



جامعة ابن طفيل
+⓪ΛΠΞ+ ΣΘΙ ΕΞΗΘΗ
Ibn Tofail University
Faculté des Sciences

Université Ibn Tofail
Faculté des Sciences, Kénitra

Mémoire de Projet de Fin d'Etudes

Master Intelligence Artificielle et Réalité Virtuelle

Détection automatique des anévrismes intracrâniens par apprentissage profond sur des nuages de points 3D

Établissement d'accueil : Université Ibn Tofail

Elaboré par : Mme. Khadija Amadoun

Encadré par : Mr. Anass Nouri (FS Kéntira -UIT)

Mme. Souad EDDAROUICH (CRMEF - Rabat)

Soutenu le 24/09/2024, devant le jury composé de :

- Mr. A. Nouri (FS Kéntira - UIT)
 - Mme. S. EDDAROUICH (CRMEF - Rabat)
 - Mr. R. Messoussi (FS Kéntira - UIT)
 - Mme. R. Touahni (FS Kéntira - UIT)
 - Mr. I. Moumen (FS Kéntira - UIT)
-

Dédicace

Je dédie ce travail à ma chère mère, pour son amour infini et ses sacrifices inlassables. Ton soutien indéfectible tout au long de mon parcours a été le socle de toutes mes réussites. Je m'efforcerai toujours d'être une source de fierté à tes yeux.

À mon frère, qui a toujours été à mes côtés, m'offrant encouragement et force. Ta confiance en moi a été inestimable et m'a poussé à persévérer, même dans les moments les plus difficiles.

À mes amis, qui ont partagé mon parcours, célébrant mes succès et m'épaulant dans les moments de défi. Votre bienveillance et votre amitié ont été inestimables.

À mes professeurs, pour vos conseils et votre soutien tout au long de mon parcours académique. Vos enseignements resteront à jamais gravés.

Remerciement

Avant d'entamer ce rapport, je tiens à exprimer ma plus profonde gratitude à Pr. Raja Touahni, coordonnatrice de mon programme de master. Ce fut un immense privilège de travailler sous votre supervision. Votre soutien indéfectible et vos conseils rigoureux ont été essentiels tout au long de mon parcours académique. Votre bienveillance, votre disponibilité constante et votre mentorat m'ont profondément inspiré, et pour cela, je vous en suis infiniment reconnaissant.

Je souhaite également remercier chaleureusement Pr. Anass Nouri, qui a été à la fois mon professeur et mon encadrant interne pour ce projet. Vos conseils et votre soutien pendant cette période ont été inestimables. Je vous suis profondément reconnaissant pour les connaissances et les encouragements que vous m'avez prodigués, qui ont été cruciaux dans la réalisation de ce projet.

De plus, j'aimerais exprimer ma reconnaissance à Pr. Eddarouich Souad, qui a été aussi à la fois mon enseignante et encadrante externe. L'encouragement et le soutien que vous m'avez apportés tout au long de mes études ont grandement contribué à mon développement, et je vous en suis sincèrement reconnaissant.

Je tiens aussi à remercier l'ensemble du corps enseignant qui m'a soutenu et guidé durant ces deux dernières années. Votre dévouement et votre expertise ont joué un rôle fondamental dans la construction de mon parcours éducatif, et je vous en suis sincèrement reconnaissant pour les savoirs et les expériences partagés.

Enfin, je tiens à exprimer ma gratitude à toutes les personnes qui ont contribué, directement ou indirectement, à la réussite de ce projet. Mes remerciements les plus sincères vont à ma famille, mes amis, et à tous ceux qui m'ont offert leur soutien et leurs encouragements tout au long de ce parcours. Votre aide a été inestimable et est profondément appréciée.

Résumé

Ce rapport présente une approche de détection automatique des anévrismes intracrâniens (AIC) par apprentissage profond sur des nuages de points 3D avec le modèle PointNet++. Le traitement des données débute par la conversion des fichiers .nrrd des vaisseaux sanguins en des maillages 3D après en nuages de points, chaque point étant caractérisé par ses coordonnées spatiales et ses normales de surface. Les données ont ensuite été enrichies et subdivisées pour mieux capturer la structure des anévrismes, garantissant ainsi une meilleure qualité d'apprentissage pour le modèle.

Le modèle a été entraîné sur trois types de données : des données réelles, des données synthétiques, et des données augmentées combinant à la fois des données réelles et synthétiques. Cette combinaison visait à améliorer la robustesse du modèle et à évaluer l'impact de chaque type de données sur la qualité des prédictions. Les résultats montrent que l'entraînement sur des données réelles permet d'atteindre des performances optimales, avec une précision accrue dans la détection des anévrismes. L'entraînement sur des données synthétiques a toutefois montré des limites, nécessitant des améliorations dans la génération des données pour mieux refléter les caractéristiques des anévrismes réels.

Les performances globales du modèle ont été évaluées à l'aide de métriques telles que l'Intersection over Union (IOU), fournissant une évaluation complète de la qualité des prédictions. Ces résultats démontrent que l'utilisation de PointNet++ est particulièrement avantageuse pour la segmentation et la classification des anévrismes intracrâniens dans des nuages de points 3D. Après, un post-traitement a été appliqué, consistant à comparer les distances entre les barycentres des clusters prédits à ceux des anévrismes réels. Cette étape a permis d'avoir un IOU plus pertinent.

Mots clés : AIC, PointNet++, nuages de points, segmentation, détection automatique, apprentissage profond, données synthétiques, IOU.

Abstract

Artificial intelligence (AI) plays a crucial role in various sectors, providing advanced solutions to complex problems. In the context of intracranial aneurysm detection, deep learning techniques like PointNet++ are essential for improving the accuracy and efficiency of diagnosis. This project focused on the use of PointNet++ for the segmentation and classification of aneurysms from 3D point clouds. The project was divided into several distinct phases. Initially, the PointNet++ model was tested on ShapeNetDataCore, a well-known database in the field of point clouds. This helped in better understanding the model's capabilities before applying it to data specific to intracranial aneurysm detection. Subsequently, data preparation was carried out, including the transformation of meshes into point clouds, their upsampling, and conversion into files suitable for model training.

In the following phases, PointNet++ was trained on various types of data, including real, synthetic, and augmented data. Each data type allowed for evaluating the impact on the model's performance. Finally, post-processing steps were implemented, including calculating distances between barycenters to obtain a more relevant Intersection over Union (IOU) score.

This report provides a detailed account of the project steps, the methods used, and the results obtained. It highlights the significant role of AI, particularly PointNet++, in improving intracranial aneurysm detection and demonstrates how these techniques can be applied to solve real clinical challenges.

Table des matières

Dédicace	2
Remerciement	3
Résumé	4
Abstract	5
Table des figures	9
Liste des Tableaux	10
Liste des Abréviations	11
Introduction	12
1 Etat de l'art	16
1.1 Définition des anévrismes intracrâniens	16
1.2 L'importance de la détection automatique des anévrismes	17
1.3 Le cercle de Willis et son rôle	18
1.4 Types d'acquisitions d'images médicales	19
1.5 Formats d'images utilisés en imagerie médicale	20
1.6 Introduction à l'IA, au ML et au DL	20
1.7 Méthodes de détection des anévrismes intracrâniens basées sur les images	21
1.8 Méthodes de détection des anévrismes intracrâniens basées sur les nuages de points	22
2 Méthodologie	23
2.1 Originalité	23
2.1.1 Avantages des Nuages de Points par Rapport aux Stacks 3D .	23
2.1.2 Génération de Bifurcations à l'Aide d'un Modèle Synthétique	24
2.2 Fonctionnement du Modèle PointNet++	25

2.2.1	Limitations de PointNet	26
2.2.2	Introduction de la Hiérarchie dans PointNet++	26
2.2.3	Méthode d'Échantillonnage et de Groupement	27
2.2.4	Apprentissage des Caractéristiques Locales	27
2.2.5	Multi-Échelle et Multi-Résolution	27
2.2.6	Propagation des Caractéristiques et Segmentation	28
2.2.7	Applications et Résultats du Modèle	29
2.3	Préparation et Validation Initiale du Modèle	29
2.4	Répartition des jeux de données	30
2.5	Prétraitement des Données au but de convertir les Fichiers .nrrd vers les Nuages de Points	31
2.6	Outils et Technologies Utilisés	34
2.6.1	Python et PyTorch	34
2.6.2	Trimesh et PyMeshLab	35
2.6.3	Visualisation avec MeshLab	35
2.7	Métriques de performance : IOU	36
3	Expérimentations et résultats	38
3.1	Résultats de l'Entraînement	38
3.2	Résultats de la Prédiction	41
3.2.1	Pré-traitement des Données de Test et Prédictions : Centrage et mise en échelle	41
3.2.2	Analyse des résultats	43
3.3	Post-traitement : Iou	44
	Conclusion	46
	Références	48

Table des figures

1	Anévrisme intracrânien	12
2	Rupture d'anévrisme intracrânien dans le cerveau humain	13
3	Représentiondes objets en nuages de points : chaise, table, ghitare...etc	13
1.1	L'anévrisme intracrânien dans le cerveau humain	17
1.2	Cercle de willis	18
1.3	Différence entre IA, ML et DL	21
2.1	L'architecture du modèle Pointnet++	26
2.2	(a) Groupement Multi-échelle (MSG) ; (b) Groupement Multi-résolution (MRG)[2]	28
2.3	Les résultats de segmentation avec ShapeNetCore dataset	30
2.4	Un maillage 3D d'une bifurcation réelle avec un AIC	30
2.5	Un maillage 3D d'une bifurcation réelle sans un AIC	30
2.6	Un maillage 3D d'une bifurcation synthétique avec un AIC	31
2.7	Un maillage 3D d'une bifurcation synthétique sans un AIC	31
2.8	Répartition des volumes des bifurcations avec AIC sélectionnées	32
2.9	Un maillage 3D d'une bifurcation avec un AIC où la partie verte représente l'anévrisme	33
2.10	Un maillage 3D d'une bifurcation sans un AIC	33
2.11	Un maillage 3D du set de l'entrainement	33
2.12	Nuage de points du maillage 3D après transformation	33
2.13	L'affichage des nuages de points colorés en format (.ply) où la partie rouge représente un AIC	34
2.14	L'interface graphique de MeshLab	35
3.1	Courbe d'exactitude de la validation pour les données Réelles sur 200 epochs	39
3.2	Courbe de perte de la validation pour les données Réelles sur 200 epochs	39

3.3	Courbe d'exactitude de la validation pour les données Augmentées sur 200 epochs	40
3.4	Courbe de perte de la validation pour les données Augmentées sur 200 epochs	40
3.5	Courbe d'exactitude de la validation pour les données Synthétiques (validation sur les Synthétiques) sur 200 epochs	40
3.6	Courbe de perte de la validation pour les données Synthétiques (validation sur les Synthétiques) sur 200 epochs	40
3.7	Courbe d'exactitude de la validation pour les données Réelles (validation sur les Réelles) sur 200 epochs	41
3.8	Courbe de perte de la validation pour les données Réelles (validation sur les Réelles) sur 200 epochs	41
3.9	Bifurcation avec AIC (vérité terrain)	42
3.10	Prédiction de la bifurcation avec AIC (données réelles)	42
3.11	Bifurcation avec AIC (vérité terrain)	42
3.12	Prédiction de la bifurcation avec AIC (données réelles)	42
3.13	Prédiction de la bi- furcation avec AIC (dans le cas des données réelles) avant le post-traitement où les points jaunes représente la prédiction du AIC	45
3.14	Prédiction de la bi- furcation avec AIC (dans le cas des données réelles) après le post-traitement où les points rouge représente la vérité terrain du AIC et les points vertes représente la prédiction du AIC	45

