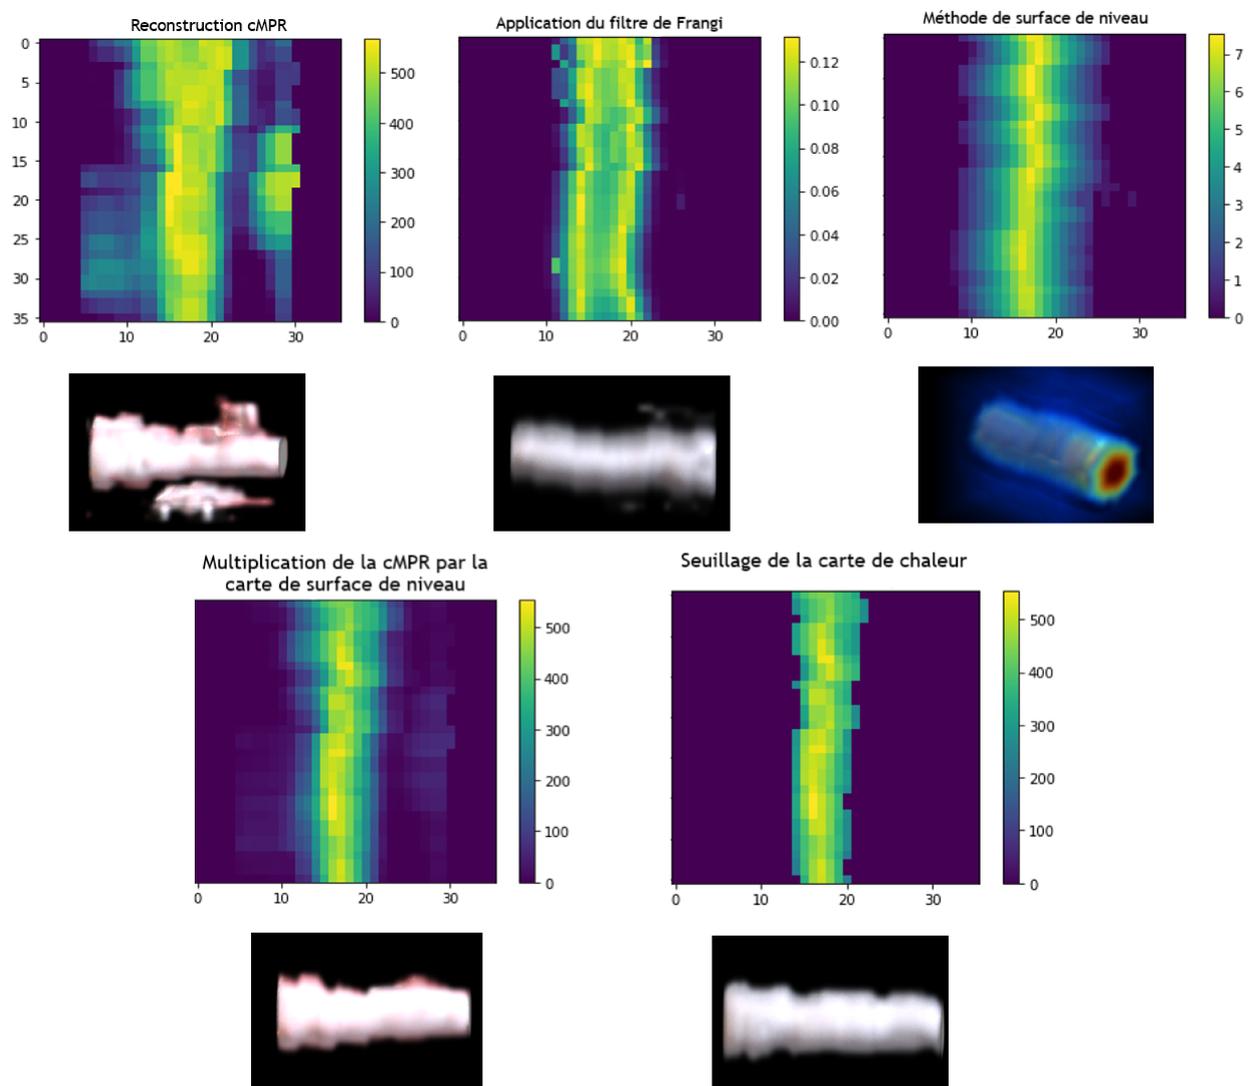


FIGURE 6.11 – Les étapes de pré-traitement du volume cMPR : d’abord un filtre de Frangi est appliqué pour accentuer les structures vasculaires. Ensuite, nous créons une carte de chaleur à partir du filtrage de Frangi à l’aide de la méthode de ligne de niveau. Finalement, nous appliquons un seuillage des valeurs et un filtrage gaussien.

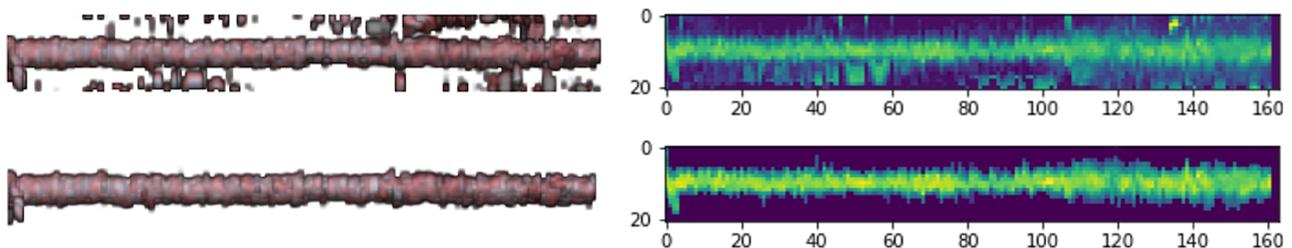


FIGURE 6.12 – Le résultat du pré-traitement d’un long vaisseau (affichage 3D à gauche et MIP à droite).

Après avoir adressé les structures avoisinantes des vaisseaux, nous nous intéressons à la problématique du décalage des cMPR (6.10), provenant principalement des mauvaises annotations des points de la ligne centrale des artères. Afin de contrer cette problématique, nous exploitons les résultats de segmentation du pipeline de pré-traitement pour réévaluer l’alignement des sections transversales. Par conséquent, nous proposons d’utiliser une régression circulaire aux moindres carrés pour essayer de chercher un cercle de rayon r et de centre I qui coïncide au mieux avec la distribution des points de chaque section transversale 2D le long de l’artère. La section est de résolution 20×20 pixels dans notre cas. Le centre I doit idéalement être positionné au centre, c’est à dire, $I_{ideal} = (10, 10)$. De ce fait, nous translatons la section en entière par un vecteur $\vec{t} = \begin{pmatrix} I_x - 10 \\ I_y - 10 \end{pmatrix}$. Dans le cas où nous détectons une diminution ou augmentation brusque du rayon de l’artère (diminution ou augmentation de 20 %), nous n’appliquons pas cette translation. Nous suspectons que cette diminution est due à une pathologie et nous gardons la section intacte.

Notre base d’apprentissage est formée de 16 patients pour l’entraînement et 8 pour la validation. Elle contient un total de 1338 volumes de résolution $(20 \times 20 \times 36)$ qui se départage comme suit : 954 sains, 291 avec une lésion non significative et 93 avec une lésion significative. La base d’entraînement constitue 66% de la base d’apprentissage alors que le reste est dédié pour la base de validation.

6.4.2 Architecture

L’architecture proposée, comme le montre la figure 6.14, est constitué de deux canaux parallèles identiques. Chaque branche de réseau contient deux couches de convolutions $(3 \times 3 \times 3)$, deux couches de max-pooling $(2 \times 2 \times 2)$ et une couche entièrement connectée. La sortie de chaque branche de réseau est concaténée et envoyée à une deux couches entièrement connectée pour combiner les deux cartes de caractéristiques. Nous utilisons l’unité linéaire rectifiée (ReLU) comme fonction d’activation pour toutes les couches, sauf la dernière. La couche de sortie a une seule unité, et nous utilisons la tangente hyperbolique pour prédire le degré de la sténose. Nous changeons le problème de classification en un problème de régression pour pénaliser les

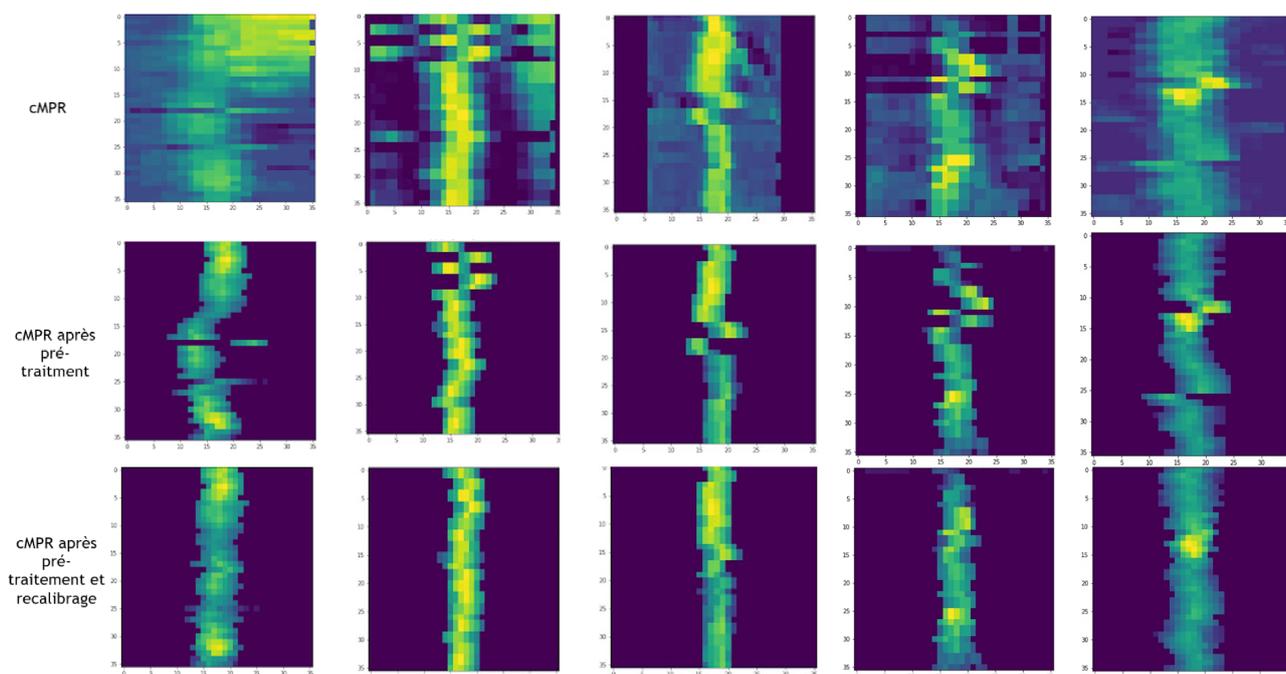


FIGURE 6.13 – Le résultat final après la segmentation grossière des artères et le recalibrage.

erreurs de prédiction pour la classe de la sténose significative. En effet, notre vérité de terrain est construite de manière que :

- l'absence de sténose est étiquetée comme -1 ;
- la sténose non significative (rétrécissement entre 20 et 50%) comme 0 ;
- la sténose significative (rétrécissement supérieur à 50%) comme 1.

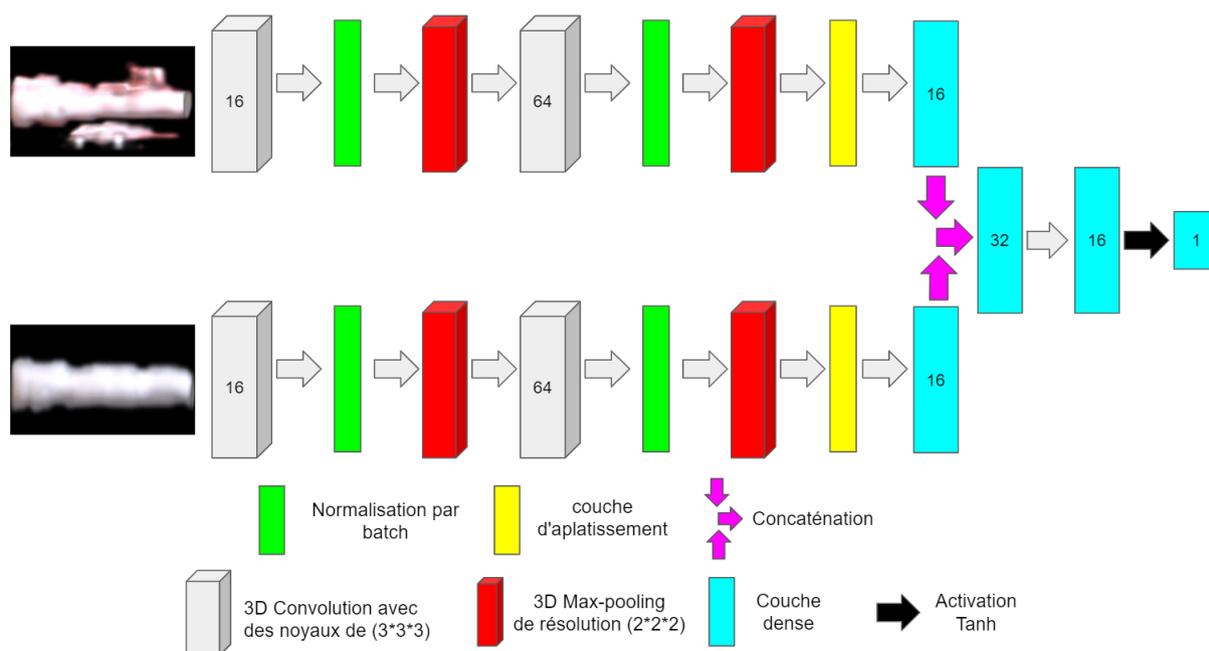


FIGURE 6.14 – L'architecture du CNN à double entrée de la détection de la sténose.

L'ensemble d'image de la tangente hyperbolique est $] - 1, 1[$ qui est moins restreint que celui de la fonction linéaire (\mathbb{R}) ou de ReLu (\mathbb{R}_+). Une prédiction d'une sténose significative comme absence de sténose est pénalisé plus que dans un cas de classification. Ceci force le modèle à éviter ce type d'erreur.

Nous initialisons les poids de la convolution et des couches denses avec la distribution uniforme de Xavier [207]. Tous les biais sont initialisés à 0. Le réseau est entraîné pendant 1600 époques en faisant le choix d'un arrêt précoce si l'erreur quadratique moyenne sur les données de validation atteint un seuil de 10^{-8} ou si elle ne diminue plus pendant 100 époques. Nous estimons les paramètres optimum du réseau en utilisant l'optimiseur d'Adam [208] avec un taux d'apprentissage de 0,001, $\beta_1 = 0,9$, $\beta_2 = 0,999$, $\epsilon = 10^{-8}$ et une décroissance $\eta = 10^{-6}$.

6.4.3 Résultats

TABLE 6.1 – Comparaison des résultats de l'approche à double entrée et à entrée unique (cMPR sans les corrections). L'évaluation est faite sur 8 patients qui appartiennent à la base de données de CHU Poitiers en utilisant les métriques : sensibilité (rappel), précision (valeur prédictive positive), le DSC (coefficient de similarité Dice), AUC (aire sous la courbe) et MCC (coefficient de corrélation de Matthew)

Modèle	Classes	Précision	Sensibilité	DSC	AUC	MCC
Entrée double	Sain	0,93	0,86	0,90	0,8550	0,6755
	Sténose	0,71	0,85	0,77		
Entrée simple	Sain	0,91	0,88	0,90	0,831	0,655
	Sténose	0,72	0,80	0,76		

Nous commençons l'analyse des résultats par l'évaluation de l'apport de l'approche à double entrées contre celle d'une entrée unique. La table 6.1 résume les performances des deux modèles. Nous pouvons constater que la deuxième branche de réseau qui contient les cMPR corrigées permet à notre modèle de détecter mieux la sténose (sensibilité 0,85 contre 0,80). La sensibilité confirme la capacité d'identifier les lésions présents dans le jeu de données du CHU potiers. Nous pouvons aussi se référer aux mesures de AUC et MCC qui évaluent les performances globales du modèle ou nous déduisons que le modèle à double entrées a une meilleure compréhension de la nature des lésions. Nous tenons aussi à signaler l'apport du remplacement de l'approche

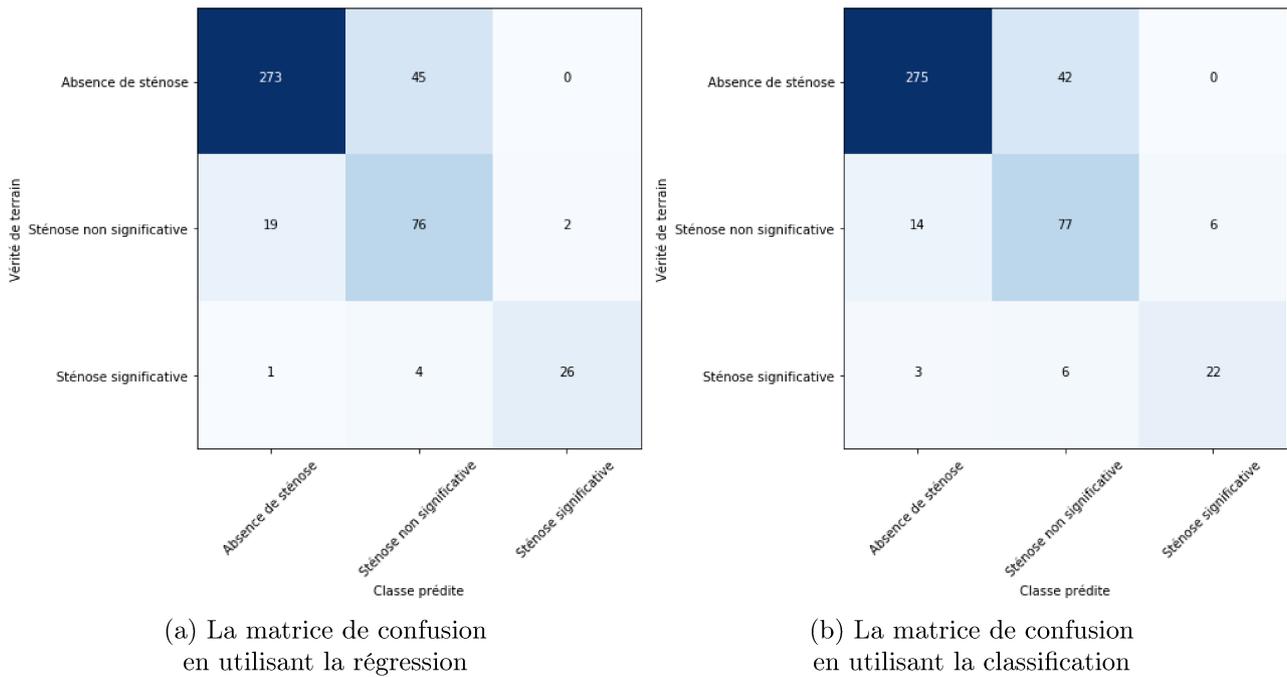


FIGURE 6.15 – Comparaison entre les matrices de confusion du modèle à double entrée en utilisant la régression et la classification

classique de classification par une approche de régression comme indiqué dans la figure 6.15. Nous constatons que les erreurs de classification de la sténose significative en absence de sténose ont largement diminuées (3 à 1). Ce qui est pour les experts, l’erreur la plus à craindre dans la réalité clinique. L’analyse des cartes de caractéristiques n’est pas toujours évidente vu leur complexité. Mais, dans la figure 6.16 nous pouvons identifier quelques différences majeurs entre la carte du modèle à double entrée et celui à entrée unique. Nous constatons que la carte du premier est plutôt destinée à l’analyse des structures au niveau et à l’extérieur de la paroi de l’artère tandis que la carte de deuxième contient des filtres qui essaient de segmenter les artères (fenêtres (1,2), (2,1), (3,2) et (4,3) de la figure 6.16b). Nous déduisons alors que l’introduction de la deuxième entrée, qui représente une segmentation grossière de l’artère, aide le modèle à focaliser sa recherche des caractéristiques sur les zones les plus intéressantes qui sont les voisinages de la paroi du vaisseau. Enfin, par rapport aux méthodes de la littérature qui n’utilisent que le cMPR en entrée, nous montrons qu’en ajoutant une seconde entrée qui joue le rôle d’une segmentation grossière, nous parvenons à améliorer les performances du modèle. Cette amélioration est le signe d’une meilleure compréhension des spécificités des lésions. Avec le cMPR et les corrections préalables, nous avons introduit au CNN une représentation

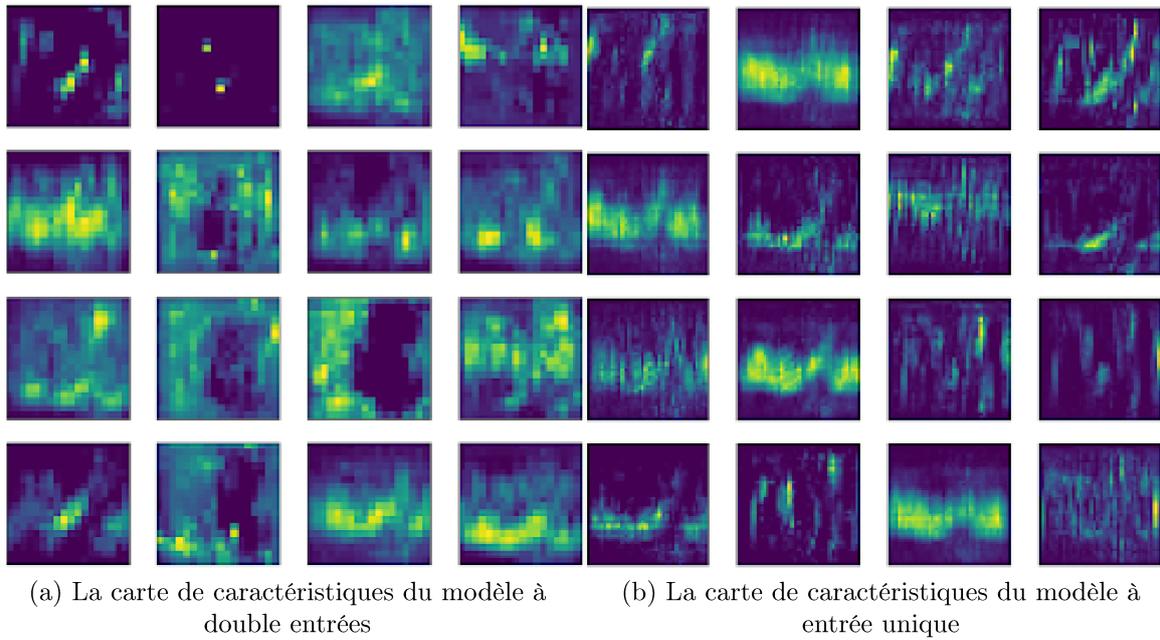


FIGURE 6.16 – Comparaison entre les cartes de caractéristiques du modèle à double entrée et celui à une seule entrée.

