



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

UNIVERSITE ABOUBAKR BELKAÏD TLEMCE
FACULTE DE TECHNOLOGIE

DEPARTEMENT DE GENIE BIOMEDICAL

LABORATOIRE DE RECHERCHE GENIE BIOMEDICAL

THESE

Pour Obtenir Le Titre De Docteur En Génie Biomédical, Spécialité Imagerie
Médicale

Présenté par BENAHMED Amina

Reconstruction 3D du foie pour une planification chirurgicale personnalisée.

Soutenue publiquement le 04 /12 / 2025

Devant le Jury :

Nom & Prénoms,	Grade	Etablissement	Qualité
HAMZA CHERIF Lotfi	Professeur	Université de Tlemcen (Faculté de Technologie)	Président
KHEMIS Kamila	MCA	Université de Tlemcen (Faculté de Technologie)	Directeur
SAIDI Meryem	MCA	Ecole supérieure de Management(ESMT)	Examinatrice 1
FEROUI Amel	Professeur	Université de Tlemcen (Faculté de Technologie)	Examinatrice 2
LOUDJEDI Salim	Professeur	Université de Tlemcen (Faculté de médecine)	Invité

Année universitaire 2025-2026

Remerciements

Avant toute chose, je rends grâce à **ALLAH**, le Tout-Puissant, pour m'avoir accordé la force, la volonté, la patience et la clarté d'esprit nécessaires à la réalisation de ce travail doctoral.

Je tiens à exprimer ma profonde reconnaissance à **Madame LOUDJEDI Kamila**, directrice de cette thèse, pour la qualité de son encadrement scientifique, ses conseils éclairés, sa rigueur méthodologique et son accompagnement constant tout au long de ce travail. Sa disponibilité et son exigence intellectuelle ont été déterminantes dans l'élaboration et l'aboutissement de cette recherche.

Je remercie sincèrement **HAMZA CHERIF Lotfi** d'avoir accepté de présider le jury de soutenance. Je suis également reconnaissant à **Madame Feroui Amel** et **Madame Saidi Meryem** pour avoir accepté d'examiner ce travail et d'apporter ses observations pertinentes en tant que rapporteur et membre du jury.

Je souhaite également remercier l'ensemble des personnes qui, d'une manière ou d'une autre, ont contribué à la réalisation de cette thèse. Qu'il me soit permis d'exprimer ma gratitude envers tous les enseignants et le personnel du **Département de Génie Biomédical**, pour leur accompagnement durant mon parcours académique.

Enfin, je tiens à adresser mes remerciements à toutes les personnes qui m'ont soutenu, conseillé ou encouragé, que ce soit sur le plan scientifique, moral ou matériel, au cours de ces années de travail et de réflexion.

A Mes parents

Mon mari

Mes frères et mes sœurs

Résumé

Les avancées récentes en intelligence artificielle et en traitement d'image médicale ont considérablement amélioré la planification chirurgicale, notamment en chirurgie hépatique. La reconstruction 3D du foie à partir d'images tomodensitométriques représente un enjeu majeur pour la visualisation anatomique préopératoire.

Nous proposons une méthode automatisée de reconstruction tridimensionnelle du foie en combinant la segmentation par réseau de neurones convolutifs U-Net pour le parenchyme hépatique, un seuillage fondé sur les valeurs de Hounsfield pour les structures vasculaires, et l'algorithme Marching Cubes pour la reconstruction 3D à partir des isovaleurs extraites. L'entraînement a été effectué sur les bases Task03_Liver et 3Dircadb01, avec une optimisation des hyperparamètres (taux d'apprentissage, nombre d'époques, taille de batchs, régularisation). Les performances ont été évaluées sur la base Task08_HepaticVessel.

Le modèle a obtenu des résultats de segmentation très satisfaisants, supérieurs à ceux rapportés dans la littérature, selon les métriques classiques (Dice, précision, rappel). La visualisation 3D en rendu transparent du foie et de son arbre vasculaire, intégrant le modèle d'illumination de Phong, améliore considérablement l'interprétation clinique.

Cette méthode offre une solution robuste pour la planification chirurgicale assistée par l'IA. Des perspectives d'amélioration incluent l'intégration d'une segmentation hépatique selon les segments de Couinaud pour une planification plus fine.

Mots-clés

Segmentation automatique, reconstruction 3D, foie, U-Net, tomodensitométrie, intelligence artificielle, chirurgie hépatique, Marching Cubes, modèle de Phong, segmentation vasculaire

Abstract

Recent advances in artificial intelligence and medical image processing have significantly improved surgical planning, particularly in liver surgery. 3D liver reconstruction from computed tomography images represents a major challenge for preoperative anatomical visualization.

We propose an automated method for three-dimensional liver reconstruction by combining U-Net convolutional neural network segmentation for the liver parenchyma, Hounsfield thresholding for vascular structures, and the Marching Cubes algorithm for 3D reconstruction from extracted isovalues. Training was performed on the Task03_Liver and 3Dircadb01 databases, with hyperparameter optimization (learning rate, number of epochs, batch size, regularization). Performance was evaluated on the Task08_HepaticVessel database.

The model achieved very satisfactory segmentation results, superior to those reported in the literature, according to traditional metrics (Dice, precision, recall). The transparently rendered 3D visualization of the liver and its vascular tree, incorporating the Phong illumination model, significantly improves clinical interpretation.

This method offers a robust solution for AI-assisted surgical planning. Potential improvements include the integration of liver segmentation based on Couinaud segments for more precise planning.

Keywords:

Automatic segmentation, 3D reconstruction, liver, U-Net, computed tomography, artificial intelligence, liver surgery, Marching Cubes, Phong model, vascular segmentation.

الملخص:

أدت التطورات الحديثة في الذكاء الاصطناعي ومعالجة الصور الطبية إلى تحسين التخطيط الجراحي بشكل ملحوظ، وخاصةً في جراحة الكبد. ويمثل إعادة بناء الكبد ثلاثي الأبعاد باستخدام صور التصوير المقطعي المحوسب تحديًا كبيرًا للتصور التشريحي قبل الجراحة.

نقترح طريقة آلية لإعادة بناء الكبد ثلاثي الأبعاد من خلال الجمع بين تجزئة الشبكة العصبية التلافيفية U-Net لنسيج الكبد، وعتبات هونسفيلد للهياكل الوعائية، وخوارزمية Marching Cubes لإعادة البناء ثلاثي الأبعاد من القيم المتساوية المستخرجة. أُجري التدريب على قاعدتي بيانات Task03_Liver وDircadb013، مع تحسين المعاملات الفائقة (معدل التعلم، عدد المراحل، حجم الدفعة، التنظيم). وتم تقييم الأداء على قاعدة بيانات Task08_HepaticVessel.

حقق النموذج نتائج تجزئة مرضية للغاية، متفوقة على تلك المذكورة في المراجع، وفقًا للمقاييس التقليدية (النرد، الدقة، التذكر). يُحسن التصور ثلاثي الأبعاد الشفاف للكبد وشجرة الأوعية الدموية، والذي يتضمن نموذج إضاءة فونغ، التفسير السريري بشكل كبير.

تُقدم هذه الطريقة حلاً فعالاً للتخطيط الجراحي بمساعدة الذكاء الاصطناعي. تشمل التحسينات المحتملة دمج تجزئة الكبد استنادًا إلى مقاطع كوينو لتخطيط أكثر دقة.

الكلمات المفتاحية:

التجزئة التلقائية، إعادة البناء ثلاثي الأبعاد، الكبد، شبكة U-Net، التصوير المقطعي المحوسب، الذكاء الاصطناعي، جراحة الكبد، مكعبات مارشينغ، نموذج فونغ، تجزئة الأوعية الدموية

Table des matières

Table des matières

Chapitre I : Aspect Médical.....	3
Structure du chapitre	4
1. Introduction	4
2. Anatomie du foie	5
3. Vascularisation sanguine du foie	6
4. Physiologie Hépatique.....	9
5. Histologie hépatique.....	10
6. Introduction aux pathologies hépatiques :	14
6.1. Infections	14
6.2. Le Dommage-cirrhose :	14
6.3. Les tumeurs malignes :	16
6.3.1. Cancers d'origine cellulaire :	16
6.3.2. Cancers d'origine vasculaire :	16
7. CHC et transplantation hépatique	18
8. La transplantation hépatique.....	19
7.1. Définition	20
7.2. Les types de transplantation hépatique	20
7.2.1. La transplantation orthotopique :	21
7.2.2. La transplantation hétérotopique :	21
9. Priorité à la transplantation hépatique	22
10. Les étapes de la transplantation hépatique	23
9.1. Le bilan du receveur	23
9.2. Le bilan du donneur cadavérique.....	24
9.3. L'intervention chirurgicale	24
9.4. Le suivi postopératoire en imagerie	26
11. Conclusion.....	27
Chapitre II : Reconstruction et Visualisation 3D	28
Structure du chapitre	29
1. Introduction	29

Table des matières

2.	La Reconstruction 3D.....	29
2.1.	Définition :	29
2.2.	La production d'image Sinogramme :	31
2.2.1.	Mesure de l'atténuation des rayons X (sinogramme) :	31
2.3.	La Projections 1D vers l'image 2D :	33
2.3.1.	L'algorithme de reconstruction aux données du sinogramme :	33
2.4.	De l'image 2D vers l'image 3D :	35
3.	La Modélisations 3D	38
3.1.	Modélisation polygonale	38
3.1.1	L'algorithme Marching cubes.....	38
3.2.	Modélisation 3D par courbes.....	41
3.3.	Modélisation par surfaces.....	42
3.4.	Modélisation géométrique	43
3.5.	Modélisation organique	44
4.	Visualisation 3D.....	46
4.1.	Approches Surfaiques	46
4.2.	Approches Volumiques	47
5.	Les modalités de visualisation 3D	51
5.2	Réalité virtuelle	51
5.2.1	Les systèmes à retour d'effort Haptiques	53
5.3	Réalité augmentée	55
6.	Le Modèle hépatique 3D de Couinaud	56
7.	Reconstruction 3D personnalisée du foie et état de l'art.....	59
8.	État de l'art de la reconstruction 3D des images médicale	61
9.	Conclusion	63
	Chapitre III : Segmentation du foie	64
	Structure du chapitre	65
1.	Introduction	65
2.	Segmentation des images médicales.....	66
2.1.	Définition de la Segmentation	66
3.	Les Approches Principales de la Segmentation	68
3.1	Approches Classiques.....	68
3.1.1	Le Seuillage (Thresholding) :	68
3.1.2	Méthodes Basées sur les Contours.....	72

Table des matières

3.1.3	Segmentation Basée sur la Région.....	78
3.1.4	Méthodes Basées sur l'Énergie et les Graphes.....	80
3.2.	Approches Basées sur l'Apprentissage Automatique	82
3.2.1.	La classification non supervisée (clustering)	83
3.2.2.	La Classification Supervisée.....	86
4.	État de l'Art sur la Segmentation du Foie : Approches Classiques, classification par Machine Learning (ML) et Deep Learning (DL)	87
5.	Méthodes Basées sur L'apprentissage profond (Deep Learning).....	89
5.1.	Neurone artificiel.....	90
5.2.	Les types de réseaux de neurones	93
5.3.	Les Réseaux de neurones convolutifs (CNN)	95
5.3.1.	Architecture d'un CNN	95
5.4	Apprentissage du CNN.....	104
5.4.1	Entraînement et Apprentissage des CNN.....	107
5.4.2.	Importance de l'Entraînement.....	110
5.5.	Optimisation et Régularisation	110
5.5.1	Techniques d'Optimisation.....	111
5.5.2	Méthodes de Régularisation.....	111
6.	Méthodes d'apprentissage profond.....	112
7.	Conclusion	113
	Chapitre IV : Méthode proposée, Résultats et discussion.	117
	Structure de chapitre :	118
1.	Introduction	118
2.	Méthode proposée	119
3.	Environnement de développement.....	121
4.	Base de données	123
4.1	La Base de données « Task03_Liver »	123
4.2	La Base de données « 3D-IRCADb (3D Image Reconstruction for Comparison of Algorithm Database) »:.....	124
4.3	La Base de données « Hepatic Vessel ».....	125
5.	Description du modèle de la segmentation automatique.....	126
5.1.	Architecture du Modèle U-Net	126
5.2.	Le fonctionnement d'U-Net.....	127
5.2.1	Au sein du premier bloc (contraction)	128

Table des matières

5.2.2	Au sein du goulot d'étranglement.....	129
5.2.3	Au sein de bloc d'expansion.....	129
5.3.	L'algorithme de rétro propagation, appliqué aux résultats de l'U - Net.....	133
5.4.	Hyper- paramètres du modèle.....	137
5.4.1	Compilation du Modèle	137
5.4.2	Optimiseur Adam	137
5.4.3	Fonction de Perte : Dice Loss	137
5.4.4	Fonction d'Activation.....	138
5.4.5	Métriques : Dice Coefficient.....	138
5.4.6	Entraînement du Modèle (Epochs)	138
5.4.7	Taille de Batch.....	139
5.4.8	Callback : ModelCheckpoint	139
6.	Implémentation du modèle de Segmentation.....	139
6.1.	Préparation des données	139
6.1.1	Redimensionnement des images	139
6.1.2	Fenêtrage centré sur le foie.....	140
6.1.3	Normalisation des intensités	140
6.2	Entrainement et validation	142
6.2.1	Réglage des Hyper paramètre	142
6.3	Interprétation des résultats	149
6.3.1	Performance du modèle	149
6.3.2	Impact du Learning_rate (LR) de 1e-3.....	149
6.3.3	Impact du dropout = 0.1.....	149
7.	Résultats de Segmentation.....	158
8.	Analyse quantitative des résultats &Discussion	159
8.1	Les critères d'évaluations	159
8.2.1	Définitions de TP, TN, FP, FN en segmentation.....	160
8.2.2	Définitions des critères d'évaluations de la segmentation des images médicales par un modèle d'apprentissage profond.....	161
8.3	Evaluation du modèle de segmentation	165
8.4	Evaluation de la Segmentation sur la base de l'annotation de Couinaud	167
9.	Reconstruction 3D du foie.....	171
10.	Conclusion.....	179
	Conclusion :	182

Table des matières

Bibliographie.....184

Liste des figures

Liste des figures

Figure I. 1 Position et anatomie générale du foie	5
Figure I. 2 La vascularisation hépatobiliaire.....	7
Figure I. 3 Vascularisation reliant le foie au reste de l'organisme.....	7
Figure I. 4 Structure des lobules hépatiques et circulation lobulaire (vue en coupe d'un-lobule).....	8
Figure I. 5 Le système artère –veine du foie sur une image scanner.....	9
Figure I. 6 Histologie hépatique(hépatocyte).....	12
Figure I. 7 Schématisation de triades portale vers la veine centrale.....	13
Figure I. 8 Schématisation de cellule de Kupffer.....	13
Figure I. 9 Les causes de la cirrhose.....	15
Figure I. 10 la cirrhose du Foie.....	15
Figure I. 11 Le Cancer Hépatocellulaire détruit le foie et un risque pour les organes voisins, (a). foie sain et foie malade, (b). Image CT Abdominale en lumière blanche, (c). Un CT Abdominale illustre la position de Cancer Hépatocellulaire les organes voisins.	17
Figure I. 12 Mortalité liée au Carcinome hépatocellulaire en Afrique (EL Serag, 2007).....	18
Figure I. 13 Tumeur du foie Métastatique (de poumon vers le foie).	18
Figure I. 14 Les segments du foie.....	20
Figure I. 15 Transplantation auxiliaire orthotopique, (a). Le greffon est un foie droit, (b). Le greffon est un foie gauche.....	21
Figure I. 16 La transplantation hétérotopique.....	22
Figure I. 17 La technique préservation de la veine cave (a). Piggyback (L. Sulpice, 2013), (b). Piggyback(en transparente).	25
Figure II. 1 Spectre Electromagnétique.	30
Figure II. 2 Sinogramme : principe d'acquisition et image réelle.	31
Figure II. 3 Echantillonnage 2D et 3D : pixels et Voxel (CNRS, 2002).	37
Figure II. 4 Principe de reconstruction d'une surface 2D par Marching squares.	40
Figure II. 5 Situations envisageables de reconstruction pour Marching cubes.....	41
Figure II. 6 Modélisation 3D par courbes pour la construction d'une surface 3D.	42
Figure II. 7 Surface extrudées (création d'une surface en prolongeant une esquisse ou des arêtes le long d'un chemin).	43
Figure II. 8 Modélisation géométrique.	44
Figure II. 9 Metaballs (a : fusion de deux sphères avec R_i et R_j rayons d'influence; b : modélisation organique du tube digestif humain par méta-balls).....	45
Figure II. 10 Principe de la projection radiographique de synthèse (Digitally Reconstructed Radiograph).....	48
Figure II. 11 Systèmes de coordonnées de Rendu volumique et échantillonnage le long d'un rayon. ...	49
Figure II. 12 Casque de réalité virtuelle.	52
Figure II. 13 Réalité virtuelle après reconstruction 3D et planification per-opératoire (A : planification, B : résection virtuelle, C : vérification, D: validation de l'opération en réalité).	53