Liste des tableaux

2.1 Répartition des jeux de données selon leurs types	30
3.1 Les résultats de l'entraînement, du test, et de la validation pour les trois types de Données sur 200 epochs	38
3.2 Pourcentage de bifurcations avec AIC détectées pour les différents modèles	43

Liste des Abréviations

AIC	Anévrismes Intracrâniens
AVC	Accident Vasculaire Cérébral
CAD	Computer Aided Design
CNN	convolutional neural network
DL	Deep Learning
IA	Intelligence Artificielle
IOU	Intersection Over Union
IRM	Imagerie par Résonance Magnétique
ML	Machine Learning
3D	3 Dimensions

Introduction

Les anévrismes intracrâniens (AIC) (figure 1.1) se définissent par une hernie acquise de la paroi artérielle, survenant préférentiellement sur une bifurcation artérielle, avec une prédilection topographique caractéristique au niveau des vaisseaux de la base du crâne. La détection fortuite d'un AIC par scanner ou IRM est fréquente, ces examens étant de plus en plus pratiqués [1]. Ces anomalies vasculaires graves, si elles ne sont pas détectées et traitées à temps, peuvent entraîner des complications potentiellement mortelles. L'identification précoce et précise de ces anévrismes est donc essentielle pour la planification des interventions thérapeutiques. La détection des anévrismes intracrâniens permet de prévenir des complica-

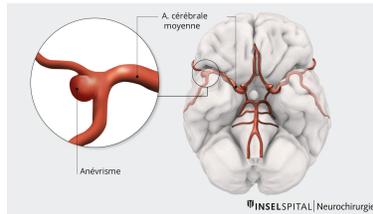


FIGURE 1 – Anévrisme intracrânien

tions graves, telles que les ruptures (Figure 1.2) pouvant entraîner des hémorragies cérébrales et des séquelles neurologiques majeures. Une fois détecté, un anévrisme peut être surveillé de près pour évaluer son évolution, et des décisions thérapeutiques peuvent être prises pour éviter sa rupture. Cela inclut des interventions chirurgicales, comme le clipping, ou des techniques moins invasives, telles que l'embolisation endovasculaire. En somme, la détection précoce des anévrismes offre la possibilité d'une prise en charge proactive et personnalisée, augmentant ainsi les chances de survie et la qualité de vie des patients. Dans ce contexte, le présent travail se concentre spécifiquement sur la détection des anévrismes au niveau du cercle de Willis, une région où ces anomalies se manifestent fréquemment en raison de la complexité de la circulation sanguine et des bifurcations artérielles. Nous proposons une approche de détection automatique des anévrismes intracrâniens sur des nuages de points 3D (Figure 1.3), basée sur l'apprentissage profond et utilisant le modèle PointNet++. Les nuages de points sont des ensembles de points discrets

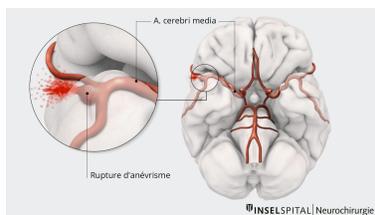


FIGURE 2 – Rupture d’anévrisme intracrânien dans le cerveau humain

dans l’espace 3D, utilisés pour représenter des surfaces ou des volumes complexes. Il existe différents formats de fichiers pour les nuages de points, chacun avec ses propres avantages et limites. Parmi ces formats les plus courant sont les suivants :

- * PLY (Polygon File Format) : format largement utilisé qui prend en charge à la fois le stockage de données ASCII et binaire ;
- * LAS (LiDAR Data Exchange Format) : format utilisé pour enregistrer les données des nuages de points LiDAR, offrant une bonne compression et un support aux métadonnées.
- * E57 (ASTM E57 Standard) : format polyvalent et indépendant de l’éditeur qui prend en charge différents types de données, notamment les nuages de points, les images et les métadonnées.

Les formats ci-dessus ne sont que quelques exemples, mais il existe de nombreux autres types de formats de nuages de points, en fonction des exigences spécifiques d’un projet. Ils trouvent des applications variées, notamment en médecine, où ils servent à la reconstruction anatomique, l’analyse des structures internes et le suivi de la progression des maladies. En architecture et patrimoine, les nuages de points permettent la numérisation précise d’objets et de bâtiments. En robotique, ils sont essentiels pour la navigation autonome, aidant les robots à comprendre et interagir avec leur environnement en trois dimensions. Nous nous intéressons spécifiquement

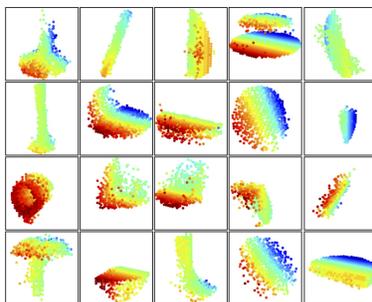


FIGURE 3 – Représentiondes objets en nuages de points : chaise, table, ghitare...etc

à l’analyse des bifurcations vasculaires en utilisant des crops 3D, c’est-à-dire des sous-volumes extraits autour des structures d’intérêt. Travailler sur des images 3D complètes est souvent trop coûteux en termes de calcul et de mémoire. Pour sur-

monter cette limitation, nous utilisons des crops plus petits, qui permettent de cibler précisément les régions critiques tout en réduisant la complexité computationnelle. Cette approche rend le processus d'apprentissage plus efficace et permet d'obtenir des résultats plus précis avec des ressources limitées.

Afin de mener à bien cet apprentissage, nous avons opté pour l'utilisation d'un modèle synthétique. Ce choix s'explique par deux raisons principales : d'une part, il nous permet d'entraîner le modèle exclusivement sur des données synthétiques avant de le tester sur des images réelles, ce qui est crucial pour évaluer sa capacité de généralisation. D'autre part, il facilite l'augmentation des données réelles en simulant différentes variations, enrichissant ainsi le jeu de données et améliorant la robustesse du modèle. L'utilisation d'un modèle synthétique offre donc une flexibilité et une diversité de données essentielles pour un apprentissage performant.

Ainsi, notre approche combine l'extraction de crops 3D pertinents, l'utilisation de données synthétiques et l'application de techniques avancées de traitement de nuages de points pour améliorer la détection des anévrismes. En plus de son potentiel pour le diagnostic médical, cette méthode pourrait également ouvrir la voie à des applications similaires dans d'autres domaines nécessitant une analyse fine de structures complexes en 3D.

Après l'entraînement, le modèle est testé sur un ensemble de données inédites pour évaluer sa capacité à prédire la présence d'anévrismes. Cependant, il peut arriver que le modèle génère des prédictions incorrectes, telles que la détection de plusieurs clusters d'anévrismes au sein d'une même bifurcation. Pour quantifier la performance du modèle, une étape de post-traitement est mise en place, où les distances entre les barycentres des clusters prédits sont comparées à ceux des clusters de la vérité terrain. Cette comparaison permet de calculer la métrique Intersection over Union (IoU), qui évalue la précision de la localisation des anévrismes prédits par rapport à la vérité terrain.

Pour améliorer les performances du modèle, plusieurs approches peuvent être envisagées. L'une d'elles consiste à augmenter la taille de la base de données réelle, surtout si l'apprentissage est effectué sur des images réelles. Une autre approche est d'enrichir et d'améliorer les données synthétiques afin qu'elles soient plus représentatives des données réelles. L'intégration des données réelles et synthétiques peut également être bénéfique, en utilisant les synthétiques pour augmenter le volume des données réelles.

En conclusion, bien que la comparaison des clusters prédits avec la vérité terrain soit utile pour évaluer les performances, l'amélioration du modèle repose sur l'enrichissement des jeux de données et l'optimisation des paramètres d'entraînement. L'objectif de ce travail de fin d'études est de présenter cette méthodologie

en détail et de démontrer son efficacité à travers des résultats expérimentaux.

Chapitre 1

Etat de l'art

La détection automatique des anévrismes intracrâniens repose sur une large diversité de méthodes, issues de l'imagerie médicale, de l'intelligence artificielle (IA) et de l'apprentissage profond. Ce chapitre se propose d'explorer des concepts fondamentaux, tels que la définition des anévrismes intracrâniens, leur importance cruciale dans le diagnostic médical, ainsi que le rôle du cercle de Willis dans la circulation cérébrale. Nous présenterons également les différents types d'acquisitions d'images médicales et les formats d'images couramment utilisés dans le cadre de la détection des anévrismes.

Ensuite, nous aborderons les principes de l'intelligence artificielle appliqués à ce domaine, en commençant par les méthodes traditionnelles de détection basées sur les images médicales. Nous examinerons également les approches récentes de l'état de l'art qui utilisent des techniques d'apprentissage profond pour analyser les nuages de points et les volumes 3D. Une attention particulière sera portée aux différentes architectures de réseaux de neurones, aux stratégies de prétraitement des données et aux métriques d'évaluation spécifiques à ce problème.

Enfin, nous discuterons des limitations actuelles de ces méthodes et des perspectives d'amélioration, en mettant en lumière les défis liés à l'entraînement des modèles sur des données synthétiques, ainsi que les problèmes de généralisation des modèles aux données réelles. Ce chapitre servira ainsi de base pour comprendre les avancées récentes et les défis actuels dans le domaine de la détection automatique des anévrismes intracrâniens.

1.1 Définition des anévrismes intracrâniens

Un anévrisme intracrânien (AIC) est une dilatation localisée de la paroi d'une artère cérébrale, le plus souvent située au niveau des bifurcations des vaisseaux

sanguins du cerveau. Cette pathologie est due à une faiblesse de la paroi artérielle, provoquant la formation d'une poche qui peut, en cas de rupture, entraîner une hémorragie sous-arachnoïdienne. Les causes exactes des anévrismes sont encore débattues, mais des facteurs génétiques, le tabagisme, l'hypertension et certaines maladies du tissu conjonctif sont souvent associés à leur formation.

Les anévrismes touchent environ 2 à 5 % de la population générale, mais tous ne se rompent pas. Lorsqu'ils se rompent, les conséquences peuvent être fatales, avec un taux de mortalité d'environ 50 % dans les 30 jours suivant l'hémorragie. Les patients survivants présentent souvent des séquelles neurologiques importantes. Les symptômes d'un anévrisme non rompu peuvent inclure des maux de tête sévères, des troubles de la vision, ou des douleurs oculaires, mais ils passent fréquemment inaperçus jusqu'à leur rupture. Le traitement des anévrismes non rompus repose généralement sur des interventions chirurgicales, telles que le clippage ou la coiling endovasculaire, pour prévenir leur rupture.

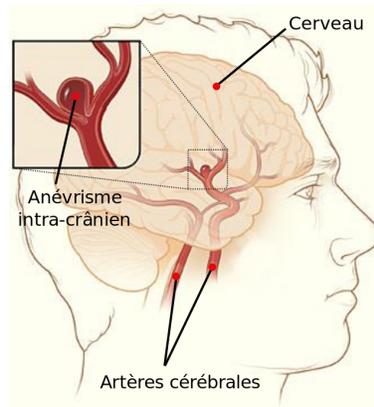


FIGURE 1.1 – L'anévrisme intracrânien dans le cerveau humain

1.2 L'importance de la détection automatique des anévrismes

La détection précoce des anévrismes est essentielle pour prévenir les ruptures et minimiser les risques associés. Cependant, la détection manuelle d'un anévrisme à partir d'images médicales est un processus long et complexe, sujet aux erreurs humaines telles que la fatigue ou le manque de concentration. En raison de la nature complexe des structures vasculaires intracrâniennes, une détection automatique des anévrismes à l'aide de l'intelligence artificielle (IA) et de méthodes d'apprentissage profond peut significativement améliorer la précision, la rapidité et la cohérence du diagnostic.

Les systèmes automatisés peuvent réduire le fardeau des radiologues et fournir des analyses en temps réel, notamment dans des situations où les interventions rapides sont critiques. Ces technologies permettent également de standardiser les diagnostics et de réduire la variabilité inter-observateurs, rendant le processus plus fiable.