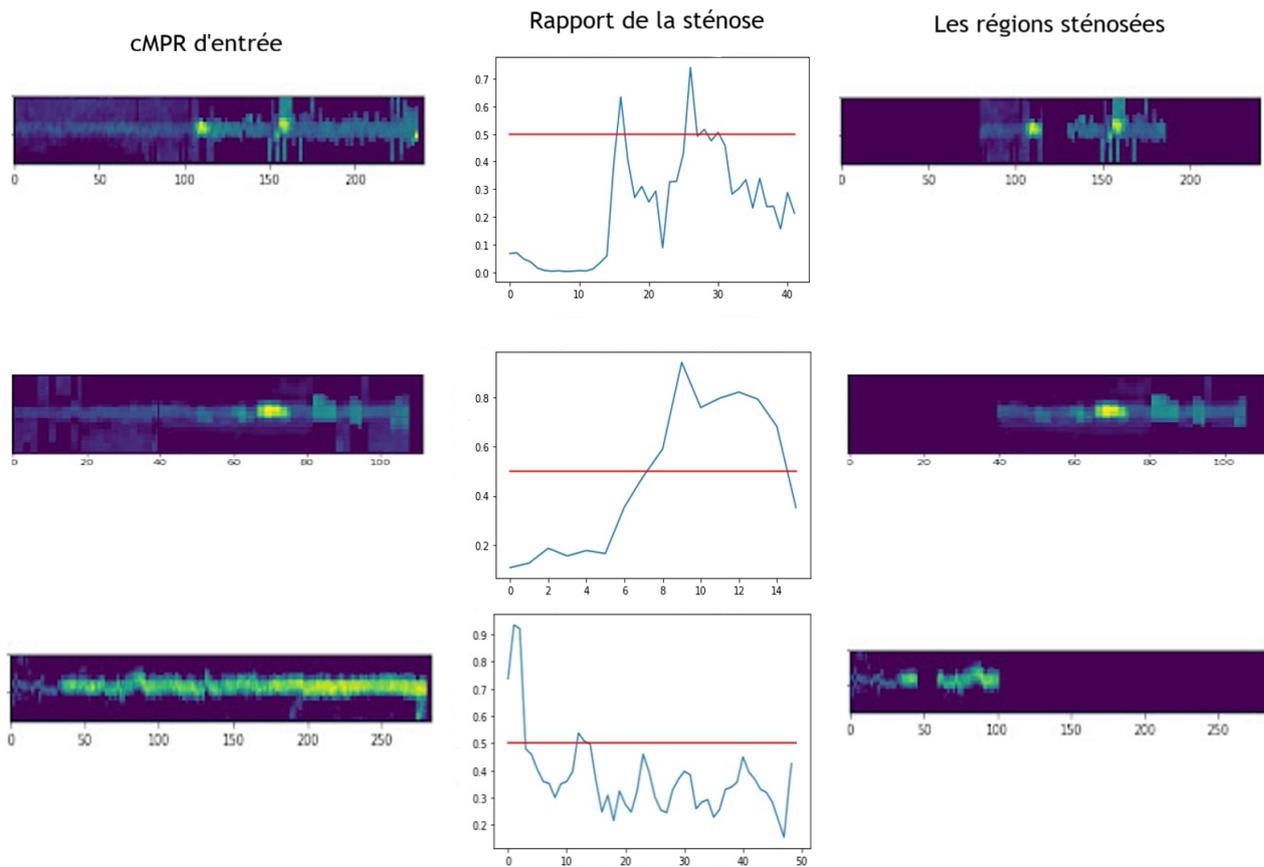


FIGURE 6.17 – Les rapports de la sténose prédits par le modèle pour un ensemble des artères.

simpliste des vaisseaux qui lui permet de rechercher des caractéristiques plus sophistiquées et complexes. Comme nous l'avons mentionné dans la section 2.2.3, les CNNs sont assez efficaces pour représenter ce type de système. Par contre, nous montrons que les connaissances fournies par les méthodes classiques (pour le pré-traitement) sont précieuses pour réduire la complexité et ainsi faciliter la mise en place des CNN.

A la fin, la figure 6.18 résume l'ensemble de nos travaux à présent. A partir d'un volume CT d'un patient, nous effectuons l'extraction des artères coronaires. Le résultat de notre pipeline final est le rapport de la sténose que nous livrons aux experts. Il prend la forme de celui des experts. Nous rapportons l'ensemble des artères détectés et nos résultats de détection. Les experts peuvent regarder ainsi l'artère suspecte en 3D et en cMPR. Nous isolons les régions sténosées pour une meilleur visualisation (6.17).

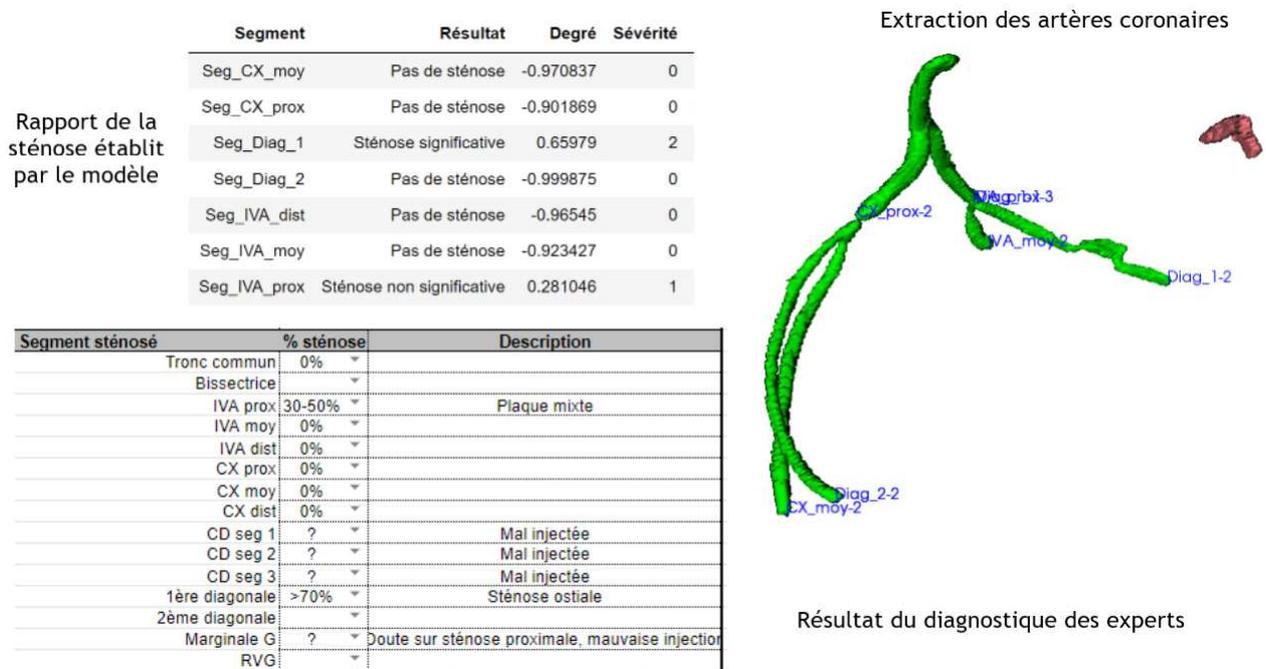


FIGURE 6.18 – Les rapports de la sténose prédits par rapport au diagnostic des experts sur l'ensemble de l'arbre artériel d'un patient.

6.5 Classification des plaques

La plaque d'athérome peut être classée selon sa nature en plaque calcifiée, plaque douce (non calcifiée) et plaque mixte [183]. La plaque calcifiée est considérée comme stable et la densité

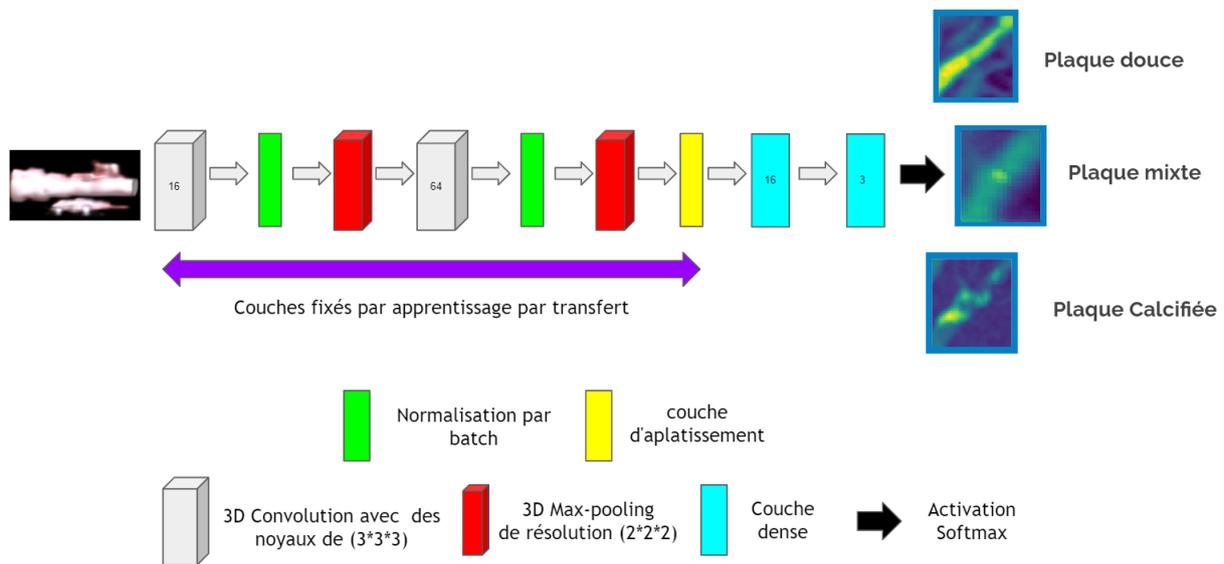


FIGURE 6.19 – L’architecture du modèle proposé pour la classification des plaques. Le modèle est entraîné via l’apprentissage par transfert à partir du branche de réseau associée à l’entrée cMPR du modèle de la détection de la sténose.

de calcium dans les artères coronaires est un facteur prédictif important des incidents cardiovasculaires [184]. Contrairement à la plaque calcifiée, la plaque douce et la plaque mixte sont considérées comme instables et plus sujettes à la rupture. Une telle rupture peut entraîner des lésions irréversibles du myocarde (un infarctus du myocarde [185] par exemple). Étant donné que les différents types de plaque et les différents degrés de sténose conduisent à des stratégies de gestion différentes pour les patients, il est crucial alors de caractériser la plaque une fois la sténose détectée.

Nous proposons de bénéficier des connaissances acquises par le modèle de la détection de la sténose pour la classification des plaques. En effet, nous introduisons un CNN de classification utilisant l’apprentissage par transfert pour exploiter les cartes de caractéristiques du modèle précédent. La figure 6.19 présente l’architecture du CNN proposée. Nous reprenons le premier branche de réseau du modèle de la détection de la sténose dont l’entrée est la cMPR de l’artère. Nous ajoutons deux couches denses pour dédier le CNN à la classification des plaques. Nous fixons les paramètres de toutes les couches de convolutions pour deux raisons primaires :

- le modèle de la détection de la sténose identifie les lésions. Par conséquent, nous n’avons pas besoin de rechercher leurs caractéristiques de nouveau ;
- le CNN de classification est entraîné seulement sur l’ensemble des lésions. Ainsi, le jeu de

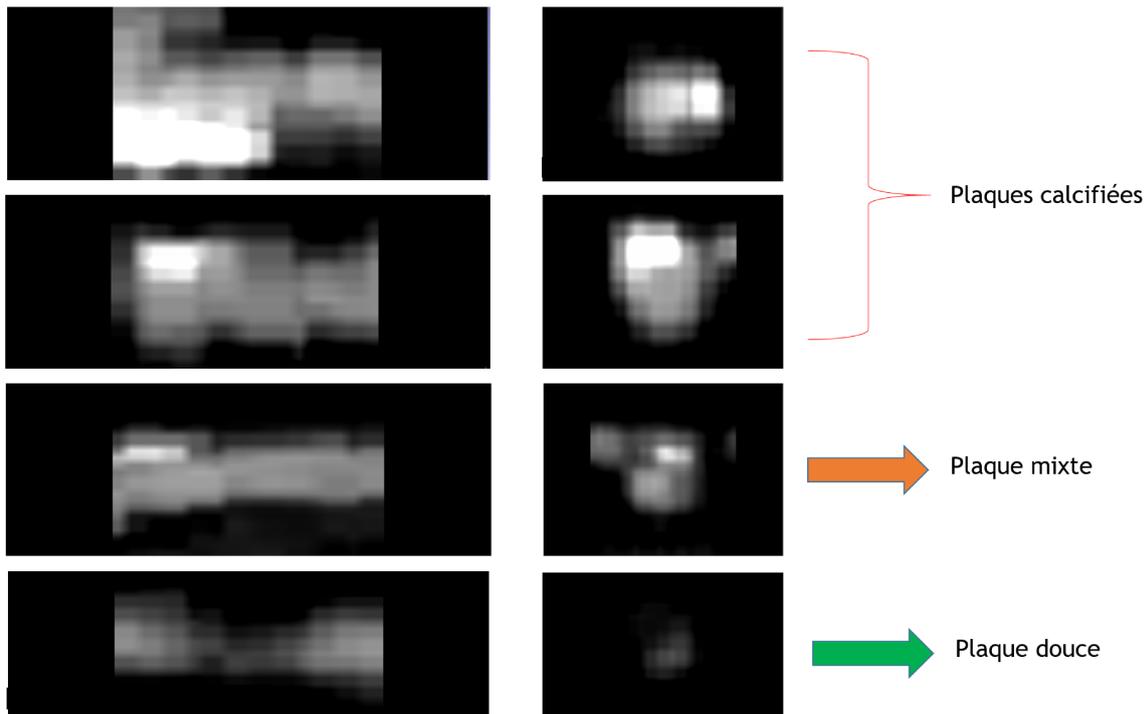
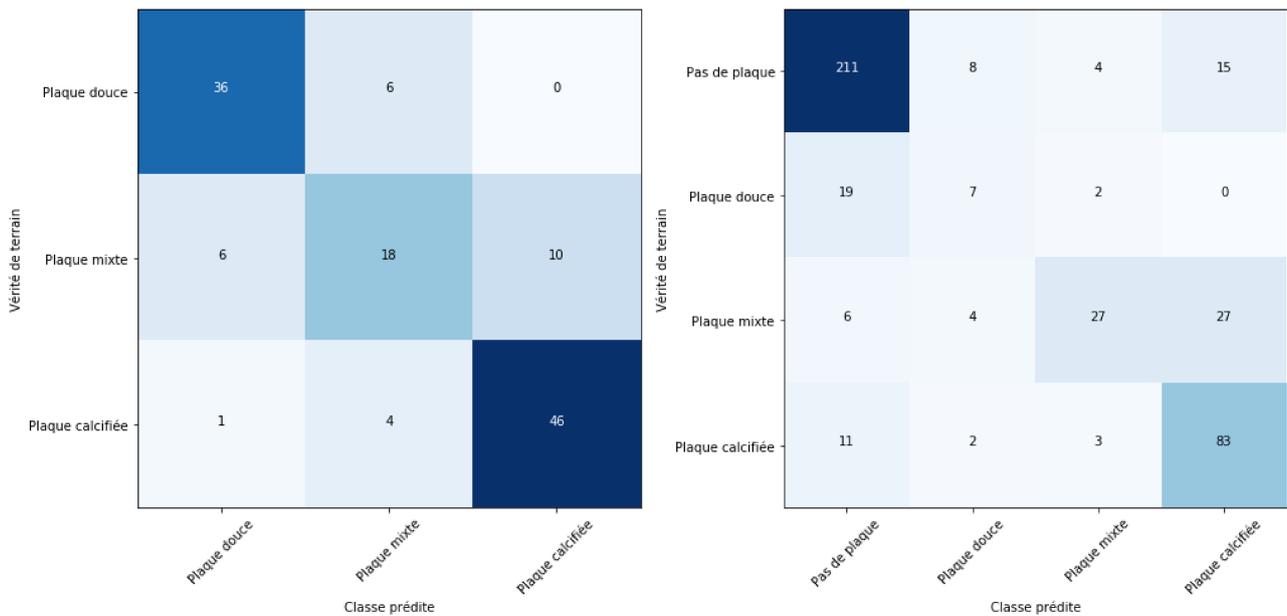


FIGURE 6.20 – Les entrées de notre modèle (le morceau de lésion identifié par le modèle de la détection de la sténose) en fonction de leur type. A gauche s’affiche la MIP de la lésion alors qu’à droite une section transversale de la partie atteinte est représenté. Le volume de calcification (blanc foncé) est l’indicateur du type de la plaque : douce en absence de calcification, mixte si la calcification occupe moins de 50% de la zone de rétrécissement et calcifiée si elle dépasse le seuil de 50%.

données est très restreint.

Finalement, le modèle vise à différencier les trois types des plaques (cf figure 6.20) : plaque douce (absence de calcification), plaque mixte (calcification inférieure à 50%) et plaque calcifiée (calcification supérieure à 50%) à l’aide d’une fonction d’activation softmax. Nous reprenons les résultats des prédictions du modèle de détection des sténoses. Contrairement aux travaux de Zreik et al [153], nous choisissons de séparer les deux tâches de détection et de classification. D’une part, leur combinaison crée une redondance de la classe d’absence de sténose et de plaque. D’autre part, nous pouvons nous retrouver avec des scénarios irréalistes d’absence de sténose mais de plaque calcifiée. Cela peut créer plus de doute et de confusion pour les experts. Par conséquent, nous proposons de suivre l’approche plus standard consistant à détecter les sténoses d’abord et classifier le type des plaques ensuite.

Les résultats de classification sont indiqués dans la figure 6.21. Notre modèle parvient à bien séparer les différents types de plaques avec des taux de précision de : 0.86 pour les plaques



(a) La matrice de confusion de notre modèle

(b) La matrice de confusion de Zreik et al [153]

FIGURE 6.21 – Comparaison entre les matrices de confusion du notre modèle et le modèle de Zreik et al [153]. Chacun a utilisé sa propre base de données. Par conséquent, la comparaison est à des fins approximatives et non concluantes.

douces, 0.54 pour les plaques mixtes et 0.9 pour les plaques calcifiées. Entre les plaques douces et les plaques calcifiées, nous constatons qu’une seule lésion a été mal prédite. Nous rappelons que nous utilisons les entrées en cMPR sans correction ou amélioration, du coup, les structures adjacentes peuvent parfois bloquer les calcifications. La majorité des erreurs est en relation avec la classe des plaques mixtes. Pour comprendre ce comportement, nous regardons les résultats de la méthode de Zreik. Nous pouvons constater qu’elle souffre à caractériser deux types de classes (plaques douces et mixtes). Nous rappelons que leur méthode a été testée sur une base de données différente, mais nous utilisons leurs résultats pour donner un aperçu des défis de cette tâche. Bien que la mise en œuvre conjointe de deux tâches consécutives (la détection et de la classification) ait permis à leur méthode d’obtenir de meilleurs résultats, nous pouvons en déduire qu’elle était plus bénéfique à la tâche de détection. Notre modèle, quoique séparé, partage le même type d’entrée (la cMPR) ainsi l’extracteur des caractéristiques du modèle de la détection de la sténose.

La détection des plaques mixtes reste un défi. Ce ne sont pas des lésions facilement interprétables. Leur définition s’écroule de la combinaison des deux autres lésions. Les plaques mixtes

sont à la fois des plaques douces et calcifiées. Le seul indicateur est le volume de calcification dans la zone de rétrécissement qui doit être inférieur à 50%. Donc la structure des plaques mixtes varie entre : 50% calcifiée et 50% non calcifiée jusqu'à 1% calcifiée et 99% non calcifiée. C'est l'une des raisons principales qui rend difficile la séparation entre les lésions mixtes des lésions calcifiées quand le volume de calcification est proche de 50%. C'est pourquoi, la majorité des travaux dans la littérature inclut la classe mixte avec la classe calcifiée.

Nous admettons que notre modèle a des difficultés à bien distinguer la classe mixte mais il offre une meilleure compréhension de ses caractéristiques grâce à son extracteur qui est axé sur la différenciation entre les lésions. D'ailleurs, une introduction d'un intervalle de seuil au lieu d'un chiffre discret (de 40 à 60 % au lieu de 50%) peut aider les modèles à mieux s'adapter. D'une part, parce que c'est difficile de quantifier exactement le volume de la calcification par rapport au volume du rétrécissement. D'autre part, les CNN se basent sur les caractéristiques visuelles. Donc, si visuellement, la différence entre une sténose à 48 % de calcification et une sténose à 52% est négligeable, il devient difficile pour les CNN de les bien caractériser .

6.6 Conclusion

Dans ce chapitre, nous avons présenté une nouvelle méthode basée sur l'apprentissage profond pour la détection des sténoses. Largement inspirés par le processus clinique réel, nous avons appliqué la transformation cMPR comme entrée du modèle pour simplifier la forme du vaisseau. Cette technique est très sensible à la qualité de l'extraction des artères. Nous avons ensuite proposé un processus de pré-traitement pour améliorer la robustesse du modèle. Nous avons exploité les méthodes classiques pour créer une segmentation grossière des artères et avons ainsi mis en place un CNN à double entrée pour en tirer profit.