Liste des figures

Figure II. 14 Equipements à retour d'effort.	54
Figure II. 15 Réalité augmentée (a)-laparoscopie, (b)- image 3D reconstruites à partir de coupes scanné (Soler, 2010).	56
Figure II. 16 Les huit segments de Couinaud avec vascularisation de chaque segment (5 secteurs et 8 segments).	57
Figure II. 17Planification de chirurgie hépatique à la base de la segmentation de Couinaud superposée aux images ct-scan.	59
Figure II. 18Les segments de Couinaud sont généralement approximés par des plans droits (a) qui sont en réalité des plans irréguliers (b) (Jean H. D. Fasel, 2013).	60
Figure III. 1Coupe CT abdominal avec identification de différentes classes.	66
Figure III. 2 Illustration formelle de la segmentation d'image.	67
Figure III. 3 Image CT abdominale avec histogramme montrant les variations anatomiques aux intensités similaires.	70
Figure III. 4 Application du seuillage manuel sur une image CT abdominale.	70
Figure III. 5 Superposition des résultats de segmentation par seuillage simple avec l'image originale du foie,(a) lobes hépatiques,(b) vaisseaux hépatiques.	71
Figure III. 6 Seuillage avec la méthode Otsu.....	72
Figure III. 7 Application de méthode de Canny sur l'image CT abdominal.	73
Figure III. 8 Segmentation avec méthode de Canny et seuillage hystérésis.	74
Figure III. 9Procédure de Level-set : 1. Initialisation de contour 2. Itération jusqu'à convergence (nombre d'itération donné) (Ehsani Rad, 2017).	76
Figure III. 10Segmentation du foie avec la méthode Levelset.	77
Figure III. 11Procédure de croissance de région.....	79
Figure III. 12Segmentation par la méthode croissance en région.	80
Figure III. 13Schéma synoptique de l'algorithme Graph cuts (BOUDRAA, 2022).....	81
Figure III. 14Segmentation par la méthode GraphCuts.	82
Figure III. 15 Types d'apprentissage machine à usage courant pour la segmentation des images médicales (F. Brunelle, 2019)	83
Figure III. 16 Processus de l'algorithme K-means. (Li, 21–22 December 2008).	84
Figure III. 17 Segmentation du foie par la méthode k-means et opérations morphologiques en post-traitement.	85
Figure III. 18 Position du Deep Learning dans les approches d'intelligence artificielle.	90
Figure III. 19Schéma du fonctionnement d'un neurone biologique (a) et d'un neurone artificiel(b). ...	91

Liste des figures

Figure III. 20 Modèle mathématique du neurone artificiel.	92
Figure III. 21 Architecture d'un CNN	96
Figure III. 22 Evolution des cartes de caractéristiques dans le temps.	97
Figure III. 23 Application d'un filtre de convolution 3x3 sur une image 4x4 avec un padding de 1 et un stride de 2 (Yunji Chen, 2024).	98
Figure III. 24 Exemple de max pooling et de average pooling à partir d'une carte de caractéristique intermédiaire (Liang Minfei, 2022)	99
Figure III. 25 Apprentissage d'un réseau de neurones.	100
Figure III. 26 Fonction d'activation les plus utilisés dans le domaine médical.	102
Figure III. 27 Couche entièrement connectée.	103
Figure III. 28 Comparaison entre une classification et une régression	105
Figure III. 29 Qualités d'apprentissage	107
Figure III. 30 Algorithme de descente de gradient montrant la minimisation de la fonction de coût.	110
Figure IV. 1 Flow chart pour la segmentation et la reconstruction 3D du foie et de son réseaux vasculaire (Amina Benahmed, 2024)	120
Figure IV. 2 python le langage de la recherche et programmation IA (intelligence artificiel) dans la segmentation médicale	123
Figure IV. 3 Images CT abdominal de la base de données « Task03_Liver» avec annotation de l'expert en dessous de chaque image source.....	124
Figure IV. 4 Images CT abdominales de la base de données « 3D-IRCADb »avec l'annotation de l'expert en dessous de chaque image source.....	125
Figure IV. 5 Images CT abdominales de la base de données « HepaticVessel ».	126
Figure IV. 6Architecture U-Net (Olaf Ronneberger, 2015).....	127
Figure IV. 7 Opération de convolution : chaque image 3D va être scannée par un filtre 3D de convolution, chaque filtre a un poids et un biais propre (f1, f2) : [weight (w0, w1), biais (b1, b2)]...129	129
Figure IV. 8 La fonction d'activation sigmoid.	130
Figure IV. 9 Sorties du Modèle U-Net	132
Figure IV. 10 les Etapes de segmentation supervisées par le modèle U-Net.	136
Figure IV. 11 Préparation de base de données (3Dircadb) de la partie d'apprentissage de modèle U-Net.....	142
Figure IV. 12: Variation du Dice coefficient pendant le training et pendant la validation (dropout : 10%des neurones sont désactivés et Learning rate Grand) et image prédite par le model.	144

Liste des figures

Figure IV. 13 Variation du Dice coefficient et fonction perte (loss) pendant le training et la validation (dropout : 10%des neurones sont désactivés et Learning rate moyen).....	146
Figure IV. 14 Pré-traitement sur trois coupes CT abdominales à différentes profondeurs : premières sections du foie(a), partie centrale du foie(b), fin du volume hépatique(c).....	147
Figure IV. 15 Résultats de segmentation avec U-Net (avec le meilleur ajustement d' hyper paramètres)	148
Figure IV. 16 Variation du Dice coefficient pendant le training et pendant la validation (dropout : 20%des neurones sont désactivés et Learning rate moyen avec 8 Epoch d'entraînement).	150
Figure IV. 17 Résultats de segmentation avec U-Net (partie test), Dropout=0.2 (20% des neurones sont désactivés)	151
Figure IV. 18Préparation de la base de données Task03_Liverpour l'apprentissage du modèle U-Net.....	153
Figure IV. 19 Résultats de segmentation (partie test) des images CT abdominales (premières coupes du volume hépatique avec un ajustement optimal des hyper paramètres).....	154
Figure IV. 20 Résultats de segmentation (partie test) des images CT abdominales (les dernières coupes du volume hépatique et ajustement optimal des hyper paramètres).....	155
Figure IV. 21 Variation du Dice coefficient pendant l'entraînement et pendant la validation (dropout : 10%des neurones sont désactivés et Learning rate moyen avec 8 Epoch d'entraînement).	156
Figure IV. 22Variation du Dice coefficient pendant l'entraînement et pendant la validation (dropout : 10%des neurones sont désactivés, Learning rate moyen, Batch Normalisation avec 20 Epochs d'entraînement).	157
Figure IV. 23 Test de la Segmentation du foie par le modèle U-Net sur différentes coupes abdominales	159
Figure IV. 24 Illustration imagée des notions de TP, FP, FN, TN.....	161
Figure IV. 25 Matrice de confusion.....	164
Figure IV. 26 Tracé des valeurs des métriques d'évaluation du modèle de segmentation	166
Figure IV. 27 Comparaison des méthodes de segmentation de différents chercheurs sur la base du Dice Similarity Coefficient (DSC).....	167
Figure IV. 28 Contours anatomiques des segments de Couinaud superposés à l'image segmentée ...	168
Figure IV. 29 Contours anatomiques des vaisseaux de Couinaud superposés à l'image des vaisseaux segmentée en régions connexes.....	170
Figure IV. 30 Schéma descriptif de la Reconstruction 3D du foie et des vaisseaux hépatiques.....	172
Figure IV. 31Concaténation des coupes ct abdominal segmentées représentant un foie humain.....	173
Figure IV. 32 Histogramme des intensités du volume segmenté.	174

Liste des figures

Figure IV. 33 Visualisation 3D d'un foie humain segmenté puis Reconstruit avec l'algorithme Marching Cubes.	176
Figure IV. 34 Visualisation 3D du système vasculaire d'un foie humain segmenté puis Reconstruit avec l'algorithme Marching Cubes.....	Erreur ! Signet non défini.
Figure IV. 35 Foie segmentée à partir des coupes CT abdominale avec présence de tumeurs.....	Erreur ! Signet non défini.
Figure IV. 36 Histogramme des intensités du volume hépatique malade.	177
Figure IV. 37 Visualisations 3D après Reconstruction 3D par L'algorithme Marching Cubes d'un foie humain malade segmenté.	178
Figure IV. 38 Visualisations 3D, après Reconstruction 3D avec L'algorithme Marching Cubes, de l'arbre vasculaire d'un foie humain malade mettant en évidence les zones tumorales.	178

Liste des tableaux

Liste des tableaux

Tableau III. 1 Types et caractéristiques de réseaux de neurone artificiel.	94
Tableau III. 2 Réseaux de neurones courants dans le domaine médical.	94
Tableau III. 3 Comparaison entre Sous-apprentissage et Sur-apprentissage....	108

Liste des abréviations

Liste des abréviations

Adam : Adaptive moment Estimation
AdaGrad : Adaptive Gradient Algorithm
Base De Données « Task03_Liver » lien : <http://medicaldecathlon.com>
Base De Données « 3D-IRCADb01 » lien : <https://www.ircad.fr/research/3dircadb/>
Base De Données « Hepatic Vessel » lien : <http://medicaldecathlon.com>
CHC : Carcinome Hépatocellulaire
CNN : Réseaux De Neurones Convolutifs
DL : Deep Learning (ApprentissageProfond)
DRR : Digitally Reconstructed Radiographs
DSC:DiceSimilarity Coefficient
HLA : Humain LococyteAntigens
IRM : Imagerie Par Résonnance Magnétique
INR : Rapport International Normalisé
Graph Cuts : Coupe De Graphe
Chat_GPT : Generative Pretrained Transformer.
Lr: Learning Rate (TauxD'apprentissage)
MIP : Maximum Intensity Projection
ML: Machine Learning
MELD : Model For End-Stage Liver Disease
MELD-Na : Model For End-Stage Liver Disease (EnFonction De Sodium)Sérique
NASH : Non Alcoholic SteatoHepatitis
NLP : Natural Langage Processing
Relu : Rectified Linear Unit
RMsprop : Root Mean Square Propagation
ROI : Region Of Interest
SGD : Stochastic Gradient Descent
TDM : Tomodensitométrie
TAP : Thorax De L'abdomen Et Du Pelvis
VOI :VolumOf Interest

INTRODUCTION GENERALE

INTRODUCTION GENERALE

L'imagerie médicale occupe aujourd'hui une place centrale dans la recherche clinique, le diagnostic, le suivi thérapeutique et le développement de traitements personnalisés. Elle regroupe un ensemble de technologies permettant non seulement d'identifier et de surveiller des pathologies, mais aussi de mieux comprendre leur fonctionnement et de guider les gestes chirurgicaux. Dans ce contexte, la reconstruction tridimensionnelle (3D) du foie, associée à la segmentation anatomique selon Couinaud, constitue une étape essentielle dans la préparation à la transplantation hépatique.

La greffe hépatique est une intervention complexe qui consiste à remplacer un foie malade par un foie sain, prélevé chez un donneur vivant ou en état de mort cérébrale. Elle est souvent indiquée pour des pathologies graves comme la cirrhose terminale, l'hépatite fulminante ou certaines maladies métaboliques ou auto-immunes. La réussite de cette intervention dépend en grande partie de la qualité de la planification préopératoire. Le chirurgien doit disposer d'une représentation mentale claire et précise de la structure tridimensionnelle du foie, de ses segments anatomiques et de son réseau vasculaire. Une reconstruction 3D fidèle et bien segmentée s'impose donc comme un outil indispensable pour guider le geste chirurgical.

Cependant, cette tâche soulève plusieurs problématiques majeures. D'une part, la segmentation du foie à partir de coupes tomodensitométriques reste difficile, car les organes voisins comme l'estomac ou le pancréas partagent des intensités similaires, rendant les frontières peu distinctes. D'autre part, les vaisseaux sanguins et le tissu hépatique présentent un contraste comparable, ce qui complique leur différenciation automatique. À cela s'ajoute la charge de travail importante liée au grand nombre de coupes 2D à segmenter manuellement, chaque coupe contenant des informations anatomiques différentes, qu'il est essentiel

INTRODUCTION GENERALE

d'interpréter correctement. Ces contraintes rendent les méthodes classiques de traitement d'image peu efficaces et difficilement adaptables à une utilisation clinique rapide et fiable.

C'est dans ce contexte que s'inscrit le présent travail de recherche, qui vise à apporter une solution concrète à ces problématiques par l'intégration de techniques issues de l'intelligence artificielle. En particulier, l'utilisation du modèle d'apprentissage profond U-Net, reconnu pour ses performances en segmentation d'images médicales, permet d'envisager une segmentation automatisée, précise et personnalisée du foie. Ce modèle, fondé sur une architecture de réseau de neurones convolutifs, apprend à distinguer finement les structures anatomiques à partir d'un grand ensemble de données annotées, et permet une extraction rapide et fiable des contours du foie et de ses vaisseaux.

Cette approche innovante ouvre ainsi la voie à une reconstruction 3D efficace et adaptée aux besoins cliniques. Elle vise à améliorer significativement la planification des greffes hépatiques, à minimiser les risques opératoires, à raccourcir les durées d'intervention et à augmenter les chances de réussite chirurgicale. Ce travail s'inscrit donc pleinement dans une dynamique de modernisation de la chirurgie assistée par l'intelligence artificielle

Chapitre I : Aspect Médical

Chapitre I : Aspect Médical

Structure de chapitre

Ce chapitre présente l'aspect médical de base nécessaire pour une compréhension de la problématique utilisée dans cette thèse. L'anatomie du foie, sa vascularisation sanguine et leur fonctionnement sont décrits. L'histologie hépatique est également présentée car la chirurgie hépatique demande précision allant jusqu'au niveau cellulaire. En outre, les pathologies hépatiques, causes, évolution, diagnostic et traitement sont présentées en fin de ce chapitre. L'accent sera porté sur la solution chirurgicale à savoir la transplantation hépatique.

1. Introduction

Le foie est un organe vital, situé en haut et à droite de l'abdomen, il représente une glande appartenant au tube digestif quia plusieurs fonctions nécessaires et indispensables au maintien de la vie dont la sécrétion de la bile, l'élimination des éléments toxiques ou pathogènes provenant du tractus digestif. Le foie joue un rôle important dans de nombreuses fonctions physiologiques car c'est un lieu de synthèse et/ou de stockage majeur pour les protéines, les glucides, des vitamines et des ions.

En cas de déséquilibre de foie sur le plan tissulaire, le foie devient malade et la vie du patient est en risque. Pour toutes ses raisons, nous décrivons cet organe en détail, en considérant son anatomie, son histologie, sa vascularisation et son fonctionnement normal (physiologie) ainsi que ses pathologies dites pathologies hépatiques.

Chapitre I : Aspect Médical

2. Anatomie du foie

Le foie est l'organe le plus volumineux de l'organisme après la peau de poids de 1.5kg pour un volume de $28 \times 9 \times 15 \text{ cm}^3$. On le retrouve dans l'hypochondre droit sous le diaphragme, dans l'épigastre et se prolonge jusque dans l'hypochondre gauche, et il est protégé par la cage thoracique (**Figure I.1**) Il est formé de 4 lobes: deux lobes principaux, le droit très volumineux, le gauche plus petit, séparés par le ligament falciforme, Deux lobes mineurs, les lobes caudé et carré, forment la face viscérale qui contient le hile du foie ou entrent et sortent les pédicules des voies biliaires, ainsi que de l'artère hépatique et de la veine porte.

Le foie est délimité par une capsule fibreuse, il a une coloration rouge brun. Il est à la fois dur rigide et friable, se moulant sur les organes voisins (Gérard Abadjian, 2008).