1.3 Le cercle de Willis et son rôle

Le cercle de Willis est une structure vasculaire située à la base du cerveau, formée par l'interconnexion de plusieurs artères principales, notamment les artères carotides internes et les artères vertébrales. Cette configuration circulaire joue un rôle essentiel dans la circulation sanguine cérébrale en garantissant une perfusion adéquate du cerveau.

Sa principale fonction est de maintenir un apport sanguin constant, même en cas de rétrécissement ou d'occlusion d'une artère. En agissant comme un réseau de secours, le cercle de Willis permet de compenser les perturbations de la circulation sanguine, assurant ainsi que les différentes régions du cerveau reçoivent l'oxygène et les nutriments nécessaires à leur bon fonctionnement.

Cependant, cette zone est également particulièrement vulnérable à la formation d'anévrismes intracrâniens, surtout aux bifurcations artérielles, où la pression sanguine est plus susceptible d'entraîner des dilatations anormales des vaisseaux. La détection précoce des anévrismes dans cette région est donc cruciale. Une rupture d'un anévrisme peut provoquer des AVC ischémiques ou des hémorragies sous-arachnoïdiennes, entraînant des conséquences potentiellement fatales. Ainsi, la surveillance et la détection des anomalies vasculaires au sein du cercle de Willis sont essentielles pour la prévention des complications graves associées aux anévrismes intracrâniens.

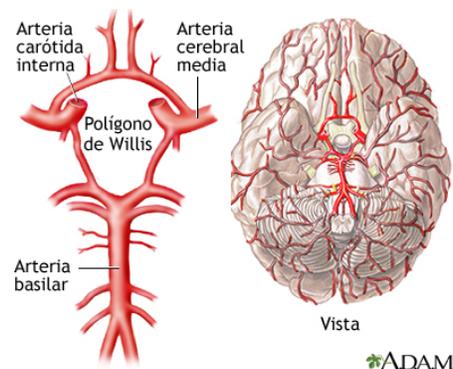


FIGURE 1.2 – Cercle de willis

1.4 Types d'acquisitions d'images médicales

La détection des anévrismes intracrâniens repose sur des techniques d'imagerie avancées, qui permettent de visualiser les structures vasculaires cérébrales avec une grande précision. Voici les méthodes les plus courantes :

IRM (Imagerie par Résonance Magnétique) : Permet une excellente résolution des tissus mous et est souvent utilisée pour visualiser les anévrismes non rompus. Elle est non invasive et ne nécessite pas l'utilisation de rayons X.

MRA (Imagerie par Résonance Magnétique Angiographique) : Spécialement utilisée pour visualiser les vaisseaux sanguins. C'est une technique non invasive permettant de détecter les anévrismes grâce à des agents de contraste, tout en utilisant les principes de l'IRM pour obtenir des images des artères.

CTA (Angiographie par Tomodensitométrie) : Utilise des rayons X combinés à un agent de contraste injecté pour visualiser les vaisseaux sanguins et les anévrismes. Elle offre une résolution plus élevée et est particulièrement efficace pour diagnostiquer les anévrismes rompus.

DSA (Angiographie numérisée par soustraction) : Méthode invasive où un cathéter est inséré dans une artère pour injecter un produit de contraste directement dans les vaisseaux sanguins. Les images obtenues sont très précises et sont souvent utilisées avant une intervention chirurgicale. Cependant, en raison de son caractère invasif, elle est moins fréquemment utilisée pour le dépistage.

TDM (Tomodensitométrie) : Couramment appelée scanner, cette méthode repose sur les rayons X pour créer des images détaillées en coupe du cerveau. Bien qu'elle ne soit pas spécifiquement destinée aux vaisseaux sanguins, elle peut être utilisée en première ligne pour diagnostiquer des anomalies intracrâniennes, y compris les anévrismes.

Ultrason Doppler transcrânien : Technique non invasive basée sur les ultrasons, permettant de mesurer le flux sanguin dans les principales artères cérébrales. Elle est moins utilisée pour la détection des anévrismes eux-mêmes, mais peut être employée pour détecter des anomalies dans le flux sanguin qui pourraient suggérer la présence d'un anévrisme.

PET (Tomographie par Émission de Positons) : Technique qui utilise des traceurs radioactifs pour évaluer la fonction des tissus et des organes. Bien qu'elle ne soit pas couramment utilisée pour la détection directe des anévrismes, elle peut être combinée avec des techniques comme la TDM pour fournir des informations fonctionnelles complémentaires sur la perfusion cérébrale.

Chaque méthode présente des avantages et des inconvénients en fonction du type d'anévrisme à diagnostiquer (rompu ou non rompu), de la localisation et des

besoins cliniques spécifiques. L'IRM et l'angiographie MRA sont privilégiées pour les anévrismes non rompus, tandis que la CTA et la DSA sont plus souvent utilisées dans des cas d'urgence ou pour des évaluations chirurgicales.

1.5 Formats d'images utilisés en imagerie médicale

Les images médicales sont souvent stockées dans des formats spécifiques pour faciliter leur analyse. Les principaux formats d'images sont :

1. .nrrd (Nearly Raw Raster Data) : Couramment utilisé pour stocker des images volumétriques.
2. .tif : Format d'image utilisé en radiologie pour sa capacité à stocker des images haute résolution.
3. .dicom : Le format standard utilisé pour l'archivage et la transmission d'images médicales.

1.6 Introduction à l'IA, au ML et au DL

L'intelligence artificielle (IA) désigne un ensemble de technologies permettant aux machines d'effectuer des tâches complexes nécessitant normalement une intelligence humaine, telles que la reconnaissance de motifs, la prise de décision, ou encore l'apprentissage. L'IA repose sur des modèles algorithmiques capables de traiter de grandes quantités de données et d'en tirer des informations pour effectuer des prédictions ou prendre des décisions.

L'IA se divise principalement en trois sous-catégories :

1. IA générale : Une forme hypothétique d'intelligence artificielle capable d'effectuer n'importe quelle tâche cognitive humaine de manière flexible et autonome. Ce type d'IA n'existe pas encore.
2. IA spécialisée : C'est l'IA que nous utilisons aujourd'hui dans divers secteurs (santé, industrie, finance). Elle est conçue pour résoudre des tâches spécifiques, comme la détection des anomalies médicales, l'analyse d'images ou la reconnaissance vocale.

L'apprentissage automatique (Machine Learning, ML) est une sous-catégorie de l'IA qui permet aux machines d'apprendre à partir de données sans être explicitement programmées pour chaque tâche. Plutôt que de suivre des instructions précises, les algorithmes de ML développent des modèles statistiques à partir des données fournies, puis utilisent ces modèles pour effectuer des prédictions ou classifications sur de nouvelles données.

L'apprentissage profond (Deep Learning, DL) est une sous-catégorie du ML qui utilise des réseaux de neurones artificiels, souvent très profonds (de nombreuses couches), pour modéliser des relations complexes au sein des données. Les réseaux de neurones profonds sont particulièrement adaptés à l'analyse d'images médicales complexes, car ils peuvent automatiquement extraire et apprendre des caractéristiques à différents niveaux d'abstraction. Le DL est particulièrement efficace dans les tâches impliquant de grandes quantités de données, telles que la reconnaissance d'images, la segmentation d'objets ou la classification de formes complexes, ce qui le rend particulièrement efficace pour les tâches de vision par ordinateur, comme la détection et la classification des anévrismes.

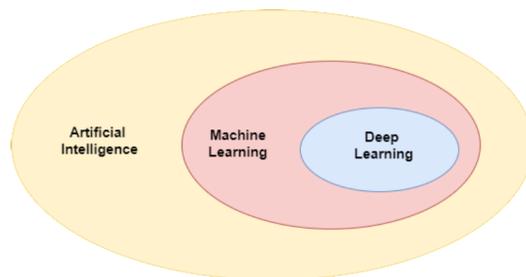


FIGURE 1.3 – Différence entre IA, ML et DL

1.7 Méthodes de détection des anévrismes intracrâniens basées sur les images

Historiquement, la détection des anévrismes intracrâniens a été réalisée manuellement par des radiologues à partir de l'imagerie par résonance magnétique (IRM)[1] ou de tomodensitométrie (scanner). Ces méthodes, bien qu'efficaces dans de nombreux cas, présentent des limitations inhérentes à l'intervention humaine, notamment la fatigue, l'inattention et les compétences variables des cliniciens. De plus, le diagnostic est parfois subjectif et peut varier d'un professionnel à l'autre. Les avancées technologiques ont permis de développer des méthodes de détection assistées par ordinateur (CAD), qui visent à surmonter ces limitations en offrant des outils d'aide au diagnostic pour les spécialistes.

La détection des anévrismes intracrâniens repose sur diverses méthodes utilisant des images, qu'elles soient en 2D ou en 3D. Parmi ces approches, on trouve des techniques de traitement d'image comme la segmentation par seuil, l'analyse de contours et les méthodes basées sur les caractéristiques, qui nécessitent souvent une interprétation manuelle par des experts, ce qui peut être long et sujet à des erreurs.

Avec l'avènement de l'intelligence artificielle, des solutions plus modernes ont émergé. Les méthodes basées sur le deep learning comme les réseaux de neurones convolutifs (CNN) [3] sont devenus des outils populaires dans ce domaine. Ils analysent les images médicales pour détecter automatiquement les anévrismes, atteignant souvent des performances comparables à celles des experts humains dans certaines études (références nécessaires pour des taux spécifiques).

Bien que les CNN soient efficaces pour traiter des images 2D et 3D, leur performance peut être affectée par la complexité et la variabilité des données médicales. Pour surmonter ces limitations, des approches plus récentes se concentrent sur l'analyse directe des nuages de points 3D, qui permettent de mieux capturer la géométrie complexe des structures vasculaires, offrant ainsi des perspectives prometteuses pour la détection des anévrismes.

1.8 Méthodes de détection des anévrismes intracrâniens basées sur les nuages de points

Contrairement aux méthodes basées sur des images 2D ou 3D structurées, les nuages de points permettent de représenter directement les structures 3D complexes sans perte de résolution. Ces représentations non structurées sont particulièrement adaptées à l'analyse des formes et des géométries irrégulières des vaisseaux sanguins. Des modèles comme PointNet [4] et PointNet++ [2] ont démontré leur efficacité dans le traitement de ces données, en particulier dans le domaine médical pour des tâches de segmentation et de classification.

PointNet utilise une approche globale qui prend en compte l'ensemble du nuage de points, permettant de capturer les caractéristiques essentielles de la forme sans dépendre de la structure de l'entrée. PointNet++ améliore cette approche en intégrant des techniques de hiérarchisation qui exploitent à la fois des informations locales et globales, rendant le modèle plus performant face à des variations de densité dans les nuages de points.

Ces modèles exploitent la géométrie tridimensionnelle des objets, ce qui les rend particulièrement adaptés à la détection d'anévrismes intracrâniens, où la forme et la localisation des bifurcations sont cruciales. En préservant l'information géométrique des structures vasculaires complexes, PointNet++ permet une analyse fine des données, rendant ce modèle particulièrement efficace pour la détection des anévrismes dans les nuages de points.

Chapitre 2

Méthodologie

Dans cette étude, nous avons adopté une approche basée sur le modèle PointNet++ pour la détection automatique des anévrismes intracrâniens à partir de nuages de points 3D. Le pipeline que nous avons développé exploite directement les caractéristiques géométriques des structures vasculaires et comprend plusieurs étapes de prétraitement, d'enrichissement des données, et post-traitement, visant à maximiser la précision de la détection tout en minimisant les erreurs de prédiction.