Les méthodes d'apprentissage profond de la littérature n'ont exploité que des volumes cMPR en entrée. De plus, les méthodes basées uniquement sur la segmentation présentent une multitude de limitations. Nous avons montré qu'en combinant les deux types d'entrées, nous avons pu améliorer les performances du modèle ainsi que la qualité de sa carte de caractéristiques.

Nous avons comblé notre travail de l'extraction des artères coronaires dans le chapitre 5 par

deux méthodes entièrement automatique pour la détection de la sténose et la classification des plaques. A l'issue de ce pipeline, les experts auront accès à une extraction de l'arbre artériel et à une analyse par artère de l'existence de sténoses et du type de plaques si elles existent. Nous avons mis à leur disposition des segments d'artères séparés, des artères en cMPR, des régions sténosées et un intervalle de confiance pour une meilleure visualisation et analyse.

Après avoir appris les risques cardiovasculaires, nous poursuivons avec l'identification des pathologies qui ciblent les artères. De la prévention des risques cardiovasculaires à la prévention des accidents vasculaires cérébraux, le chapitre suivant est consacré à la détection des anévrismes intracrâniens non rompus à partir des MRA-TOF.

Chapitre 7

Segmentation des anévrismes intracrâniens non rompus

7.1 Introduction

Le domaine de l'imagerie médicale est en évolution constante. Ce qui augmente la charge de travail qui se repose sur les épaules des experts médicaux. Cette expansion n'est pas seulement liée à l'augmentation du nombre d'examens mais aussi à l'augmentation du nombre d'images par examen. En moyenne les experts médicaux interprètent environ 20 images par minute d'une journée de travail normale [186]. Une telle charge de travail peut engendrer une fatigue physique, en particulier pour les tâches difficiles où toute structure malsaine manquée ou ratée peut être fatale pour le patient. La détection d'anévrisme est un excellent exemple d'une tâche aussi fastidieuse qu'exigeante avec des conséquences énormes pour les patients.

Un anévrisme est un gonflement de l'artère et peut être causé par un affaiblissement de la paroi du vaisseau sanguin. Selon [187], 2 à 3 % de la population est atteinte d'un anévrisme intracrânien, sa rupture est fatale dans 50 % des cas. Malheureusement, le danger imminent d'une telle rupture est un facteur de multiples éléments comme la taille, la localisation et la configuration lésionnelle de l'anévrisme [188] par exemple.

Bien que l'étalon-or de la détection des anévrismes est l'angiographie par soustraction numérique (DSA), l'angiographie par tomographie assistée par ordinateur (CTA) et l'IRM sont certainement les plus responsables de leur diagnostic. En fait, l'anévrisme est très probablement découvert dans deux situations radicalement différentes. Soit de manière fortuite lors d'une IRM réalisée à la recherche d'une autre pathologie cérébrale et, dans ce cas, l'anévrisme découvert n'est pas rompu, soit lors de la recherche d'une cause d'hémorragie sous-arachnoïdienne et, dans ce cas, l'anévrisme est déjà rompu (le scanner est privilégié). L'un des inconvénients de l'utilisation de la CTA est la limitation spatiale (largeur de champ), les anévrismes d'un diamètre inférieur à 3 mm sont le plus souvent manqués. Par conséquent, pour une approche plus préventive et pour éliminer le risque de rupture d'anévrisme, la demande de modèles de détection automatique assistée par ordinateur pour aider les efforts des neurologues dans l'inspection des scans IRM, devient de plus en plus forte.

Au cours des deux dernières décennies, la communauté des chercheurs a accordé une attention particulière à la tâche de détection des anévrismes, notamment à partir du l'MRA 3D en temps de vol (MRA-TOF) pour une approche préventive. L'automatisation de cette détection a pris de multiples formes. Des recherches antérieures, notamment Hayashi et al. [190] ont utilisé des études basées sur la courbure pour mettre en évidence la surface irrégulière des anévrismes. Arimura et al. [189] ont opté pour une sélection des candidats basée sur un seuillage multiple des niveaux de gris sur l'image rehaussée des points et une analyse discriminante linéaire à quatre caractéristiques pour éliminer les faux-positifs (principalement basés sur la taille, la forme, les structures locales,...). Yang et al [191] ont adopté une approche d'ajustement du rayon pour détecter les changements de diamètres des vaisseaux et ainsi extraire un ensemble de points d'intérêt. De telles approches nécessitent un tri et une sélection d'anévrismes suspects parmi les candidats extraits (plusieurs milliers) et exigent par conséquent un ensemble de règles manuelles qui risquent d'éliminer certains des vrais anévrismes et de laisser de côté un grand nombre de fausses détections. Pour améliorer le processus d'élimination des faux positifs, Nomura et al. [192] ont fourni un classificateur d'ensemble à 63 caractéristiques entraîné avec un algorithme de boosting. Alors que l'extraction de l'ensemble des points d'intérêt était toujours basée sur le calcul numérique des valeurs propres de la matrice hessienne et des courbures gaussiennes,

le classifieur de post-traitement a apporté plus d'automatisation et de généralisation au choix des prédictions candidates.

L'essor des algorithmes d'apprentissage profond, notamment dans le domaine du traitement des images a été très bénéfique à la tâche de détection des anévrismes. Nakao et al. [193] ont remplacé le processus de détection manuel par un CNN 2D qui départage les images MIP en candidats d'anévrisme et en vaisseaux sains. Pour améliorer le choix des patches utilisé dans leur approche, Ueda et al. [194] ont utilisé un algorithme de présélection qui extrait les anomalies artérielles (vrais anévrismes, dilatation infundibulaire, bifurcations de vaisseaux et sténoses de vaisseaux) pour n'envoyer que ces structures malsaines à un Resnet-18 [53] afin de distinguer les vrais anévrismes du reste des pathologies. D'autre part, Sichtermand et al. [195] ont décidé d'opter pour une architecture Deepmedic [196] tout en utilisant les images TOF brutes au lieu d'extraire les vaisseaux, ce qui le rend plus enclin aux prédictions faussement positives. Récemment, Joo et al. [197] ont développé un pipeline complet pour la détection d'anévrisme en utilisant la segmentation des vaisseaux, le patching 3D et l'architecture ResNet 3D [53]. Cependant, seules les images MRA-TOF ont été utilisées comme données d'entrée sans aucune transformation MIP, qui a été appliquée de manière fructueuse dans [193, 198]. De plus, l'étude menée n'incluait pas les images de mauvaise qualité, les anévrismes fusiformes, disséqués ou rompus.

Les approches 2D et 3D présentent autant d'avantages que d'inconvénients. D'une part, la première met en évidence les caractéristiques les plus importantes des images d'entrées mais ne met pas en évidence les relations spatiales entre ces structures dans l'affichage 2D. Un autre inconvénient peut se manifester lorsque d'autres structures insignifiantes avec des valeurs élevées viennent masquer certaines des informations pertinentes que nous recherchons. D'autre part, l'approche 3D possède massivement plus d'informations que la transformation MIP, ce qui peut conduire à une dilution de l'effort d'extraction des caractéristiques. Dans le but d'exploiter les avantages des deux approches et de remédier à leurs limites, nous suggérons qu'un couplage des entrées 3D et MIP, aidé par les techniques de traitement appropriées, permette au modèle de concentrer sa recherche de cartes de caractéristiques sur la forme et l'emplacement de la déflation de l'anévrisme dans l'espace 2D et 3D à la fois.

En résumé, dans ce chapitre, nous présentons :

- (i) Une nouvelle méthode pour la segmentation et la détection d'anévrisme intracrânien. Il s'agit d'un modèle d'apprentissage profond à double entrées et à sortie unique qui utilise des données hybrides en entrée (MIP 3D et 2D)
- (ii) Notre méthode a atteint la meilleure sensibilité dans le défi ADAM [199] et des performances comparables à celles de l'inspection visuelle humaine pour la quintessence des anévrismes graves, tout en garantissant une meilleure détection pour les structures plus petites
- (iii) Notre pipeline complet présente un fort potentiel de généralisation sur des bases de données difficiles, grâce à des processus de pré-traitement et d'apprentissage sophistiqués
- (iv) L'utilisation de petits patches permet de contourner les limites de mémoire et de calcul ainsi que la rareté des données(un problème récurrent pour les scientifiques dans l'imagerie médicale).

Dans la prochaine sous-section, nous décrivons les données utilisées dans cette étude. Ensuite, nous décrivons les techniques que nous avons proposées pour permettre d'établir un diagnostic complet de détection et de segmentation des anévrismes, ainsi que leurs rôles dans l'amélioration du pipeline complet. La quatrième sous-section reprend les détails de l'implémentation et présente les résultats de l'évaluation de cette méthode sur le jeu de données ADAM. L'avant-dernière sous-section est consacrée à la discussion sur les résultats comparatifs des onze algorithmes d'extraction d'anévrismes qui ont participé au défi ADAM par rapport au nôtre. Enfin, nous concluons ce chapitre en énumérant les contributions de notre travail, ses limites et les travaux futurs.

7.2 Méthodologie proposée

La tâche de détection d'anévrisme présente une panoplie de défis, allant des diverses modalités et protocoles d'acquisition à la petitesse des structures en question. Notre pipeline de traitement illustré à la Fig 7.1 montre la séquence des étapes successives nécessaires à la segmentation com-

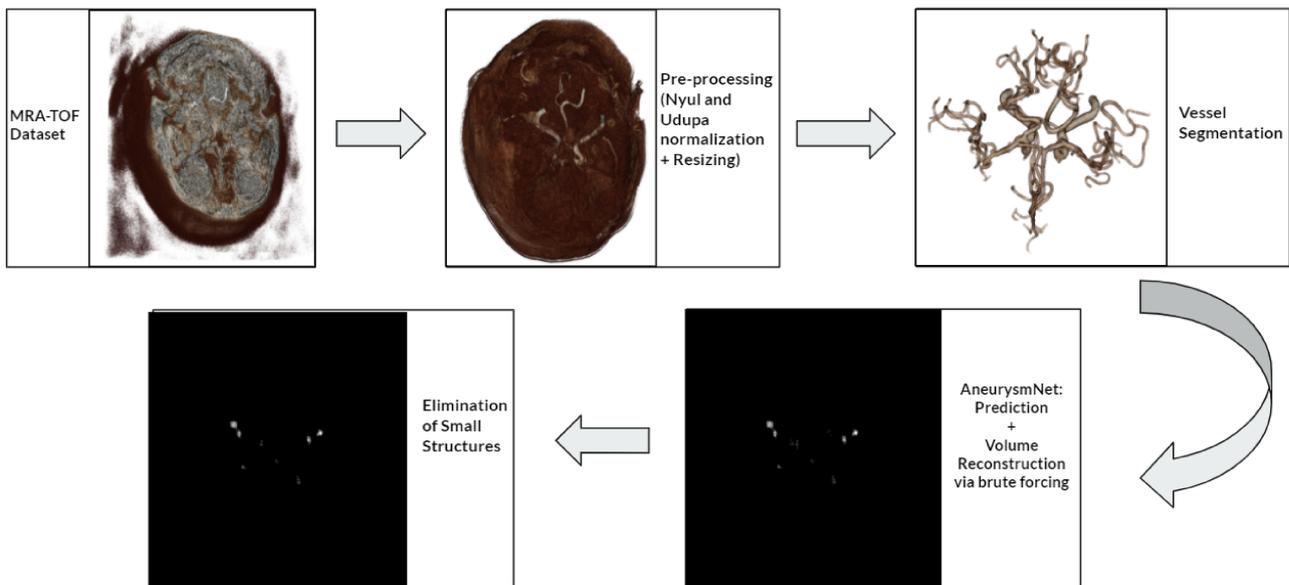


FIGURE 7.1 – **Pipeline complet de l’algorithme de segmentation des anévrismes intracrâniens** : les données brutes des MRA TOF sont prétraitées afin d’extraire les vaisseaux. Ensuite, le modèle réseau neuronal AneurysmNet prédit les anévrismes présumés et, enfin, un algorithme de post-traitement simple basé sur la taille de la structure prédite est mis en œuvre pour éliminer les petites prédictions bruitées.

plète d’un anévrisme. Il comprend une étape de pré-traitement et une étape de segmentation des vaisseaux qui apporte une uniformité aux données et contribue massivement à la robustesse de notre modèle. Le cœur du pipeline susmentionné est le modèle AneurysmNet. Nous proposons d’utiliser la puissance des modèles d’apprentissage profond afin de générer une segmentation complète des anévrismes dans un jeu de données TOF-MRA donné en utilisant une double entrées hybride : 2D MIPs et 3D. Notre prédicteur a obtenu des bonnes performances globalement le classant parmi les 4 premiers lors de l’évaluation de l’ensemble de données du défi ADAM, avec le meilleur taux de sensibilité. Les éléments qui constituent notre pipeline sont décrits dans les paragraphes suivants.

7.2.1 pré-traitement

Le contexte clinique réel offre une distribution large et diversifiée de jeux de données (protocoles d’acquisition, modalités, types de scanners...). Une des priorités les plus importantes est de fournir un outil fiable pour standardiser ces MRA variés. En effet, même pour un même patient, dans la même région cérébrale prédéterminée, en utilisant le même protocole d’acquisition, on

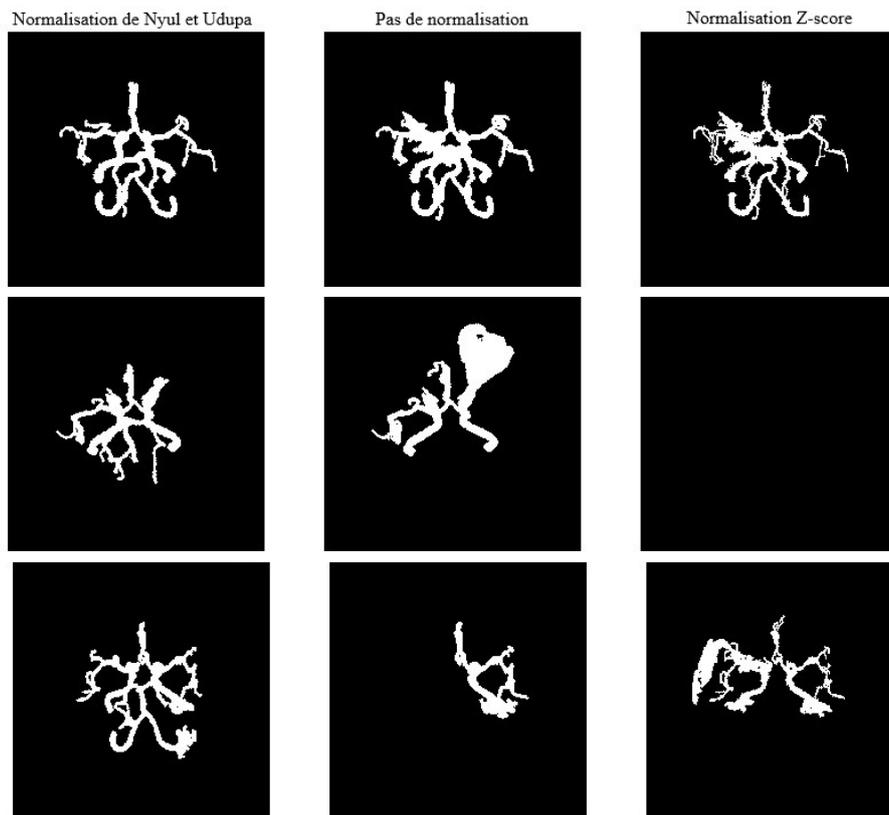


FIGURE 7.2 – **Étude de normalisation** : élimination des résidus bruités dus à l’inhibition de l’intensité à l’extérieur des vaisseaux (première ligne). La normalisation du Z-score entraîne un échec de la segmentation des vaisseaux alors que celle sans normalisation conserve une partie crânienne importante en raison de la similarité des intensités (rangée du milieu). La normalisation de Nyul et Udupa aide l’algorithme de segmentation des vaisseaux à trouver l’arbre artériel complet. (dernière ligne)

peut se retrouver avec des intensités dont l’ordre de grandeur fluctue. Ces dernières n’étant pas calibrées vis à vis d’une quantité physique à proprement parler en IRM. Bien que la solution la plus simple consiste à effectuer une normalisation Min-Max de la plage d’intensité, ce choix ne fonctionne malheureusement pas de manière cohérente puisqu’il n’agit pas sur la distribution des valeurs des intensités en vue de les uniformiser selon [201]. C’est pourquoi nous utilisons la normalisation de Nyul et d’Udupa [202] pour assurer l’uniformité des échelles d’intensité dans le large éventail d’ensembles de données MRA produits par les contextes cliniques réels.

Cette méthode est basée sur une technique de mise en correspondance des histogrammes. L’histogramme de chaque ensemble de données MRA est transformé pour correspondre à un histogramme standard prédéterminé. Cette déformation tire parti du calcul des points de repère et entraîne donc une transformation non linéaire des intensités. Les avantages de la transformation de l’histogramme original sont doubles : d’une part, elle est indépendante des protocoles d’ac-

quisition et des origines des scanners, d'autre part, elle promet à la fois une inhibition ou une impulsion des structures adjacentes qui peuvent se chevaucher en intensité. Comme le montre la Fig 7.2, en conservant l'algorithme de segmentation des vaisseaux tel quel et en ne changeant que la méthode de normalisation (Nyul et Udupa, pas de normalisation du tout, normalisation par cote standard Z[203]), la contribution de l'approche de normalisation de Nyul et Udupa à l'amélioration de la qualité de la segmentation des vaisseaux est tangible. Cela est dû en grande partie à la transformation non linéaire des intensités qui délimite des frontières améliorées entre les structures voisines.

Bien que la normalisation de l'intensité soit une priorité pour standardiser les prédictions et l'évaluation, les contextes cliniques réels produisent malheureusement des ensembles de données hétérogènes en termes de taille et de forme, que la normalisation de l'intensité ne peut résoudre à elle seule. L'écart entre certains MRA varie de $(0.2 \times 0.2 \times 0.5) \text{ mm}^3$ à $(0.6 \times 0.6 \times 1.0) \text{ mm}^3$ en taille de voxel, c'est pourquoi nous optons pour un redimensionnement anisotrope à l'aide d'une interpolation trilineaire. Ceci révèle les étapes de pré-traitement qui visent à normaliser les données à travers les multiples variables mobiles des environnements cliniques réels.

7.2.2 Segmentation des vaisseaux

Les anévrismes sont de petites structures par rapport à la taille des vaisseaux ou même de l'ensemble des données MRA. Afin de faciliter le processus de recherche de ces anomalies, nous devons détourner notre attention des zones qui ne contiennent pas d'anévrisme. Un anévrisme ne peut être attaché qu'à une paroi artérielle. Dans ces conditions, une approche de segmentation des vaisseaux peut éliminer plus de 99 % des positions non pertinentes.

L'algorithme suivant [192] définit les étapes clés pour extraire l'arbre vasculaire d'un volume MRA (Fig 7.3). Dans un premier temps, nous calculons la moyenne η et l'écart-type σ de la région du quart central. Ensuite, nous extrayons les régions connectées dont l'intensité des voxels satisfait la condition $I(x, y, z) \geq \eta - 2\sigma$. Troisièmement, nous effectuons des transformations morphologiques sur le masque initial à l'aide de différents filtres (principalement la fermeture et l'érosion) qui permettent d'extraire le volume interne qui contient des intensités de voxel

$I(x, y, z) \geq \eta + 2\sigma$. À ce stade, nous aurons encore différents candidats de régions. Nous procédons en choisissant les structures qui satisfont les conditions suivantes :

- leur volume doit être égal à 2,7 % du volume intérieur ;
- leur centre de gravité doit être situé dans le quart central du plan $(0, x, y)$.

Enfin, afin de récupérer les vaisseaux sous segmentés et de ne pas perdre une partie de l'information pertinente, nous corrigeons la segmentation avec un filtrage de transformation morphologique supplémentaire (principalement dilatation et fermeture).

À ce stade, après la normalisation et l'extraction des vaisseaux, nous confions la tâche de détection et de segmentation des anévrismes à notre modèle CNN proposé : AneurysmNet.

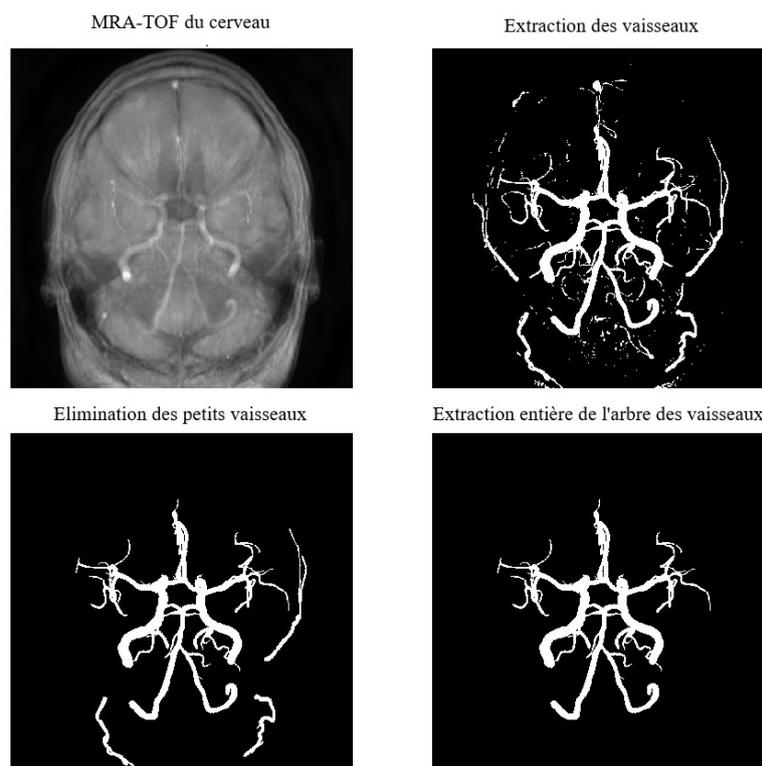


FIGURE 7.3 – **Pipeline de segmentation des vaisseaux** : Une étape d'extraction des vaisseaux, suivie d'une transformation morphologique puis d'un processus d'élimination des petits vaisseaux, permet une segmentation précise des vaisseaux et de certaines autres structures. L'omission de ces petites réponses permet une extraction complète de l'arbre vasculaire (les figures montrées sont les MIPs du volume entier et les vaisseaux sont intensifiés pour des raisons d'affichage).