Figure I. 1 Position et anatomie générale du foie

Chapitre I : Aspect Médical

3. Vascularisation sanguine du foie

Le foie est l'un des organes les plus richement vascularisés : il reçoit 25 à 30 % du débit cardiaque et contient plus de 10 % du volume sanguin total et est traversé chaque minute par 1,5 litres de sang en moyenne. La diffusion des thérapeutiques intra-artérielles hépatiques (radio- et chimio-embolisation, chimiothérapie intra-artérielle hépatique) a incité les radiologues à parfaire leurs connaissances de l'anatomie artérielle hépatique. Ces procédures parfois complexes nécessitent le plus souvent un cathétérisme artériel sélectif. La connaissance des différentes artères du foie et des organes périphériques est donc primordiale pour optimiser le geste chirurgical et éviter les complications (S. Favelier, June 2015).

Le foie reçoit un apport sanguin de deux vaisseaux : de l'artère hépatique qui délivre le sang oxygéné de la circulation générale nécessaire aux cellules du foie et de la veine porte hépatique qui délivre du sang désoxygéné de l'intestin grêle et du colon contenant des nutriments (filtration et élimination).

Ces vaisseaux se divisent jusqu'à former un très dense réseau de vaisseaux extrêmement fins (**Figure I.2**) et les veinules sus hépatiques (vascularisation efférente) drainent les capillaires sinusoides et se jettent dans la veine sus-hépatique. Celle-ci rejoint la veine cave inférieure (**Figure I.3**).

Chapitre I : Aspect Médical




Figure I. 2 La vascularisation hépatobiliaire.




Figure I. 3 Vascularisation reliant le foie au reste de l'organisme

Chapitre I : Aspect Médical

Au niveau cellulaire, le flux sanguin arrive au niveau des sinusoides hépatiques qui sont des capillaires en contact étroit avec les hépatocytes.

Les sinusoides transportent un sang d'origine mixte, portal et artériel, et assurent une perfusion unidirectionnelle des lobules hépatiques, de leur périphérie vers leur centre. Leur paroi régule les échanges entre les hépatocytes et le sang circulant et assure des fonctions spécifiques. Les sinusoides se drainent dans les veines Centro-lobulaires qui rejoignent, par l'intermédiaire de veines collectrices, les veines sus-hépatiques (Scoazec, 2002)(**Figure I.4**).




Figure I. 4 Structure des lobules hépatiques et circulation lobulaire (vue en coupe d'un-lobule)

Il existe trois types d'artère hépatique (**Figure I.5**) :

- L'artère hépatique moyenne, qui naît du tronc cœliaque,
- L'artère hépatique droite, qui naît de l'artère mésentérique supérieure,

Chapitre I : Aspect Médical

- L'artère hépatique gauche, qui naît de l'artère gastrique gauche.
- En outre, Les veines sus-hépatiques drainent le sang en provenance du foie et viennent se jeter dans la veine cave inférieure. Elles sont au nombre de trois, gauche, médiane ou centrale, et droite.




Figure I. 5 Le système artère –veine du foie sur une image scanner.

4. Physiologie Hépatique

L'organisation incroyable des cellules du foie, lui permet d'établir son bon fonctionnement.

Le foie du point de vue anatomique est un organe mais du point de vue physiologique c'est une glande amphicrine avec des fonctions exocrines et endocrines.

Les fonctions exocrines sont assurées par le foie biliaire constitué par les canalicules et canaux biliaires, responsable de la sécrétion de la bile, le foie vasculaire qui est constitué des

Chapitre I : Aspect Médical

veines, artères et sinusoides, qui permettent la régulation de la masse sanguine dans l'organisme.

Les fonctions endocrines sont effectuées par la même cellule l'hépatocyte, Les hépatocytes sont le support des fonctions métaboliques, synthèse des hormones et des protéines (albumine, facteurs de coagulation, ...), filtration du sang, élimination des toxines, stockage et synthèse des sucres...

En effet, les fonctions biologiques assurées par le foie sont vitales (Lê Sylvie, 2024)(plus de 500 fonctions ont été identifiées à ce jour). A titre d'exemple, la synthèse des protéines permet de réguler de nombreuses fonctions telles que l'immunité, la coagulation sanguine, la pression artérielle et la croissance dans l'organisme. D'autre part, l'élimination des produits toxiques et des médicaments se fait grâce à des enzymes spécifiques par le biais des cellules macrophagiques de Küpffer (cellules étoilées).De plus, le foie assure la fonction de stockage du glycogène et est le seul organe capable déléber le glucose dans le sang, des lipides, des vitamines liposolubles (A, D, K, E et B12) et des minéraux, comme le fer et le cuivre²⁰(Flavien Bessaguet, 2021).

5. Histologie hépatique

L'histologie hépatique est l'étude microscopique des tissus du foie, elle permet de bien comprendre leur fonctionnement indispensable à l'organisme.

Comme vue précédemment, le foie est composé de lobes ,Ces derniers sont formés d'un grand nombre d'unités fonctionnelles, appelées lobules qui sont formés de cellules épithéliales spécialisées, appelées cellules hépatiques (hépatocytes).Ces dernières sont disposées en plaques irrégulières, ramifiées et reliées entre elles autour d'une veine centrale, autour de

Chapitre I : Aspect Médical

laquelle se trouvent les vaisseaux qui apportent le sang et les canaux biliaires qui drainent la bile (Yousr, 2023)

Les hépatocytes, qui sont les cellules responsables de la fonction principale du foie, assurent les tâches métaboliques de cet organe, notamment la production et l'élimination de la bile, qui fait partie intégrante du métabolisme de la bilirubine.

Les sinusoides hépatiques forment un système capillaire hautement spécialisé où les échanges se déroulent entre les hépatocytes et le sang en circulation.

Le foie comporte de grands espaces tapissés d'un endothélium, sinusoides, à travers lesquels circule le sang. Les sinusoides sont aussi, en partie, tapissés de cellules réticulo-endothéliales étoilées (cellules de Kupffer).

À la périphérie, on trouve les espaces portes, dont chacun contient une triade portale composée d'un petit canal biliaire, d'une artériole (branche de l'artère hépatique) et d'une veinule (branche de la veine porte). Les ramifications de la veinule et celles de l'artériole assurent la vascularisation du lobule en se jetant dans les sinusoides (espaces vasculaires qui alternent avec les travées cellulaires et confluent dans la veine centrolobulaire, rameau d'origine des veines sus-hépatiques (**Figure I.6**).

Chapitre I : Aspect Médical




Figure I. 6 Histologie hépatique (hépatocyte).

Le lobule, de forme hexagonale, contient une veine centrale, et à chaque sommet, une « triade porte » (Gilgenkrantz, 2022) composée d'une artère hépatique, d'une veine porte, et d'un canal biliaire (**Figure I.7**).

Les cellules de Kupffer (**Figure I.8**) font du foie un siège de mécanismes immunitaires complexes, chargés de détruire les globules blancs et les globules rouges usés, ainsi que des substances toxiques et des bactéries (BABA, 2022).

Chapitre I : Aspect Médical




Figure I. 7 Schématisation de triades portale vers la veine centrale.




Figure I. 8 Schématisation de cellule de Kupffer.

Chapitre I : Aspect Médical

6. Introduction aux pathologies hépatiques

Les maladies du foie et ses complications les plus graves sont une cause majeure de morbidité et de mortalité mondiale. Environ deux millions de morts après insuffisance hépatique aiguë, cirrhose et cancer du foie (carcinome hépatocellulaire). La cirrhose du foie reste l'un des problèmes centraux de santé publique dans le monde.

Dans cette section, la discussion se concentre sur les pathologies hépatiques les plus fréquents.

Les pathologies hépatiques peuvent être largement séparées en trois principaux groupes:

6.1. Infections : Les infections du tissu hépatique peuvent être causées par les bactéries, les virus, ou par des agents pathogènes infectieux qui sont capable de cibler spécifiquement le foie, comme l'hépatite **B**(VHB) et le virus de l'hépatite C (VHC).

6.2. Le Dommage-cirrhose : Les infections chroniques conduisent au dommage du foie, à savoir, lésions tissulaires spécifiques au foie. De plus, des lésions hépatiques chroniques et les infections chroniques peuvent déclencher une cirrhose du foie en provoquant une réponse inflammatoire dérégulée (**Figure I.9**). En raison de la forte hausse de la NASH, le nombre de cancers du foie pourrait augmenter de 55%, au niveau mondial, d'ici à 2040. C'est la première cause de maladie chronique du foie dans le monde et ce sera prochainement la première cause de greffe du foie (Colnet, 2024).

La cirrhose du foie évolutive est une maladie potentiellement mortelle avec des options thérapeutiques actuellement limitées, Les patients souffrant de cirrhose du foie

Chapitre I : Aspect Médical

à un stade assez tardif (**Figure I.10**) en raison de l'absence de symptômes spécifiques dans les premiers stades peuvent développer un cancer « carcinome hépatocellulaire (CHC) ».




Figure I. 9 Les causes de la cirrhose.




Figure I. 10 Cirrhose du Foie.

Chapitre I : Aspect Médical

6.3. Les tumeurs malignes : Le troisième grand groupe de maladies du foie sont les tumeurs malignes du foie ou cancer de foie sous une croissance anormale au niveau des cellules hépatiques, le carcinome hépatocellulaire (CHC) est le cancer le plus courant, par la suite nous allons voir les type de cancer foie.

Les cancers du foie peuvent provenir d'un problème au niveau cellulaire ou vasculaire.

6.3.1. Cancers d'origine cellulaire :

Comme nous l'avons vu, le foie est composé principalement de deux sortes de cellules : les hépatocytes et les cellules qui forment les canaux biliaires. Chacun de ces types de cellules peut donner naissance à un cancer. Les hépatocarcinomes, encore appelé Carcinome Hépatocellulaire(CHC) se développent à partir des hépatocytes (**Figure I.11**).


Le **CHC** représente la 6^{ème} cause de cancer et la 3^{ème} cause de mortalité lié au cancer (ferlay J, 2010)(**Figure I.12**), il survient le plus souvent en raison d'une cirrhose du foie préexistante.Nous avons aussi, Les cholangiocarcinomes se développent à partir des cellules formant les canaux biliaires.

6.3.2. Cancers d'origine vasculaire :


Les vaisseaux du foie peuvent également donner naissance à des tumeurs c'est le cas des angiosarcomes et des hémangioendothéliomes sont les tumeurs provenant d'autre cancers dite métastase hépatique, la **figure I.13** illustre le déclenchement de cancer de foie à cause d'un autre cancer dans les poumons.

85-90% des cancers du foie sont des hépatocarcinomes (hépatocytes), tandis que 10-15% sont des cholangiocarcinomes (les cellules des canaux biliaires).


Chapitre I : Aspect Médical



(a)



(b)



(c)

Figure I. 11 Le Cancer Hépatocellulaire détruit le foie et présente un risque pour les organes voisins, (a). Foie sain et foie malade, (b). Image CT Abdominale en lumière blanche, (c). CT Abdominale illustrant la position de Cancer Hépatocellulaire et dans les organes voisins.

Chapitre I : Aspect Médical




Figure I. 12 Mortalité liée au Carcinome hépatocellulaire en Afrique (EL Serag, 2007).




Figure I. 13 Tumeur du foie Métastatique (de poumon vers le foie).

7. CHC et transplantation hépatique

Chapitre I : Aspect Médical

Le traitement du CHC est principalement effectué par transplantation hépatique (70% avec 5ans de survie). La place de l'imagerie et du radiologue est centrale dans le bilan et le suivi de la greffe hépatique. En pratique, l'échographie permet le dépistage, le scanner abdominal confirme l'image vue en échographie et l'IRM et/ou l'échographie de contraste affirme le diagnostic de CHC en cas de doute sur le résultat du scanner. Il arrive que l'on fasse réaliser un PET-scan pour mieux caractériser le cancer et rechercher une éventuelle dissémination en dehors du foie (Dr. E. Vibert, 2014).

L'imagerie a pour principal objectif de diagnostiquer les complications à un stade précoce pour éviter les dommages irréversibles sur le greffon. Les complications biliaires sont les plus fréquentes, alors que les complications vasculaires, en particulier artérielles, sont rares mais les plus graves. Enfin, la radiologie interventionnelle joue un rôle essentiel dans le traitement des complications.

8. La transplantation hépatique

La transplantation hépatique est la seconde greffe la plus fréquente après la greffe de rein.

Cette dernière est indiquée chez les patients atteints de CHC sur cirrhose, et elle est considérée comme le traitement théorique « idéal » car traitant la tumeur et sa cause (Blanc JF, 2015).

L'analyse de l'imagerie en post-transplantation nécessite la connaissance du type de transplantation hépatique, le détail des anastomoses effectuées, et les techniques chirurgicales de base sont nécessaire pour un suivi adapté.

Nous allons détailler la transplantation hépatique, ses indications ainsi que les étapes de pré-transplantation. Dans le cadre de l'imagerie, nous nous intéresserons en particulier au bilan préopératoire.

Chapitre I : Aspect Médical

7.1. Définition

Le foie ayant la capacité de régénération est intéressant pour une transplantation hépatique, La transplantation hépatique, est une intervention chirurgicale consistant à remplacer un foie malade par un foie sain, prélevé sur un donneur, un ou plus d'un segment peut être retiré selon des conditions de docteur en médecine Couinaud (**Figure I. 14**) (voir chapitre II)

La majorité des transplantations hépatiques utilise des greffons en position orthotopique issus de donneurs en état de mort encéphalique, mais les techniques du « foie partagé », du donneur vivant ou utilisant des donneurs décédés après arrêt circulatoire représentent d'autres alternatives possibles.




Figure I. 14 Les segments de foie.

7.2. Les types de transplantation hépatique

IL est important de connaître les appellations et les distinctions pour pouvoir faire le suivi postopératoire.

La transplantation peut être effectuée selon deux techniques chirurgicales :

Chapitre I : Aspect Médical

7.2.1. La transplantation orthotopique

Consistant en l'enlèvement complet de l'organe malade afin de le remplacer par le greffon sain (Le Larousse médical 2012). Elle est dite orthotopique lorsque le greffon reprend la place du foie natif enlevé (**Figure I.15**). Le greffon est prélevé sur un donneur décédé. Cette transplantation est la plus utilisée et est indiquée chez les malades souffrant de maladie hépatique fatale à plus ou moins brève échéance : c'est le cas des insuffisances hépatiques aiguës, des insuffisances hépatiques chroniques évoluées ou au stade terminal et du carcinome hépatocellulaire, avec d'excellents résultats grâce aux progrès de la chirurgie et des traitements immunosuppresseurs.




Figure I. 15 Transplantation auxiliaire orthotopique, (a). Le greffon est un foie droit, (b). Le greffon est un foie gauche.

7.2.2. La transplantation hétérotopique

Consiste, quant à elle, à garder l'organe malade et à transplanter le greffon sain non loin de celui-ci (**Figure I.16**) (Le Larousse médical 2012). C'est le cas où la transplantation d'un foie entier n'est possible que si l'organe vient d'un donneur cadavérique, contrairement à la transplantation d'un morceau de foie qui est possible soit en provenance d'un donneur cadavérique ou vivant.

Chapitre I : Aspect Médical




Figure I. 16 La transplantation hétérotopique.

La transplantation d'un greffon partiel, foie partiel (un héli foie droit ou gauche) a pu être prélevé sur un donneur vivant apparenté (situation très rare en France) ou provenir du partage (split des anglosaxons) d'un greffon entier volumineux.

Les deux moitiés sont alors utilisées pour greffer un adulte (foie droit) et un enfant (foie gauche). Il arrive exceptionnellement que l'indication de greffe soit liée à un déficit enzymatique congénital d'origine hépatique (ex. neuropathie amyloïde liée à la synthèse et au dépôt dans les gaines nerveuses d'un pré albumine anormale synthétisée par le foie).

Lors de la transplantation, le foie malade, structurellement normal peut être utilisé pour greffer un malade en situation d'urgence. On parle de greffe domino parce que le foie enlevé va immédiatement à un autre malade.

9. Priorité à la transplantation hépatique

La loi sur la transplantation est entrée en vigueur le 1er juillet 2007, la Suisse a opté pour le modèle basé sur le score MELD (Model for end-stage liverdisease).

Chapitre I : Aspect Médical

Le score MELD sert à évaluer la gravité de la condition d'un patient souffrant d'une maladie du foie. Ce score est essentiel pour prendre des décisions relatives aux transplantations hépatiques pour les patients atteints de maladies hépatiques terminales. En effet, le nombre de donneurs de foie est largement inférieur à la demande. Il constitue un outil précieux pour effectuer des évaluations délicates des risques et des bénéfices dans des situations particulières.