2.1 Originalité

2.1.1 Avantages des Nuages de Points par Rapport aux Stacks 3D

L'une des originalités de cette approche réside dans l'utilisation des nuages de points 3D au lieu de stacks d'images 3D comme base d'entrée. Les stacks 3D, bien que couramment utilisés en imagerie médicale, présentent plusieurs limitations pour la segmentation de formes complexes comme les bifurcations artérielles. En effet, ces images sont souvent des coupes successives qui peuvent entraîner une perte de résolution au niveau des détails subtils. Elles nécessitent également une grande capacité de calcul pour traiter les volumes et imposent une structure rigide, ce qui limite la représentation des formes géométriques irrégulières des anévrismes.

En revanche, les nuages de points permettent une modélisation directe des structures vasculaires en 3D, sans dépendance aux grilles ou à la résolution des images. Cette flexibilité permet d'exploiter pleinement la géométrie complexe des bifurcations et des anévrismes. De plus, avec PointNet++, il est possible de capturer à la fois des caractéristiques locales et globales dans ces nuages de points, offrant ainsi une meilleure performance de détection.

2.1.2 Génération de Bifurcations à l'Aide d'un Modèle Synthétique

La détection précise des anévrismes intracrâniens est un enjeu majeur en imagerie médicale, notamment pour prévenir les risques de rupture et les conséquences graves qui peuvent en découler. Toutefois, obtenir des annotations manuelles fiables sur des images 3D pour l'entraînement des modèles d'apprentissage profond est une tâche extrêmement laborieuse. Pour répondre à ce défi, les auteurs de l'article [6] propose une approche novatrice qui repose sur la génération de modèles synthétiques de bifurcations artérielles, combinées à des anévrismes simulés, afin de créer de vastes ensembles de données utilisés pour former des réseaux de neurones profonds.

1. Modélisation Géométrique : La première étape de cette approche consiste à créer un modèle 3D réaliste de bifurcations artérielles.

* Création de la bifurcation artérielle : Un cube de 60x60x60 voxels est utilisé comme espace de modélisation. À l'intérieur de ce cube, trois points sont sélectionnés sur les faces pour représenter les extrémités des branches artérielles. Les segments reliant ces points au centre du cube forment le "squelette" de la bifurcation. Ce squelette est ensuite épaissi en le convoluant avec une sphère binaire, simulant les parois épaisses des artères réelles. Pour rendre le modèle plus réaliste, une déformation élastique est appliquée aux branches afin de reproduire la tortuosité naturelle des artères dans le cerveau.

* Ajout de l'anévrisme : Un anévrisme est modélisé en fusionnant une sphère binaire avec la bifurcation artérielle. Cette sphère subit également des déformations géométriques pour refléter la complexité des anévrismes observés dans les structures vasculaires réelles. L'anévrisme est positionné dans la région où la pression sanguine est la plus élevée, généralement à l'angle formé par deux branches artérielles, ce qui correspond à l'emplacement typique des anévrismes sacciformes.

* Calcul de la position et de la distance de l'anévrisme : La position précise de l'anévrisme par rapport à la bifurcation est déterminée par des vecteurs directionnels tracés à partir du centre de la bifurcation. Une équation spécifique est utilisée pour calculer la distance optimale à laquelle placer l'anévrisme, en fonction de l'angle formé par les branches et de l'épaisseur des artères.

2. Modélisation du Bruit : En plus de la modélisation géométrique, il est essentiel de reproduire le bruit présent dans les acquisitions MRA-TOF (An-

giographie par résonance magnétique en temps de vol) pour que les modèles synthétiques soient réalistes. Le bruit dans ces images est approximé par une distribution gaussienne, et des filtres spécifiques sont appliqués pour correspondre aux caractéristiques statistiques des images réelles. Cela permet d’ajouter un bruit réaliste autour des bifurcations et des anévrismes synthétiques, imitant ainsi les diverses composantes du cerveau comme la matière grise, le liquide céphalo-rachidien, et les autres tissus visibles sur les images MRA-TOF.

En combinant ces éléments, le modèle synthétique permet de générer un grand nombre d’images réalistes de bifurcations artérielles portant des anévrismes. Ces données synthétiques peuvent ensuite être utilisées pour entraîner des réseaux de neurones, facilitant ainsi la détection et la segmentation automatique des anévrismes dans des données d’imagerie réelles.

3. Intégration dans l’Entraînement du Modèle : Les données synthétiques générées sont intégrées dans le processus d’entraînement du modèle PointNet++ :

- * Enrichissement des Données : En utilisant des bifurcations synthétiques, le jeu de données est enrichi, permettant au modèle de rencontrer un plus grand nombre de variations d’anévrismes.

- * Amélioration de la Généralisation : Le modèle peut ainsi apprendre à détecter des anévrismes dans des contextes variés, ce qui améliore sa capacité de généralisation sur des cas réels non rencontrés lors de l’entraînement.

4. Avantages de l’Approche Synthétique :

- * Diversification des Scénarios : La génération synthétique permet de créer des situations rares ou inexistantes dans les données réelles.

- * Réduction du Surapprentissage : En exposant le modèle à une diversité accrue, on réduit le risque de surapprentissage sur les données réelles limitées.

2.2 Fonctionnement du Modèle PointNet++

Le modèle PointNet++[2] est une extension hiérarchique du modèle PointNet [4] qui améliore sa capacité à capturer des caractéristiques locales des nuages de points 3D. Contrairement à PointNet, qui traite l’ensemble des points de manière globale, PointNet++ introduit des niveaux d’abstraction locaux, permettant une meilleure prise en compte des structures locales à différentes échelles.

2.2.1 Limitations de PointNet

PointNet est un modèle de deep learning qui fonctionne sur des nuages de points non ordonnés, offrant des propriétés d'invariance aux permutations et une capacité à traiter directement des points bruts. Toutefois, une limitation majeure de PointNet est son incapacité à capturer des relations locales entre les points. Il traite les points de manière indépendante avant d'agréger globalement les caractéristiques, ce qui limite sa capacité à reconnaître des motifs locaux, surtout dans des scènes où la densité de points varie.

2.2.2 Introduction de la Hiérarchie dans PointNet++

PointNet++ surmonte ces limitations en introduisant une hiérarchie d'apprentissage des caractéristiques, similaire aux réseaux convolutifs utilisés en traitement d'image, mais adaptée aux nuages de points 3D. Le modèle procède par étapes successives où :

1. Des sous-ensembles de points sont échantillonnés.
2. Les caractéristiques locales sont apprises à partir de ces sous-ensembles.
3. Ces sous-ensembles sont ensuite agrégés pour capturer les relations à plus grande échelle.

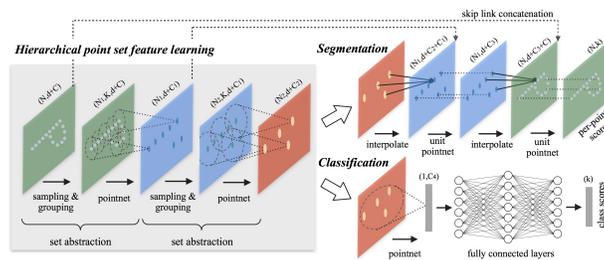


FIGURE 2.1 – L'architecture du modèle Pointnet++

L'image de l'architecture de PointNet++ illustre le flux hiérarchique dans lequel des points 3D sont d'abord échantillonnés, puis regroupés autour de points centraux à différentes échelles pour capturer des caractéristiques locales. Chaque région locale est ensuite traitée par un mini PointNet, qui extrait des caractéristiques, propagées ensuite à des niveaux d'abstraction supérieurs. Le modèle combine ces caractéristiques locales et globales, puis les propage aux points originaux via des interpolations, permettant d'effectuer des tâches de classification ou de segmentation précises sur des nuages de points de tailles variées. Alors, Ce processus de construction d'une hiérarchie permet au modèle de capturer à la fois des motifs locaux et globaux dans des nuages de points, améliorant ainsi la capacité à comprendre des formes complexes comme les bifurcations vasculaires et les anévrismes

intracrâniens.

2.2.3 Méthode d'Échantillonnage et de Groupement

Dans PointNet++, l'échantillonnage et le groupement des points sont des étapes essentielles pour structurer le nuage de points en sous-ensembles sur lesquels l'apprentissage des caractéristiques locales peut être effectué.

1. Échantillonnage par Points les Plus Éloignés (FPS) : Ce mécanisme est utilisé pour sélectionner un sous-ensemble de points à partir du nuage original. Il garantit que les points sélectionnés sont les plus éloignés les uns des autres dans l'espace, ce qui assure une couverture homogène de l'espace 3D. Cela permet d'éviter que certains points ne soient trop proches les uns des autres, ce qui pourrait entraîner une perte de diversité dans les caractéristiques apprises.
2. Groupement des Points Locaux : Après l'échantillonnage, chaque point sélectionné devient un centre (ou "centroïde") autour duquel une région locale est définie. Pour former ces régions locales, PointNet++ utilise deux méthodes :
 - Requête en boule (ball query) :** Cette méthode sélectionne tous les points situés à l'intérieur d'une sphère de rayon donné autour du point centroïde.
 - k-plus proches voisins (kNN) :** Ici, les k points les plus proches du centroïde sont sélectionnés pour former le sous-ensemble local. Une fois les points groupés, le modèle applique PointNet à chaque sous-ensemble local pour apprendre des caractéristiques spécifiques à ces zones.

2.2.4 Apprentissage des Caractéristiques Locales

Une fois les sous-ensembles formés, PointNet++ applique PointNet, dans sa version initiale, pour extraire les caractéristiques locales de chaque sous-ensemble. Chaque région locale est traitée indépendamment, et des caractéristiques de haut niveau sont apprises. Ces caractéristiques sont ensuite propagées à des niveaux supérieurs, où des regroupements plus globaux sont effectués.

2.2.5 Multi-Échelle et Multi-Résolution

L'une des forces majeures de PointNet++ réside dans sa capacité à capturer des motifs locaux à différentes échelles, ce qui est essentiel pour traiter des scènes réelles avec des densités de points variables. Le modèle utilise deux approches distinctes pour résoudre ce problème :

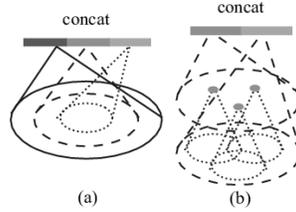


FIGURE 2.2 – (a) Groupement Multi-échelle (MSG); (b) Groupement Multi-résolution (MRG)[2]

- Groupement Multi-Échelle (MSG) :

Cette méthode apprend des caractéristiques à plusieurs échelles simultanément (voir Figure 2.2(a)). Autour de chaque point centroïde, plusieurs régions de différentes tailles sont formées (par exemple, des sphères de petits et grands rayons), et les caractéristiques locales sont extraites pour chacune de ces échelles. Cela permet au modèle de capturer des informations aussi bien fines que grossières, ce qui est crucial pour comprendre des structures à densité variable. Les caractéristiques extraites à chaque échelle sont ensuite concaténées pour former une représentation riche de chaque point.

- Groupement Multi-Résolution (MRG) :

Le MRG est une version plus efficace du MSG, où l'apprentissage des caractéristiques à différentes résolutions se fait en combinant les caractéristiques locales à faible résolution avec des caractéristiques globales extraites directement des points bruts (voir Figure 2.2(b)). Cette méthode réduit le coût computationnel tout en conservant la capacité d'adaptation à la densité des points.

2.2.6 Propagation des Caractéristiques et Segmentation

Pour les tâches de segmentation (comme la détection d'anévrismes), PointNet++ inclut un mécanisme de propagation des caractéristiques des points centraux vers les points originaux. Cette interpolation est réalisée en utilisant une technique d'inverse des distances, où les caractéristiques des points échantillonnés sont propagées aux points voisins non échantillonnés en fonction de leur proximité. Les connexions de saut sont utilisées pour combiner ces caractéristiques avec celles des points originaux, afin de conserver à la fois des informations locales fines et des informations globales de haut niveau.

Cette méthode est particulièrement efficace pour la segmentation sémantique des nuages de points, où il est crucial de prédire l'étiquette de chaque point du nuage en fonction de son contexte local et global.