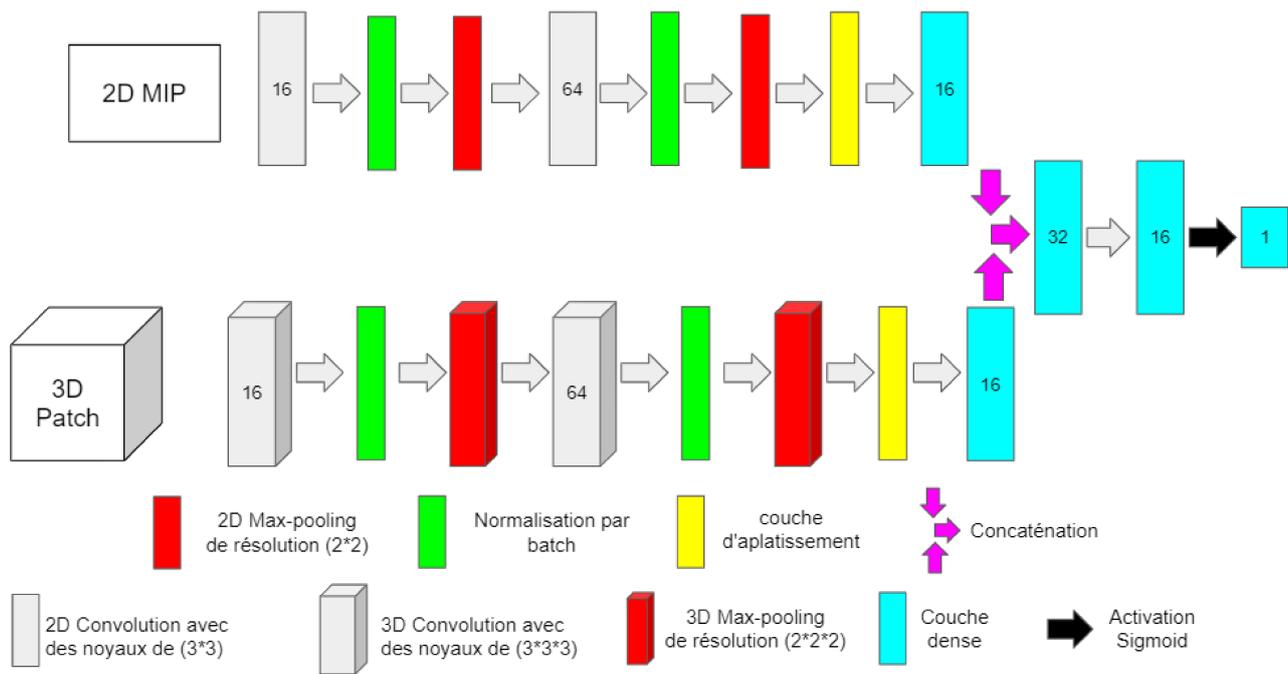


FIGURE 7.4 – Modèle à double entrées hybride 3D et 2,5D et à sortie unique

7.2.3 AneurysmNet

AneurysmNet est le modèle d'apprentissage profond à double entrées et à sortie unique qui constitue le fondement de notre pipeline de détection. Il utilise des données hybrides en entrée, ce qui lui permet d'exploiter les avantages des patches 3D et des MIP 2D pour obtenir de meilleures performances de détection. Cette méthode permet d'obtenir des performances équivalentes à celles d'une inspection visuelle humaine grâce à ses deux voies de traitement parallèles. Nous proposons d'effectuer une segmentation des anévrismes en utilisant une méthode de classification par patch. Ainsi, à partir d'un patch 3D isotrope \mathbf{P} , nous déterminons si ce dernier contient des signes d'irrégularités qui peuvent être qualifiées comme des anomalies d'anévrisme. Comme mentionné dans la section 7.1, les méthodes de l'état de l'art utilisaient des images 2D MIP qui se sont avérées efficaces. En partie, parce que les images MIP offrent plus d'informations qu'une coupe d'image 2D standard mais gardent également un coût de calcul raisonnable par rapport au traitement des volumes 3D.

Notre travail s'inspire de l'une des études pionnières qui a réussi à combiner les CNN et les MIP. Ce travail est celui de Nakao et al [193]. L'évaluation de l'image MIP repose sur l'axe le long duquel le volume 3D est projeté. Cette perte d'information peut être surmontée à un certain

degré en utilisant des projections multiples le long de plusieurs axes. En ce sens, cet ensemble de transformations résultantes offre plus de connaissances au modèle qu'une simple coupe 2D ou un MIP orthogonal. Malheureusement, cet effort ne compense pas la perte de la dimension de profondeur après les projections. De plus, les images MIP peuvent être trompeuses lorsque certaines structures de haute intensité bloquent les vaisseaux. D'un autre côté, l'utilisation de petits patchs 3D pour une tâche de classification avec un modèle contenant un grand nombre de paramètres peut conduire à un surapprentissage, une dégradation de la qualité de la carte de caractéristiques et une dilution de l'effort d'extraction. Heureusement, les travaux prometteurs de Hegde et al [205], qui ont montré de meilleures performances en utilisant des données hybrides (2D et 3D en même temps) que des données volumétriques uniquement, nous ont incités à privilégier une approche de modèle à double entrées et à sortie unique dans cette étude. Afin de déterminer finalement une probabilité postérieure de la présence d'un anévrisme dans une zone déterminée, notre CNN proposé prend comme entrée :

- (i) un patch volumique 3D de $(w \times w \times w)$ voxels avec une mesure de voxels isotrope v (en mm) centré sur un point $\mathbf{x} \in V$, V étant la zone artérielle segmentée.
- (ii) une image 2D $(w \times (n * w))$ en transformation MIP avec n projections

Les valeurs de w et v dépendent des dimensions du vaisseau. Ensemble, elles déterminent la résolution d'entrée et le champ réceptif physique du CNN en coordonnées spatiales. Ici,

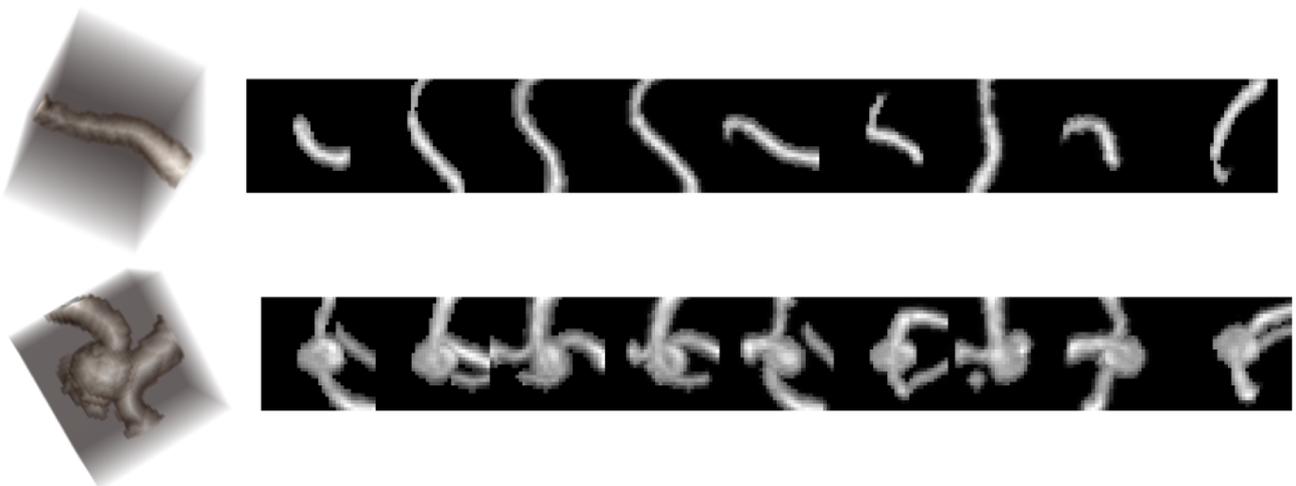


FIGURE 7.5 – **Les types d'entrée** : la première ligne est une représentation d'un vaisseau sain en 3D et MIP, tandis que la deuxième ligne est l'illustration d'un vaisseau contenant un anévrisme intracrânien.

$w = 16$ pixels et $v = 0,5$ mm, sont choisis pour suffisamment envelopper un champ récepteur physique de 8 mm qui devrait contenir le volume entier de l'artère. Le nombre $n = 9$ couvre les projections le long des axes x , y , z , xy , yx , xz , zx , yz et zy . Comme le montre la figure 7.5, nous pouvons clairement remarquer la disparité entre la distribution ou la forme d'un vaisseau sain, bien allongé (ligne du haut) et un anévrisme ou, dans de nombreux cas, une bifurcation ou des zones fortement courbées (ligne du bas).

Le réseau, comme le montre la Fig 7.4, est constitué de deux canaux parallèles presque identiques. Chaque canal contient deux couches convolutionnelles (3×3 noyaux pour 2D, $3 \times 3 \times 3$ pour 3D), deux couches de max-pooling (2×2 pour 2D, $2 \times 2 \times 2$ pour 3D) et une couche entièrement connectée. La seule différence est que le premier canal est un canal de traitement en 2D tandis que le second est configuré pour la 3D. La sortie de chaque canal est concaténée et envoyée à une couche entièrement connectée pour combiner les deux cartes de caractéristiques extraites. Nous utilisons l'unité linéaire rectifiée (ReLU) comme fonction d'activation pour toutes les couches, sauf la dernière. La couche de sortie a une seule unité, et la fonction logistique est appliquée à la sortie pour décider sur les valeurs de la carte de caractéristiques amalgamées, la probabilité qu'une entrée soit positive (malsaine, contient un anévrisme) ou négative (saine, ne contient pas d'anévrisme).

7.2.4 Post-treatment

Le partitionnement en patches implique que notre modèle ne permet pas une segmentation immédiate de l'anévrisme mais une cascade de prédictions qui crée la structure complète. Une telle approche peut parfois produire des valeurs aberrantes qui n'appartiennent pas à une structure réelle. Elles sont formées par un petit nombre de pixels qui peuvent ne pas être qualifiés d'anévrisme. La taille du volume de l'anévrisme en coordonnées réelles peut être approximée par l'équation générale du volume de la sphère :

$$V = \frac{4}{3}\pi\left(\frac{R}{v}\right)^3 \quad (7.1)$$

R étant le rayon de l'anévrisme en mm et v étant l'espacement des voxels. Le plus petit anévrisme présent dans l'ensemble de données ADAM a un rayon de $0,7mm$, ce qui correspond à un volume de $11,5$ pixels. Ces valeurs peuvent être confirmées dans la fig.7.6 où la taille de l'anévrisme a un minimum de 12 voxels. Sur la base de ce fait, nous éliminons toutes les structures prédites qui ont un volume global inférieur à 10 voxels.

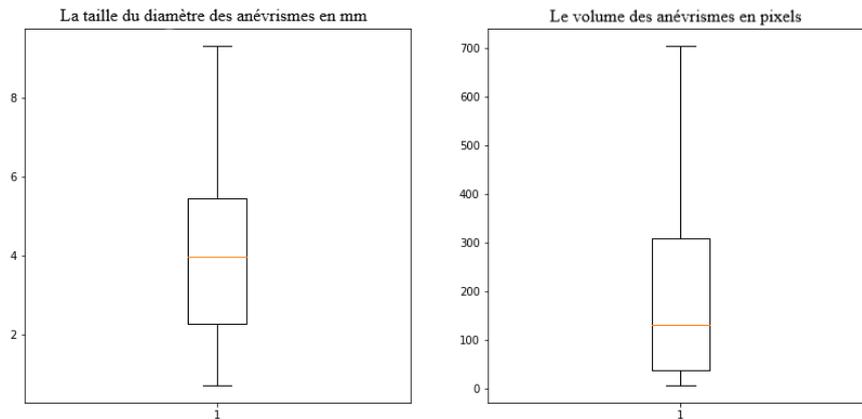


FIGURE 7.6 – Une correspondance entre le rayon de l'anévrisme en mm (à gauche) et la taille de son volume total en coordonnées réelles (en voxel).

7.3 Expérimentations

7.3.1 Détails de l'implémentation

L'algorithme de détection et de segmentation des anévrismes a été réalisé en python 3.7 avec les bibliothèques Tensorflow et Keras [206]. Le réseau est entraîné avec une mesure d'entropie croisée binaire sur chaque patch pour évaluer la qualité de la prédiction qu'un patch donné contienne un anévrisme ou non. Nous initialisons les poids de la convolution et des couches denses avec la distribution uniforme de Xavier [207]. Tous les biais sont initialisés à 0. Nous entraînons le réseau pendant 1000 époques en faisant le choix d'un arrêt précoce si l'entropie croisée globale sur les données de validation atteint un seuil de 10^{-8} ou si elle ne diminue plus pendant 50 époques. Nous estimons les paramètres optimum du réseau en utilisant l'optimiseur d'Adam [208] avec un taux d'apprentissage de 0,001, $\beta_1 = 0,9$, $\beta_2 = 0,999$, $\epsilon = 10^{-8}$ et une décroissance $\eta = 10^{-6}$. En raison des restrictions de mémoire découlant de la nature hybride

du modèle, nous optons pour une taille de lot (batch size) de 1028. Toutes les expériences ont été réalisées sur une station de travail avec Intel Core i7-7820HQ utilisant une carte graphique NVidia Quadro M1200 4 Go.

7.3.2 Évaluation

Notre méthode a été évaluée dans le cadre du défi ADAM [199] qui a pris place dans la conférence MICCAI 2020, ce qui nous permet de comparer notre algorithme à ceux des autres participants. Le défi ADAM propose deux tâches distinctes. La première est une tâche de détection. Il est demandé aux participants de fournir le centre de gravité de l'anévrisme suspect en coordonnées réelles. Soit G_p et G_t le centre de gravité prédit et le centre de gravité réel respectivement, R le rayon de l'anévrisme fourni par le comité ADAM et v l'espacement des voxels. Si $\|G_t - G_p\| \leq \frac{R}{v}$, la détection est considérée comme correcte puisque la structure prédite se trouve dans le rayon de l'anévrisme réel. L'évaluation des performances de l'algorithme pour la première tâche est basée sur la sensibilité et le nombre de faux positifs par cas calculés comme indiqué dans les équations ci-dessous :

$$Sensitivity = \frac{TP}{T} \quad (7.2)$$

$$False\ positive\ per\ case(FP/c) = N - TP \quad (7.3)$$

avec N le nombre d'anévrismes prédits, T le nombre d'anévrismes fournis et TP le nombre de prédictions correctes. Pour le défi ADAM, les équipes participantes sont classées du meilleur au pire en fonction de leur score relatif dans chaque métrique (0 étant le meilleur, 1 étant le pire). Le rang final est calculé en fonction de la moyenne des rangs obtenus pour les différentes métriques. Le deuxième aspect de l'évaluation est réalisé en utilisant trois métriques supplémentaires pour la deuxième tâche de segmentation qui sont le coefficient de similarité de Dice, la distance de Hausdroff et enfin la similarité volumétrique. En fait, le coefficient de Dice est la mesure de validation principale pour évaluer la segmentation d'images ou de volumes. Il est défini comme suit :

$$DSC = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (7.4)$$

où FN est le nombre d'anévrismes que le modèle n'a pas réussi à détecter, TP et FP sont définis ci-dessus dans l'équation 7.2. De son côté, la distance de Hausdroff mesure principalement la précision de la limite de la segmentation par rapport à la vérité terrain. Il s'agit d'une évaluation de la forme de la structure prédite et de sa compatibilité avec le véritable anévrisme. En ajoutant à cela la notion de similarité volumétrique, l'évaluation contiendra par conséquent une meilleure compréhension des changements de volume (explicitement la croissance des anévrismes prédits) dans la segmentation automatique. Soit V_p le volume prédit, V_g la segmentation de la vérité terrain et $d(x, y)$ la fonction de distance euclidienne. La distance de Hausdroff (MHD) et la similarité volumétrique (VS) sont définies respectivement comme suit :

$$MHD(V_p, V_g) = \max \{ \sup_{x \in V_p} \inf_{y \in V_g} d(x, y), \sup_{y \in V_g} \inf_{x \in V_p} d(x, y) \} \quad (7.5)$$

$$VS = 1 - \frac{|FN - FP|}{2TP + FN + FP} \quad (7.6)$$

Une description plus détaillée de ces métriques et de la justification de leur choix comme norme d'évaluation peut être trouvée dans [199].

7.4 Résultats

Modèle	Sensibilité	FP/c
2.5 MIP	98.23%	8.04
Double-Entrée	92.34%	4.76
Double-Entrée + Normalisation	91.76%	3.25

TABLE 7.1 – La sensibilité en % et le taux des faux-positifs par cas pour le modèle 2.5 MIP et notre segmentation proposée avec et sans normalisation de toutes les images de l'ensemble de données de validation ADAM que nous avons partitionné localement.

Tout d'abord, nous fournissons des résultats d'évaluation de notre proposition de CNN à double-entrée unique-sortie et de notre mise en œuvre de l'algorithme MIP uniquement [193]. La sensibilité et le taux des FP/c sont présentés dans la table 7.1, où les améliorations lors de l'ajout du deuxième canal sont très proéminentes, notamment en réduisant le rapport FP/c de moitié. Nous soulignons également la contribution de la normalisation de Nyul et Udupa qui permet

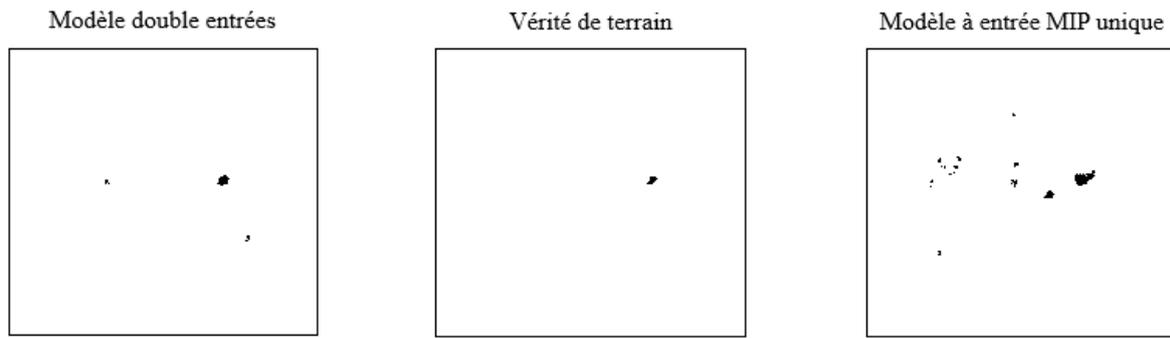


FIGURE 7.7 – **Un cas de réduction des faux-positifs** : bien que le modèle proposé ait détecté le véritable anévrisme et éliminé 11 faux positifs, il a détecté un faux anévrisme qui n'a pas été détecté par le modèle 2,5D MIP (les anévrismes sont représentés en noir alors que le fond est en blanc, l'inversion des couleurs est pour des fins d'affichage)

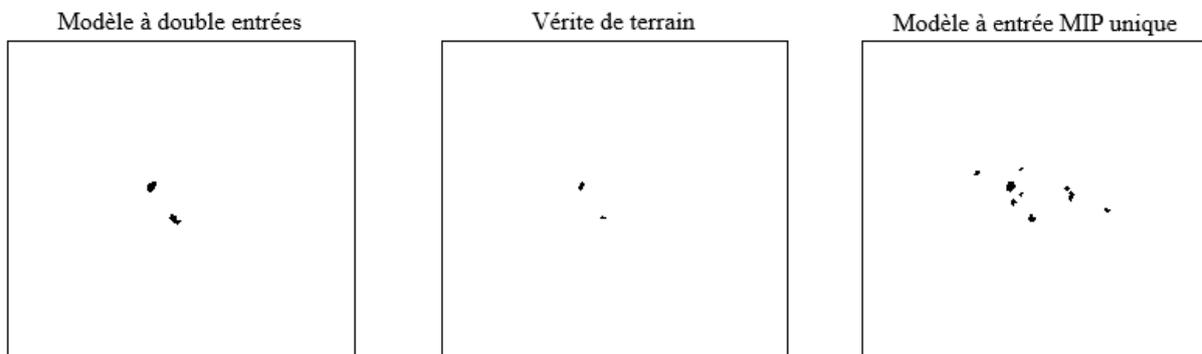
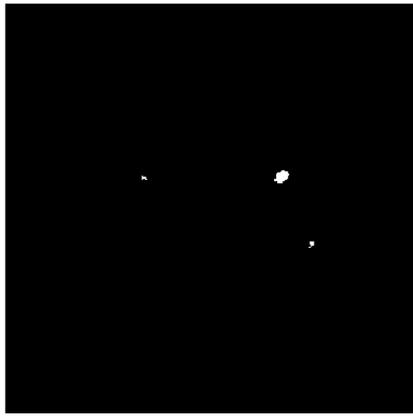


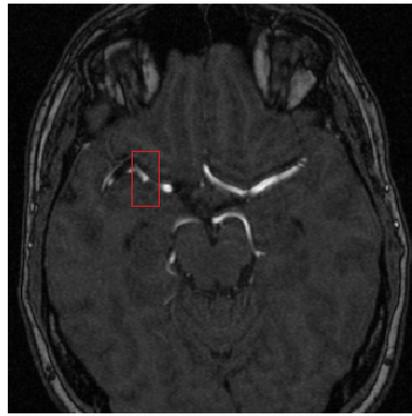
FIGURE 7.8 – **Un cas de 100 % de sensibilité et 0 faux-positif par cas** : le modèle proposé élimine les fausses détections produites par le modèle de base à un seul canal tout en gardant les vrais anévrismes (les anévrismes sont représentés en noir et l'arrière-plan en blanc, l'inversion des couleurs est destinée à l'affichage).

de réduire le rapport susmentionné de 1,5 par cas. Cette augmentation des performances est principalement due à l'amélioration du processus d'extraction des vaisseaux, comme le montre la figure 7.2.