Ce score est calculé à partir de trois valeurs de laboratoire comprenant :

- La bilirubine totale : capacité d'éliminer la bile.
- la créatinine : vérification d'insuffisance rénale (Syndrome Hépto-Rénal).
- l'INR (Rapport international normalisé) : Il s'agit d'une mesure des facteurs de coagulation que le foie est incapable de fabriquer à mesure que la maladie hépatique progresse.
- Le Sodium Sérique qui consiste à évaluer les niveaux de sodium (fonction ajoutée à la formule en janvier 2016 (MELD-Na))

Plus le score de MELD est élevé, plus la situation est grave et plus le patient est prioritaire sur la liste d'attente helvétique centralisée, dans son groupe sanguin. Les patients les plus gravement atteints seront donc transplantés en premier.

10. Les étapes de la transplantation hépatique

L'imagerie intervient à toutes les étapes de la transplantation hépatique, dans la sélection des receveurs, la sélection des donneurs et lors du suivi après transplantation hépatique.

9.1. Le bilan du receveur

Le receveur doit être examiné à la pré-transplantation avec un scanner TDM, l'examen incluant l'exploration des sinus, du thorax de l'abdomen et du pelvis (TAP). Le protocole

Chapitre I : Aspect Médical

d'acquisition comporte au moins trois phases : sans injection, au temps artériel et au temps portal. Si le patient a une cirrhose, il faut faire un dépistage du CHC. En cas d'antécédent de CHC ou de doute au scanner, une IRM complémentaire doit être inclus. Les patients insuffisants rénaux bénéficient également de préférence d'une IRM pour l'exploration hépatique.

Les différents éléments à évaluer sont :

- Le bilan vasculaire : la perméabilité des vaisseaux.
- Étude des artères (athérome, thrombose).
- Étude du tronc porte (vascularisation, calibre), les variantes anatomiques, notamment de l'artère hépatique, mais également du système porte (veine gastrique gauche).

9.2. Le bilan du donneur cadavérique

L'imagerie du donneur est préférentiellement scanno-graphique. La qualité du parenchyme du greffon est évaluée.

La transplantation d'un organe allogénique est caractérisée par une réponse immunitaire contre l'organe qui conduit au rejet (Hulin, 2008),

Pour éviter le rejet, il est nécessaire d'avoir un HLA (Humain Leucocyte Antigens) compatible et optimale avec un traitement immunosuppresseur. Les agents immunosuppresseurs ont la capacité de réguler la réponse immunitaire tant cellulaire qu'humorale, qui est liée au rejet aigu des greffes d'organes solides.

9.3. L'intervention chirurgicale

La transplantation hépatique comprend quatre phases :

- l'hépatectomie (l'ablation du foie malade),
- la phase anhépatique (absence de foie),

Chapitre I : Aspect Médical

- la phase d'implantation (installation du nouveau foie).
- la phase post-implantation.

Une incision majeure est effectuée au niveau supérieur de l'abdomen, sous les côtes et s'étendant principalement sur le flanc droit.

L'hépatectomie consiste à disséquer toutes les structures ligamentaires du foie, ainsi que la voie biliaire principale, l'artère hépatique, les veines sus-hépatiques et la veine porte. En général, la portion rétrohépatique de la veine cave inférieure est retirée avec le foie, bien qu'il existe une technique alternative, appelée "piggyback" (**Figure I.17**) Cette technique consiste à conserver la continuité de la veine cave inférieure du receveur, afin d'y adosser celle du greffon en englobant l'ostium des veines hépatiques. L'avantage principal est d'éviter la complexité technique liée à la réalisation de deux anastomoses caves inférieures (sus- et sous-hépatiques)




Figure I. 17 La technique préservation de la veine cave (a). Piggyback(**L. Sulpice, 2013**), (b). Piggyback(en transparente).

Le sang du donneur présent dans le foie sera drainé et remplacé par une solution de conservation réfrigérée, spécifiquement conçue pour préserver les organes. L'implantation de

Chapitre I : Aspect Médical

ce nouveau foie nécessite de procéder à des anastomoses, c'est-à-dire des connexions, de la veine cave inférieure, de la veine porte et de l'artère hépatique.

Une fois le flux sanguin rétabli dans le nouveau foie, les voies biliaires, en l'occurrence le canal cholédoque, seront reliées à l'intestin grêle. En général, l'intervention dure entre cinq et six heures, mais elle peut varier en fonction de la complexité de l'opération et de l'expérience du chirurgien.

9.4. Le suivi postopératoire en imagerie (A. Paisant, 2018)

Le suivi en imagerie est indispensable en postopératoire précoce, pour dépister les complications et intervenir rapidement, mais également au long et court terme. Ces contrôles se font en échographie-Doppler. En cas d'anomalie en échographie ou doute, un complément par scanner est réalisé avec 3 temps d'injection (sans injection, artériel vasculaire et portal). Les contrôles se font à J0 en préopératoire, J1, J7, puis toutes les semaines jusqu'à la sortie. La première année, une échographie-Doppler est réalisée à 3 mois, 6 mois et 1 an de la greffe, puis tous les ans. La fréquence est rapprochée en cas d'anomalie clinique ou biologique sur le suivi.

Chapitre I : Aspect Médical

11. Conclusion

Dans ce chapitre nous avons présenté l'anatomie du foie au niveau macroscopique et microscopique (histologie), ainsi que sa physiologie.

A titre de vulgarisation de toutes ces notions présentées dans ce chapitre, nous pouvons dire que le foie est responsable de transformer notre nourriture en énergie et que c'est un deuxième cœur dont il faut prendre soin avec une bonne qualité de vie. Un foie malade peut évoluer vers une cirrhose, un cancer : deuxième cause de mortalité dans le monde.

La prise en charge des pathologies hépatiques est principalement chirurgicale. Les cas les plus graves (stade terminal) seront traités par transplantation. Cette intervention est particulièrement intéressante car le foie a la capacité de régénération et très complexe à l'image de la complexité anatomique et fonctionnelle du foie. La place de l'imagerie est fondamentale dans le bilan et le suivi de greffe hépatique.

En particulier, la reconstruction du foie et de son arbre vasculaire en 3D est une étape nécessaire afin de planifier la TH : l'approche la moins invasive possible. Pour cela le chirurgien doit avoir un bon modèle mental des relations spatiales 3D entre les différents segments du foie et le système vasculaire interne et externe et ceci pour chaque patient (voir partie anatomie personnalisée). Dans ce contexte la visualisation 3D est en pleine expansion. Cette visualisation est précédée par l'étape de modélisation 3D. Ce traitement informatique passe par plusieurs étapes dont la segmentation. C'est le traitement le plus difficile car doit être complètement automatisé, en raison du nombre important des coupes tomographiques nécessaires pour une modélisation fidèle des structures anatomiques de chaque foie.

Chapitre I : Aspect Médical

L'automatisation de la segmentation est un challenge car les vaisseaux sanguins et les tissus hépatiques présentent un contraste similaire sur les TDM. Les méthodes classiques seront, insuffisantes, les techniques les plus récentes seront donc analysées et synthétisées dans le chapitre 2.

Chapitre II : Reconstruction et Visualisation 3D

Chapitre II : Reconstruction et Visualisation

Structure de chapitre

Ce chapitre est structuré de la manière suivante : Nous expliquerons le principe de la reconstruction 3D ainsi que de la modélisation 3D. Nous exposerons quelques techniques de visualisation 3D avec des exemples d'applications médicales. Nous aborderons le model 3D du foie, longtemps considéré comme une référence en planification chirurgical et enfin on donnera l'état actuel de recherche en reconstruction 3D.

1. Introduction

La reconstruction 3D est une technique avancée dans le traitement d'image, elle est indispensable dans divers domaines médicaux, tels que la chirurgie, la radiologie, la planification de traitement, la recherche et l'éducation. En chirurgie elle permet aux chirurgiens de visualiser en détail les organes et les tissus avant une intervention chirurgicale, ce qui va améliorer la précision et la sécurité des procédures chirurgicales qui seront adaptées à chaque malade, évitant ainsi toute complication.

2. La Reconstruction 3D

2.1. Définition :

D'après la littérature, la reconstruction 3D à partir d'images, « image-based 3D reconstruction » en anglais, désigne la technique qui permet d'obtenir une représentation en trois dimensions d'un objet ou d'une scène à partir d'un ensemble d'images prises sous différents points de vue de l'objet ou de la scène(Farah, 2021).

Chapitre II : Reconstruction et Visualisation

La reconstruction 3D en imagerie médicale dépend des données acquises à partir du système d'imagerie. Les Systèmes d'imagerie médicale tels que le scanner TDM, l'échographie, l'imagerie des radio-isotopes (médecine nucléaire) sont des systèmes qui permettent de voir l'intérieur du corps humain de manière non invasive (BELHADJ, 2009).

Ils utilisent pour cela des ondes dont le pouvoir de pénétration est plus grand que celui de la lumière visible. Cette dernière nous délivre les traditionnelles images de réflexion, tel que nous les percevons avec notre système oculaire. Les autres rayons sont des ondes électromagnétiques avec une énergie beaucoup plus grande que celle de la lumière (rayons X, rayons Gamma) (Figure spectre électromagnétique) ou des ondes acoustiques pour l'imagerie par ultrasons (Figure II.1).




Figure II. 1 Spectre Electromagnétique.

L'interaction de ces ondes avec les tissus de notre corps est corrélée avec les différences de nos structures tissulaires internes. A titre d'exemple, pour le scanner X, les rayons X seront plus ou moins atténués selon la nature du tissu qu'ils traversent (os, tissus mou...) avant d'arriver au capteur.

Chapitre II : Reconstruction et Visualisation

La valeur mesurée au niveau du capteur nous permet d'identifier les tissus ayant interagis dans la direction source d'excitation-capteur, connaissant leurs coefficients d'atténuation ou leurs valeurs dans l'échelle de Hounsfield.

2.2. La production d'image Sinogramme :

Le capteur, dans le cas du scanner TDM est un scintillateur qui transforme les rayons X ainsi atténués en lumière (UV) puis les composants optoélectroniques (photodiode) et électroniques (photomultiplicateur, convertisseur analogique numérique) prennent le relais pour nous donner un nombre qui est proportionnel à la première mesure et qui permet d'identifier les tissus. Les mesures sont effectuées sous plusieurs angles d'incidence (typiquement de 0° degrés à 180°) et les nombres sont codés en niveaux de gris dans une matrice appelée sinogramme, en raison des formes sinusoïdales qu'on y distingue et qui permettent d'assurer que l'acquisition (en rotation autour du patient) s'est effectuée correctement (pas de problèmes de bougé) (**Figure II.2**).




Figure II. 2 Sinogramme : principe d'acquisition et image réelle.

2.2.1. Mesure de l'atténuation des rayons X (sinogramme) :

Chapitre II : Reconstruction et Visualisation

1. Positionner le patient dans le scanner CT.

2. L'émetteur de rayons X tourne autour du corps :

└ Il effectue des rotations de 0° à 180° (ou parfois 360°).

└ À chaque angle θ , un faisceau traverse le corps.

3. Des détecteurs sont placés en face du tube à rayons X :

└ Ils mesurent l'intensité I détectée après traversée du corps.

4. Calcul de l'atténuation pour chaque rayon :

└ I_0 = intensité initiale émise

└ I = intensité reçue par le détecteur

└ μ = coefficient d'atténuation (lié à la densité du tissu)

└ Formule : $\mu(x, y) = -\ln(I / I_0)$

5. Chaque mesure correspond à un point dans une projection :

└ Une ligne de projections est obtenue pour chaque angle θ .

└ Répéter l'opération pour tous les angles (ex : $\theta = 0^\circ, 1^\circ, \dots, 179^\circ$).

6. Le résultat forme une image appelée :

└ **Sinogramme** $S(t, \theta)$ = ensemble des projections pour tous les angles.

A ce stade nous ne pouvons pas encore voir l'image de nos tissus, mais on a toutes les données nécessaires dans ce sinogramme.

Chapitre II : Reconstruction et Visualisation

Dans La matrice du sinogramme, chaque colonne représente une projection à un angle donné θ , généralement compris entre 0° et 180° . Chaque ligne correspond à une position spécifique sur les détecteurs placés en face du faisceau de rayons X. Ainsi, chaque élément de la matrice contient une valeur d'atténuation mesurée à une position t et un angle θ précis. Ces valeurs représentent combien les tissus du corps ont absorbé ou affaibli le faisceau de rayons X.

L'image 2D ou coupe 2D ou « slice » est obtenue après reconstruction tomographique. C'est l'application d'un algorithme de reconstruction aux données du sinogramme.

2.3. La Projections 1D vers l'image 2D

2.3.1. L'algorithme de reconstruction aux données du sinogramme

L'algorithme peut être choisi parmi deux familles de méthodes : les méthodes de rétroprojection comme la rétroprojection filtrée et les méthodes itératives (F. BEN-BOUALLEGUE, 2017), ces dernières sont théoriquement plus satisfaisantes pour résoudre les problèmes inverses. Elles intègrent des modèles mathématiques permettant de corriger les perturbations et d'améliorer la qualité de l'image reconstruite (Kanan, 2023.)

A. Algorithme de Rétroprojection Filtrée

Entrée : $S(t, \theta)$: sinogramme (projections en fonction de t et angle θ)

Sortie : $f(x, y)$: image 2D reconstruite

1. Pour chaque angle θ :

Chapitre II : Reconstruction et Visualisation

a. Extraire la projection $P_\theta(t)$ depuis $S(t, \theta)$

b. Appliquer un filtre en fréquence (Ram-Lak, Shepp-Logan, etc.) sur $P_\theta(t)$

→ utiliser FFT / IFFT pour transformer, filtrer, et revenir dans le domaine spatial

c. Pour chaque pixel (x, y) :

i. Calculer $t = x \cdot \cos(\theta) + y \cdot \sin(\theta)$

ii. Ajouter la valeur interpolée de $P_\theta(t)$ à $f(x, y)$

2. Normaliser $f(x, y)$ (optionnel)

B. Algorithme des méthodes itératives

Entrée : $S(t, \theta)$: sinogramme

Sortie : $f(x, y)$: image reconstruite

Initialiser : $f_0(x, y) = 0$: image vide ou estimation initiale

Répéter pour $k = 1$ à $N_{\text{itérations}}$:

Pour chaque angle θ et chaque rayon j :

Chapitre II : Reconstruction et Visualisation

a. Simuler la projection $\hat{P}_j = \text{somme}(f_k(x, y) \text{ le long du rayon } j)$

b. Calculer l'erreur : $e_j = (S_j - \hat{P}_j)$

c. Corriger chaque pixel traversé par le rayon j :

$$f_{k+1}(x, y) = f_k(x, y) + \lambda * e_j * \text{poids}(x, y)$$

(poids dépend de la part du pixel dans le rayon)

(Optionnel : ajouter régularisation, contrainte de positivité)

Retourner $f_N(x, y)$

2.4. De l'image 2D vers l'image 3D

L'image 2D, ainsi obtenue, est une fonction discrète de $[1 \dots N] \times [1 \dots M] \rightarrow [0 \dots 2^n - 1]$ qui associe à chaque pixel dans la position (i, j) du plan 2D, un niveau de gris (**Figure II. 3**). Dans cette image de coupe 2D, différents niveaux de gris représentent différentes structures tissulaires (foie, reins, os,...).

Pour obtenir les mesures des coupes voisines, on ajoute un mouvement de translation, celui de la table d'examen. La juxtaposition de l'ensemble des données de reconstruction 2D est un volume de données : une fonction discrète de $[1 \dots N] \times [1 \dots M] \times [1 \dots Q] \rightarrow [0 \dots 2^n - 1]$, où

Chapitre II : Reconstruction et Visualisation

chaque Voxel dans la position spatiale (i,j,k) aura un niveau de gris compris entre 0 et 2^n-1 (**Figure II. 3**).

La valeur maximale de niveau de gris est 2^n-1 avec n le nombre de bits utilisés pour le codage du niveau de gris. Ainsi si un seul octet est utilisé (8 bits) cette valeur est de 255 et représente le signal maximal affiché en blanc.

Si l'image 2D peut être directement visualisée ou moyennant un Pré-traitement adéquat (rehaussement de contraste, filtrage,...), il n'en est de même pour les données 3D. En effet les données 2D seront affichées sur un écran 2D, ceci ne cause aucun problème, à part celui de la résolution d'écran... Par contre, il va falloir projeter les données 3D sur ce même écran 2D. Et pour se faire, il faut passer par plusieurs étapes de traitement : segmentation coupe par coupe (Berkache, 2013): modélisation surfacique ou volumique de l'organe ou la région d'intérêt segmentée et projection sur l'écran 2D.