2.2.7 Applications et Résultats du Modèle

PointNet++ a montré des résultats impressionnants dans des tâches de classification et de segmentation de nuages de points. Grâce à sa capacité à s'adapter aux densités variées et à capturer des caractéristiques multi-échelles, il surpasse les performances des modèles précédents, notamment dans des applications complexes comme la segmentation de scènes 3D réelles et la classification d'objets en 3D.

2.3 Préparation et Validation Initiale du Modèle

Avant de personnaliser et d'appliquer le modèle PointNet++ à notre ensemble de données d'anévrismes intracrâniens, nous avons d'abord utilisé le code source original disponible sur GitHub, fourni par les auteurs de PointNet++. Cette étape initiale a impliqué le test du modèle sur ShapeNetDataCore, une base de données largement utilisée pour les recherches en apprentissage automatique sur les nuages de points.

ShapeNetDataCore est une vaste collection de modèles 3D provenant de divers objets du monde réel, répartis en différentes catégories. Elle est conçue pour évaluer les performances des algorithmes de traitement de nuages de points, offrant des objets avec des formes variées et des détails géométriques complexes. Cette base de données comprend des centaines de milliers de modèles, chacun représenté sous forme de nuages de points avec des annotations qui permettent l'apprentissage supervisé.

Nous avons utilisé cette base de données pour comprendre les performances du modèle PointNet++ dans des conditions contrôlées et sur des types de données standards avant d'adapter le modèle à notre projet spécifique. Cette validation préliminaire nous a permis de nous familiariser avec le traitement des données, les ajustements nécessaires et les paramètres optimaux pour notre propre ensemble de données. En analysant les résultats obtenus avec ShapeNetDataCore, nous avons pu mieux appréhender les spécificités du modèle et préparer efficacement son application à la détection des anévrismes intracrâniens.

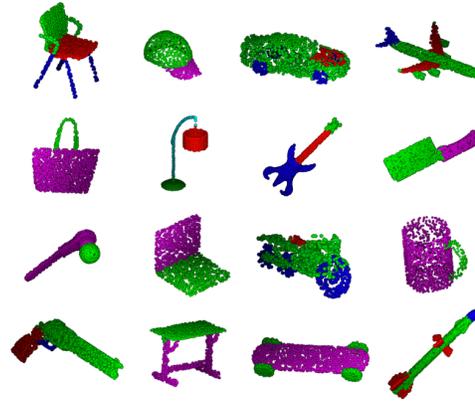


FIGURE 2.3 – Les résultats de segmentation avec ShapeNetCore dataset

2.4 Répartition des jeux de données

Cette section décrit la répartition des jeux de données utilisés pour l’entraînement, le test, et la validation. Les données comprennent des échantillons réels, augmentés (réels + synthétiques), et synthétiques avec une validation synthétique et d’autre avec une validation réelle, comme détaillé dans le tableau ci-dessous.

TABLE 2.1 – Répartition des jeux de données selon leurs types

Type de Données	Répartition des Données		
	Entraînement (60%)	Test (20%)	Validation (20%)
Données Réelles	279 Réelle	93 Réelle	93 Réelle
Données Augmentées	403 Réelle + Synthétique	133 Réelle	134 Réelle + Synthétique
Données Synthétiques (validation Synthétique)	154 Synthétique	51 Réelle	51 Synthétique
Données Synthétiques (validation Réelle)	154 Synthétique	51 Réelle	51 Réelle

Données Réelles : Dans ce cas, toutes les données utilisées pour l’entraînement, le test et la validation sont réelles.

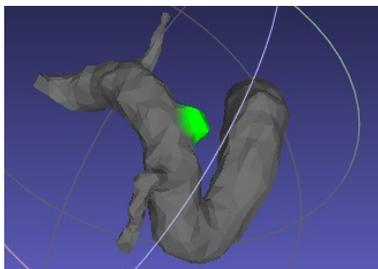


FIGURE 2.4 – Un maillage 3D d’une bifurcation réelle avec un AIC

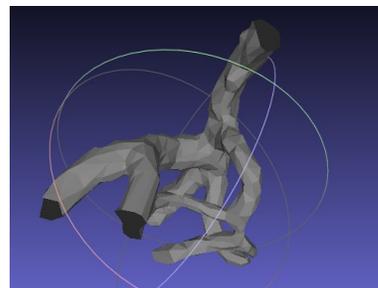


FIGURE 2.5 – Un maillage 3D d’une bifurcation réelle sans un AIC

Données Augmentées : Ce scénario inclut des données réelles et synthétiques pour l’entraînement et la validation. L’entraînement utilise une combinaison de 403 échantillons réelles et synthétiques. Le test est effectué sur 133 échantillons

réels, tandis que la validation est faite sur une combinaison de 134 échantillons réelles et synthétiques.

Données Synthétiques (validation Synthétique) : Ici, seules les données synthétiques sont utilisées pour l'entraînement et la validation, tandis que le test est effectué sur des données réelles.

Données Synthétiques (validation Réelle) : Dans ce cas, les données synthétiques sont utilisées seulement pour l'entraînement et la validation le test sont effectués sur des données réelles.

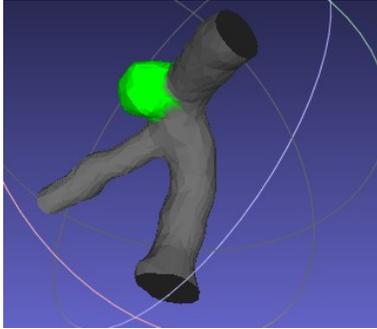


FIGURE 2.6 – Un maillage 3D d'une bifurcation synthétique avec un AIC



FIGURE 2.7 – Un maillage 3D d'une bifurcation synthétique sans un AIC

2.5 Prétraitement des Données au but de convertir les Fichiers .nrrd vers les Nuages de Points

Le processus de transformation commence par la conversion des fichiers volumétriques au format .nrrd en nuages de points, suivie de plusieurs étapes de prétraitement pour garantir une représentation optimale des bifurcations artérielles et des anévrismes.

1. **Détection des Bifurcations et Extraction des Crops 3D** Ce processus consiste à parcourir les stacks volumétriques réelles au format .nrrd et à détecter les centres de bifurcations. Ces centres servent de points de référence pour extraire des crops 3D de taille 64x64x64 autour des bifurcations. Cette étape est essentielle pour s'assurer que les données capturent à la fois les bifurcations artérielles et les anévrismes potentiels.
2. **Lissage Gaussien** Avant la conversion des fichiers .nrrd en maillages 3D, un lissage gaussien est appliqué aux données volumétriques. Cela permet d'éliminer le bruit et de simplifier les surfaces complexes des bifurcations, facilitant ainsi la conversion en maillages tout en conservant les détails essentiels.

3. **Sélection des Bifurcations par volume** Pour constituer un ensemble de données représentatif, nous avons calculé le volume de chaque bifurcation. Parmi les bifurcations initiales, nous avons sélectionné de manière à couvrir toute la gamme de volumes, du plus petit au plus grand. Cette approche garantit que l'ensemble de données est représentatif des différentes tailles de bifurcations, ce qui aide le réseau à apprendre de manière plus générale.

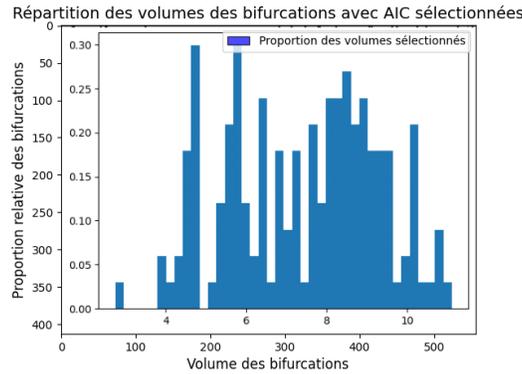


FIGURE 2.8 – Répartition des volumes des bifurcations avec AIC sélectionnées

La figure ci-dessous illustre la distribution des volumes des bifurcations sélectionnées pour constituer l'ensemble de données. Chaque barre représente une gamme spécifique de volumes, avec l'axe horizontal indiquant la taille des volumes et l'axe vertical représentant la proportion relative des bifurcations appartenant à chaque intervalle de volume. Cette répartition permet de s'assurer que l'ensemble de données couvre une diversité de tailles de bifurcations, garantissant ainsi une meilleure généralisation lors de l'entraînement du modèle.

4. **Conversion en Maillage 3D (.obj)** Les bifurcations sélectionnées ont été converties en maillage 3D au format .obj. Ce maillage capture les surfaces des bifurcations et des anévrismes en 3D. Les couches intérieures non pertinentes sont ensuite supprimées pour ne conserver que les structures nécessaires à l'analyse.

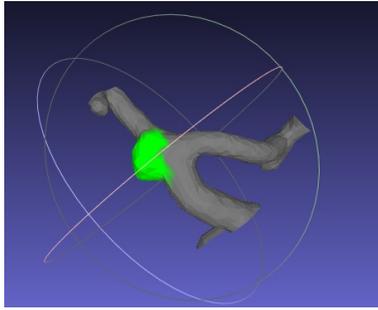


FIGURE 2.9 – Un maillage 3D d'une bifurcation avec un AIC où la partie verte représente l'anévrisme

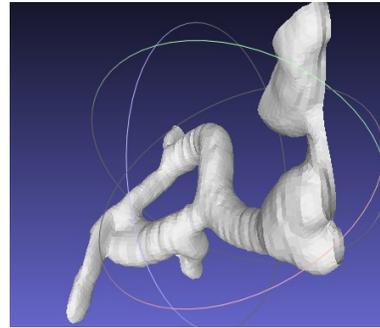


FIGURE 2.10 – Un maillage 3D d'une bifurcation sans un AIC

5. **Transformation des Maillages 3D en Nuages de Points** À partir du maillage 3D, les coordonnées des points 3D et les normales de surface sont extraites pour créer des nuages de points. Ces données sont stockées dans des fichiers .txt, avec chaque point portant des informations sur sa position et son orientation.

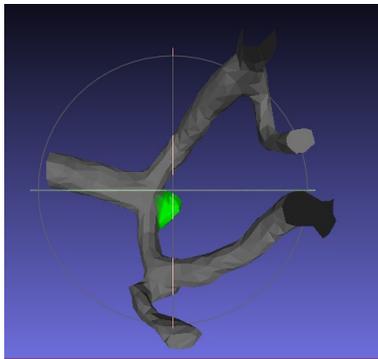


FIGURE 2.11 – Un maillage 3D du set de l'entraînement

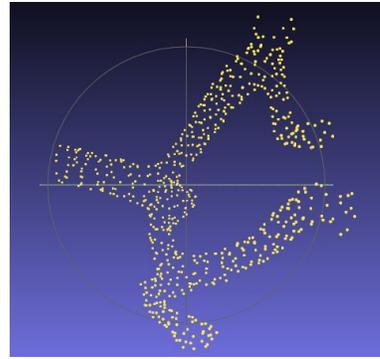


FIGURE 2.12 – Nuage de points du maillage 3D après transformation

6. **Étiquetage des Points** Chaque point du nuage de points est étiqueté en fonction de la présence ou de l'absence d'anévrisme. Les points représentant des anévrismes reçoivent le label 1.0, tandis que les autres sont étiquetés 0.0. Cette étape est cruciale pour la segmentation ultérieure des anévrismes par le modèle PointNet++.
7. **Conversion en Fichiers .ply Colorés** Les nuages de points sont ensuite convertis en fichiers .ply colorés. Les points représentant des anévrismes sont colorés en rouge (label 1.0), tandis que les autres sont colorés en blanc (label 0.0). Cette étape permet une visualisation facile des anévrismes et facilite la validation des données.