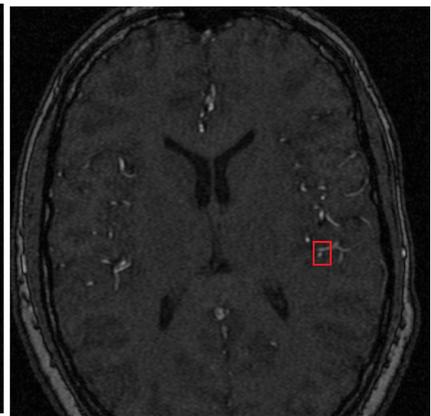
Comme l'analyse statistique confirme notre approche, nous passons à l'évaluation visuelle des prédictions. Comme le montre la fig.7.7, le modèle proposé a détecté avec succès l'anévrisme présent dans l'ensemble de données de vérité-terrain et a éliminé plus de 11 faux positifs précédemment prédits. Néanmoins, il a introduit une nouvelle fausse détection qui prouve à un certain degré que le modèle à double entrées offre une interprétation différente des données et pas seulement un outil d'élimination des faux anévrismes qui base la prédiction sur le canal 2D. La fig.7.8 présente une situation de détection parfaite avec une sensibilité de 100 % et



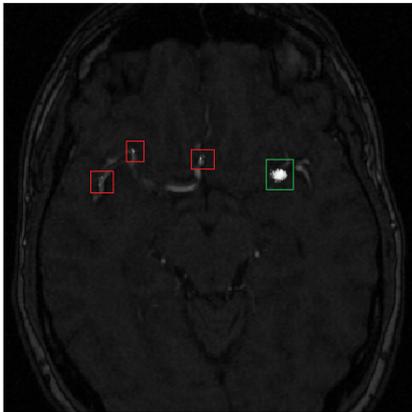
(a) La prédiction complète du modèle hybride. Le résultat est projeté pour un affichage en 2D



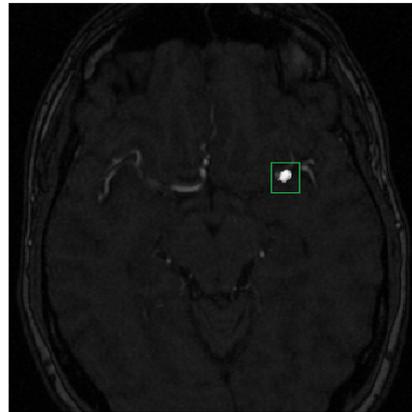
(b) La première fausse prédiction est une petite bosse à l'extérieur du vaisseau artériel.



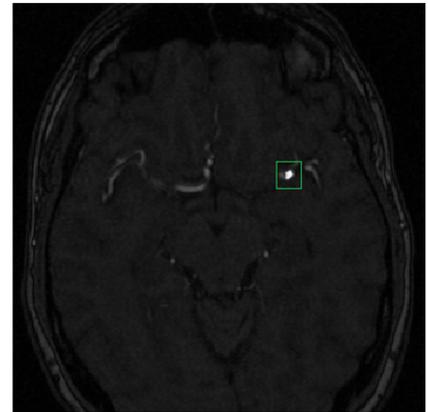
(c) La deuxième fausse prédiction est l'apparition d'une petite branche en dehors d'un vaisseau secondaire.



(d) La prédiction du modèle 2.5 MIP qui contient une détection correcte mais plus grande de l'anévrisme réel et trois autres fausses prédictions sur la même profondeur.



(e) La prédiction correcte de l'anévrisme par le Double-Entrée Unique-Sortie, la taille est plus grande que l'anévrisme réel mais plus petite que la prédiction du modèle MIP.



(f) L'emplacement de l'anévrisme de la vérité de terrain est mis en évidence en blanc gras. L'anévrisme est de taille moyenne avec un rayon d'un peu plus de 4 mm.

FIGURE 7.9 – Un cas de prédiction de 100% de sensibilité de 2 faux positifs par le modèle proposé. La prédiction complète est illustrée en (a). Les figures (b) et (c) soulignent les faux positifs prédits. La ligne en dessous compare la vérité de terrain, les résultats des modèles MIP et hybride sur le même profondeur (même coupe du volume MRA).

aucun faux positif détecté. Bien que le modèle original ait produit 7 faux positifs, le nouveau modèle proposé les élimine tous en ne conservant que les vrais anévrismes. Cela confirme que le modèle est fortement capable d'une détection parfaite sans produire de prédictions bruitées. En revenant à la fig.7.9b, une petite bosse sur l'extérieur de la paroi artérielle est prédite comme un anévrisme de 0,74 mm de rayon (le plus petit rayon que nous autorisons est de 0,7 mm). La deuxième prédiction erronée, comme le montre la fig.7.9c, se produit sur une bifurcation

d'une petite branche et d'un vaisseau secondaire, ce qui donne un anévrisme de 0,76 mm de rayon. En poursuivant la comparaison entre les deux modèles, nous soulignons dans la fig.7.9f la tendance continuelle du modèle 2.5 MIP à détecter le virage à angle élevé des vaisseaux ou le détour soudain pris par les artères sous forme d'anévrisme. Cela peut s'expliquer par le fait que les images MIP perdent la dimension de profondeur et qu'il devient donc difficile de distinguer le chevauchement des vaisseaux à ces endroits. Nous pouvons voir sur la fig.7.10 que la plupart des fausses prédictions ont un petit rayon pour les deux modèles mais que le modèle hybride a une moyenne (1,05 à 0,98 mm) et une médiane (0,89 à 0,85 mm) supérieures, ce qui suggère que l'une des contributions de l'approche hybride est la suppression de ces petites prédictions d'artefacts bruités.

Motivés par les résultats préliminaires obtenus à partir de la configuration locale de test (50 % pour l'entraînement, 20 % pour la validation et 30 % pour le test), nous avons soumis notre modèle hybride pour évaluer ses performances sur les 142 IRM de l'ensemble de test dont nous n'avons pas accès. L'évaluation est faite par le comité ADAM et les résultats sont résumés dans la table 7.2. Notre modèle est classé quatrième dans le score global parmi 11 participants. Nous avons obtenu la meilleure sensibilité du défi avec 70%, ce qui nous a propulsé à la cinquième place du premier défi, à seulement 0,06 points de la première place. L'équipe de la première place n'a participé qu'au défi de la détection et a utilisé le Retina U-net couplé à un réseau

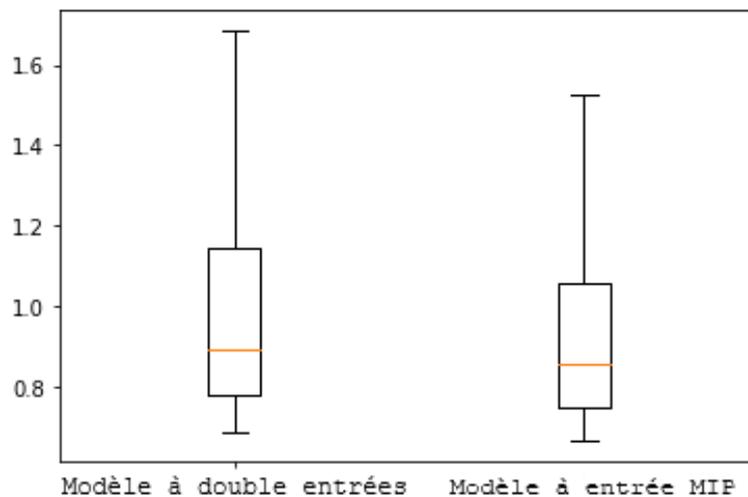


FIGURE 7.10 – Le rayon en *mm* des fausses prédictions pour le modèle Double-Entrée Unique-Sortie ainsi que pour le modèle classique

TABLE 7.2 – Résultats sur le jeu de données de test du défi ADAM (base de données privée et non publique)[209]

Equipe	Sensibilité	FP/C	Score(1 ^{er} défi)	DSC	MHD(mm)	VS	Score(2 ^{ème} défi)	Score(Total)
mibaumgartner	66%	0.14	0.03	Nan	Nan	Nan	Nan	Nan
Junma	61%	0.18	0.07	41%	8.96	50%	0.00	0.035
Joker	63%	0.16	0.06	40%	8.67	48%	0.02	0.04
Kubiac	60%	0.36	0.08	28%	18.13	39%	0.24	0.16
Xlim (ours)	70%	4.02	0.09	21%	36.82	39%	0.41	0.25
Inteneural	49%	0.88	0.17	17%	23.98	36%	0.39	0.28
Zelosmediacorp	21%	0.05	0.36	9%	9.76	13%	0.52	0.44
Stronger	20%	0.45	0.38	7%	24.42	21%	0.57	0.475
Tum_Ibbm	43%	22.67	0.70	7%	65.02	31%	0.31	0.505
Ibbm	2%	0.01	0.50	1%	12.77	1%	0.69	0.595
Unil_Chuv	20%	1.45	0.40	Nan	Nan	Nan	Nan	Nan

d'agrégation de chemins pour produire les prédictions finales comme point central des boîtes englobantes. Quant aux équipes Junma et Joker, elles ont utilisé respectivement le 3D U-net et le No New-Net (une variation du U-net) couplés à une fonction de perte d'ensemble pour le premier (perte Dice + entropie croisée + perte TopK) et quatre modèles distincts "assemblés" avec vote majoritaire pour le second. Même si notre approche par patch ne favorise pas une grande précision de segmentation volumétrique (VS), l'approche hybride proposée parvient à se placer dans les trois premières places en VS avec 39% et dans les quatre premières places en DSC avec 21%. Il convient de mentionner que plusieurs algorithmes participants ont utilisé un seuil de faux positifs comme étape de post-traitement pour limiter le nombre de sorties d'anévrisme. Cette approche a donné lieu à de nombreux modèles présentant un très faible ratio de faux positifs par cas, mais également une faible sensibilité. Elle a également exposé notre méthode à un rang inférieur dans la métrique des faux positifs par cas puisque notre modèle n'a pas de critère de seuil pour le nombre autorisé d'anévrismes. De plus, le DSC souffre de la prédiction de certains faux-positifs pour un patient sain. Une petite erreur sur les scans négatifs

TABLE 7.3 – L'évaluation de la deuxième tâche pour les 5 meilleures équipes sur les scans positifs uniquement (patients ayant au moins un anévrisme) et les résultats de l'entraînement par rapport à la sensibilité des tests sur les deux ensembles de données complets.[199]

Place	Equipe	DSC	MHD	VS	Rang	Sensibilité d'entraînement	Sensibilité de test	Diff sensibilité
1	Junma	64%	2.62	71%	0	94%	64%	-33%
2	Joker	60%	2.95	66%	0.11	92%	63%	-29%
3	Kubiac	45%	4.95	53%	0.53	100%	60%	-40%
4	Xlim	40%	6.55	58%	0.61	89%	70%	-19%
8	Inteneural	34%	5.76	42%	0.8	96%	67%	-29%

est évaluée comme un zéro automatique. Pour cela, nous fournissons également l'analyse des scans positifs dans la table 7.3 ci-dessous. Comme indiqué précédemment, les performances du modèle s'améliorent considérablement (presque par un facteur de 2) sur les cas positifs, ce qui prouve que cette évaluation n'augurait rien de bon avec notre approche de cette tâche (ne pas limiter le nombre de faux positifs par cas). Notre modèle a gagné une place lorsqu'il a été testé sur ce sous-ensemble de patients tout en conservant la troisième meilleure valeur VS avec 58% contre 38% pour l'ensemble de test. En outre, pour évaluer la capacité de généralisation de notre algorithme, nous nous référons à la même table 7.3 ci-dessus. Bien que parmi les équipes les plus performantes, notre modèle soit le moins apte à détecter un anévrisme sur l'ensemble d'entraînement, il exprime une grande capacité de généralisation sur un ensemble de test très difficile en obtenant la meilleure sensibilité sur les données susmentionnées et le meilleur rapport de différence qui peut finalement mesurer la capacité de généralisation globale des modèles. Pour investiguer davantage le taux de détection, nous déterminons la performance du modèle en fonction de la taille de l'anévrisme. De toute évidence, plus la taille de l'anévrisme est élevée, plus il risque de se rompre et de constituer un danger clinique. Comme on pouvait le prévoir, la sensibilité de la plupart des algorithmes augmente avec le diamètre de l'anévrisme, mais comme le montre la fig. 7.11, notre modèle présente la meilleure sensibilité pour les classes d'anévrismes petits, grands et surtout sévères. Selon les neurologues, la détection visuelle humaine présente une sensibilité moyenne de 38 % pour les anévrismes de moins de 3 mm et de 94 % pour les autres, comme indiqué par [210]. Notre modèle est donc conforme à l'inspection visuelle

humaine tout en offrant une meilleure sensibilité pour les petites structures et un rappel très élevé pour les plus risquées. Cette performance du modèle pourrait être éclipsée par le faible DSC obtenu, qui est en soi une mesure très difficile pour mesurer de petits objets qui comptent principalement une dizaine de voxels et qui peut être encore plus réduite lorsque l'on standardise à une taille de voxel commune et pratique pour tous les ensembles de données. Le chevauchement devient de moins en moins improbable, ce qui se traduit par un mauvais DSC.

7.5 Discussion

Nous avons présenté notre méthode basée sur l'apprentissage profond pour la segmentation d'anévrismes intracrâniens en 3D TOF-MRA. Nos expériences ont montré que le modèle hybride était capable de fournir des connaissances pertinentes sur les anomalies présentées dans les vaisseaux artériels à une position donnée. Ce modèle a obtenu d'excellents résultats en matière

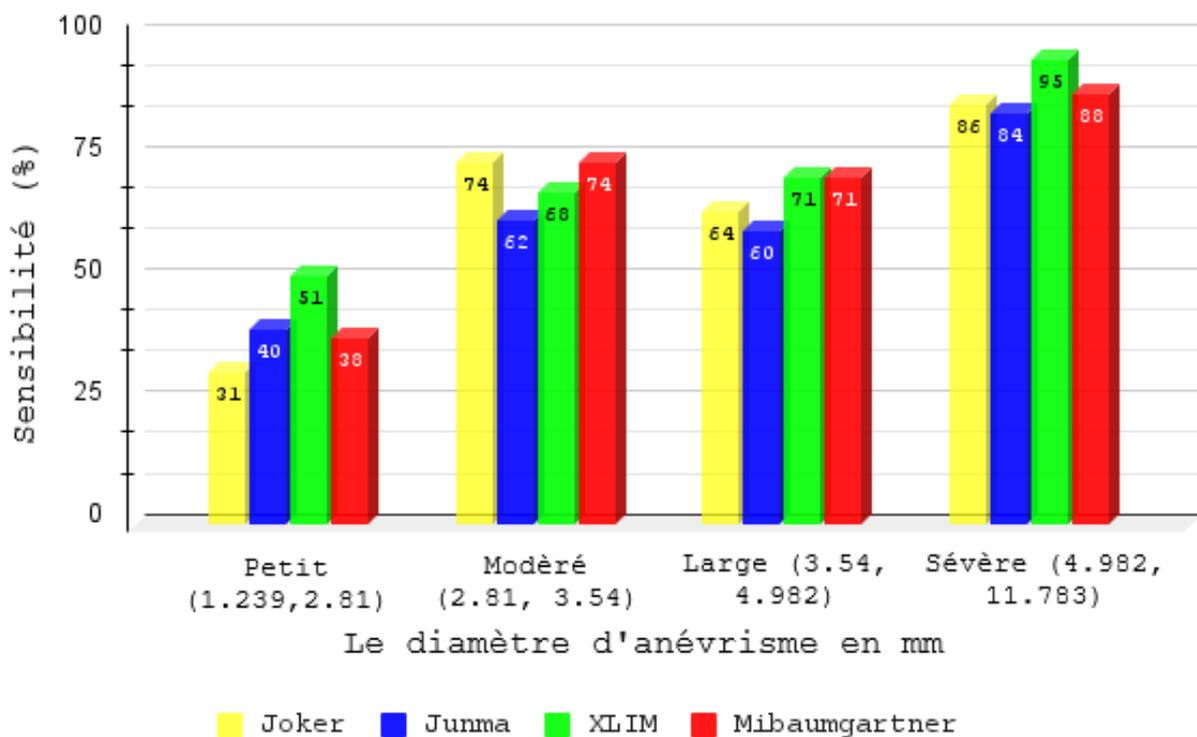


FIGURE 7.11 – La sensibilité de détection en fonction du diamètre de l'anévrisme pour les 3 équipes les plus performantes du challenge en comparaison avec notre algorithme. Le diamètre de l'anévrisme est divisé en quatre quartiles (principalement les classes petite, modérée, grande et sévère). [199]

de détection et de segmentation, se classant au quatrième rang parmi les 11 résultats publiés pour les 142 images TOF-MRA de test du cadre d'évaluation du défi ADAM.

Les méthodes classées premier et second ont exigé un volume 3D complet avec une fonction de coût d'ensemble qui couvre les métriques d'évaluation présentées dans le défi. L'équipe classée troisième a proposé un ensemble de 18 réseaux neuronaux qui se compose de 2 architectures CNN différentes, à savoir un U-net encodeur-décodeur à double entrées (volumes 3D à basse et haute résolution en entrée) et un CNN à double chemin (ne contient pas de couches de pooling). Ces modèles sont entraînés avec une fonction de coût d'ensemble et ils ajoutent une autre variante de l'encodeur-décodeur U-net entraîné sur du simple Dice au lieu du Dice généralisé. L'entraînement est effectué sur 6 ensembles différents de groupes, ce qui porte le total à 18 réseaux neuronaux dont la moyenne des prédictions sera calculée ultérieurement pour prédire l'existence d'anévrismes.

Notre méthode, en revanche, ne nécessite que de petits patches 3D (pour éviter l'énorme coût de calcul d'un volume TOF complet) et une seule exécution du réseau neuronal. Sur la base de l'extraction des vaisseaux, notre modèle sera capable de segmenter les vaisseaux extraits en se basant sur la distribution de probabilité fournie par notre unique fonction de perte d'entropie binaire croisée. La sensibilité des anévrismes extraits était la plus élevée du défi avec une moyenne de 70 %.

Notre méthode hybride est un modèle supervisé qui nécessite éventuellement des données d'entraînement représentatives. Par conséquent, une annotation de la vérité du terrain est nécessaire. Heureusement, avec l'approche de partitionnement par patch, un petit nombre de patients peut suffire pour entraîner le modèle. L'exigence d'un nombre limité de données d'entraînement renforce la portabilité de la méthode, ce qui facilite son application à d'autres tâches. La transférabilité de cette méthode à d'autres applications dépend de la bonne configuration de certains hyperparamètres qui conduiront à la configuration parfaite pour les nouvelles données. D'une part, le champ réceptif physique des couches convolutionnelles doit être déterminé par la taille des structures ciblées. La première dépend de la largeur du patch w (en voxels) et de la largeur du voxel v (en mm). D'autre part, les images MIP peuvent être ajustées pour inclure plus ou

moins de projections du patch 3D (n est le nombre de projections). L'architecture illustrée à la Fig 7.4 peut facilement être réduite ou étendue pour s'adapter à différentes valeurs de w , v et n .

7.6 Conclusion

L'objectif de ce chapitre était la proposition d'une nouvelle méthode de la détection et la segmentation des anévrismes intracrâniens non rompu qui rectifie le manque constaté d'automatisation de quelques approches et l'unidimensionnalité des autres après l'étude approfondie de l'état de l'art.

Suite au manque perçu lors de l'analyse de l'état de l'art et à l'issue de nos travaux, nous proposons une nouvelle méthode reposant sur une double entrées de données hybrides (2D MIPs et 3D) qui a atteint la meilleure sensibilité lors du défi ADAM et se compare aux performances de l'inspection visuelle humaine. Le centre de notre pipeline est un modèle d'apprentissage profond qui est associé à un bloc de pré-traitement complet et, ensemble, ils présentent un fort potentiel de généralisation sur des bases de données difficiles. Enfin, l'adaptation de l'approche de partitionnement par patch permet de contourner les limites de mémoire et de calcul ainsi que la rareté des données.

Nous avons présenté ensuite dans ce chapitre des résultats qui montrent que des données d'entrée hybrides permettent au CNN de bénéficier simultanément d'information différentes provenant du 2D MIP et des patches 3D bruts pour détecter les anévrismes avec une sensibilité et une précision élevées. Cette méthode ne nécessite ni l'extraction manuelle de caractéristiques, ni l'utilisation de filtres préétablis pour déterminer la localisation et la taille de l'anévrisme intracrânien, mais utilise au contraire un CNN pour accomplir directement cette tâche à partir d'images TOF. Ce modèle peut être entraîné à détecter d'autres anomalies des vaisseaux, comme les sténoses, ce qui le rend utilisable pour d'autres applications.

En pratique, les neurologues experts préfèrent un taux de sensibilité élevé à un faible taux de faux positifs par cas. Il est plus facile et surtout moins fastidieux d'écarter les prédictions

bruitées lorsqu'elles sont à un taux acceptable que d'examiner le volume MRA entier du patient à la recherche d'anévrismes non détectés. C'est pourquoi nous n'avons pas introduit un seuil maximal de nombre d'anévrismes prédits, lequel aurait probablement pu nuire à la sensibilité du modèle.

Chapitre 8

Conclusion et perspectives

8.1 Conclusion générale

Les maladies cardiovasculaires et les accidents vasculaires cérébrales ont longtemps été la principale cause de décès en France, comme dans de nombreux pays. Depuis quelques années, elles se situent en France au deuxième rang des causes de mortalité, après les tumeurs, du fait d'une diminution continue du nombre de décès cardiovasculaires en lien avec l'amélioration de la prévention et de la prise en charge thérapeutique. Néanmoins, chez la femme, ces maladies restent la première cause de mortalité.

Le développement de techniques de traitement d'images et d'intelligence artificielle en particulier, a entraîné une évolution importante dans l'imagerie médicale. Il permet une systématisation poussée dans l'analyse des images et des propositions de diagnostics, permettant au médecin de se concentrer sur les points essentiels. Dans ce contexte, cette thèse s'intéresse à l'étude et l'élaboration de techniques d'intelligence artificielle pour l'analyse de données à caractère biomédical en vue de la prévention des risques cardiovasculaires (sténoses) et les accidents vasculaires cérébrales (anévrismes).