IL faut noter que la reconstruction décrite ci-dessus peut se faire directement en 3D avec des données volumiques obtenues avec des capteurs surfaciques permettant l'acquisition de plusieurs coupes en même temps et/ou simplement au mouvement continu du tube à rayons X avec translation de la table d'examen. Chaque Voxel a un niveau de gris qui représente une propriété physique du tissu (absorption de rayons X dans le cas de la tomographie informatisée (CT) (Moussawi, 2014).

Finalement le volume de données que nous obtenons correspond bien à la définition de la littérature citée plus haut, car ils ont bien été acquis sous plusieurs incidences : on obtient une série (Q) de plans 2D (taille $M*N$) du patient dont l'intensité des pixels représentent la propriété physique d'atténuation, caractéristique des tissus concernés.

Chapitre II : Reconstruction et Visualisation

Enfin l'opération de reconstruction 3D est l'extraction des structures géométriques représentant le VOI (Volum Of Interest)(Wafa ABID, 2009)).

Dans notre cas le VOI est l'ensemble des voxels appartenant au foie, L'image 3D reconstruite est donc celle du foie segmenté à partir d'un scanner abdominal.




Figure II. 3 Echantillonnage 2D et 3D : pixels et Voxel (CNRS, 2002).

Que l'acquisition se fasse directement en 3D ou coupe par coupe, le processus de reconstruction passe impérativement par la phase de segmentation pour sélectionner distinctement le ou les VOIs.

Adly et al. Ont effectué la reconstruction avec l'approche Radiographie Multi planaire (Adly, 2022).

Pour Brandou et al. La reconstruction est basée sur les silhouettes, la texture et le mouvement (BRANDOU, 2008). Enfin, une approche qui s'adapte parfaitement au scanner TDM coupe par coupe est celle proposée par Farah et al. Il s'agit de la reconstruction 3D à partir de coupes sériées (Farah, 2021)

Chapitre II : Reconstruction et Visualisation

3. La Modélisations 3D

La modélisation 3D est l'une des premières phases de traitement 3D. Elle est la première phase si les objets sont créés sans passer par le système d'acquisition d'images ou de signal, en s'inspirant, par exemple des atlas médicaux. Ce genre de modélisation « à partir d'atlas » est préconisé pour l'enseignement. La modélisation 3D après acquisition de signal (image) aura un autre intérêt : diagnostique ou thérapeutique.

3.1. Modélisation polygonale

La modélisation polygonale est une technique puissante pour créer des formes 3D complexes et détaillées en utilisant des polygones (ou faces) triangulées ou quadrangulées.

Le modèle est construit à partir d'un maillage (ou mesh) composé de sommets (vertex), d'arêtes (edges) et de faces (faces) triangulées ou quadrangulées.

Les polygones sont créés manuellement ou à l'aide d'algorithmes. La subdivision permet d'affiner le maillage localement ce qui permet une adaptation aux formes complexes.

3.1.1 L'algorithme Marching cubes

Marching Cubes est un algorithme de polygonisation utilisé pour convertir un champ scalaire 3D en un maillage triangulaire 3D. Autrement dit c'est un algorithme qui permet une modélisation polygonale à partir de données scalaires. Il a été introduit pour la première fois par William E. Lorensen et Harvey E. Cline en 1987.

3.1.1.a Caractéristiques principales


Chapitre II : Reconstruction et Visualisation

- a- **Polygonisation** : Marching Cubes convertit un champ scalaire 3D en un maillage de surface 2D, le rendant ainsi adapté à la visualisation et au rendu.
- b- **Ensemble de niveaux** : l'algorithme fonctionne sur un ensemble de niveaux, où les sommets de chaque cube sont classés comme étant au-dessus, en dessous ou sur l'isosurface.
- c- **Génération de triangles** : l'algorithme génère des triangles en connectant les sommets qui définissent l'intersection de la surface, créant ainsi un maillage de triangles connectés.
- d- **Basé sur le volume** : Marching Cubes fonctionne directement avec des données de volume 3D, ce qui le rend adapté aux applications telles que l'imagerie médicale, la visualisation scientifique et la conception assistée par ordinateur (CAO).

Enfin, Marching Cubes a été implémenté dans diverses bibliothèques et Framework, notamment SciPy (Python), VTK (C++) et OpenGL (C++). L'algorithme est également disponible en tant qu'implémentation autonome dans divers langages de programmation.

Pour mieux comprendre son fonctionnement nous allons donner le cas 2D : Marching squares.


La figure II.4 illustre les étapes de reconstruction/modélisation 2D par Marching squares.




Soit la forme reconstruite (en vert) placée dans une grille de maillage de 2D.

- Attribuer la valeur **ZERO** aux sommets situés hors surface.
- Attribuer la valeur **UN** aux sommets situés à l'intérieur de la surface.


Chapitre II : Reconstruction et Visualisation



Les sommets de reconstruction (en mauve) sont placés aux centres des segments de bords de la forme (segment avec un sommet à l'intérieur et un sommet à l'extérieur de la forme).



Situations de voisinage à considérer pour relier les sommets de reconstruction



Relier les sommets de reconstruction en considérant les différentes situations de voisinage ci-dessus.

Figure II. 4 Principe de reconstruction d'une surface 2D par Marching squares.

Extension au cas 3D : Marching Cubes.

Le principe de la figure II.4 est appliqué au cas 3D en remplaçant le carré par un cube, 8 sommets au lieu de 4, les segments de reconstruction deviennent des surfaces (**Figure II.5**).

Chapitre II : Reconstruction et Visualisation




Figure II. 5 Situations envisageables de reconstruction pour Marching cubes.

3.2. Modélisation 3D par courbes

La modélisation 3D par courbes est une méthode de création de modèles tridimensionnels qui se base sur l'utilisation de courbes adaptatives pour définir les surfaces. Le maillage adaptatif ajuste les subdivisions en fonction de la complexité des courbes dans une région donnée. Une surface parfaitement plane aura un nombre de subdivision très faible ou nul, ce qui en fait la technique de modélisation la plus précise.

Chapitre II : Reconstruction et Visualisation

La modélisation par courbes propose plusieurs solutions mathématiques, toutes basées sur des points de control : les courbes Bezier, les courbes BSplines, les NURBS....etc

Avant de commencer la modélisation, il est important de réfléchir à la structure des surfaces du modèle. Cette structure conditionne l'agencement des courbes 3D. Un réseau de courbes (2D ou 3D) est créé pour servir de base à la génération des surfaces (**FigureII.6**).




Figure II. 6 Modélisation 3D par courbes pour la construction d'une surface 3D.

La modélisation 3D par courbes est largement utilisée dans les domaines de l'architecture et de la CAO industrielle. Le domaine médical n'est cependant pas exclu.

3.3. Modélisation par surfaces

La modélisation par surfaces est une approche de modélisation géométrique qui consiste à représenter les objets 3D en utilisant des surfaces pour définir leur forme et leur structure.

Elle comporte plusieurs techniques tel que les surfaces extrudées, tournées, planes, balayées ou bombée (**Figure II.7**)

Chapitre II : Reconstruction et Visualisation




Figure II. 7 Surface extrudées (création d'une surface en prolongeant une esquisse ou des arêtes le long d'un chemin).

La modélisation par surfaces permet de créer des formes complexes et organiques avec une grande précision ou d'ajouter des détails et des modifications à une surface sans affecter la globalité de l'objet. Elle s'applique pour la modélisation des carrosseries de voiture, les pièces de mobilier ou les modèles 3D pour l'infographie, le domaine médical n'est, a priori, pas exclu.

3.4. Modélisation géométrique

La modélisation géométrique consiste à combiner des formes géométriques simples (cylindres, cubes, etc.) par opérations booléennes (union, intersection, soustraction) pour créer des formes complexes. Elle est généralement utilisée pour la conception de produits et d'objets et ne s'adapte pas naturellement au domaine de l'imagerie médicale (**Figure II.8**).

Chapitre II : Reconstruction et Visualisation




Figure II. 8 Modélisation géométrique.

3.5. Modélisation organique

La modélisation polygonale peut être complexe et laborieuse pour les formes très organiques ou avec des détails fins. La modélisation organique vient combler cette limite. La modélisation organique est une approche qui consiste à créer des modèles tridimensionnels réalistes d'organes ou de tissus biologiques pour étudier leurs structures et leurs fonctions. Ces modèles sont utilisés pour améliorer la compréhension de la physiologie et de la pathologie des organes, ainsi que pour développer de nouveaux traitements et des médicaments.

Une technique puissante pour la modélisation organique est dite Lessurface de convolution « en anglais : Metaballs », inventées par Jim Blinn au début des années 1980.


Chaque balle est définie comme une fonction mathématique à N dimensions, permettant de générer des formes complexes et naturelles.

Les Metaballs sont des « isosurfaces n-dimensionnelles d'apparence organique, caractérisées par leur capacité à fusionner lorsqu'elles sont proches pour créer des objets uniques et contigus » ; le maillage créé par l'algorithme metaboules est appelé une isosurface (ou une


Chapitre II : Reconstruction et Visualisation

isoligne en 2D), ce sont des boules n-dimensionnelles qui « s'agglutinent » graphiquement lorsqu'elles sont proches les unes des autres (danielilett, 2020).

De ce fait, les méta-balls sont particulièrement utiles pour imiter et suivre les formes naturelles présentes dans la réalité (**Figure II.9**).



(a)



(b)

Figure II. 9 Metaballs (a : fusion de deux sphères avec R_i et R_j rayons d'influence, b : modélisation organique du tube digestif humain par méta-balls).

Les métaboules sont le plus souvent utilisées en 3D, avec des applications allant de l'imagerie médicale à la simulation de fluides.

Cependant, il convient de noter que les calculs impliqués par les Metaballs peuvent être lourds en termes de ressources, notamment pour les applications nécessitant des formes très complexes ou des détails fins (Olivier Gourmel, 2010,3).

Chapitre II : Reconstruction et Visualisation

4. Visualisation 3D

La visualisation 3D connaît deux approches : l'approche volumique et l'approche surfacique.

4.1. Approches Surfaciques

Historiquement, les méthodes de reconstruction surfacique sont les premières qui sont apparues, Ils procurent une vision tridimensionnelle extérieure d'éléments anatomiques et pathologiques. Il nécessite plusieurs traitements de l'image, le plus important est le seuillage des voxels.

Ce seuillage permet la sélection de certains éléments anatomiques ou pathologiques en fonction de leurs densités.

Les surfaces sont créées en reliant tous les pixels correspondants à la même atténuation. Il est possible également d'appliquer une lumière imaginaire, se reflétant sur les surfaces, leur permettant d'apparaître sous différents niveaux colorimétriques. Le problème de la reconstruction tridimensionnelle consiste alors à bâtir un maillage surfacique entre les contours de deux coupes adjacentes.

L'algorithme le plus courant permettant de réaliser cette opération est l'algorithme de rendu surfacique « Marching Cubes » Il est simple robuste et rapide et très utilisé dans le domaine médical puisqu'il permet l'extraction d'isosurfaces à partir de données volumétriques (coupes sériées). Les isosurfaces sont une très bonne approximation des surfaces d'origine qui représentent les organes à modéliser. Nous obtenons une modélisation médicale réaliste (Bouhleb, 2009).

Chapitre II : Reconstruction et Visualisation

4.2. Approches Volumiques

L'approche volumique (**rendu volumique**) est plus ou moins récente, elle est basée sur la projection de l'ensemble des données du volume sur un plan (écran 2D), en affectant des coefficients de transparence et des couleurs variables aux voxels en fonction de leur densité (en unités Hounsfield) L'information contenue dans chacun des voxels constituant le volume de données est préservée dans l'image finale. L'avantage fondamental de ce type de reconstruction sur le suivant est de ne pas recourir à une segmentation par seuillage pour créer une reconstruction 3D. L'atténuation relative des voxels est traduite en échelle de gris ou en couleurs.

La limite principale du rendu volumique est le temps passé à créer des images pertinentes.

Parmi les méthodes de rendu volumique, citons les projections radiographiques de synthèse souvent notées **DRR** (Digitally Reconstructed Radiographs).

La DRR est une simulation d'une image radiographique 2D conventionnelle, créée à partir de données de tomodensitométrie (CT), Rappelons qu'une radiographie, ou image radiographique conventionnelle, est une vue 2D unique de l'absorption totale des rayons X à travers le corps le long d'un axe donné. Deux objets (par exemple, des os) situés l'un en face de l'autre se chevauchent dans l'image. En revanche, une image CT 3D donne une représentation volumétrique.

Chapitre II : Reconstruction et Visualisation




Figure II. 10 Principe de la projection radiographique de synthèse (Digitaly Reconstructed Radiograph).

Dans une DRR (**Figure II.10**), chaque pixel de l'image est considéré comme un rayon qui traverse un volume. La complexité de l'algorithme réside ici dans la manière dont le rayon va interagir avec les échantillons (ou voxels) du volume (formules d'accumulation). On échantillonne des valeurs le long du rayon et en calcule la contribution de ces valeurs, suivant un modèle de rendu, à la couleur finale du pixel (**Figure II.11**).

Chapitre II : Reconstruction et Visualisation




Figure II. 11 Systèmes de coordonnées de Rendu volumique et échantillonnage le long d'un rayon.

Chapitre II : Reconstruction et Visualisation

Les formules d'accumulation expriment la manière avec laquelle on calcul des DDRs d'un volume traversé par un rayon donné.

Il y a plusieurs formulations :

- Imitation du rayon X.
- Imitation de radiographie classique (atténuation).
- MIP : Maximum Intensity Projection

a- **Imitation du Rayon X** : elle est directement liée à la formulation physique du fait que nous cherchons à imiter la physique des rayons X. Elle est donnée par :

$$I_{accum} = e^{-\int_{l_1}^{l_2} \mu(l) dl} \dots \dots \dots (II. 1)$$

Avec I_{accum} la valeur finale du pixel après accumulation, l_1 et l_2 les points d'entrée et de sortie du rayon dans le volume scanner et $\mu(l)$ est le coefficient d'atténuation du voxel traversé par le rayon à l'emplacement l le long du rayon.

b- Imitation du Radiographie classique

Cette formule s'intéresse à l'atténuation du rayon à travers le volume. Elle est donnée par :

$$A = -\int_{l_1}^{l_2} \mu(l) dl \dots \dots \dots (II. 2)$$

c- Projection de l'intensité maximale (Maximum Intensity Projection MIP)

C'est la plus simple formule d'accumulation et l'une des plus utilisées dans le domaine médical. Elle consiste à rechercher l'intensité maximale des valeurs traversées par le rayon.

Elle est donnée par :

Chapitre II : Reconstruction et Visualisation

$$I_{MIP}(L) = \max(\mu(l)), 0 \leq l \leq L \dots \dots \dots (II. 3)$$

5. Les modalités de visualisation 3D

La visualisation 3D peut se faire selon deux approches : la réalité virtuelle ou la réalité augmentée.

5.2 Réalité virtuelle

L'expression « réalité virtuelle » (ou multimédia immersif ou réalité simulée par ordinateur) est une technologie informatique qui simule la présence physique d'un utilisateur dans un environnement un univers entièrement créé en 3D, où l'utilisateur peut se déplacer et interagir avec des éléments virtuels, tels que des objets, des personnages ou des scènes.

Pour visualiser ces scènes 100% virtuelles sur un plan 2D on peut utiliser une des techniques citées plus haut (DRR...). Le plan de projection peut être un écran ou moniteur de visualisation comme il peut faire partie du casque de réalité virtuelle (**Figure II.12**), ou les deux.

Quand l'affichage se fait sur un écran, on utilise l'outil de rotation pour changer le point de vue, opération qui n'est pas d'un grand confort, mais permet d'explorer l'objet 3D.

Le casque de réalité virtuelle est beaucoup plus adapté à la visualisation 3D. C'est un dispositif électronique portatif qui permet d'immerger l'utilisateur dans le monde virtuel. Il est porté sur la tête et permet d'accéder à un espace 3D en détectant les mouvements de l'utilisateur et en affichant à chaque fois une image avec un décalage minimal pour ne pas causer d'inconfort et de malaise.


Chapitre II : Reconstruction et Visualisation



Figure II. 12 Casque de réalité virtuelle.

Donc dans le premier l'interaction avec l'utilisateur est l'interface graphique du logiciel de visualisation (click sur le bouton de rotation, mise à l'échelle,...) tandis que dans le deuxième cas l'interaction exploite des capteurs de mouvement (position dans l'espace), pour changer le point de vue ou d'avancer dans la scène 3D.

La Figure II.13 illustre une visualisation en réalité virtuelle du foie après reconstruction 3D.