FIGURE 2.13 – L’affichage des nuages de points colorés en format (.ply) où la partie rouge représente un AIC

8. **Suréchantillonnage des Nuages de Points** Afin de garantir une meilleure représentation des bifurcations et d’améliorer la précision du modèle, les nuages de points sont suréchantillonnés. Bien que le modèle PointNet++ soit conçu pour fonctionner sur 2048 points par nuage de points, ici, nous utilisons 4096 points pour capturer plus finement les détails géométriques des bifurcations et des anévrismes.
9. **Reconversion en Format .txt** Après avoir généré les fichiers .ply, ceux-ci sont reconvertis en format .txt pour être compatibles avec le modèle PointNet++. Chaque fichier .txt contient les coordonnées (x, y, z) , les normales (n_x, n_y, n_z) , ainsi que les labels indiquant la présence ou non d’anévrismes.

2.6 Outils et Technologies Utilisés

2.6.1 Python et PyTorch

Python est le langage de programmation principal utilisé pour le développement et l’exécution des scripts de traitement des données et d’entraînement du modèle. Sa simplicité et sa vaste bibliothèque d’outils pour le traitement de données, l’apprentissage automatique et la manipulation de fichiers en font un choix idéal pour ce projet. PyTorch, une bibliothèque de deep learning en Python, a été employée pour la construction et l’entraînement du modèle PointNet++. PyTorch offre une flexibilité élevée et des capacités robustes pour le calcul différentiel et l’optimisation, ce qui est crucial pour gérer des réseaux de neurones complexes et volumineux. Grâce à ses fonctionnalités de calcul sur GPU, PyTorch permet un entraînement rapide et efficace des modèles de deep learning.

2.6.2 Trimesh et PyMeshLab

Trimesh est une bibliothèque Python spécialisée dans la manipulation et l'analyse des maillages 3D. Elle a été utilisée pour lire, modifier et convertir les maillages 3D nécessaires à la création des nuages de points. Trimesh facilite les opérations complexes sur les maillages, telles que la fusion, le découpage, et la simplification. PyMeshLab est une autre bibliothèque Python qui a complété les tâches de traitement de maillages. Elle est conçue pour effectuer des opérations géométriques avancées sur les maillages 3D, comme le nettoyage des surfaces, la réparation des maillages, et la transformation des formats. Ensemble, ces outils ont permis de préparer les maillages 3D de manière efficace avant leur conversion en nuages de points.

2.6.3 Visualisation avec MeshLab

MeshLab est un logiciel de visualisation et d'édition de maillages 3D. Il a été utilisé pour explorer visuellement les maillages 3D et les nuages de points générés. MeshLab offre une gamme complète d'outils pour l'analyse visuelle des données 3D, permettant de vérifier la qualité des conversions de maillages et d'inspecter les résultats obtenus après traitement. La possibilité d'appliquer des filtres et de visualiser les maillages en différentes vues aide à garantir que les données sont correctes et prêtes pour l'entraînement du modèle. MeshLab a joué un rôle clé dans la validation des données et la détection d'éventuelles erreurs dans les maillages avant l'analyse finale.

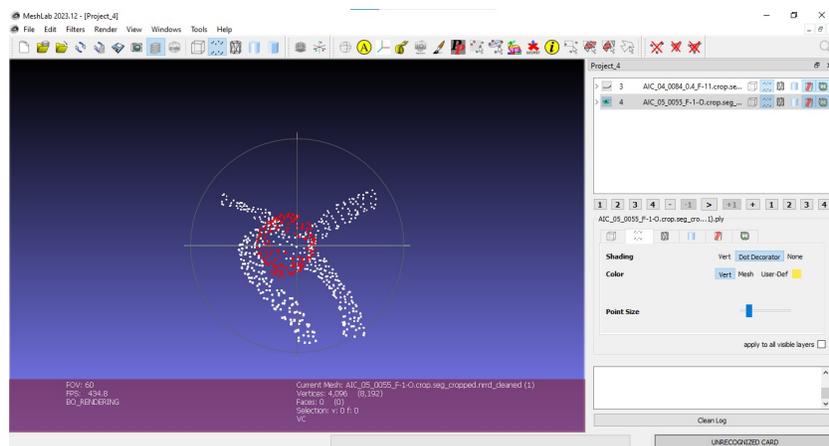


FIGURE 2.14 – L'interface graphique de MeshLab

2.7 Métriques de performance : IOU

L'intersection sur l'union (IoU) est une mesure clé utilisée en vision par ordinateur pour évaluer les performances et la précision des algorithmes de détection d'objets. Elle quantifie le degré de chevauchement entre deux boîtes englobantes : l'une représentant la « vérité de terrain » (l'emplacement réel d'un objet) et l'autre représentant la « prédiction » du modèle pour le même objet. Il mesure le degré d'alignement d'un objet prédit sur l'annotation réelle de l'objet. Un score d'IOU plus élevé implique une prédiction plus précise.

Sa représentation mathématique est la suivante :

$$\textit{Intersection over Union} = \frac{\textit{Area of Intersection}}{\textit{Area of Union}}$$

Où,

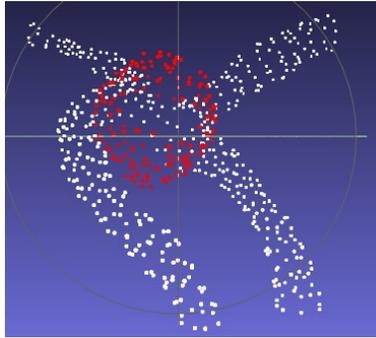
Area of Intersection : Surface commune partagée par les deux boîtes de délimitation (chevauchement).

Area of Union : surface totale couverte par les deux boîtes de délimitation.

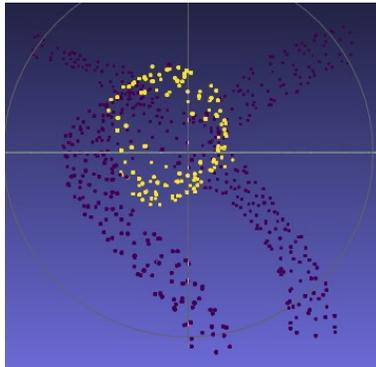
Pour calculer l'IOU, on prends en considération les coordonnées des points qui représentent les anévrismes détectés par le modèle ainsi que les coordonnées des points correspondants dans la vérité de terrain. Afin d'avoir un IOU plus précis et significatif, nous avons suivie les étapes suivantes :

1. Extraction des Coordonnées : Pour chaque prédiction d'anévrisme, nous extrayons les coordonnées des points 3D qui composent le volume prédit.
2. Identification de la Vérité de Terrain : De même, nous identifions les coordonnées des points dans la vérité de terrain qui correspondent à l'anévrisme réel.
3. Calcul de l'Aire d'Intersection et d'Union : L'aire d'intersection est déterminée par le nombre de points 3D qui se chevauchent entre la prédiction et la vérité de terrain. L'aire d'union est calculée comme la somme de tous les points des deux ensembles moins l'aire d'intersection.

Exemple Prenons un exemple pour illustrer ce concept. Considérons une vérité de terrain représentant un anévrisme, qui se compose de plusieurs points 3D (en rouge) :



Et voici une prédiction du modèle (en jaune) pour le même anévrisme :



Dans cet exemple, le score IoU calculé est de 0.8533, indiquant un chevauchement significatif entre la vérité de terrain et la prédiction. Comme ce score est largement supérieur à 10 %, on peut conclure que l'anévrisme a été correctement détecté. Cette approche permet de quantifier avec précision la performance de notre modèle en termes de détection d'anévrismes.

Chapitre 3

Expérimentations et résultats

Ce chapitre présente les résultats obtenus à partir de l’entraînement et de l’évaluation du modèle PointNet++ sur les différents ensembles de données. Les performances du modèle sont mesurées à travers plusieurs indicateurs, notamment l’exactitude de l’entraînement, l’exactitude du test, et l’exactitude de validation. On a également analysé la métrique d’Intersection over Union (IOU) pour évaluer la qualité des prédictions du modèle en termes de localisation précise des anévrismes. Les résultats obtenus permettent de comparer l’efficacité du modèle sur des données réelles, augmentées, et synthétiques, et de mettre en évidence les forces et les limites de l’approche proposée.

3.1 Résultats de l’Entraînement

Les performances du modèle PointNet++ ont été évaluées sur trois types de données : Données Réelles, Données Augmentées, et Données Synthétiques avec une validation synthétique et d’autre avec une validation réelle. Les résultats de l’entraînement, du test, et de la validation sont résumés dans le tableau ci-dessous.

TABLE 3.1 – Les résultats de l’entraînement, du test, et de la validation pour les trois types de Données sur 200 epochs

Types de Données	Résultats			
	Train Accuracy	Train Loss	Test Accuracy	Validation Accuracy
Données Réelles	0.99330	0.01722	0.96126	0.95438
Données Augmentées	0.98750	0.02575	0.96969	0.96012
Données Synthétiques (validation Synthétique)	0.97818	0.04019	0.93335	0.95773
Données Synthétiques (validation Réelle)	0.97886	0.03906	0.93687	0.94576

Le tableau 3.1 présente les résultats d’entraînement, de test et de validation obtenus sur trois types de données (réelles, augmentées et synthétiques) après 200

époches d'entraînement. Pour les données réelles, l'exactitude d'entraînement atteint 99,33 % avec une perte d'entraînement de 0,01722, tandis que les performances sur les ensembles de test et de validation sont respectivement de 96,13 % et 95,44 %. Les données augmentées montrent une légère diminution de l'exactitude d'entraînement à 98,75 %, avec une perte de 0,02575, mais elles affichent des résultats de test et de validation améliorés, atteignant 96,97 % et 96,01 %. En revanche, les données synthétiques présentent une exactitude d'entraînement de 97,82 % et une perte de 0,04019, avec des performances de test et de validation de 93,34 % et 95,77 % pour la validation synthétique, et 93,69 % et 94,58 % pour la validation réelle. Ces résultats soulignent l'efficacité du modèle sur les données réelles et augmentées, tout en indiquant des défis avec les données synthétiques, ce qui peut impliquer une nécessité d'amélioration dans la qualité ou la représentativité des données synthétiques utilisées.

En complément du tableau, les courbes de accuracy et de loss de validation sont présentées dans les figures ci-dessous, permettant de visualiser la convergence du modèle et sa capacité de généralisation sur les différents ensembles de données.

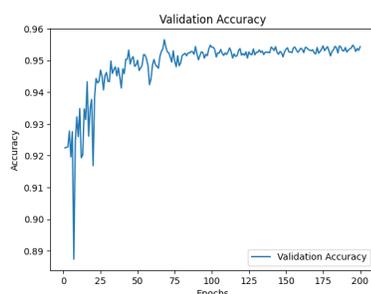


FIGURE 3.1 – Courbe d'exactitude de la validation pour les données Réelles sur 200 epochs

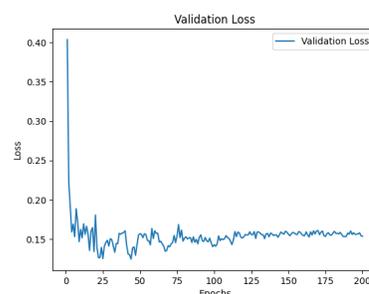


FIGURE 3.2 – Courbe de perte de la validation pour les données Réelles sur 200 epochs

Dans la figure 3.1, la courbe d'exactitude augmente rapidement au début, atteignant environ 0,95 au bout de 50 époques. Après cela, elle se stabilise avec des fluctuations mineures. Cela montre que le modèle converge bien sur les données réelles, atteignant une performance stable après un nombre limité d'époques. Cependant, les fluctuations après 50 époques suggèrent un léger surapprentissage ou des variations dans les données de validation.