Dans cette thèse, nous avons fait face à plusieurs défis scientifiques du domaine de l'imagerie médicale notamment l'extraction des structures vasculaires, la détection de la sténose et la segmentation des anévrismes intracrâniens non rompus. Ce travail a impliqué une interaction

pluridisciplinaire, ce qui nous a permis de mieux comprendre les problèmes à traiter et d'acquérir des connaissances supplémentaires utiles à leur résolution. En particulier, nos approches bénéficient des connaissances anatomiques afin d'améliorer la précision et la robustesse des différents modèles proposés. Ces connaissances sont intégrées dans les différents algorithmes à différents niveaux : le pré-traitement, la caractérisation des structures cibles et la réduction des fausses détections en post-traitement. Toutes les méthodes proposées exploitent une combinaison de techniques classiques de traitement d'image et de méthodes d'apprentissage profond. La majorité de nos contributions scientifiques et les résultats inclus dans cette thèse ont été publiés dans des conférences internationales et des revues au cours des trois dernières années.

L'extraction des artères coronaires est une étape cruciale vers l'objectif principale de la détection et classification de la sténose. Ainsi, le chapitre 5 décrit notre proposition d'un pipeline complet qui traite la problématique de l'extraction de l'arbre artériel coronaire à partir des images CT. Nous avons exploré les multiples difficultés attachées à ce défi et nous avons réussi à mettre en place deux versions d'un modèle qui répondent aux plusieurs besoins influençant la robustesse de la performance du pipeline proposé. Il s'agit d'un CNN 3D utilisé comme détecteur local de la ligne centrale des artères coronaires, remplaçant ainsi les filtres et des fonctions de coût manuels utilisés pour l'identification des vaisseaux. Cette approche a donné des excellents résultats d'extraction sur les jeux de données de Rotterdam [163] avec un taux de 95,48%. Néanmoins, après avoir testé cette méthode sur le jeu de donnée de CHU Poitiers, nous avons identifié quelques défauts notamment l'incapacité de gérer les interruptions dans l'arbre artériel. C'est pourquoi, nous avons proposé une deuxième version améliorée du pipeline original qui est équipé d'un modèle d'analyse intelligente des composants connectés. C'est un mécanisme de contrôle et de récupération des artères interrompues. Nous avons aussi remplacé l'algorithme de détection de la région cardiaque par un modèle de segmentation des sept sous-structures du coeur. Ce dernier pourrait être utilisé, indépendamment, dans différentes applications cliniques telles que la définition des axes du coeur, la génération des différentes vues des cavités cardiaques, l'investigation des maladies cardiaques et vasculaires et le guidage en temps réel de procédures d'interventions.

Dans le chapitre 6, nous sommes intéressés à l'étude des maladies coronariennes et principa-

lement la détection de la sténose et la classification des plaques. Nous étions inspiré par le processus clinique réel pour mettre en place notre modèle de détection des lésions. En effet, l’alignement des artères est un processus fréquent dans l’usage clinique et fournit une visualisation simpliste de l’arbre artériel et les lésions. Par conséquent, nous avons proposé d’appliquer la transformation cMPR pour éviter les problématiques de segmentation des artères et s’appuyer sur l’extraction efficace des lignes centrales par notre méthode d’identification des artères coronaires. Malheureusement, la cMPR est une technique très vulnérable à la qualité de cette extraction. C’est pourquoi, nous avons implémenté un module de pré-traitement qui corrige et améliore cette reconstruction. Nous avons montré que notre modèle hybride proposé à double entrées 3D qui combine les volumes reconstruites et les volumes corrigés, a obtenu des performances supérieures à celui qui utilise du cMPR uniquement.

Nous avons conclu ce chapitre par l’introduction d’une méthode qui se rajoute à celle de la détection de sténose pour prédire le type de calcification (doux, calcifiée, mixte). L’ensemble de ces méthodes ont été évalué et testé sur le jeu de données du CHU Poitiers en obtenant de bonnes performances.

Au cours du chapitre 7, nous avons étudié le thème des accidents vasculaires cérébrales et notamment la rupture des anévrismes intracrâniens. Les anévrismes sont généralement découverts dans deux situations radicalement différentes. Soit lors d’une IRM réalisée à la recherche d’une autre pathologie cérébrale et, dans ce cas, l’anévrisme découvert n’est pas rompu, soit lors de la recherche d’une cause d’hémorragie sous-arachnoïdienne et, dans ce cas, l’anévrisme est déjà rompu (le scanner est privilégié). C’est pourquoi, et pour renforcer le cadre préventive dans lequel cette thèse s’inscrit, nous avons introduit une nouvelle méthode reposant sur un CNN à double entrées de données hybrides (2D MIPs et 3D) pour la segmentation des anévrismes intracrâniens non rompu à partir des images MRA-TOF. Celle-ci a atteint la meilleure sensibilité lors du défi ADAM [199] et se compare aux performances de l’inspection visuelle humaine.

Finalement, bien que le chapitre 4 porte sur les différents jeux de données et métriques d’évaluation utilisés pendant cette thèse, nous avons consacré une grande partie pour la description du jeu de données de CHU Poitiers que nous avons mis en place. Ceci constitue l’une des contributions de ma thèse et couronne les efforts partagés des différentes parties prenantes dans cette

doctorat.

8.2 Perspectives

Nous avons démontré tout au long de cette thèse les bonnes performances de nos approches pour une extraction des artères coronaires de qualité. Cependant, certains points d'amélioration sont prévus pour augmenter la robustesse de l'approche. Les axes d'amélioration pour les travaux futurs devraient inclure la réduction du temps de calcul et l'utilisation de la segmentation des sous-structures du coeur comme étape de pré-traitement pour accélérer le processus. En outre, nous proposons d'ajouter une étape automatisée pour l'étiquetage des différents segments d'artères selon la norme AHA-17. Une telle implémentation permettra d'analyser les résultats de l'extraction des artères d'une manière analytique pour renforcer la robustesse des prédictions. L'approche proposée pourrait également être testée afin de filtrer d'autres types de structures vasculaires humaines ou animales.

Une deuxième perspective concernant la détection des sténoses est la réduction des faux positifs. Comme nous avons pu l'observer, notre modèle souffre principalement d'un nombre considérable de faux positifs. En outre, plusieurs sténoses non significatives ont été manquées par l'algorithme. Notre modèle a été entraîné sur un ensemble de données où les vaisseaux présentant un rétrécissement inférieur à 20% étaient étiquetés comme des vaisseaux sains. Le modèle a donc eu tendance à ignorer les petites sténoses. En outre, notre modèle est capable de différencier trois classes alors que la norme générale est d'utiliser CAD-RADS, une classification de 5 classes. Enfin, notre approche est basée sur une excellente extraction des artères coronaires. Par conséquent, le pipeline de détection des sténoses doit absolument être rattaché à un bon extracteur de lignes centrales.

Concernant la segmentation des anévrismes, nous avons plusieurs perspectives possibles qui permettront d'améliorer son potentiel. Malgré l'efficacité du modèle de la segmentation des anévrismes, certaines modifications et certains ajustements peuvent être mis en œuvre dans le cadre de travaux futurs pour améliorer son potentiel. Tout d'abord, l'ensemble des anévrismes

prédits peut être examiné par un classifieur post-traitement afin d'étudier plus en détail certains des faux positifs en fonction de leur topologie, de leur forme, de leur taille et bien d'autres connaissances médicales. Deuxièmement, la segmentation est mise à mal par le manque d'utilisation d'une fonction de coût adéquate. L'incorporation d'une fonction appropriée peut donc se révéler bénéfique pour l'amélioration des performances du modèle. Cependant, certaines des limites du modèle proposé sont principalement sa forte dépendance à l'égard d'un algorithme de segmentation des vaisseaux précis, qui a échoué dans trois cas dans l'ensemble d'entraînement ADAM, et l'approche par patches qui empêche le modèle d'examiner les données en vue globale.

Enfin, une étude peut être menée dans un environnement clinique réel pour évaluer la contribution de notre modèle au diagnostic des experts. Bien que nous offrons des algorithmes entièrement automatiques qui ne nécessitent pas des interactions, il faut permettre aux cliniciens d'ajuster, rectifier et agir sur l'ensemble des méthodes au cours de leur diagnostic. Cette étude peut porter sur le confort des experts quant à la manière de présenter les résultats obtenus. Afin de simplifier leur interprétation, nous pouvons proposer de standardiser leur visualisation sous la forme actuellement utilisée dans le milieu médical.

Références de nos publications

Saifeddine Rjiba, Thierry Urruty, Pascal Bourdon, Christine Fernandez-Maloigne, Roger Delepaule, Luc-Philippe Christiaens et Remy Guillevin : "*CenterlineNet : Automatic Coronary Artery Centerline Extraction for Computed Tomographic Angiographic Images Using Convolutional Neural Network Architectures*" dans International Conference on Image Processing Theory, Tools and Applications (IPTA), IEEE, 1-6, Nov 2020,

<https://doi.org/10.1109/IPTA50016.2020.9286458>

Kimberley M. Timmins, Irene C. van der Schaaf, Saifeddine Rjiba et al : "*Comparing methods of detecting and segmenting unruptured intracranial aneurysms on TOF-MRAS : The ADAM challenge*" dans NeuroImage, Volume 238, 2021,

<https://doi.org/10.1016/j.neuroimage.2021.118216>

Saifeddine Rjiba, Thierry Urruty, Pascal Bourdon, Guillaume Herpe, Christine Fernandez-Maloigne, Remy Guillevin : "*AneurysmNet : Deep Neural Network-Based Segmentation of Aneurysms in 3D-MR Angiography*" dans The International Journal for Computer Assisted Radiology and Surgery (IJCARS)". Cette soumission a été accepté en révisions majeurs le 5 Mai 2022.

Bibliographie

- [1] The surprising dangers of CT scans and X-rays, <https://www.consumerreports.org/cro/magazine/2015/01/the-surprising-dangers-of-ct-scans-and-x-rays/index.htm>, (Accessed on 01 04 2022)
- [2] Mikla Victor I. and Mikla Victor V. : Medical Imaging Technology. Elsevier, p. 37, ISBN 978-0-12-417036-0, (2013-08-23)
- [3] Aquilion ONE GENESIS Edition overview, Canon Medical Systems France. <https://fr.medical.canon/product-solutions/computed-tomography/product-solutionsgenesis-edition-overview/>, consulté le 20 avril 2022
- [4] Vitrea® Enterprise Suite, Canon Medical Systems, <https://fr.medical.canon/product-solutions/healthcare-it/vital-solutions/vitrea-advanced/vitrea-advanced-imaging-enterprise/>
- [5] Göran Bergström and Margaretha Persson and Martin Adiels et al. :Prevalence of subclinical coronary artery atherosclerosis in the general population. Circulation, 2021
- [6] Clinique de l'espoir tunisien, Comment calculer son IMC? <https://www.clinique-espoir-tunisie.fr/blog/comment-calculer-imc/>
- [7] Coeur, anatomie, rôle, opération, <https://sante.journaldesfemmes.fr/fiches-anatomie-et-examens/2526844-coeur-anatomie-role-operation-maladies-cardiovasc> consulté le 20 avril 2022
- [8] Artère coronaire : définition, schéma, rôle, combien en a-t-on?, <https://sante.journaldesfemmes.fr/fiches-anatomie-et-examens/>

- [2652141-artere-coronaire-definition-schema-role-circonflexe-droite-gauche/](#), consulté le 20 avril 2022
- [9] La chirurgie des artères coronaires, <https://chirurgie-cardiaque-artois.fr/index.php/pathologies-traitees/chirurgie-des-arteres-coronaires>, consulté le 20 avril 2022
- [10] Conseil de l'europe, L'IA c'est quoi, <https://www.coe.int/fr/web/artificial-intelligence/glossary>, "en ligne ; consulté le 17 avril 2021"
- [11] Arthur L. Samuel : Some studies in machine learning using the game of checkers. IBM Journal of research and development, (1959), 210-229
- [12] Overfitting and Methods of Addressing it, <https://analystprep.com/study-notes/cfa-level-2/quantitative-method/overfitting-methods-addressing/>, "en ligne, consulté le 26 avril 2022"
- [13] Andrej Karpathy : CS231n Convolutional Neural Networks for Visual Recognition, <http://cs231n.github.io/neural-networks-1/>, "en ligne ; consulté le 18 avril 2021"
- [14] Franck Rosenblatt : The Perceptron : A Probabilistic Model for Information Storage and Organization in The Brain, Psychological Review, 1958, 65–386
- [15] Marvin Minsky and Seymour Papert : Perceptrons : An Introduction to Computational Geometry, MIT Press, 1969, <https://www.bibsonomy.org/bibtex/206a5a6751b3e61408455fca2ed8d87fc/sb3000>
- [16] David E Rumelhart and Geoffrey E. Hinton and Ronald J Williams : Learning Internal Representations by Error Propagation, Parallel Distributed Processing : Explorations in the Microstructure of Cognition, Vol. 1, MIT Press, 1986, 318–362, <http://dl.acm.org/citation.cfm?id=104279.104293>
- [17] Fukushima Kunihiro : Neocognitron : A Self-Organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position, Biological Cybernetics, 1980, 193–202
- [18] Yann Lecun and Léon Bottou and Yoshua Bengio and Patrick Haffner : Gradient-based learning applied to document recognition, Proceedings of the IEEE, 1998, 2278–2324

- [19] vishrut singhal : What do you mean by Convolutional Neural Network?, <https://discuss.boardinfinity.com/t/what-do-you-mean-by-convolutional-neural-network/8533>, consulté le 16 avril 2022
- [20] Oliver Dürr and Beate Sick and Elvis Murina : Probabilistic Deep Learning With Python, Keras and TensorFlow Probability, October 2020, ISBN 9781617296079, 296 pages
- [21] Nanjing Nari and Xiaoyang Tan : Unsupervised feature learning with C-SVDDNet. Pattern Recognition. (2016), <https://doi.org/10.1016/j.patcog.2016.06.001>.
- [22] Abraham Montoya-Obeso : Recognition of Mexican cultural content with Deep learning networks. Image Processing [eess.IV]. Université de Bordeaux ; Instituto politécnico nacional (México), 2020.
- [23] Ajay Shrestha and Ausif Mahmood : Review of Deep Learning Algorithms and Architectures, in IEEE Access, vol. 7, pp. 53040-53065, 2019
- [24] Rocio Vargas, Amir Mosavi and Ramon Ruiz : Deep learning : A review, Proc. Advances in Intelligent Systems and Computing, pp. 1-11, 2017.
- [25] Ke Chen : Deep and modular neural networks, Springer Handbook of Computational Intelligence, Berlin, Germany, pp. 473-494, 2015.
- [26] Y. LeCun and K. Kavukcuoglu and C. Farabet, "Convolutional networks and applications in vision", Proc. IEEE Int. Symp. Circuits Syst., pp. 253-256, May/Jun. 2010
- [27] Deng Jia and Dong Wei and Socher Richard and Li Li-Jia and Li Kai and Fei-Fei Li : Imagenet : A large-scale hierarchical image database, 2009 IEEE conference on computer vision and pattern recognition, Ieee, 248–255, 2009
- [28] Simonyan Karen and Zisserman Andrew : Very Deep Convolutional Networks for Large-Scale Image Recognition, arXiv, 2014, <https://doi.org/10.48550/arxiv.1409.1556>
- [29] Christian Szegedy and Vincent Vanhoucke and Sergey Ioffe and Jon Shlens and Zbigniew Wojna : Rethinking the Inception Architecture for Computer Vision, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 2818-2826, <https://doi.org/10.1109/CVPR.2016.308>

- [30] Olaf Ronneberger and Philipp Fischer and Thomas Brox : U-Net : Convolutional Networks for Biomedical Image Segmentation. CoRR (2015) <http://arxiv.org/abs/1505.04597>
- [31] Ozan Oktay and Jo Schlemper and Loic Le Folgoc and Matthew Lee and Mattias Heinrich and Kazunari Misawa and Kensaku Mori and Steven McDonagh and Nils Y Hammerla and Bernhard Kainz and Ben Glocker and Daniel Rueckert : Attention U-Net : Learning Where to Look for the Pancreas, 2018, <https://arxiv.org/abs/1804.03999>
- [32] Zongwei Zhou and Md Mahfuzur Rahman Siddiquee and Nima Tajbakhsh and Jianming Liang : UNet++ : A Nested U-Net Architecture for Medical Image Segmentation, 2018, <https://arxiv.org/abs/1807.10165>
- [33] Fausto Milletari and Nassir Navab and Seyed-Ahmad Ahmadi : V-Net : Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation, 2016, <https://arxiv.org/abs/1606.04797>
- [34] Md Zahangir Alom and Mahmudul Hasan and Chris Yakopcic and Tarek M. Taha, and Vijayan K Asari : Recurrent Residual Convolutional Neural Network based on U-Net (R2U-Net) for Medical Image Segmentation, 2018, <https://arxiv.org/abs/1802.06955>
- [35] Huimin Huang and Lanfen Lin and Ruofeng Tong and Hongjie Hu and Qiaowei Zhang and Yutaro Iwamoto and Xianhua Han and Yen-Wei Chen and Jian Wu : UNet 3+ : A Full-Scale Connected UNet for Medical Image Segmentation, 2020, <https://arxiv.org/abs/2004.08790>
- [36] Oskar Maier and Bjoern H. Menze and Janina von der Gablentz et al. : ISLES 2015- A public evaluation benchmark for ischemic stroke lesion segmentation from multispectral MRI. *Med Image Anal.* 2017 Jan ;35 :250-269. <https://doi.org/10.1016/j.media.2016.07.009>, Epub 2016 Jul 21. PMID : 27475911.
- [37] Konstantinos Kamnitsas and Enzo Ferrante and Sarah Parisot and Christian Ledig and Aditya Nori and Antonio Criminisi and Daniel Rueckert and Ben Glocker : DeepMedic for Brain Tumor Segmentation. In *Proceedings of the International Workshop on Brain lesion : Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, Athens, Greece, 17 October 2016 ; pp. 138–149

- [38] Konstantinos Kamnitsas and Christian Ledig and Virginia F J Newcombe and Joanna P Simpson and Andrew D Kane and David K Menon and Daniel Rueckert and Ben Glocker : Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. *Med. Image Anal.* 2017, 36, 61–78
- [39] Bjoern Menze and Mauricio Reyes and Jayashree Kalpathy-Cramer and Keyvan Farahani and Spyridon Bakas and Christos Davatzikos : Multimodal Brain Tumor Image Segmentation Benchmark : “Change Detection”, Proceedings of MICCAI-BRATS 2016
- [40] Chenhong Zhou and Changxing Ding and Xinchao Wang and Zhentai Lu and Dacheng Tao : One-pass Multi-task Networks with Cross-task Guided Attention for Brain Tumor Segmentation. *IEEE Trans. Image Process.* 2020, 29, 4516–4529
- [41] Bjoern H Menze and Andras Jakab, Stefan Bauer, Jayashree Kalpathy-Cramer, Keyvan Farahani, Justin Kirby, et al. : The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS), *IEEE Transactions on Medical Imaging* 34(10), 1993-2024, (2015), <https://doi.org/10.1109/TMI.2014.2377694>
- [42] Spyridon Bakas and Hamed Akbari and Aristeidis Sotiras and Michel Bilello and Martin Rozycki and Justin S. Kirby et al. : Advancing The Cancer Genome Atlas glioma MRI collections with expert segmentation labels and radiomic features, *Nature Scientific Data*, 4 :170117 (2017), <https://doi.org/10.1038/sdata.2017.117>
- [43] Spyridon Bakas and Mauricio Reyes and Andras Jakab and Stefan Bauer and Markus Rempfler and Alessandro Crimi et al. : Identifying the Best Machine Learning Algorithms for Brain Tumor Segmentation, Progression Assessment, and Overall Survival Prediction in the BRATS Challenge, arXiv preprint arXiv :1811.02629 (2018)
- [44] Tran Minh Quan and David Grant Colburn Hildebrand and Won-Ki Jeong : FusionNet : A Deep Fully Residual Convolutional Neural Network for Image Segmentation in Connectomics, *Frontiers in Computer Science*, 2021, <https://doi.org/10.3389/fcomp.2021.613981>
- [45] Le cancer du foie, <https://curie.fr/dossier-pedagogique/cancer-du-foie-epidemiologie>, consulté le 29 mars 2022

- [46] Eugene Vorontsov and Milena Cerny and Philippe Régnier et al. : Deep learning for automated segmentation of liver lesions at CT in patients with colorectal cancer liver metastases, *Radiology : Artificial Intelligence*, vol. 1, no. 2, article 180014, 2019
- [47] Hyunseok Seo and Charles Huang and Maxime Bassenne and Ruoxiu Xiao and Lei Xing : Modified U-Net (mU-Net) with incorporation of object dependent high level features for improved liver and livertumor segmentation in CT images, *IEEE Transactions on Medical Imaging*, vol. 39, no. 5, pp. 1316–1325, 2020
- [48] Xiaomeng Li and Hao Chen and Xiaojuan Qi and Qi Dou and Chi-Wing Fu and Pheng Ann Heng : H-DenseUNet : Hybrid Densely Connected UNet for Liver and Liver Tumor Segmentation from CT Volumes. *IEEE Trans. Med. Imaging* 2018, 37, 2663–2674
- [49] Patrick Bilic and Patrick Ferdinand Christ Eugene Vorontsov and Grzegorz Chlebus and Hao Chen et al. : The Liver Tumor Segmentation Benchmark (LiTS), arXiv, 2019
- [50] Afshin Shoeibi and Marjane Khodatars and Roohallah Aliazadehsani et al. : Automated detection and forecasting of covid-19 using deep learning techniques : A review. arXiv preprint [arXiv:2007.10785](https://arxiv.org/abs/2007.10785), 2020
- [51] Connor Shorten and M. Khoshgoftaar Taghi and Furht Borko : Deep Learning applications for COVID-19. *Journal of Big Data* 8.1 (2021) : 1-54.
- [52] Tarik Alafif and Abdul Muneeim Tehame and Saleh Bajaba et al. : Machine and deep learning towards COVID-19 diagnosis and treatment : survey, challenges, and future directions. *International journal of environmental research and public health*, 2021, vol. 18, no 3, p. 1117
- [53] Kaiming He and Xiangyu Zhang and Shaoqing Ren and Jian Sun : Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 770-778, 2016
- [54] Review of Zhang He and Sun Ren : Deep Residual Learning for Image Recognition, <http://neural.vision/blog/article-reviews/deep-learning/he-resnet-2015/>, consulté le 16 avril 2022
- [55] Aman Arora : Squeeze and Excitation Networks Explained with PyTorch Implementation, <https://amaarora.github.io/2020/07/24/SeNet.html>, consulté le 16 avril 2022