Chapitre II : Reconstruction et Visualisation

Figure II. 13Réalité virtuelle après reconstruction 3D et planification per-opératoire (A : planification, B : résection virtuelle, C : vérification, D: validation de l'opération en réalité).

Les systèmes dits à retour d'effort Haptiques se classent dans un niveau de performance plus élevé en termes d'interaction entre le monde virtuel et le monde réel.

5.2.1 Les systèmes à retour d'effort Haptiques

Un équipement à retour d'effort est un type d'interface qui permet à l'utilisateur de commander un robot ou un avatar dans un environnement virtuel en ressentant les forces et les moments auxquels ils sont soumis. Ces sont conçus pour offrir une expérience d'immersion naturelle et pour permettre aux utilisateurs de commander les actions avec précision et efficacité. Ils sont utilisés dans de nombreux domaines, notamment l'industrie, la formation et la recherche. En ce qui concerne la santé, les systèmes à retour d'effort se retrouvent dans les interventions chirurgicales par robot interposé et sont particulièrement intéressantes en télémédecine (intervention à distance pour palier à l'absence de compétences in situ).

Exemples d'équipements à retour d'effort (**Figure II.14**)

- Bras à retour d'effort : ces bras polyarticulés sont équipés d'un organe de saisie (poignée ou stylo) qui permet à l'utilisateur de commander les mouvements du robot esclave. Ils sont couramment utilisés pour des interventions à distance ou pour faire fonctionner des avatars numériques.
- Interfaces à retour d'effort sur plusieurs doigts : ces interfaces permettent à l'utilisateur de simuler des interactions avec des objets virtuels en utilisant plusieurs doigts. Elles sont utilisées pour la simulation de tâches de fraisage osseux ou pour la simulation de conduite automobile.

Chapitre II : Reconstruction et Visualisation

- Périphériques de commande à retour d'effort : ces périphériques sont conçus pour commander des robots ou des avatars dans des environnements virtuels en ressentant les forces et les moments auxquels ils sont soumis. Ils sont souvent utilisés pour la téléopération et la réalité virtuelle.




Figure II. 14 Equipements à retour d'effort.

Ces systèmes comportent trois composants : les dispositifs Haptiques, les capteurs de mouvement et les logiciels de simulation.

- Les dispositifs Haptiques (joystick Haptique, gant Haptique ou stylo Haptique) génèrent des forces physiques qui simulent le toucher, permettant aux utilisateurs de ressentir la consistance des structures anatomiques virtuelles.
- Les capteurs de mouvement captent et enregistrent les mouvements, de l'utilisateur dans l'espace 3D, données qui sont essentielles pour synchroniser les actions de l'utilisateur avec les réponses Haptiques du système.
- Les logiciels de simulation permettent la création et la visualisation de modèles 3D à partir de données médicales (reconstruction et visualisation 3D). De plus, ils intègrent

Chapitre II : Reconstruction et Visualisation

des algorithmes pour générer des retours d'effort en temps réel, basés sur la géométrie et les propriétés des tissus médicaux.

5.3 Réalité augmentée

C'est l'insertion d'éléments virtuels dans une séquence vidéo réelle à la différence de la réalité virtuelle où la totalité de la scène est générée artificiellement, une séquence en réalité augmentée contient à la fois des éléments réels et virtuels.

La planification des opérations chirurgicales en per-opératoire est l'une des applications médicales de la réalité augmentée. Elle consiste à superposer les images virtuelles obtenues après reconstruction 3D de coupes scanner sur de la scène explorée en temps réel en lumière blanche (avec la caméra CCD de l'optique laparoscopique). Ce traitement met en évidence ce qui est invisible en lumière blanche (profondeur des structures anatomiques, vaisseaux sanguins sous-jacents une tumeur...) (**Figure II.15**).



(a)

Chapitre II : Reconstruction et Visualisation



(b)

Figure II. 15 Réalité augmentée (a)-laparoscopie, (b)- image 3D reconstruites à partir de coupes scanné (Soler, 2010).

6. Le Modèle hépatique 3D de Couinaud

Le chirurgien et anatomiste français Claude Couinaud décrit une segmentation fonctionnelle du foie qui donne une représentation 3D du foie sous forme de segments. Selon Couinaud, le foie est divisé en secteurs (parties fonctionnelles), eux-mêmes divisés en segments (parties vascularisées par l'artère hépatique et veine porte). Chaque segment reçoit une branche de la veine porte, une branche de l'artère hépatique et un conduit biliaire, Donc, Chaque segment a son propre afflux vasculaire, son propre écoulement et son propre drainage biliaire (figure 12) (segmentation hépatique, 2020) .

Chapitre II : Reconstruction et Visualisation




Figure II. 16 Les huit segments de Couinaud avec vascularisation de chaque segment (5 secteurs et 8 segments).

La **Figure II.16** illustre : la veine hépatique est éclatée en trois branches :

- La veine hépatique gauche : sépare le secteur latéral gauche du secteur paramédian gauche.
- La veine hépatique médiane : sépare le foie en foie gauche et foie droit.
- La veine hépatique droite : sépare le secteur antérieur droit du secteur postérieur droit(ou secteur latéral droit).

Les branches de division de veine porte délimitent les secteurs du foie en huit segments.

- Secteur latéral gauche : segment II et III
- Secteur paramédian gauche : segment IV
- Secteur postérieur : segment VII et VI

Chapitre II : Reconstruction et Visualisation

- Secteur antérieur : segment VIII et V
- Segment I : correspond au lobe caudé et la partie du foie en avant de la veine cave.

Cette segmentation a longtemps été incontournable pour la planification de la chirurgie hépatobiliaire. En effet, une hépatectomie d'un segment doit tenir compte des veines de drainage (sortie) et des vaisseaux sanguins d'admission (entrée). La section d'une veine de drainage commune à plusieurs segments (segment sain que nous souhaitons garder et celui qu'il faut enlever) va à terme provoquer la nécrose du segment sain. Une telle faute chirurgicale est impardonnable et peut, par exemple, provoquer le décès du donneur sain à la suite d'une transplantation hépatique.

En pratique, lorsqu'une lésion est localisée dans le segment latéral du lobe gauche, les deux segments de Couinaud II et III sont généralement retirés en fonction du plan formé par la fissure ombilicale (c'est-à-dire segment-hépatectomie latérale gauche) (**Figure II.17**).

Chapitre II : Reconstruction et Visualisation




Figure II. 17 Planification de chirurgie hépatique à la base de la segmentation de Couinaud superposée aux images ct-scan.

7. Reconstruction 3D personnalisée du foie et état de l'art

La modélisation de Couinaud est une bonne estimation du modèle hépatique général, cependant l'anatomie hépatique individuelle s'en écarte. En effet, le foie est bien divisé en huit segments autonomes mais le volume, la position et la forme de ces segments et leurs frontières segmentaires présentent une variabilité significative (Fischer, et al., November 2002.).

Les variations anatomiques de l'artère hépatique sont importantes dans la planification et la réalisation des interventions chirurgicales abdominales, la variation la plus courante étant l'artère hépatique droite remplacée (type III selon la classification de Michels) qui est la principale source d'approvisionnement en sang de la voie biliaire (George Nossios, 2017).

Chapitre II : Reconstruction et Visualisation

Les veines hépatiques présentent une grande variabilité morphologique de plusieurs points de vue : formation, niveau de terminaison, nombre, avec des différences en fonction du sexe et par rapport au type morphologique de l'individu (Petru Bordei, 2019).




Figure II. 18 Les segments de Couinaud sont généralement approximatés par des plans droits (a) qui sont en réalité des plans irréguliers (b) (Jean H. D. Fasel, 2013).

La **Figure II.18** illustre Les limitations de segmentation de Couinaud, et la complexité de l'anatomie et du système vasculaire hépatique, donne la problématique suivante : reconstruire des modèles anatomiques vasculaires personnalisés.

Donc lors de la planification d'une transplantation hépatique ou résection tumorale la reconstruction du parenchyme et des vaisseaux hépatiques puis visualisation 3D de ces derniers pour chaque patient est préférable à une planification grossière basée sur les segments Couinaud. Ce sujet de thèse vient résoudre cette problématique. Nous commençons par lui dresser un état de l'art.

Chapitre II : Reconstruction et Visualisation

8. État de l'art de la reconstruction 3D des images médicale :

La reconstruction 3D à partir d'une image médicale TDM ou IRM est l'un des axes principaux de la recherche en traitement d'images médicales, Nous allons citer quelques travaux ayant traité ce thème.

Ran Wei(Ran Wei, 2022)a proposé une méthode de reconstruction IRM 3D en temps réel à partir de la ciné-IRM en utilisant un réseau non supervisé, la méthode proposée utilisait une IRM 3D de référence et une IRM ciné pour générer les données de formation. Ensuite, un réseau a été formé de manière non supervisée pour estimer la relation entre l'IRM ciné acquise sur le plan coronal et le champ vectoriel de déformation (DVF) qui décrit le mouvement respiratoire du patient. Après le processus de formation, l'IRM ciné coronale a été entrée dans le réseau et le DVF correspondant a été obtenu. En enveloppant l'IRM 3D de référence avec le DVF généré, l'IRM 3D a pu être reconstruite.

Fei Tong et all(Fei Tong, 2020), ils ont proposé une méthode de Reconstruction 3D du foie basée sur un réseau neuronal profond « X-ray2Shape : Reconstruction 3D du foie à partir d'une seule image de projection 2D» qui combine un GCN (graph convolutionnel network) et un CNN (convolutionnel network) à partir d'une seule image DRR (digitallyreconstructedradiograph) à faible contraste.


Le modèle initial 3D est projeté sur l'image DRR d'entrée, et les caractéristiques de l'image correspondant à chaque sommet peuvent être extraites. Nous concaténons ensuite les caractéristiques de l'image et les coordonnées des sommets 3D et les incorporons dans un réseau GCN pour la déformation, Pour générer une forme 3D précise et lisse, ils ont utilisé la fonction de perte MSE et la fonction pertelaplacienne discrète, cette apprend la déformation

Chapitre II : Reconstruction et Visualisation

du maillage à partir d'un modèle 3D et de caractéristiques profondes calculées à partir d'une seule image.

Sarmah et al. (Sarmah, (2023)) proposent une revue de la littérature, sur des techniques de reconstruction de plusieurs organes dans l'aide au diagnostic médical. Diverses méthodes et principes liés à la reconstruction 3D ont été mis en évidence, ils ont décrit sur la reconstruction 3D du foie, L'un des travaux proposés (Chen et al.) une approche Deep Learning par encodeur-décodeur en série (SED). Deux SED ont été utilisés : le premier pour segmenter la ROI et le second pour segmenter au plus les résultats obtenus à partir du premier réseau. Le SED a été conçu à l'aide d'une architecture U-Net. Les résultats sont facilement reconstruits en 3D de bonne qualité.

S. Pla-Alemany et al. (S. Pla-Alemany, 2021), dans le contexte médical, La segmentation et la classification du foie selon la classification de Couinaud sont essentielles pour le diagnostic assisté par ordinateur et la planification du traitement, ils ont proposé une méthode alternative de segmentation automatique qui permet d'améliorer la précision et le temps de traitement suivi par une classification multi-atlas pour la segmentation de Couinaud, l'algorithme a été implémenté sur 20 sujets de la base de données 3D de l'IRCAD afin de segmenter et classer le volume hépatique en ses segments de Couinaud, et les résultats sont satisfaisants, ils ont fourni une segmentation hépatique multi-atlas automatique et une classification de Couinaud au moyen d'une analyse d'images CT.



Chapitre II : Reconstruction et Visualisation

9. Conclusion

Dans ce chapitre nous avons fait un tour d'horizon sur le contexte de l'imagerie en trois dimensions, en considérant le cas particulier de l'imagerie médicale. Nous avons abordé la notion de reconstruction 3D à partir de données médicales, ainsi que la notion de modélisation avec diverses techniques, pas forcément courantes dans le domaine médical. Nous avons finalement considéré le cas particulier du foie en présentant un model longtemps suivi, en planification chirurgicale, il s'agit du model de Couinaud. Nous avons dressé les limites de ce model qui impliquent la nécessité d'une reconstruction 3D personnalisée. Enfin nous présentons l'état de l'art, point de départ et de référence pour entreprendre notre démarche scientifique permettant de résoudre, à notre tour, le problème de la reconstruction hépatique en 3D.

Dans le processus de reconstruction, nous avons évoqué l'importance de la segmentation des VOIs, qui est dans notre cas : le foie. Segmentation qui doit se faire de manière complètement automatique. Le prochain chapitre sera donc consacré à la segmentation des coupes tomодensitométriques abdominales.

Chapitre III : Segmentation du foie

Chapitre III : Segmentation du foie

Structure de chapitre

Dans ce chapitre, nous introduisons donc la notion de segmentation. Nous aborderons tout d'abord les grandes familles d'approches existantes avec des exemples d'application sur les coupes CT abdominales, puis nous présenterons les travaux récents issus de la littérature ainsi qu'une étude comparative. Nous terminerons par la justification du choix de la méthode de segmentation la plus adaptée à cet organe spécifique

1. Introduction

De nos jours, que ce soit pour le bilan préopératoire (diagnostique) ou le bilan peropératoire (traitement et suivi), l'imagerie médicale reste un outil essentiel. Elle permet au médecin d'obtenir une série d'images de l'intérieur du corps humain, illustrant l'état de l'organe à traiter. Dans le cas de la transplantation hépatique, comme nous l'avons vu dans le chapitre 2, une reconstruction 3D est souvent nécessaire.

Dans ce chapitre, nous détaillons la tâche de segmentation, qui constitue la première étape du processus de reconstruction 3D.

La segmentation est un traitement d'image qui permet de classer chaque pixel selon une catégorie regroupant des pixels ayant les mêmes propriétés physiques. Nous expliquerons ce qu'est la segmentation ainsi que les différentes approches fondamentales.

L'un des enjeux majeurs de la segmentation est l'identification précise de la classe correspondant au foie, ce qui est rendu complexe par la nature des données et le nombre d'images nécessaires pour reconstituer un volume précis. Cela nous conduit à une étude de l'état de l'art sur les méthodes de segmentation automatique et intelligente.

Chapitre III : Segmentation du foie

2. Segmentation des images médicales

2.1. Définition de la Segmentation

La segmentation d'image est le processus qui consiste à diviser une image en régions (ou classes) distinctes et homogènes, en fonction de propriétés telles que l'intensité, la couleur, la texture ou la forme. Chaque région correspond à une structure ou un objet spécifique présent dans l'image.

Pour un ordinateur, une image est constituée d'un ensemble de points (pixels), chacun ayant un niveau de gris (AbdelazizDaoudi, 2015). Ainsi, une région correspond à un ensemble de pixels présentant un niveau de gris similaire (**figure III.1**).




Figure III. 1 Coupe CT abdominal avec identification de différentes classes.

Chapitre III : Segmentation du foie

Définition formelle

Soit une image I , La segmentation est un traitement de bas niveau qui consiste à créer une partition de I en sous-ensembles r_i , appelés régions, tels que :

Chaque région est un ensemble de pixels connexes partageant des propriétés communes ;

Deux régions différentes ont des propriétés distinctes ;

L'intersection entre deux régions est vide.




Figure III. 2 Illustration formelle de la segmentation d'image.

Dans la **figure III.2**, pour obtenir une telle représentation à partir d'une image numérique I , il est nécessaire d'appliquer un algorithme de segmentation basé sur un prédicat d'homogénéité P . En traitement d'image, la segmentation consiste donc à diviser une image I en N régions R_i , disjointes et homogènes, selon un critère (intensité, couleur, texture, etc.)(KHEROUBI Ghania, 2011).

Soit I , une image et E , une partition de I constituée de Sous-ensembles connexes.

$$E = R_1, R_2, \dots, R_n$$

• avec $R_i \neq \emptyset$ et R_i connexe ($\forall i = 1 \dots n$),

✓ $I = \cup R_i, (\forall i = 1 \dots n)$

✓ $P(R_i) = \text{vrai}, \forall i = 1 \dots, n.$

✓ $P(R_i \cup R_j) = \text{faux} \forall i \neq j$

Chapitre III : Segmentation du foie

Différents algorithmes de segmentation ont été développés en fonction des propriétés spécifiques à extraire, des défis inhérents au traitement des images et des approches adoptées pour l'agrégation des pixels, c'est ce que nous allons explorer dans le paragraphe suivant.