Pour la figure 3.2, la perte diminue rapidement pour atteindre un minimum autour de 0,1, puis se stabilise avec quelques variations mineures. Cela indique que le modèle apprend efficacement. Les variations autour du minimum suggèrent que le modèle oscille autour de son optimum, probablement à cause d'une légère suradéquation aux données d'entraînement.

La courbe de la figure 3.3 montre une croissance rapide de l'exactitude, qui

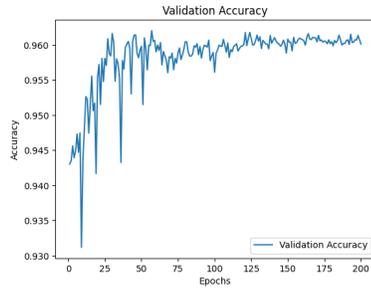


FIGURE 3.3 – Courbe d’exactitude de la validation pour les données Augmentées sur 200 epochs

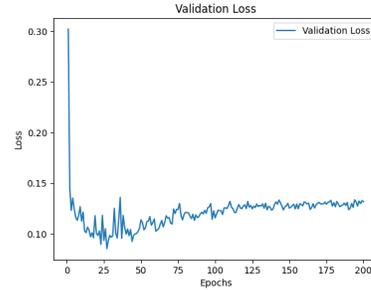


FIGURE 3.4 – Courbe de perte de la validation pour les données Augmentées sur 200 epochs

atteint environ 0,95 puis fluctue autour de cette valeur. L’utilisation de données augmentées semble améliorer la performance initiale, mais les fluctuations indiquent que le modèle peut avoir du mal à généraliser parfaitement avec des données augmentées.

La perte dans la figure 3.4 diminue initialement puis se stabilise autour de 0,1. Des variations significatives sont observées après 100 époques. Les variations après une phase de stabilisation montrent que le modèle a du mal à trouver un minimum stable, peut-être en raison de la diversité accrue des données augmentées.

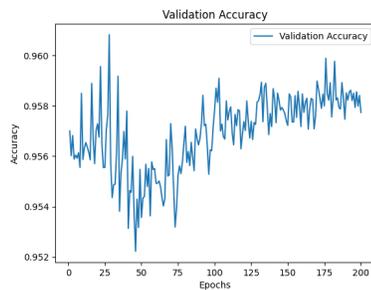


FIGURE 3.5 – Courbe d’exactitude de la validation pour les données Synthétiques (validation sur les Synthétiques) sur 200 epochs

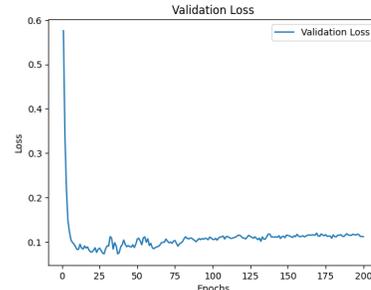


FIGURE 3.6 – Courbe de perte de la validation pour les données Synthétiques (validation sur les Synthétiques) sur 200 epochs

Pour la figure 3.5, l’exactitude augmente rapidement jusqu’à 0,95 et présente ensuite des fluctuations plus prononcées que les autres courbes. Donc, les fluctuations suggèrent que le modèle est moins stable sur les données synthétiques, ce qui peut indiquer une variabilité ou une complexité plus élevée dans ces données par rapport aux réelles

Dans la figure 3.6, la perte diminue rapidement au début, mais oscille fortement autour de 0,15 après 50 époques. Les oscillations peuvent indiquer que le modèle a des difficultés à se stabiliser, probablement en raison de la différence entre les données d’entraînement et de validation.

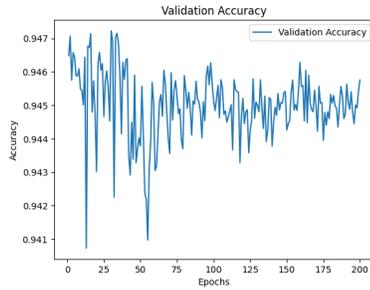


FIGURE 3.7 – Courbe d’exactitude de la validation pour les données Réelles (validation sur les Réelles) sur 200 epochs

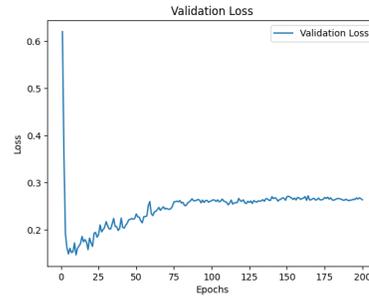


FIGURE 3.8 – Courbe de perte de la validation pour les données Réelles (validation sur les Réelles) sur 200 epochs

L’exactitude de validation dans la figure 3.7 commence à environ 0,93 et montre des fluctuations plus importantes que les autres courbes. Cela montre que le modèle, entraîné sur des données synthétiques, a du mal à généraliser sur des données réelles. Les fluctuations montrent que le modèle ne parvient pas à capturer complètement la distribution des données réelles.

Dans la figure 3.8, la perte diminue au début, mais reste relativement élevée (autour de 0,3) avec des fluctuations. La perte plus élevée et les fluctuations montrent que le modèle a du mal à généraliser sur les données réelles après avoir été entraîné sur des données synthétiques. Cela suggère que les données synthétiques ne capturent pas complètement les caractéristiques des données réelles.

3.2 Résultats de la Prédiction

Après l’entraînement du modèle PointNet++ sur les ensembles de données préparés, nous avons évalué sa capacité à détecter les anévrismes intracrâniens sur les jeux de données de test. Les prédictions obtenues ont été analysées pour identifier la présence d’anévrismes dans les bifurcations artérielles et les résultats montrent des performances globalement prometteuses. Cependant, certaines erreurs subsistent, notamment des faux positifs, où le modèle a identifié des anévrismes inexistantes, et des faux négatifs, où des anévrismes présents n’ont pas été détectés. Ces erreurs peuvent diminuer la performance globale du modèle et nécessitent une analyse approfondie afin d’améliorer les résultats futurs.

3.2.1 Pré-traitement des Données de Test et Prédictions : Centrage et mise en échelle

Avant de procéder à l’analyse des prédictions, un pré-traitement a été effectué pour garantir la cohérence entre les données de vérité terrain et les prédictions

du modèle. Les données de vérité terrain ont été centrées pour uniformiser leur position dans l'espace, tandis que les prédictions ont été centrées et mises à l'échelle pour s'assurer qu'elles soient alignées à la fois en termes de centre et d'échelle avec la vérité terrain. Cette étape est cruciale pour permettre un calcul précis de l'Intersection over Union (IOU) entre les prédictions et la vérité terrain, en évitant toute distorsion liée à des différences d'échelle ou de position.

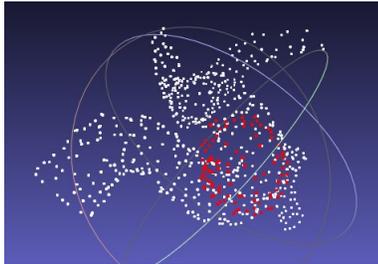


FIGURE 3.9 – Bifurcation avec AIC (vérité terrain)

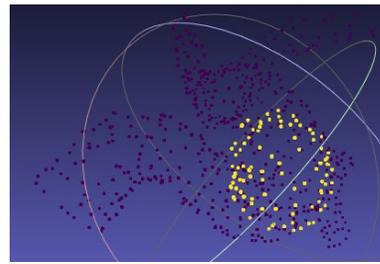


FIGURE 3.10 – Prédiction de la bifurcation avec AIC (données réelles)

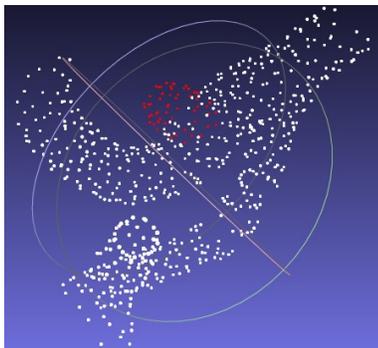


FIGURE 3.11 – Bifurcation avec AIC (vérité terrain)

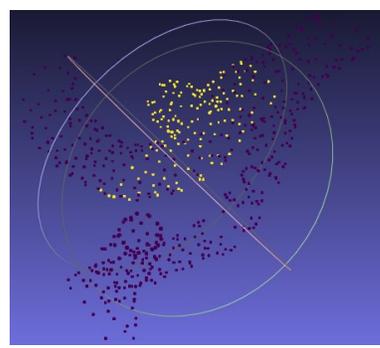


FIGURE 3.12 – Prédiction de la bifurcation avec AIC (données réelles)

Sur la figure (3.9), nous voyons une bifurcation avec un anévrisme intracrânien (AIC) d'après la vérité terrain. Les points en rouge représentent l'anévrisme. La figure (3.10) montre la prédiction de la même bifurcation effectuée à l'aide du modèle entraîné sur des données réelles. Pour cette bifurcation, nous avons obtenu un IOU de 0,9748, indiquant que le modèle a correctement prédit la zone de l'anévrisme.

Dans la figure (3.11), une bifurcation avec un AIC de la vérité terrain est illustrée, où les points rouges indiquent l'anévrisme. La figure (3.12) montre la prédiction correspondante à l'aide du modèle entraîné sur des données réelles. Pour cette bifurcation, un IOU de 2,7690 a été obtenu, signifiant que le modèle a identifié des points supplémentaires comme étant des anévrismes, bien qu'ils ne soient pas considérés comme tels dans la vérité terrain. Cela souligne la nécessité d'une analyse et d'un post-traitement plus approfondis des prédictions pour améliorer la précision du modèle.

En revanche, pour les bifurcations sans anévrismes (sans AIC), le modèle s’est montré particulièrement robuste, quel que soit le type de données utilisé lors de l’entraînement (données réelles, augmentées ou synthétiques). Aucun problème de faux positifs n’a été observé dans ces cas, indiquant que le modèle distingue efficacement les bifurcations saines de celles présentant des anévrismes. Ce résultat démontre la capacité du modèle à éviter les détections erronées dans des cas où il n’y a pas de pathologie, ce qui est crucial pour limiter les faux diagnostics en pratique clinique.

3.2.2 Analyse des résultats

Nous avons évalué la performance du modèle sur des bifurcations réelles avec anévrisme intracrânien (AIC) en testant différents modèles entraînés sur des données réelles, synthétiques ou augmentées. Le pourcentage de bifurcations avec AIC détectées correspond au nombre de bifurcations avec un IOU supérieur à 0.1 (10%) divisé par le nombre total de bifurcations avec AIC.

TABLE 3.2 – Pourcentage de bifurcations avec AIC détectées pour les différents modèles

Types de donnée	Nombre total de bifurcations avec AIC (sur données réelles)	Pourcentage détecté (%)
Réelles	45	100%
Augmentées	55	98.18%
Synthétiques (validation synthétique)	20	65%
Synthétiques (validation réelle)	20	35%

Entraînement sur données réelles : Lorsque le modèle est entraîné uniquement sur des données réelles, il détecte 100% des bifurcations avec AIC dans l’ensemble de test composé également de données réelles. Ce résultat montre une excellente performance du modèle lorsqu’il est testé dans le même contexte que celui de l’entraînement.

Entraînement sur données Augmentées : Pour le le modèle est entraîné sur des données Augmentées, il détecte 98.18% des bifurcations avec AIC dans l’ensemble de test composé seulement de données réelles.

Entraînement sur données synthétiques (validation synthétique) : Le modèle entraîné uniquement sur des données synthétiques avec la validation aussi sur les synthétiques obtient un taux de détection de 65%. Cela montre une amélioration par rapport au modèle validé sur les réelles, mais des lacunes subsistent. L’ajout de données synthétiques semble renforcer le modèle, mais il reste des écarts avec les données réelles.

Entraînement sur données synthétiques (validation réelle) : Le modèle entraîné uniquement sur des données synthétiques avec la validation sur les réelles

parvient à détecter 35% des bifurcations avec AIC dans les données réelles. Ce faible taux de détection est probablement dû aux différences significatives entre les caractéristiques des données synthétiques et celles des données réelles, ce qui limite la généralisation du modèle.