- [56] Alex Krizhevsky and Ilya Sutskever and Geoffrey E. Hinton : ImageNet Classification with Deep Convolutional Neural Networks. In Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1. NIPS'12. USA : Curran Associates Inc.. 2012. pp. 1097–1105
- [57] Shih-Chung Benedict Lo and Matthew T. Freedman and Brian H. Krasner and Jyh-Shyan Lin and Seong K Mun : Computer-assisted diagnosis of lung nodule detection using artificial convolution neural network, 1993, <https://doi.org/10.1117/12.154572>
- [58] S. Kevin Zhou and Hayit Greenspan and Christos Davatzikos and James S. Duncan and Bram van Ginneken et al : A Review of Deep Learning in Medical Imaging : Imaging Traits, Technology Trends, Case Studies With Progress Highlights, and Future Promises, in Proceedings of the IEEE, vol. 109, no. 5, pp. 820-838, May 2021, <https://doi.org/10.1109/JPROC.2021.3054390>
- [59] Xiaoqing Liu and Kunlun Gao and Bo Liu and Chengwei Pan and Kongming Liang et al. : Advances in deep learning-based medical image analysis. Health Data Science 2021 (2021)
- [60] Mohammad Hesam Hesamian et al : Deep learning techniques for medical image segmentation : achievements and challenges. Journal of digital imaging 32.4 (2019) : 582-596
- [61] Intisar Rizwan I Haque and Jeremiah Neubert : Deep learning approaches to biomedical image segmentation. Informatics in Medicine Unlocked 18 (2020) : 100297
- [62] Xiao Yang and Roland Kwitt and Martin Styner and Marc Niethammer : Quicksilver : Fast predictive image registration – a deep learning approach, Neuroimage, 158 (2017), pp. 378-396
- [63] Guorong Wu and Minjeong Kim and Qian Wang and Brent C Munsell and Dinggang Shen : Scalable high-performance image registration framework by unsupervised deep feature representations learning, IEEE Trans Biomed Eng, 63 (2016), pp. 1505-1516
- [64] Seyed Sadegh Mohseni Salehi and Shadab Khan and Deniz Erdogmus and Ali Gholipour : Real-time deep pose estimation with geodesic loss for image-to-template rigid registration, IEEE Trans Med Imaging (2018)

- [65] Daniel Toth and Shun Miao and Tanja Kurzendorfer and Christopher A. Rinaldi and Rui Liao and Tommaso Mansi et al : 3D/2D model-to-image registration by imitation learning for cardiac procedures, *Int J Comput Assist Radiol Surg* (2018)
- [66] Lei Xiang and Yu Qiao and Dong Nie and Le An and Qian Wang and Dinggang Shen : Deep auto-context convolutional neural networks for standard-dose PET image estimation from low-dose PET/MRI, *Neurocomputing*, 267 (2017), pp. 406-416
- [67] Siyuan Shan and Wen Yan and Xiaoqing Guo and Eric I-Chao Chang and Yubo Fan and Yan Xu : Unsupervised end-to-end learning for deformable medical image registration, [arXiv:1711.08608v2](https://arxiv.org/abs/1711.08608v2), (2017)
- [68] Guha Balakrishnan and Amy Zhao and Mert R. Sabuncu and John Guttag and Adrian V. Dalca : An unsupervised learning model for deformable medical image registration, [arXiv:1802.02604v3](https://arxiv.org/abs/1802.02604v3), (2018)
- [69] Bob D. de Vos and Floris F. Berendsen and Max A. Viergever and Hessam Sokooti and Marius Staring and Ivana Išgum : A deep learning framework for unsupervised affine and deformable image registration, [arXiv:1809.06130v1](https://arxiv.org/abs/1809.06130v1), (2018)
- [70] David Lesage and Elsa D. Angelini and Isabelle Bloch and Gareth Funka-Lea : A review of 3D vessel lumen segmentation techniques : Models, features and extraction schemes. *Medical Image Analysis* **13**(5), 819 - 845 (2009), <https://doi.org/10.1016/j.media.2009.07.011>
- [71] Geert Litjens and Francesco Ciompi and Jelmer M. Wolterink, Bob D. de Vos and Tim Leiner and Jonas Teuwen and Ivana Išgum : State-of-the-Art Deep Learning in Cardiovascular Image Analysis, *JACC : Cardiovascular Imaging*, Volume 12, Issue 8, Part 1, 2019, Pages 1549-1565, ISSN 1936-878X, <https://doi.org/10.1016/j.jcmg.2019.06.009>
- [72] Javeed Ashir and Khan Shafqat Ullah and Ali Liaqat and Ali Sardar and Imrana Yakubu and Rahman Atiqur and Muhammad Zubair Asghar : Machine Learning-Based Automated Diagnostic Systems Developed for Heart Failure Prediction Using Different Types of Data Modalities : A Systematic Review and Future Directions, *Computational and Mathematical Methods in Medicine*, 2022, 1–30, <https://doi.org/10.1155/2022/9288452>
- [73] Pieter Kitslaar and Michel Frenay and Elco Oost and Jouke Dijkstra and Berend Stoel and Johan Reiber : Connected Component and Morphology Based Extraction of Arterial

- Centerlines of the Heart (CocomoBeach). The MIDAS Journal, (2008), <https://doi.org/10.54294/cbngt2>
- [74] Karl Krissian and Sara Arencibia Garcia : A minimal cost path and level set evolution approach for carotid bifurcation segmentation. Insight Journal, 2009. 60, 67, 72
- [75] Andrzej Szymczak : Vessel tracking by connecting the dots. MICCAI, 2008. xx, 56, 57, 59, 60
- [76] Jack Lee and Patricia Beighley and Erik Ritman and Nicolas Smith : Automatic segmentation of 3D micro-CT coronary vascular images, Medical Image Analysis, Volume 11, Issue 6, 2007, Pages 630-647, ISSN 1361-8415, <https://doi.org/10.1016/j.media.2007.06.012>
- [77] Suheyla Cetin Karayumak and Ali Demir and Anthony Yezzi and Muzaffer Degertekin and Gozde Unal : Vessel tractography using an intensity based tensor model with branch detection. IEEE transactions on medical imaging, 2012
- [78] Suheyla Cetin Karayumak and Gozde Unal : A higher-order tensor vessel tractography for segmentation of vascular structures. IEEE transactions on medical imaging. 2015
- [79] Max W K Law and Albert C S Chung : Efficient implementation for spherical flux computation and its application to vascular segmentation. IEEE Trans Image Process. 2009 Mar ;18(3) :596-612, <https://doi.org/10.1109/TIP.2008.2010073>, PMID : 19211333
- [80] Nicolas Passat and Christian Ronse and Joseph Baruthio and Jean-Paul Armspach and Claude Maillot and Christine Jahn : Region-growing segmentation of brain vessels : An atlas-based automatic approach. Journal of Magnetic Resonance Imaging, 21(6) :715–725, 2005. 57, 60, 75
- [81] Albert C S Chung and J. Alison Noble and Paul Summers and Michael Brady : 3D vascular segmentation using MRA statistics and velocity field information in PC-MRA. In Information Processing in Medical Imaging - IPMI, 2082 of Lecture Notes in Computer Science :461–467, 2001
- [82] M Sabry Hassouna and Ahmed A. Farag and Stephen Hushekek and Thomas Moriarty : Cerebrovascular segmentation from tof using stochastic models. Medical Image Analysis, 10(1) :2–18, 2006

- [83] M Sabry Hassouna and Ahmed A. Farag and Stephen Hushekek and Thomas Moriarty : Statistical-based approach for extracting 3d blood vessels from tof-myra data. Proc. Med. Image Comput. Assist. Interv., pages 680–687, 2003
- [84] Charles Florin and Nikos Paragios and Jim Williams : Particle filters, a quasi-monte carlo solution for segmentation of coronaries. Proc. Med. Image Comput. Assist. Interv., pages 246–253, 2005
- [85] Ayman El-Baz and Aly A Farag and Georgy Gimel'farb and Mohamed A El-Ghar and Tarek Eldiasty : A new adaptive probabilistic model of blood vessels for segmenting mra images. In Medical Image Computing and Computer-Assisted Intervention–MICCAI 2006, pages 799–806. Springer, 2006
- [86] Albert C S Chung and J. Alison Noble : Statistical 3d vessel segmentation using a rician distribution. Proc. Med. Image Comput. Assist. Interv., pages 82–89, 1999
- [87] Gady Agam and Changhua Wu : Probabilistic modeling-based vessel enhancement in thoracic ct scans. Proc. IEEE Conf. Comput. Vision and Pattern Recognit., pages 684–689, 2005
- [88] Qin Li and Jane You and David Zhang : Vessel segmentation and width estimation in retinal images using multiscale production of matched filter responses. Expert Systems with Applications, 2012 , 39(9), 7600–7610 [doi:10.1016/j.eswa.2011.12.046](https://doi.org/10.1016/j.eswa.2011.12.046)
- [89] Stefan Wörz and Karl Rohr : A new 3d parametric intensity model for accurate segmentation and quantification of human vessels. MICCAI, pages 491–499, 2004
- [90] James A. Lowell and Andrew Hunter and David H. Steel and Ansu Basu and R. Ryder, and R. L. Kennedy : Measurement of retinal vessel widths from fundus images based on 2-D modeling, IEEE Transactions on Medical Imaging, vol. 23, no. 10, pp. 1196–1204, 2004
- [91] Xiaoyi Jiang and Daniel Mojon : Adaptive local thresholding by verification-based multi-threshold probing with application to vessel detection in retinal images, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 25, no. 1, pp. 131–137, 2003
- [92] Michal Sofka and Charles V. Stewart : Retinal vessel centerline extraction using multiscale matched filters, confidence and edge measures, IEEE Transactions on Medical Imaging, vol. 25, no. 12, pp. 1531–1546, 2006

- [93] Bob Zhang and Lin Zhang and Lei Zhang and Fakhri Karray : Retinal vessel extraction by matched filter with first-order derivative of gaussian, *Computers in Biology and Medicine* 40 (4) (2010) 438–445
- [94] Yi Yin and Mouloud Adel and Salah Bourenmane : Automatic Segmentation and Measurement of Vasculature in Retinal Fundus Images Using Probabilistic Formulation. *Computational and mathematical methods in medicine*. 2013. 260410. <https://doi.org/10.1155/2013/260410>
- [95] Rashindra Manniesing and Wiro J Niessen : Local speed functions in level set based vessel segmentation. *Proc. Med. Image Comput. Assist. Interv.*, 3216 :475–482, 2004.
- [96] Yan Yang and Allen R. Tannenbaum and Don P. Giddens : Knowledge-based 3d segmentation and reconstruction of coronary arteries using ct images. In *Engineering in Medicine and Biology Society, 2004. IEMBS '04. 26th Annual International Conference of the IEEE*, volume 1, pages 1664–1666, 2004
- [97] Michiel Schaap and Rashindra Manniesing and Ihor Smal and Theo Van Walsum and Aad Van Der Lugt and Wiro Niessen : Bayesian tracking of tubular structures and its application to carotid arteries in cta. In *Proceedings of the 10th international conference on Medical image computing and computer-assisted intervention, MICCAI'07*, pages 562–570, Berlin, Heidelberg, 2007. SpringerVerlag.
- [98] Alejandro F Frangi and Wiro J Niessen and Koen L Vincken and Max A Viergever : Multiscale vessel enhancement filtering. *Medical Image Computing and Computer-Assisted Intervention — MICCAI*, Springer Berlin Heidelberg(1998)
- [99] Yoshinobu Sato and Shin Nakajima and Nobuyuki Shiraga and Hideki Atsumi and Shigeyuki Yoshida and Thomas Koller and Guido Gerig and Ron Kikinis : Three-dimensional multi-scale line filter for segmentation and visualization of curvilinear structures in medical images. *Medical image analysis*, 143-68 (1998) [https://doi.org/10.1016/S1361-8415\(98\)80009-1](https://doi.org/10.1016/S1361-8415(98)80009-1)
- [100] Asma Kerkeni and Asma Benabdallah and Mohamed Bedoui : Coronary artery multiscale enhancement methods : A comparative study, in *Image Analysis and Recognition*, Springer, 2013, pp. 510–520

- [101] Asma Kerkeni and Asma Benabdallah and Antoine Manzanera and Mohamed Bedoui : A coronary artery segmentation method based on multiscale analysis and region growing. *Computerized Medical Imaging and Graphics*, Elsevier, 2016, 48, pp.49 - 61. <https://doi.org/10.1016/j.compmedimag>
- [102] Tony Lindeberg : Principles for automatic scale selection, *Handbook on computer vision and applications 2* (1999) 239–274
- [103] Christian Bauer and Horst Bischof : Edge Based Tube Detection for Coronary Artery Centerline Extraction. *Midas Journal* (2008), <http://hdl.handle.net/10380/1403>
- [104] Karl Krissian and Hrvoje Bogunović and Jose Maria Pozo and Maria-Cruz Villa-Uriol and Alejandro F Frangi : Minimally Interactive Knowledge-based Coronary Tracking in CTA using a Minimal Cost Path. *Midas Journal* (2008), <http://hdl.handle.net/10380/1435>
- [105] Guanyu Yang and Pieter Kitslaar and Michel Frenay and Alexander Broersen and Mark J. Boogers and Jeroen J. Bax and Johan H. C. Reiber and Jouke Dijkstra : Automatic centerline extraction of coronary arteries in coronary computed tomographic angiography. *Cardiovasc Imaging*, 28 :921–933 (2012) <https://doi.org/10.1007/s10554-011-9894-2>
- [106] Ola Friman and Milo Hindennach and Caroline Kühnel and Heinz-Otto Peitgen : Multiple hypothesis template tracking of small 3D vessel structures. *Medical image analysis*, 160—171 (2010), <https://doi.org/10.1016/j.media.2009.12.003>
- [107] Michiel Schaap and Coert T Metz and Theo van Walsum and Alina G van der Giessen et al : Standardized evaluation methodology and reference database for evaluating coronary artery centerline extraction algorithms. *Medical Image Analysis* (2009) 701-14. <https://doi.org/10.1016/j.media.2009.06.003>
- [108] Yoshiro Kitamura and Yuanzhong Li and W. Ito : Automatic coronary extraction by supervised detection and shape matching. *Proceedings - International Symposium on Biomedical Imaging*, 2012, 234–237
- [109] David Lesage and Elsa D. Angelini and Gareth Funka-Lea and Isabelle Bloch : Adaptive particle filtering for coronary artery segmentation from 3D CT angiograms. *Computer Vision and Image Understanding*, 151, (2016) 29–46

- [110] David Lesage and Elsa D. Angelini and Isabelle Bloch and Gareth Funka-Lea : Design and study of flux-based features for 3D vascular tracking, 2009 IEEE International Symposium on Biomedical Imaging : From Nano to Macro, 2009, pp. 286-289, <https://doi.org/10.1109/ISBI.2009.5193040>
- [111] Mehmet A Gülsün and Gareth Funka-Lea and Puneet Sharma and Saikiran Rapaka : Coronary Centerline Extraction via Optimal Flow Paths and CNN Path Pruning. Medical Image Computing and Computer-Assisted Intervention - MICCAI 2016, Springer International Publishing, (2016) 317–325
- [112] Jelmer M Wolterink and Robbert W van Hamersvelt and Max A Viergever and Tim Leiner and Ivana Isgum : Coronary Artery Centerline Extraction in Cardiac CT Angiography Using a CNN-Based Orientation Classifier. CoRR (2018) <http://arxiv.org/abs/1810.03143>
- [113] Zohaib Salahuddin and Matthias Lenga and Hannes Nickisch : Multi-Resolution 3D Convolutional Neural Networks for Automatic Coronary Centerline Extraction in Cardiac CT Angiography Scans, 2020, <https://doi.org/10.48550/arxiv.2010.00925>
- [114] Byunghwan Jeon : Deep Recursive Bayesian Tracking for Fully Automatic Centerline Extraction of Coronary Arteries in CT Images. Sensors. 2021 ; 21(18) :6087, <https://doi.org/10.3390/s21186087>
- [115] Zihui Guo and Junjie Bai and Yi Lu and Xin Wang and Kunlin Cao and Qi Song and Milan Sonka and Youbing Yin : DeepCenterline : A Multi-task Fully Convolutional Network for Centerline Extraction. Information Processing in Medical Imaging, Springer International Publishing, (2019) 441–453.
- [116] Bin Konga and Xin Wangb and Junjie Baib and Yi Lub and Feng Gaob and Kunlin Caob and Jun Xiab and Qi Songb and Youbing Yinb : Learning Tree-Structured Representation for 3D Coronary Artery Segmentation, Computerized Medical Imaging Society, December 2019
- [117] Yuyang Zhang and Gongning Luo and Wei Wang and Kuanquan Wang : Branch-aware double DQN for centerline extraction in coronary CT angiography, International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer ; Berlin/Heidelberg, Germany : 2020, pp. 35–44.

- [118] Jameson Merkow and David J Kriegman and Alison Marsden and Zhuowen Tu : Dense Volume-to-Volume Vascular Boundary Detection. CoRR (2016) <http://arxiv.org/abs/1605.08401>
- [119] Weimin Huang and Lu Huang and Zhiping Lin and Su Huang and Yanling Chi and Jiayin Zhou and Junmei Zhang and Ru San Tan and Liang Zhong : Coronary Artery Segmentation by Deep Learning Neural Networks on Computed Tomographic Coronary Angiographic Images, 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC 2018, Honolulu, HI, USA, July 18-21, 2018 (608–611) <https://doi.org/10.1109/EMBC.2018.8512328>
- [120] Pim Moeskops and Jelmer M. Wolterink and Bas H. M. van der Velden and Kenneth G. A. Gilhuijs and Tim Leiner and Max A. Viergever and Ivana Isgum : Deep Learning for Multi-Task Medical Image Segmentation in Multiple Modalities. CoRR (2019) <https://doi.org/10.48550/arXiv.1704.03379>
- [121] Ye Shen and Zhijun Fang and Yongbin Gao and N. Xiong and Cengsi Zhong and Xianhua Tang : Coronary Arteries Segmentation Based on 3D FCN With Attention Gate and Level Set Function, in IEEE Access, vol. 7, pp. 42826-42835, 2019 <https://doi.org/10.1109/ACCESS.2019.2908039>.
- [122] Matthew C. H. Lee and Kersten Petersen and Nick Pawlowski and Ben Glocker and Michiel Schaap : TeTrIS : Template Transformer Networks for Image Segmentation With Shape Priors, IEEE Trans. Med. Imaging 2596–2606 (2019), <https://doi.org/doi.org/10.1109/TMI.2019.2905990>
- [123] Alexandru Dorobanțiu and Valentin OGREAN and Remus Brad : Coronary Centerline Extraction from CCTA Using 3D-UNet. Future Internet 2021, 13, 101, [0.3390/fi13040101](https://doi.org/10.3390/fi13040101)
- [124] Gu Linyan and Cai Xiao-Chuan : Fusing 2D and 3D convolutional neural networks for the segmentation of aorta and coronary arteries from CT images, Artificial Intelligence in Medicine, Volume 121, 2021, <https://doi.org/10.1016/j.artmed.2021.102189>
- [125] What Is a Heart Attack?, <https://www.nhlbi.nih.gov/health/heart-attack>, consulté le 1 avril 2022

- [126] Tiziano Schepis and Mohamed Marwan and Tobias Pflederer and Martin Seltmann and Dieter Ropers and Werner G Daniel and Stephan Achenbach : Quantification of noncalcified coronary atherosclerotic plaques with dual source computed tomography : comparison to intravascular ultrasound,” *Heart*, pp. hrt-2009, 2009
- [127] Damini Dey and Tiziano Schepis and Mohamed Marwan and Piotr J Slomka and Daniel S Berman and Stephan Achenbach : Automated three-dimensional quantification of noncalcified coronary plaque from coronary CT angiography : comparison with intravascular US, *Radiology*, vol. 257, no. 2, pp. 516–522, 2010
- [128] Dongwoo Kang and Piotr J Slomka and Ryo Nakazato and Reza Arsanjani and Victor Y Cheng and James K Min and Debiao Li and Daniel S Berman and C-C Jay Kuo and Damini Dey : Automated knowledgebased detection of nonobstructive and obstructive arterial lesions from coronary ct angiography. *Medical physics*, 40(4) :041912, 2013
- [129] Daniel Rinck and Sebastian Krüger and Anja Reimann and Michael Scheuering : Shape-based segmentation and visualization techniques for evaluation of atherosclerotic plaques in coronary artery disease. In K. R. Cleary and R. L. Galloway, Jr., editors, *Medical Imaging 2006 : Visualization, Image-Guided Procedures, and Display*, volume 6141 of *Society of Photo-Optical Instrumentation Engineers (SPIE) Conference Series*, pages 124–132, March 2006
- [130] Félix Renard and Yongyi Yang : Image segmentation for detection of soft plaques in multidetector CT images. In *Image Analysis and Interpretation, 2008. SSIAI 2008. IEEE Southwest Symposium on*, pages 121–124. IEEE, 2008
- [131] İlkyay Öksüz and Devrim Ünay and Kamuran Kadıpaşaoğlu : A hybrid method for coronary artery stenoses detection and quantification in cta images. In *Proceedings of 3D Cardiovascular Imaging : a MICCAI Segmentation Challenge Workshop, 2012*
- [132] Leonardo Flórez Valencia and Maciej Orkisz and RA Corredor Jerez and JS Torres González and EM Correa Agudelo and Claire Mouton and M Hernández Hoyos : Coronary artery segmentation and stenosis quantification in CT images with use of a right generalized cylinder model. In *Proceedings of MICCAI workshop" 3D cardiovascular imaging : a MICCAI segmentation challenge, 2012*