3. Les Approches Principales de la Segmentation

Dans le domaine médical, le choix de l'approche et de la méthode de segmentation est crucial, car il conditionne le succès ou l'échec des traitements cliniques qui suivent. La segmentation des images médicales est largement étudiée dans la littérature et se divise principalement en deux grandes familles :

- ✓ Les approches classiques.
- ✓ Les approches basées sur l'apprentissage automatique

Dans cette section, nous allons définir chaque approche et illustrer leur application à travers des cas pratiques, afin d'évaluer leurs avantages et leurs limites, et ainsi déterminer la méthode la plus adaptée à notre problématique.

3.1 Approches Classiques

Ces méthodes reposent sur des techniques mathématiques et algorithmiques traditionnelles.

Parmi les principales, on retrouve le seuillage.

3.1.1 Le Seuillage (Thresholding) :

Définition

Le seuillage consiste à segmenter les pixels d'une image selon un seuil d'intensité prédéfini.

À partir de l'histogramme de l'image (représentant la distribution des niveaux de gris), on peut identifier un seuil optimal, en particulier lorsque celui-ci présente plusieurs pics.

Chapitre III : Segmentation du foie

En fixant ce seuil, on peut regrouper les pixels en deux classes : ceux dont l'intensité est supérieure ou égale au seuil, et ceux dont elle est inférieure.

- **Avantage :**

Méthode simple et rapide ;

Efficace pour les images à histogramme bimodal (objet vs fond).

- **Méthodes courantes**

Seuillage manuel ;

Seuillage automatique (ex. : méthode d'Otsu).

- **Limites**

Sensibilité au bruit ;

Difficulté à distinguer des structures anatomiques proches en intensité.

Nous avons expérimenté l'approche seuillage pour la segmentation d'une coupe abdominale CT (**figure III.3**), avec dans un premier temps l'application d'un seuillage manuel choisi à partir de l'histogramme de l'image originale. La **figure III.4** illustre le résultat de ce seuillage. Nous constatons la limite de cette méthode surtout en superposant les résultats obtenus avec l'image CT originale (**figure III.5**).

Chapitre III : Segmentation du foie





Figure III. 3 Image CT abdominale avec histogramme montrant les variations anatomiques aux intensités similaires.



- (a) Image originale,
- (b) Seuillage manuel du foie,
- (c) Tentative d'extraction des vaisseaux hépatiques.

Figure III. 4 Application du seuillage manuel sur une image CT abdominale.

Chapitre III : Segmentation du foie





Figure III. 5 Superposition des résultats de segmentation par seuillage simple avec l'image originale du foie, (a) lobes hépatiques, (b) vaisseaux hépatiques.

D'autre part, la méthode de seuillage automatique Otsu (**figure III.6**), présente de bons résultats mais elle reste sensible aux variations d'intensités ce qui peut donner des classes supplémentaires inexistantes en réalité.



(a) Image CT abdominale,

(b) Extraction des vaisseaux hépatiques,

Chapitre III : Segmentation du foie

(c) Extraction du foie,
(d) et (e) Classes indésirables présentes dans l'image.

Figure III. 6 Seuillage avec la méthode Otsu.

3.1.2 Méthodes Basées sur les Contours

Les méthodes basées sur les contours sont particulièrement adaptées pour détecter et suivre les frontières des régions dans une image. Un contour correspond à une variation rapide des niveaux de gris entre des pixels adjacents (HABIB, 2022). Ces variations marquent généralement la séparation entre deux régions.

On distingue deux grandes familles : les méthodes basées sur les gradients et les méthodes déformables.

3.1.2.a. Méthodes basées sur le gradient

Les méthodes de segmentation basées sur les gradients reposent sur l'analyse des variations d'intensité dans une image pour détecter les contours des objets. Elles s'appuient sur le calcul des dérivées locales afin d'identifier les discontinuités, qui correspondent aux transitions entre différentes régions de l'image. Ces approches sont fondamentales en traitement d'images, notamment pour la reconnaissance de formes et l'extraction de structures dans les images médicales et industrielles. Parmi les techniques les plus utilisées, on trouve les filtres de dérivation classiques (Sobel, Prewitt, Roberts), ainsi que des méthodes avancées comme l'algorithme de Canny, qui améliore la robustesse à l'échelle et au bruit grâce à un traitement multi-étapes incluant la réduction de bruit, le calcul du gradient, la direction des contours, la suppression du non-maxima et un seuillage à hystérésis.

Chapitre III : Segmentation du foie

Comme pour l'approche seuillage, nous avons expérimenté l'approche contour sur l'image CT abdominale dans le but de détecter le foie et les vaisseaux hépatiques.

Bien que rapides et efficaces pour détecter des contours de manières plus nets que celles des méthodes de seuillage (**figure III.7**), ces méthodes présentent des limites face aux images bruitées ou présentant des variations progressives d'intensité (**figure III.8**), rendant nécessaire l'utilisation de techniques complémentaires ou hybrides pour améliorer la précision de la segmentation.






Figure III. 7 Application de méthode de Canny sur l'image CT abdominal.



Chapitre III : Segmentation du foie



- (a) Image originale.
- (b) Segmentation avec l'opérateur de Canny.
- (c) Détection de contour du lobe hépatique droit.
- (d) Segmentation des veines hépatiques.
- (e) Concaténation du lobe hépatique et des veines (images c et d)

Figure III. 8 Segmentation avec la méthode de Canny et seuillage hystérésis.

En effet, dans **la figure III.8** nous avons choisi deux seuils haut et bas notés respectivement S_h et S_b . Ils sont comparés aux intensités du gradient de chaque pixel noté I_G . Le critère suivant est alors appliqué :

Si $I_G < S_b$, le pixel est rejeté ;

Si $I_G > S_h$, le pixel est accepté, comme étant un pixel contour ;

Si $S_b < I_G < S_h$, le pixel est accepté s'il est connecté à un pixel contour.

3.1.2.b. Les méthodes déformables

Les méthodes déformables reposent sur l'évolution d'une courbe dynamique qui s'adapte progressivement aux contours de l'objet cible en minimisant une fonction d'énergie. Deux techniques principales sont utilisées : les contours actifs (Snakes), qui modélisent un contour paramétrique déformable guidé par des forces internes et externes, et la méthode des

Chapitre III : Segmentation du foie

ensembles de niveaux (Level Set), qui représente implicitement le contour sous forme d'une fonction de niveau évoluant dans le temps.

Un contour actif est une courbe définie dans l'image et qui est capable de se mouvoir sous l'influence de plusieurs forces qui vont la tirer ou la pousser vers la forme. Un snake consiste à placer aux alentours de l'objet à détecter une ligne initiale de contour, l'évolution se fait à travers un processus itératif qui déforme la courbe à chaque itération jusqu'à sa position finale (MEDDABER, 2013).

Les Snakes sont rapides mais sensibles à l'initialisation, tandis que les Levelset sont plus robustes mais plus coûteux en calcul.

Le modèle Level Set est une méthode numérique qui représente implicitement les contours à l'aide de courbes de niveau. Il s'adapte aux informations de l'image comme l'intensité ou le gradient, et permet de suivre l'évolution des formes tout en gérant les changements topologiques. Le contour final est obtenu lorsque le processus de minimisation converge, correspondant au niveau 0 de la fonction LevelSet (Osher, 1988) (Esteves, 2024) (**Figure III.9**).

De plus, Level Set est moins sensible aux variations d'intensité et au bruit, ce qui améliore sa robustesse dans les images à faible contraste. Ce modèle est donc intéressant à tester sur nos images CT abdominales.

Chapitre III : Segmentation du foie




Figure III. 9 Procédure de Level-set : 1. Initialisation de contour 2. Itération jusqu'à convergence (nombre d'itération donné)(Ehsani Rad, 2017).

La **Figure III.10** illustre les résultats de la détection du contour du foie puis son l'extraction de la région « foie ». Bien que le contour soit net, nous constatons qu'il ne délimite pas correctement les frontières du foie. Ceci ne sous-entend pas l'inefficacité de cette méthode mais plutôt la difficulté de maîtriser la bonne convergence.

Chapitre III : Segmentation du foie




Figure III. 10 Segmentation du foie avec la méthode Levelset.

Cependant, les méthodes de segmentation basées sur le contour présentent certaines limites qui peuvent affecter leur efficacité et leur précision. Elles sont particulièrement sensibles au bruit ainsi qu'aux variations d'intensité dans l'image, ce qui peut conduire à une convergence incorrecte du contour. De plus, ces approches nécessitent une initialisation appropriée afin d'éviter que le contour ne se fixe sur des bords indésirables ou des artefacts présents dans l'image. Enfin, la complexité computationnelle de ces méthodes, notamment celles reposant sur les ensembles de niveaux, peut entraîner des temps de calcul élevés, limitant ainsi leur utilisation en temps réel ou sur des images de grande taille.

Chapitre III : Segmentation du foie

3.1.3 Segmentation Basée sur la Région

Les méthodes de segmentation basées sur la région consistent à regrouper les pixels partageant des caractéristiques similaires, telles que l'intensité, la couleur ou la texture, afin de former des régions homogènes. Contrairement aux approches basées sur le contour, qui se concentrent sur les discontinuités d'intensité, ces méthodes exploitent l'homogénéité des pixels pour identifier les objets dans une image. Elles sont particulièrement robustes aux bruits et adaptées aux images à faible contraste, mais peuvent être sensibles à la sélection des paramètres d'homogénéité et nécessiter une optimisation pour éviter une sur-segmentation ou une fusion incorrecte des régions.

Parmi les techniques les plus courantes, on trouve la croissance de région, la division et fusion de région (division en sous-régions successives puis fusion selon des critères d'homogénéité) ainsi que le modèle de Chan-Vese caractérisé par des régions avec un niveau de gris moyen, particulièrement adapté aux images aux contours peu marqués.

Nous nous sommes intéressés à la méthode de croissance de région qui est très utilisée dans l'imagerie médicale. Son algorithme consiste à placer initialement des points de germe (seeds) dans chaque région. Chaque région s'étend alors progressivement en fonction d'un critère de similarité (**figure III.11**).

Chapitre III : Segmentation du foie





Figure III. 11 Procédure de croissance de région.

La **figure III.12** indique le résultat de notre expérimentation sur une image CT abdominal avec des opérations morphologiques post-traitement. Les résultats sont satisfaisants mais difficilement reproductibles, sans adaptation des valeurs initiales, d'une coupe à l'autre (choix du germe), sachant que nous devons segmenter l'ensemble des coupes abdominales comportant le foie pour pouvoir le reconstruire en 3D.

Chapitre III : Segmentation du foie



- (a), Images CT abdominal avec le marquage du germe de départ,
(b), Itération de croissance $i=10$,
(c), Itération de croissance $i=2000$,
(d) Foie segmenté,
(e), Remplissage des régions vides à l'intérieur des objets,
(f), Érosion suivie par Fermeture morphologique suivie par érosion,
(g), Extraction du foie après superposition du mask (f) sur l'image CT abdominal (a).

Figure III. 12 Segmentation par la méthode croissance en région.

3.1.4 Méthodes Basées sur l'Énergie et les Graphes

Ces méthodes segmentent une image en optimisant une fonction d'énergie, souvent modélisée sous forme de graphe, pour identifier des objets ou des régions distinctes. Les méthodes basées sur l'énergie et les graphes offrent une grande efficacité pour la segmentation de structures complexes, là où les autres approches échouent. Elles sont également plus robustes face au bruit, ce qui les rend adaptées à des images présentant des artefacts ou des irrégularités. Toutefois, ces méthodes sont gourmandes en ressources, en particulier pour le

Chapitre III : Segmentation du foie

traitement d'images de grande taille ou haute résolution. De plus, le temps de calcul peut être considérable, notamment lorsque l'optimisation de la fonction d'énergie est complexe, ce qui peut limiter leur utilisation dans des applications nécessitant un traitement en temps réel.

L'algorithme le plus courant est connu sous le nom de Graph Cuts.

Graph Cuts modélise l'image sous forme d'un graphe (**figure III.13**), où chaque pixel est un nœud. L'algorithme trouve un "cut" optimal pour séparer les régions (Akyıldız Beyza, 2024-01-01).




Figure III. 13 Schéma synoptique de l'algorithme Graph cuts(BOUDRAA, 2022).

La **figure III.14** illustre l'application de Graph cuts à notre coupe CT abdominale.

Chapitre III : Segmentation du foie




Figure III. 14 Segmentation par la méthode GraphCuts.

3.2.Approches Basées sur l'Apprentissage Automatique

La classification à base d'apprentissage machine (Machine Learning ou ML) est une technique avancée de vision par ordinateur qui est inspiré par l'intelligence humaine. Elle consiste à diviser une image numérique d'une façon automatique ou semi-automatique et intelligente en groupes discrets de pixels (segments d'image). Il s'agit d'une classification au niveau des pixels.

Deux approches principales existent : la classification supervisée et la classification non supervisée (**Figure III.15**).

Chapitre III : Segmentation du foie




Figure III. 15 Types d'apprentissage machine à usage courant pour la segmentation des images médicales (F. Brunelle, 2019)

3.2.1. La classification non supervisée (clustering)

Les pixels sont assemblés en fonction d'un critère de ressemblance, généralement fondé sur la distance entre leurs vecteurs de caractéristiques. Cette approche ne nécessite pas de données étiquetées, offrant ainsi une plus grande flexibilité dans son utilisation, bien qu'elle puisse être parfois moins précise.

Les méthodes habituelles :

- ✓ K-means : Segmente les pixels en un certain nombre de regroupements préétabli tout en réduisant la variance au sein de chaque cluster.
- ✓ Mean Shift : Détecte les modes d'intensité afin de rassembler les pixels autour de ces points.
- ✓ Clustering hiérarchique : Établit une hiérarchie de regroupements en combinant ou en segmentant des ensembles de pixels.

Chapitre III : Segmentation du foie

Les approches de classification non supervisée comportent divers atouts et limites. Ces dernières n'ont pas besoin de données étiquetées, ce qui les rend particulièrement appropriées pour les applications où l'annotation manuelle est complexe ou onéreuse. En outre, elles sont performantes quand les variations d'intensité ou de texture sont bien marquées, permettant une segmentation relativement précise dans ces conditions.

Toutefois, ces techniques dépendent grandement du nombre de clusters sélectionnés (figure III.16), en particulier dans le cas du K-means (S. M. Aqil Burney, June 2014), qui est un algorithme populaire, mais ce nombre peut avoir un impact sur la qualité de la segmentation.





Figure III. 16 Processus de l'algorithme K-means. (Li, 21–22 December 2008).

De plus, leur efficacité diminue lorsqu'il s'agit d'images bruitées ou de transitions subtiles entre les régions, ce qui peut entraîner une mauvaise classification des pixels.

La **figure III.17** illustre l'application de l'algorithme K-Means sur une coupe CT abdominale. Comme indiqué ci-dessus, et en raison des faibles transitions entre régions, certains pixels

Chapitre III : Segmentation du foie

n'ont pas été classés correctement. Pour affiner cette classification nous avons ajouté des opérations morphologiques. Le résultat final est alors satisfaisant.



- (a) Segmentation de ROI par la méthode k-means,
- (b) Dilatation morphologique
- (c) Fermeture morphologique
- (d) Remplissage des trous à l'aide de la méthode de connectivité des pixels (les pixels voisins) puis érosion.
- (e) Superposition du masque binaire (d) à l'image CT abdominal.

Figure III. 17 Segmentation du foie par la méthode k-means et opérations morphologiques en post-traitement.

Chapitre III : Segmentation du foie

3.2.2. La Classification Supervisée

Cette approche repose sur l'apprentissage des propriétés discriminantes à partir d'un ensemble de données déjà étiquetées. Un modèle est entraîné à reconnaître ces propriétés et à classer les nouveaux pixels en fonction des connaissances acquises. Elle est efficace lorsque des exemples préalablement classés sont disponibles, mais nécessite un effort d'annotation important.

Les différentes étapes qui permettent de créer un modèle intelligent sont :

- Collecte et préparation des données d'entraînement,
- Conception de l'architecture du modèle de réseaux de neurones,
- Entraînement, validation et ajustement

Le modèle intelligent devient alors prêt pour effectuer la segmentation, c'est-à-dire associer chaque pixel de l'image d'entrée à une classe spécifique en se basant sur ce qu'il a appris.

Les premiers algorithmes connus sous le nom machine Learning (ML) sont :

- ✓ **SVM (Support Vector Machine)** : Sépare les classes en maximisant la marge entre elles dans un espace à plusieurs dimensions.
- ✓ **Forêts aléatoires (Random Forests)** : Entraîne plusieurs arbres de décision et agrège leurs prédictions pour une classification robuste.

Ces algorithmes sont fiables à condition que les données annotées soient précises et de bonne qualité. Ils sont également flexibles et adaptables à une large variété de types d'images. Cependant, ils présentent des limites, les plus importantes étant une segmentation qui dépend de la qualité et de la quantité des annotations ainsi que le risque de surapprentissage (overfitting) si les données sont insuffisantes ou trop spécifiques.