L'analyse démontre que l'utilisation de données augmentées permet d'obtenir un modèle plus robuste et plus généraliste. Bien que l'entraînement sur des données réelles permette d'atteindre des performances optimales dans des conditions idéales, l'ajout de données synthétiques enrichit le modèle en diversifiant les cas des anévrismes présentés. Cela améliore la capacité du modèle à généraliser sur des scénarios variés, y compris ceux qui ne sont pas représentés dans le jeu de données réel. En conséquence, les données augmentées offrent un compromis efficace entre la fidélité des données réelles et la diversité des données synthétiques, rendant le modèle plus polyvalent et apte à traiter des situations cliniques variées.

3.3 Post-traitement : Iou

Après avoir effectué les prédictions sur les données de test, le modèle a généré des erreurs, comme des faux positifs (clusters d'anévrismes détectés là où il n'y en a pas) et des faux négatifs (absence de détection là où un anévrisme est présent). Certaines bifurcations, par exemple, présentaient plusieurs clusters prédits malgré la présence d'un seul anévrisme dans la vérité terrain.

Un post-traitement a été mis en place pour analyser ces erreurs. Il consiste à calculer les barycentres des clusters prédits et ceux de la vérité terrain, puis à comparer la distance entre eux. Si la distance dépasse un seuil défini (0,1), le cluster est ignoré, car il ne correspond pas à un véritable anévrisme. Ce post-traitement ne vise pas à améliorer les faux positifs ou les résultats du modèle, mais plutôt à s'assurer que l'IOU calculé est pertinent et représentatif. Il est crucial de comprendre que ce processus n'altère pas les résultats bruts du modèle.

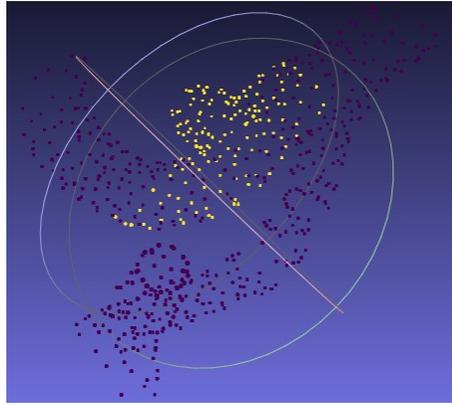


FIGURE 3.13 – Prédiction de la bi-furcation avec AIC (dans le cas des données réelles) avant le post-traitement où les points jaunes représente la prédiction du AIC

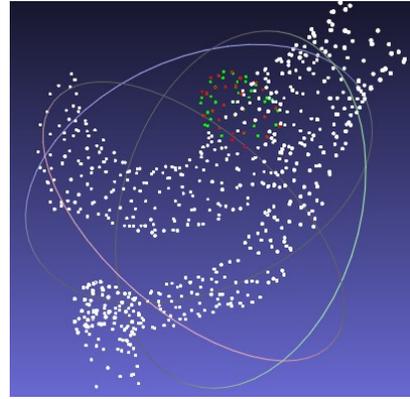


FIGURE 3.14 – Prédiction de la bi-furcation avec AIC (dans le cas des données réelles) après le post-traitement où les points rouge représente la vérité terrain du AIC et les points vertes représente la prédiction du AIC

Par exemple, pour une bifurcation spécifique, le modèle avait initialement prédit un IOU supérieur à 1 (2,7690). Après l'application du post-traitement (Figure 3.14), ce score a été ajusté à 0,8901, ce qui montre que les clusters non pertinents ont été exclus pour obtenir un IOU plus précis. Cela montre que le post-traitement ne modifie pas les prédictions, mais corrige uniquement les mesures pour évaluer la qualité des résultats de manière plus fidèle.

Cette étape est essentielle pour garantir que les métriques calculées, telles que l'IOU, reflètent correctement la performance du modèle sans changer les résultats eux-mêmes. Elle permet une meilleure évaluation des prédictions tout en évitant toute amélioration artificielle des résultats.

Conclusion

Ce projet a exploré une approche novatrice pour la détection automatique des anévrismes intracrâniens à l'aide de l'apprentissage profond sur des nuages de points 3D. L'objectif principal était d'améliorer la précision et l'efficacité de la détection en se concentrant sur les bifurcations vasculaires, une zone où ces anomalies se manifestent fréquemment. L'utilisation du modèle PointNet++ s'est révélée particulièrement adaptée pour capturer la complexité géométrique des anévrismes grâce à sa capacité à apprendre des caractéristiques locales et globales des nuages de points.

Nous avons mis en place un pipeline d'apprentissage basé sur des crops 3D extraits des images médicales volumétriques. Cette méthode a permis de surmonter les limitations associées à l'analyse d'images complètes, souvent trop coûteuse en termes de calcul et de mémoire. En focalisant l'apprentissage sur des sous-volumes ciblés, nous avons pu non seulement réduire la complexité computationnelle mais aussi améliorer la précision de la détection des anévrismes. Les résultats expérimentaux montrent que cette approche permet d'atteindre une meilleure segmentation des anomalies vasculaires par rapport aux méthodes traditionnelles de traitement d'images.

Une autre contribution importante de ce travail est l'utilisation de modèles synthétiques pour enrichir le jeu de données d'apprentissage. Les données synthétiques, générées en simulant des anévrismes dans des bifurcations artérielles, ont permis de diversifier les exemples d'entraînement et d'améliorer la robustesse du modèle face aux variations anatomiques. Cette stratégie s'est avérée efficace pour pallier le manque de données annotées disponibles, un problème majeur dans le domaine médical. En combinant des données réelles et synthétiques, nous avons pu démontrer que le modèle pouvait généraliser correctement et maintenir de bonnes performances sur des cas cliniques non vus pendant l'entraînement.

Cependant, malgré ces succès, plusieurs défis subsistent. L'un des principaux obstacles rencontrés est la génération de données synthétiques réalistes qui capturent fidèlement la variabilité et la complexité des anévrismes observés en pratique

clinique. Bien que les modèles synthétiques aient montré leur utilité, leur capacité à refléter toutes les nuances des données réelles reste limitée. De plus, le traitement des crops 3D nécessite une détection préalable des bifurcations, qui peut introduire des erreurs si les centres ne sont pas correctement identifiés.

Les résultats obtenus montrent également que l'entraînement du modèle sur des données synthétiques seules peut ne pas suffire pour une détection optimale sur des données réelles. Une stratégie d'augmentation de données plus sophistiquée, intégrant des techniques de simulation avancées, pourrait améliorer encore la performance du modèle. Par ailleurs, l'ajustement des hyperparamètres et l'exploration de nouvelles architectures de réseaux de neurones, comme les modèles basés sur les graphes, pourraient offrir des gains supplémentaires en termes de précision et de robustesse.

Les perspectives d'amélioration de ce travail sont multiples. Tout d'abord, l'amélioration de la génération de données synthétiques en utilisant des modèles géométriques et physiques plus réalistes pourrait renforcer l'efficacité du modèle. Ensuite, l'intégration de données multimodales, combinant des nuages de points avec des images volumiques 3D issues de différentes modalités d'imagerie médicale (IRM, CT, etc.), pourrait permettre de capturer des informations complémentaires et d'améliorer la performance globale du système de détection. De plus, le développement d'algorithmes de post-traitement plus sophistiqués, comme des techniques de réduction des faux positifs basées sur des méthodes bayésiennes ou d'autres modèles probabilistes, pourrait contribuer à raffiner les prédictions et à mieux filtrer les erreurs.

Enfin, les applications potentielles de cette approche vont au-delà de la détection des anévrismes intracrâniens. Elle pourrait être adaptée pour détecter d'autres anomalies vasculaires ou structures anatomiques complexes. Le transfert de cette méthodologie à d'autres domaines médicaux, tels que la détection des tumeurs ou l'analyse de la structure des os, ouvrirait de nouvelles perspectives pour l'utilisation de l'apprentissage profond dans l'analyse d'images médicales.

En conclusion, cette étude a mis en lumière le potentiel des nuages de points et des données synthétiques dans la détection automatique des anévrismes intracrâniens. Malgré les défis rencontrés, les résultats obtenus sont prometteurs et témoignent de l'efficacité de cette approche. Les travaux futurs se concentreront sur l'optimisation de ces techniques et leur application à d'autres domaines médicaux, avec pour objectif ultime d'améliorer les outils de diagnostic et d'aider les cliniciens à prendre des décisions éclairées basées sur des données fiables et précises.

Références

- [1] DESAL, H. et BOURCIER, R. Génétique des anévrismes intracrâniens. Bulletin de l'Académie Nationale de Médecine, 2019, vol. 203, no 3-4, p. 124-130, Lien : <https://www.sciencedirect.com/science/article/pii/S000140791930072X>
- [2] QI, Charles Ruizhongtai, YI, Li, SU, Hao, et al. Pointnet++ : Deep hierarchical feature learning on point sets in a metric space. Advances in neural information processing systems, 2017, vol. 30, Lien : <https://proceedings.neurips.cc/paper/2017/hash/d8bf84be3800d12f74d8b05e9b89836f-Abstract.html>
- [3] LIAO, Liang, ASSIS, Youssef, PIERRE, Fabien, et al. Une stratégie efficace de préparation des données pour la détection des anévrismes cérébraux en irm 3d-tof par deep learning. Journal of Neuroradiology, 2022, vol. 49, no 2, p. 118-119, Lien : <https://www.sciencedirect.com/science/article/abs/pii/S0150986122000165>
- [4] QI, Charles R., SU, Hao, MO, Kaichun, et al. Pointnet : Deep learning on point sets for 3d classification and segmentation. In : Proceedings of the IEEE conference on computer vision and pattern recognition. 2017. p. 652-660., Lien : https://openaccess.thecvf.com/content_cvpr_2017/html/Qi_PointNet_Deep_Learning_CVPR_2017_paper.html
- [5] YAN, X. Pointnet pointnet2 pytorch. 2021., Lien : https://github.com/yanx27/Pointnet_Pointnet2_pytorch?tab=readme-ov-file
- [6] Autrusseau, Florent, et al. "Toward a 3d arterial tree bifurcation model for intra-cranial aneurysm detection and segmentation." 2022 26th International Conference on Pattern Recognition (ICPR). IEEE, 2022. , Lien : <https://ieeexplore.ieee.org/abstract/document/9956393>

Résumé

Ce projet présente une méthode de détection automatique des anévrismes intracrâniens (AIC) à l'aide de l'apprentissage profond appliqué aux nuages de points 3D, en utilisant le modèle PointNet++. Le processus commence par la conversion des fichiers d'imagerie médicale en nuages de points 3D, puis l'enrichissement des données pour améliorer la détection des anévrismes. Le modèle est entraîné sur des données réelles, synthétiques et augmentées, afin d'évaluer l'impact de ces différentes sources de données sur les performances de détection. Les résultats montrent une meilleure performance du modèle lorsqu'il est entraîné sur des données réelles, mais les données synthétiques contribuent à la robustesse globale du modèle. La qualité des prédictions est évaluée à l'aide de l'Intersection over Union (IoU), qui compare les clusters prédits à la vérité terrain, permettant une évaluation précise de la localisation des anévrismes.

Abstract

This project presents an automatic detection method for intracranial aneurysms (AIC) using deep learning applied to 3D point clouds, with the PointNet++ model. The process begins with converting medical imaging files into 3D point clouds, followed by data enhancement to improve aneurysm detection. The model is trained on real, synthetic, and augmented data to assess the impact of these various data sources on detection performance. The results show the best performance when the model is trained on real data, but synthetic data contributes to the overall robustness of the model. Prediction quality is evaluated using the Intersection over Union (IoU), which compares the predicted clusters to the ground truth, allowing for an accurate assessment of aneurysm localization.