- [133] Peter J Yim and Rakesh Mullick and Ronald M Summers and Hani Marcos and Juan R Cebal and Rainald Lohner and Peter L Choyke : Measurement of stenosis from magnetic resonance angiography using vessel skeletons. In Proc. SPIE (Med. Imag.), volume 3978, pages 245–255. Citeseer, 2000
- [134] Yin Wang and Xinyu Meng and Daobo Wang : Automated coronary artery analysis system in 3D CTA images. In Biomedical Engineering and Informatics (BMEI), 2010 3rd International Conference on, volume 1, pages 122–126, Oct 2010
- [135] Shawn Lankton and Arthur Stillman and Paolo Raggi and Allen R Tannenbaum : Soft plaque detection and automatic vessel segmentation. In Probabilistic Models For Medical Image Analysis 2009, pages 25–33. Georgia Institute of Technology, 2009
- [136] Stefan Wesarg and M. Fawad Khan and Evelyn A. Firlre : Localizing calcifications in cardiac CT data sets using a new vessel segmentation approach. Journal of Digital Imaging 19 (3), 249–257, Sep 2006
- [137] Stefan C Saur, Hatem Alkadhi, Lotus Desbiolles, Gábor Székely, and Philippe C Cattin. Automatic detection of calcified coronary plaques in computed tomography data sets. In Medical Image Computing and Computer-Assisted Intervention–MICCAI 2008, pages 170–177. Springer, 2008
- [138] O. Wink, W.J. Niessen, and Max A Viergever : Fast delineation and visualization of vessels in 3-d angiographic images. Medical Imaging, IEEE Transactions on, 19(4) :337–346, April 2000.
- [139] Matthias Tessmann and Fernando Vega-Higuera and Dominik Fritz and Michael Scheuring and Günther Greiner and Nico Karssemeijer and Maryellen L Giger : Multi-scale feature extraction for learning-based classification of coronary artery stenosis. SPIE Proceedings Medical Imaging 2009 : Computer-Aided Diagnosis, <https://doi.org/10.1117/12.811639>
- [140] Sushil Mittal and Yefeng Zheng and Bogdan Georgescu and Fernando Vega-Higuera and Shaohua Kevin Zhou and Peter Meer and Dorin Comaniciu : Fast automatic detection of calcified coronary lesions in 3D cardiac CT images. In : Proc. of MICCAI Workshop ”Machine Learning in Medical Imaging” (MLMI), 2010

- [141] Kevin N Blackmon and Julian Streck and Christian Thilo and Gorka Bastarrika and Philip Costello and U Joseph Schoepf. Reproducibility of Automated Noncalcified Coronary Artery Plaque Burden Assessment at Coronary CT Angiography. *Journal of Thoracic Imaging*, 24(2), 96–102. (2009), <https://doi.org/10.1097/rti.0b013e31819b674b>
- [142] Yan Xu and Guoyuan Liang and Guangshu Hu and Yan Yang and Jinzhao Geng and Punam K Saha : Quantification of coronary arterial stenoses in CTA using fuzzy distance transform. *Computerized Medical Imaging and Graphics*, , Jan 2012, 11–24
- [143] Ethan J Halpern and David J Halpern : Diagnosis of coronary stenosis with ct angiography comparison of automated computer diagnosis with expert readings. *Academic Radiology* 18 (3), Mar 2011, 324–333
- [144] Elisabeth Arnoldi and Mulugeta Gebregziabher and Uwe Joseph Schoepf and Roman Goldenberg and L Ramos-Duran and PL Zwerner and Konstantin Nikolaou and MF Reiser and P Costello and C Thilo : Automated computer-aided stenosis detection at coronary CT angiography : initial experience. May 2010, *European Radiology* 20 (5), 1160–1167.
- [145] Suheyla Cetin and Gozde Unal : Automatic detection of coronary artery stenosis in CTA based on vessel intensity and geometric features. *Proceedings of MICCAI workshop" 3D cardiovascular imaging : a MICCAI segmentation challenge*
- [146] Maria A Zuluaga and Isabelle E Magnin and Marcela Hernández Hoyos and Edgar JF Delgado Leyton and Fernando Lozano and Maciej Orkisz : Automatic detection of abnormal vascular cross-sections based on Density Level Detection and Support Vector Machines, *International journal of computer assisted radiology and surgery*, 6 (2) :163-174. 2011
- [147] Armin Kanitsar and Dominik Fleischmann and Rainer Wegenkittl and Petr Felkel and Meister Eduard Gröller : CPR - Curved planar reformation. *Proceedings of the IEEE Visualization Conference*. (2002), 37-44, <https://doi.org/10.1109/VISUAL.2002.1183754>.
- [148] Hortense A. Kirisli and Michiel Schaap and C.T. Metz et al : Standardized evaluation framework for evaluating coronary artery stenosis detection, stenosis quantification and lumen segmentation algorithms in computed tomography angiography. vol. 17, pp. 859 - 876. *Medical Image Analysis* (2013), <https://doi.org/10.1016/j.media.2013.05.007>

- [149] Mirunalini P and Chandrabose Aravindan : Automatic segmentation of coronary arteries and detection of stenosis. 2013 IEEE International Conference of IEEE Region 10 (TENCON 2013), <https://doi.org/10.1109/TENCON.2013.6719010>
- [150] Melki Imen : Towards an automated framework for coronary lesions detection and quantification in cardiac CT angiography, Thèse de doctorat dirigée par Najman, Laurent Informatique Paris Est 2015, <http://www.theses.fr/2015PESC1022/document>
- [151] Qingfen Lin and Per-Erik Danielsson : Stenosis Detection Using a New Shape Space for Second Order 3D-Variations. (2001), 2082. 388-394, <https://doi.org/10.1007/3-540-45729-139>
- [152] Jelmer M Wolterink and Tim Leiner and Richard AP Takx and Max A Viergever, and Ivana Išgum : An automatic machine learning system for coronary calcium scoring in clinical non-contrast enhanced, ecg-triggered cardiac CT. In SPIE Medical Imaging, pages 90350E–90350E. International Society for Optics and Photonics, 2014.
- [153] Majd Zreik and Robbert W. van Hamersvelt and Jelmer M Wolterink and Tim Leiner, Max A Viergever and Ivana Išgum : A recurrent CNN for automatic detection and classification of coronary artery plaque and stenosis in coronary CT angiography. *IEEE Trans. Med. Imaging* 1(1), 1–11 (2018)
- [154] Tejero-de Pablos A et al. Texture-Based Classification of Significant Stenosis in CCTA Multi-view Images of Coronary Arteries. In : MICCAI. Springer ; 2019. p. 732–740
- [155] Karen Simonyan and Andrew Zisserman : Very deep convolutional networks for largescale image recognition. In : Proceedings of the International Conference on Learning Representations, pp. 1–14 (2015)
- [156] Felix Denzinger and Michael Wels and Katharina Breininger and Anika Reidelshöfer and Joachim Eckert and Michael Sühling and Axel Schmermund and Andreas Maier : Deep Learning Algorithms for Coronary Artery Plaque Characterisation from CCTA Scans. In : BVM, LNCS 2020, pp. 193–198. Springer (2020)
- [157] Özgün Çiçek and Ahmed Abdulkadir and Soeren S. Lienkamp and Thomas Brox and Olaf Ronneberger : 3D U-Net : Learning Dense Volumetric Segmentation from Sparse Annotation. *CoRR* (2016) <http://arxiv.org/abs/1606.06650>.

- [158] Sema Candemir and Richard D. White and Mutlu Demirel and Vikash Gupta and Matthew T. Bigelow and Luciano M. Prevedello and Barbaros S. Erdal : Coronary Artery Classification and Weakly Supervised Abnormality Localization on Coronary CT Angiography with 3-Dimensional Convolutional Neural Networks. arXiv preprint arXiv :1911.13219 (2019)
- [159] Delix Denzinger and Michael Wels and Katharina Breininger et al. Automatic CAD-RADS scoring using deep learning : International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, Cham, 2020. p. 45-54.
- [160] Engin Dikici and O'Donnell Thomas and Grady Leo and and White Richard : Coronary artery centerline tracking using axial symmetries. The Insight Journal, 2008.
- [161] O. Wink and Wiro J. Niessen and and Max A Viergever : Multiscale vessel tracking. IEEE Trans. Med. Imaging, 23(1) :130–133, 2004
- [162] Karl Krissian and Grégoire Malandain and Nicholas Ayache and Régis Vaillant and Yves Troussel : Model-based multiscale detection of 3d vessels. Computer Vision and Pattern Recognition, IEEE Computer Society Conference on, pages 722–727, 1998. 68
- [163] Michiel Schaap and C. T. Metz and Theo Van Walsum and Alina G van der Giessen et al : Standardized evaluation methodology and reference database for evaluating coronary artery centerline extraction algorithms. Medical Image Analysis, Oct 2009, 13 (5), 701–714.
- [164] Shubham Baghel : Understanding AUC-ROC : Clearly explained, <https://medium.datadriveninvestor.com/understanding-auc-roc-clearly-explained-74c53d292a02>
- [165] Dominik Kaspar : Application of Directional Antennas in RF-Based Indoor Localization Systems, (2005)
- [166] Ron Kikinis and Steve D Pieper and Kirby G Vosburgh : 3D Slicer : A Platform for Subject-Specific Image Analysis, Visualization, and Clinical Support. Intraoperative Imaging and Image-Guided Therapy (277–289). Springer New York (2014)
- [167] Xavier Glorot and Yoshua Bengio : Understanding the difficulty of training deep feedforward neural networks, In Proceedings of the International Conference on Artificial Intelligence and Statistics (AISTATS'10). Society for Artificial Intelligence and Statistics, 2010

- [168] Diederik P Kingma and Jimmy Ba : Adam : A Method for Stochastic Optimization, 3rd International Conference for Learning Representations, San Diego, 2015
- [169] Yefeng Zheng and Adrian Barbu and Bogdan Georgescu and Michael Scheuering and Dorin Comaniciu : Four-chamber heart modeling and automatic segmentation for 3-D cardiac CT volumes using marginal space learning and steerable features. *IEEE Trans Med Imaging*. 2008 Nov, 27(11) :1668-81, <https://doi.org/10.1109/TMI.2008.2004421>
- [170] Olivier Ecabert and Jochen Peters and Hauke Schramm and Cristian Lorenz and Jens von Berg and Matthew J Walker and Mani Vembar and Mark E Olszewski and Krishna Subramanyan and Guy Lavi and Jürgen Weese : Automatic model-based segmentation of the heart in CT images. *IEEE Trans Med Imaging*. 2008 Sep, 27(9) : 1189-201, <https://doi.org/10.1109/TMI.2008.918330>
- [171] Rongrong Zhou and Zhongxing Liao and Tinsu Pan and Sarah A Milgrom and Chelsea C Pinnix and Anhui Shi and Linglong Tang and Ju Yang and Ying Liu and Daniel Gomez and Quynh-Nhu Nguyen and Bouthaina S Dabaja and Laurence Court and Jinzhong Yang : Cardiac atlas development and validation for automatic segmentation of cardiac substructures, *Radiotherapy and Oncology*, Volume 122, Issue 1, 2017, Pages 66-71, SSN 0167-8140, [/10.1016/j.radonc.2016.11.016](https://doi.org/10.1016/j.radonc.2016.11.016)
- [172] Tarun Kanti Ghosh and Md Kamrul Hasan and Shidhartho Roy and Md. Ashraful Alam and Eklas Hossain and Mohiuddin Ahmad : Multi-Class Probabilistic Atlas-Based Whole Heart Segmentation Method in Cardiac CT and MRI, in *IEEE Access*, vol. 9, pp. 66948-66964, 2021, <https://doi.org/10.1109/ACCESS.2021.3077006>
- [173] Jinpeng Li and Rongzhao Zhang and Lin Shi and Defeng Wang : Automatic Whole-Heart Segmentation in Congenital Heart Disease Using Deeply-Supervised 3D FCN. *Lecture Notes in Computer Science*. 10129. 111-118, (2017), https://doi.org/10.1007/978-3-319-52280-7_11
- [174] Qiao Zheng and Hervé Delingette and Nicolas Duchateau and Nicholas Ayache : 3D Consistent and Robust Segmentation of Cardiac Images by Deep Learning with Spatial Propagation, *arXiv*, 2018, <https://doi.org/10.48550/ARXIV.1804.09400>

- [175] Mahendra Khened and Varghese Alex Kollerathu and Ganapathy Krishnamurthi : Fully convolutional multi-scale residual DenseNets for cardiac segmentation and automated cardiac diagnosis using ensemble of classifiers. *Med Image Anal.* 2019 Jan, 51 :21-45, <https://doi.org/10.1016/j.media.2018.10.004>
- [176] Xiuquan Du and Susu Yin and Renjun Tang and Yanping Zhang and Shuo Li : Cardiac-DeepIED : Automatic Pixel-Level Deep Segmentation for Cardiac Bi-Ventricle Using Improved End-to-End Encoder-Decoder Network. *IEEE J Transl Eng Health Med.* 2019 ;7 :1900110. Published 2019 Feb 25, <https://doi.org/10.1109/JTEHM.2019.2900628>
- [177] Xiahai Zhuang and Juan Shen : Multi-scale patch and multi-modality atlases for whole heart segmentation of MRI. *Medical Image Analysis*, 31, 77-87, 2016, <https://doi.org/10.1016/j.media.2016.02.006>
- [178] Xiahai Zhuang : Challenges and Methodologies of Fully Automatic Whole Heart Segmentation : A Review. *Journal of Healthcare Engineering*, 4,2013, <https://doi.org/10.1260/2040-2295.4.3.371>
- [179] Christian Payer and Darko Štern and Horst Bischof and Martin Urschler : Multi-label Whole Heart Segmentation Using CNNs and Anatomical Label Configurations. *Statistical Atlases and Computational Models of the Heart. ACDC and MMWHS Challenges*, 190-198, 2018, 2019, https://doi.org/10.1007/978-3-319-75541-0_20
- [180] Christian Payer and Darko Štern and Horst Bischof and Martin Urschler : Integrating spatial configuration into heatmap regression based CNNs for landmark localization. *Medical Image Analysis*, 54, 207 - 219, 2019, <https://doi.org/10.1016/j.media.2019.03.007>
- [181] Jie Hu, Li Shen, Gang Sun : *Squeeze-and-Excitation Networks*, 2017
- [182] Pamela Johnson and Elliot Fishman : Postprocessing Techniques for Cardiac Computed Tomographic Angiography. *Radiologic clinics of North America*. 48. 687-700, 2010, <https://doi.org/10.1016/j.rcl.2010.04.004>
- [183] Jinzhu Yang and Mingxu Huang and Jie Fu and Chunhui Lou and Chaolu Feng : Frangi based multi-scale level sets for retinal vascular segmentation, *Computer Methods and Programs in Biomedicine*, Volume 197, 2020, 105752, <https://doi.org/10.1016/j.cmpb.2020.105752>

- [184] Gilbert L Raff and Aiden Abidov and Stephan Achenbach and Daniel S Berman and Lawrence M Boxt and Matthew J Budoff and Victor Cheng and Tony DeFrance and Jeffrey C Hellinger and Ronald P Karlsberg : SCCT guidelines for the interpretation and reporting of coronary computed tomographic angiography, *Journal of Cardiovascular Computed Tomography*, vol. 3, no. 2, pp. 122–136, 2009
- [185] Jelmer M. Wolterink and Tim Leiner and Bob D. De Vos and Jean Louis Coatrieux and B Michael Kelm and Satoshi Kondo and Rodrigo A Salgado and Rahil Shahzad and Huazhong Shu and Miranda Snoeren et al : An evaluation of automatic coronary artery calcium scoring methods with cardiac CT using the orCaScore framework, *Medical Physics*, vol. 43, no. 5, pp. 2361–2373, 2016
- [186] Renu Virmani and Allen P Burke and Andrew Farb and and Frank D Kolodgie : Pathology of the vulnerable plaque, *Journal of the American College of Cardiology*, vol. 47, no. 8 Supplement, pp. C13–C18, 2006
- [187] Robert J McDonald and Kara M Schwartz and Laurence J Eckel and Felix E Diehn and Christopher H Hunt and Brian J Bartholmai and Bradley J Erickson and David F Kallmes : The effects of changes in utilization and technological advancements of cross-sectional imaging on radiologist workload. *Acad Radiol.* 2015 ;22(9) :1191-1198, <https://doi.org/10.1016/j.acra.2015.05.007>
- [188] Statistics and Facts, <https://bafound.org/about-brain-aneurysms/brain-aneurysm-basics/brain-aneurysm-statistics-and-facts/>, (Consulté le 20 octobre 2020)
- [189] QingLin Liu and Peng Jiang and YuHua Jiang and HuiJian Ge and ShaoLin Li and HengWei Jin and YouXiang Li : Prediction of Aneurysm Stability Using a Machine Learning Model Based on PyRadiomics-Derived Morphological Features. *Stroke*, 50(9), 2314–2321, (2019)
- [190] Hidetaka Arimura and Qiang Li and Yukunori Korogi and Toshinori Hirai and Hiroyuki Abe and Yasuyuki Yamashita and Shigehiko Katsuragawa and Ryuji Ikeda and Kunio Doi : Automated computerized scheme for detection of unruptured intracranial aneurysms in three-dimensional magnetic resonance angiography, *Academic Radiology*, 1093–1104, 2004

- [191] Naoto Hayashi and Yoshitaka Masutani and Tomohiko Masumoto and Harushi Mori and Akira Kunimatsu and Osamu Abe and Shigeki Aoki and Kuni Ohtomo and Naoki Takano and Kazuhiko Matsumoto : Feasibility of a Curvature-based Enhanced Display System for Detecting Cerebral Aneurysms in MR Angiography, *Magnetic Resonance in Medical Sciences*, 29–36, 2003
- [192] Xiaojiang Yang and Daniel J Blezek and Lionel T E Cheng and William J Ryan and David F Kallmes and Bradley J Erickson : Computer-Aided Detection of Intracranial Aneurysms in MR Angiography, *Journal of Digital Imaging*, 86–95, 2011
- [193] Yukihiro Nomura and Yoshitaka Masutani and Soichiro Miki and Mitsutaka Nemoto and Shouhei Hanaoka and Takeharu Yoshikawa and Naoto Hayashi and Kuni Ohtomo : Performance improvement in computerized detection of cerebral aneurysms by retraining classifier using feedback data collected in routine reading environment, *Journal of Biomedical Graphics and Computing*, p12, 2014
- [194] Takahiro Nakao and Shouhei Hanaoka and Yukihiro Nomura and Issei Sato and Mitsutaka Nemoto and Soichiro Miki and Eriko Maeda and Takeharu Yoshikawa, and Naoto Hayashi and Osamu Abe : Deep neural network-based computer-assisted detection of cerebral aneurysms in MR angiography : DNN-Based CAD of Cerebral Aneurysms, *Journal of Magnetic Resonance Imaging*, 948–953, 2018
- [195] Daiju Ueda and Akira Yamamoto and Masataka Nishimori and Taro Shimono and Satoshi Doishita and Akitoshi Shimazaki and Yutaka Katayama and Shinya Fukumoto and Antoine Choppin and Yuki Shimahara and Yukio Miki : Deep Learning for MR Angiography : Automated Detection of Cerebral Aneurysms, *Radiology*, 187–194, 2019
- [196] Thorsten Sichter and A Faron and Rik Sijben and Nils Teichert and Jessica Freiherr and M Wiesmann : Deep Learning-Based Detection of Intracranial Aneurysms in 3D TOF-MRA, *American Journal of Neuroradiology*, 25–32, 2019
- [197] Konstantinos Kamnitsas and Christian Ledig and Virginia F J Newcombe and Joanna P Simpson and Andrew D Kane and David K Menon and Daniel Rueckert and Ben Glocker : Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation, *Medical Image Analysis*, 61 – 78, 2017

- [198] Bio Joo and Sung Soo Ahn and Pyeong Ho Yoon and Sohi Bae and Beomseok Sohn and Yong Eun Lee and Jun Ho Bae and Moo Sung Park and Hyun Seok Choi and Seung-Koo Lee : A deep learning algorithm may automate intracranial aneurysm detection on MR angiography with high diagnostic performance, *European Radiology*, 5785–5793, 2020
- [199] Joseph N Stember and Peter Chang and Danielle M Stember and Michael Liu and Jack Grinband and Christopher G Filippi and Philip Meyers and Sachin Jambawalikar : Convolutional Neural Networks for the Detection and Measurement of Cerebral Aneurysms on Magnetic Resonance Angiography, *Journal of Digital Imaging*, 808–815, 2019
- [200] Aneurysm Detection And segmentation Challenge, <http://adam.isi.uu.nl/>, (Accessed on 06 11 2020)
- [201] Kimberley Timmins and Edwin Bennink and Irene Van Der Schaaf and Birgitta Velthuis and Ynte Ruigrok and Hugo Kuijf : Intracranial Aneurysm Detection and Segmentation Challenge, Zenodo, 2020
- [202] László G Nyúl and Jayaram K. Udupa : On standardizing the MR image intensity scale, Technical Report MIPG.250, Medical Image Processing Group, Department of Radiology, University of Pennsylvania, January 1999
- [203] László G Nyúl and Jayaram K. Udupa : On standardizing the MR image intensity scale. *Magn Reson Med.* 1072-81. Dec 1999
- [204] E. Kreyszig (1979). *Advanced Engineering Mathematics* (Fourth ed.). Wiley. p. 880, eq. 6. ISBN 0-471-02140-7
- [205] Eman Ahmed and Alexandre Saint and Abd El Rahman Shabayek and K. Cherenkova and Rig Das and G. Gusev and Djamila Aouada and B. Ottersten : *Deep Learning Advances on Different 3D Data Representations : A Survey*, 2018
- [206] Vishakh Hegde and Reza Zadeh : *FusionNet : 3D Object Classification Using Multiple Data Representations*, 2016
- [207] Chollet, François and others : *Keras*, 2015, <https://keras.io>
- [208] Xavier Glorot and Yoshua Bengio : Understanding the difficulty of training deep feedforward neural networks, *MLR Workshop and Conference Proceedings*, 249–256, 2010

- [209] Diederik Kingma and Jimmy Ba : Adam : A Method for Stochastic Optimization, International Conference on Learning Representations, 2014
- [210] Results : MICCAI 2020, <http://adam.isi.uu.nl/results/results-miccai-2020/>, (Accessed on 15 1 2020)
- [211] Philip White and Joanna Wardlaw : Can Noninvasive Imaging Accurately Depict Intracranial Aneurysms? A Systematic Review, Radiology, 2000