Chapitre III : Segmentation du foie

4. État de l'Art sur la Segmentation du Foie : Approches Classiques, classification par Machine Learning (ML) et Deep Learning (DL)

L'algorithme de croissance de région avec point de départ (seededregiongrowing) a été introduit pour la première fois par (Bischof, 1994). Il regroupe les pixels ayant des niveaux de gris similaires au sein d'une même région. Contrairement à la segmentation basée sur l'histogramme qui étudie uniquement l'intensité des niveaux de gris, cette méthode permet d'exploiter d'autres caractéristiques de l'image, comme la moyenne d'intensité, la variance, la couleur ou encore la texture.

Cependant il a été démontré (Suhui Luo, 2014) que cette méthode qui nécessite un point de départ défini manuellement, est moins efficace pour les régions hétérogènes, ce qui limite son automatisation. Dans les versions améliorées le germe de la plus grande région connectée de l'image érodée est utilisé comme point de départ automatique pour la croissance de région. Un modèle gaussien est ensuite appliqué pour déterminer le seuil de croissance en région, suivi d'un post-traitement pour combler les trous et gérer les connexions avec les tissus voisins, offrant ainsi de bons résultats avec un faible temps de calcul.

Un algorithme complètement automatisé est proposé par (Yen-Wei Chen, 2010) pour la segmentation du foie dans des images Open-MR à faible contraste (0.5T). L'approche proposée repose sur un clustering K-means pour extraire les «germes» d'objet et de fond. Ces derniers seront fournis comme valeurs initiales au Graph-cut. Graph-cut est alors appliqué pour segmenter automatiquement le foie.

La méthodologie proposée dans (Oliveira, 2011) suit quatre étapes pour segmenter le foie, les vaisseaux et les segments anatomiques selon le modèle de Couinaud. La segmentation du foie est réalisée à l'aide de l'algorithme Levelsets, dont les paramètres sont ajustés grâce à une optimisation supervisée. Ensuite, la segmentation des vaisseaux et des nodules est effectuée à

Chapitre III : Segmentation du foie

l'aide d'hybridation avec un processus de croissance de région. Ensuite, l'identification des veines hépatiques et portales repose sur le modèle anatomique du foie défini par Couinaud. Cette approche permet une segmentation détaillée et structurée du foie et de sa vascularisation, facilitant ainsi l'analyse clinique et la planification des interventions médicales mais les informations anatomiques sont nécessaires pour atteindre la précision requise.

Dans une autre étude (A. Mostafa, 2015), les auteurs proposent une hybridation entre plusieurs méthodes de base pour la segmentation du foie en tomographie assistée par ordinateur (CT). La méthodologie repose sur un prétraitement utilisant le clustering K-means itératif pour classer les pixels et éliminer les régions à haute intensité, suivi d'une segmentation par croissance de région (Region Growing) pour extraire l'ensemble du foie. Ensuite, une méthode de segmentation de l'approche morphologie mathématique (Watershed) est appliquée pour diviser le foie en plusieurs régions d'intérêt (ROIs) afin d'affiner l'analyse.

Une étude d'analyse de l'utilisation de l'apprentissage supervisé pour la classification des nodules pulmonaires (Aishwarya, 2025) établit les avantages et les limites des ML. Cette étude met en avant l'approche réseaux de neurones convolutifs CNN, un autre type d'apprentissage supervisé qui appartient à la famille « apprentissage profond » (Deep learning). Elle démontre que les CNN sont excellents pour la détection précoce du carcinome pulmonaire, compte tenu des défis actuels et des opportunités futures.

Enfin Wei et al (Wei, Jiang, Zhou, Wu, & Feng, 2024) ont résumé l'analyse des recherches publiées entre 2014 et 2024 sur la segmentation du foie et ont mis en lumière la transition progressive des méthodes de base vers des approches (ML) semi-automatiques puis entièrement automatiques, notamment le grand succès des réseaux de neurones d'apprentissage profond (DL).

Chapitre III : Segmentation du foie

Dans notre problématique, la segmentation de l'ensemble des images constituant le volume d'intérêt doit être automatique. La segmentation semi-automatique, exigeant un paramètre d'ajustement tel que le seuil, le germe, le nombre de cluster...que nous retrouvons dans les méthodes citées plus-haut dans ce chapitre, est non envisageable car elle devient vite fastidieuse compte tenu du nombre important de coupes à traiter ainsi que de la grande complexité de l'arbre vasculaire hépatique. Ajoutons à cela les variations inter-patients et les artefacts d'image.

Récemment, les architectures d'apprentissage profond (Deep Learning) ont été appliquées avec succès à la segmentation des vaisseaux hépatiques. Ces méthodes permettent d'apprendre automatiquement des hiérarchies d'attributs pertinents à partir des images médicales, offrant ainsi de meilleures performances en matière de précision et de généralisation.

Nous nous sommes alors intéressés à l'apprentissage profond (Deep Learning) qui représente une évolution des méthodes Machine Learning. Nous allons détailler cette approche dans ce qui suit.

5. Méthodes Basées sur L'apprentissage profond (Deep Learning)

Le terme "Deep Learning" a été introduit pour la première fois à la méthode supervisée par Dechter (1986), et aux réseaux neuronaux artificiels par Aizenberg et al (2000). Ces méthodes utilisent des architectures neuronales (des réseaux de neurones) complexes pour extraire automatiquement des caractéristiques pertinentes et effectuer la segmentation.

Chapitre III : Segmentation du foie




Figure III. 18 Position du Deep Learning dans les approches d'intelligence artificielle.

Le machine Learning est un sous-ensemble de l'Intelligence Artificielle (figure III.18). Il permet de développer des systèmes qui ont la capacité d'apprendre par l'expérience. Ceux-ci peuvent faire des estimations et des prédictions. Nous pouvons les utiliser pour automatiser des tâches.

Enfin, le Deep Learning est considéré comme étant une des technologies principales de machine Learning et permet un apprentissage autonome (Youcef, 2017). Nous allons étudier pas à pas cette approche révolutionnaire en commençant par le début : le neurone artificiel.

5.1. Neurone artificiel

Les réseaux de neurones artificiels (ANN) ou réseaux de neurones simulés (SNN) sont un sous-ensemble de la machine Learning. C'est une technologie qui est au cœur du Deep Learning. Elle permet aux systèmes d'apprendre automatiquement par l'expérience.

Chapitre III : Segmentation du foie

En 1957, F. Rosenblatt propose un modèle mathématique de neurone artificiel inspiré du neurone formel construit en 1943 par W. McCulloch et W. Pitts.

Les réseaux de neurones artificiels sont schématiquement inspirés du fonctionnement des neurones biologiques, complétés de méthodes statistiques (**figure III.19**).

De manière très simplifiée, un neurone biologique reçoit l'information par ses dendrites. Ces dernières vont propager l'information jusqu'au noyau. L'information est ensuite traitée et envoyée sous forme bioélectrique dans l'axone qui va lui même être connecté à d'autres neurones.

Les entrées (inputs) x_i (avec i variant de 1 à p) jouent le rôle des dendrites et apportent un signal (une valeur continue).




Figure III. 19 Schéma du fonctionnement d'un neurone biologique (a) et d'un neurone artificiel(b).

Chapitre III : Segmentation du foie

Chaque neurone artificiel, ou nœud, se connecte aux autres. Il possède un poids et un seuil (ou biais) et chaque entrée est multipliée par un poids (weights) w_i , remplaçant les synapses du neurone biologique.

La somme de ces entrées, multipliées par leurs poids respectifs, est injectée dans le noyau pour calculer la fonction d'activation h .

La fonction d'activation ou sortie h (output), envoyé biologiquement dans l'axone, est une combinaison linéaire des poids et des entrées avec l'ajout d'un biais w_0 . (**Figure III.20**).

$$y = h(w_0 + \sum_{i=1}^p w_i x_i) \quad \dots\dots\dots \text{(Equation III.1)}$$

Cette fonction d'activation h permet de prendre une décision. Historiquement, la fonction d'activation h imaginée par F. Rosenblatt était la fonction seuil de sorte que : Si la combinaison linéaire était supérieure ou égale à 0, alors la sortie y valait 1, dans le cas contraire, la sortie y valait 0.

Les réseaux de neurones artificiels possèdent des couches nodales constituées d'une couche d'entrée, d'une ou plusieurs couches cachées et d'une couche de sortie. Plus y aura de couches cachées, plus le réseau sera complexe et profond (d'où l'appellation Deep Learning).




Figure III. 20 Modèle mathématique du neurone artificiel.

Chapitre III : Segmentation du foie

Dans un groupe, tous les neurones remplissent une fonction similaire. Pour améliorer les réseaux de neurones artificiels, il faut les entraîner (phase d'entraînement ou training part).

5.2. Les types de réseaux de neurones

Comme indiqué dans la revue générale de l'analyse d'images médicales (Mohammad Hesam Hesamian, 2019), plusieurs articles récents ont été consacrés à la segmentation d'images médicales par Deep Learning.

Le tableau III.1 présente une description rapide des réseaux de neurones existant en précisant leurs principales applications et avantages.

Type de Réseau de Neurones	Description	Applications Principales	Avantages
Perceptron Multicouche (MLP)	Réseau de neurones dense avec plusieurs couches cachées	Classification, régression, détection de fraude	Simple, polyvalent
Réseaux Convolutifs (CNN)	Utilisent des filtres pour extraire des caractéristiques locales	Vision par ordinateur, reconnaissance d'image, vidéos	Efficace pour les données spatiales (images)
Réseaux Récurrents (RNN)	Possèdent des boucles, prennent en compte les dépendances temporelles	Traitement du langage, séries temporelles, audio	Traite les séquences de données
Long Short-Term Memory (LSTM)	Variante de RNN avec mémoire longue durée	Traduction automatique, reconnaissance vocale	Gère bien les longues dépendances
Gated Recurrent Unit (GRU)	Variante simplifiée de LSTM	Applications similaires à LSTM	Moins complexe, plus rapide que LSTM
Réseaux de Neurones Résiduels (ResNet)	Réseau profond avec connexions résiduelles	Reconnaissance d'image, réseaux très profonds	Réduit le problème du gradient qui disparaît
Transformers	Basé sur l'attention, non séquentiel	NLP (ChatGPT, BERT), vision, audio	Excellente performance sur grandes séquences

Chapitre III : Segmentation du foie

Autoencodeurs	Réseau non supervisé pour encoder/décoder les données	Réduction de dimension, détection d'anomalies	Apprentissage non supervisé utile
Réseaux Génératifs Adverses (GANs)	Deux réseaux en compétition (générateur et discriminateur)	Génération d'images, deepfakes, art IA	Capacité à générer des données réalistes
Self-Organizing Maps (SOM)	Réseau non supervisé pour réduction de dimension	Visualisation de données, clustering	Très utile pour l'analyse exploratoire

Tableau III. 1 Types et caractéristiques de réseaux de neurone artificiel.

Il existe deux principaux types de systèmes Deep Learning pour les images médicales : les réseaux de neuronaux convolutifs (CNN) et les réseaux de neuronaux récurrents (RNN) (Tableau III.2).

Aspect	CNN	RNN
Type de données	Données spatiales (images)	Données séquentielles (temps, vidéo)
Objectif principal	Segmentation et reconnaissance spatiale	Suivi et dépendance temporelle
Applications typiques	IRM, scanner, segmentation statique	IRM dynamiques, vidéos médicales
Meilleures performances	Structures anatomiques précises	Mouvements, séquences
Limites	Ne capte pas le temps	Moins précis spatialement

Tableau III. 2 Réseaux de neurones courants dans le domaine médical.

Pour segmenter des images médicales statiques (ex. foie sur un scanner), CNN est l'option optimale.(Ran Gu, 2020)

Pour des données temporelles ou dynamiques (ex. échographies cardiaques en mouvement), RNN ou CNN+RNN hybrides peuvent être utilisés(Soopil Kim, 2020).

Chapitre III : Segmentation du foie

Dans cette partie, nous allons introduire les notions de base sur les réseaux convolutifs, leur architecture, leurs applications ainsi que les modèles basés sur ce type de réseaux. Nous finirons par citer des architectures CNN efficaces en imagerie médicale.

5.3. Les Réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) ont été conçus à l'origine pour la reconnaissance de formes dans les images, avec une première application marquante en 1989 par Yann LeCun, pour reconnaître les chiffres manuscrits.

Un CNN est constitué de plusieurs couches hiérarchiques de neurones, où chaque couche extrait des caractéristiques visuelles de plus en plus complexes à partir des images d'entrée. Le réseau est entraîné par apprentissage supervisé, en recevant des images étiquetées et en ajustant ses poids pour améliorer sa capacité de classification à chaque itération.

5.3.1. Architecture d'un CNN

Comme nous l'avons indiqué précédemment, un CNN est un réseau de neurones spécialement conçu pour le traitement des images. Il se compose de plusieurs couches, chacune jouant un rôle spécifique dans l'extraction et l'interprétation des caractéristiques visuelles (Prasad, 2024). La figure III.21 présente l'architecture d'un CNN que nous allons détailler.

Chapitre III : Segmentation du foie




Figure III. 21 Architecture d'un CNN

5.3.1.a. Couches d'entrée (input layer)

Celle-ci reçoit directement les données brutes de l'image, généralement sous forme de matrices contenant les valeurs des pixels. La taille de cette couche est adaptée aux dimensions des images traitées, c'est-à-dire leur hauteur, leur largeur, et le nombre de canaux de couleur (exemple trois canaux pour une image couleur codée en RGB (rouge, vert, bleu)).

5.3.1.b. Couche de Convolution (Convolutional Layer)

Elles constituent le cœur de l'extraction de caractéristiques. Elles utilisent des filtres(kernels), également appelés noyaux, qui parcourent l'image pour en extraire des motifs spécifiques. Chaque filtre agit comme un détecteur capable de repérer des éléments visuels fondamentaux tels que les bords, les textures ou les formes. Au fur et à mesure que l'on progresse dans le réseau, les couches de convolution apprennent automatiquement à détecter des structures de plus en plus complexes, construisant ainsi une carte de caractéristiques (featuremap) de l'image (**figure III.22**). Les cartes de convolution sont transformées (en les aplatissant) en un vecteur, puis elles sont rassemblées pour former un vecteur unifié de caractéristiques.

Chapitre III : Segmentation du foie




Figure III. 22 Evolution des cartes de caractéristiques dans le temps.

b-1 Les paramètres des filtres de convolution

Les filtres sont un outil très importants dans la couche de convolution, il est donc important de savoir comment ajuster leurs paramètres.

i. Dimensions d'un filtre

Un filtre de taille $F \times F$ appliqué à une entrée contenant C canaux est un volume de taille $F \times F \times C$ qui effectue des convolutions sur une entrée de taille $I \times I \times C$ et qui produit une carte des caractéristiques (featuremap) de sortie de taille $O \times O \times 1$

ii. Stride de déplacement

Le stride (ou pas de déplacement) dans une couche de convolution désigne le nombre de pixels avec lequel le filtre (ou noyau) se déplace à chaque étape lorsqu'il balaie une image.

- ✓ Un stride de 1 signifie que le filtre avance pixel par pixel.

Chapitre III : Segmentation du foie

- ✓ Un stride de 2 signifie qu'il se déplace avec un pas de deux (**figure III.23**), etc.

iii.Padding :

Lors de la convolution, les pixels centraux de l'image sont utilisés plusieurs fois et Les pixels en bordure, eux, sont utilisés moins fréquemment, donc ignorés partiellement, Cela entraîne une perte d'information sur les bords → c'est l'effet de bord.

La Solution est le padding :

Le padding consiste à ajouter une bordure autour de l'image, souvent remplie de zéros (**figure III.23**). Ses avantages sont comme suit :

- Compense la perte d'information en impliquant d'avantage les bords dans les calculs,
- Préserve la taille spatiale (largeur $\times$ hauteur) de l'image en sortie.
- Permet un meilleur contrôle des dimensions de la carte de caractéristiques (featuremap).
-




Figure III. 23 Application d'un filtre de convolution 3x3 sur une image 4x4 avec un padding de 1 et un stride de 2(Yunji Chen, 2024).

Chapitre III : Segmentation du foie

5.3.1.c. Les couches de regroupement

Elles sont également appelées pooling layer. Leur rôle principal est de réduire la taille des cartes de caractéristiques issues des couches précédentes, tout en conservant les informations les plus importantes. Il existe différents types de pooling : le « max pooling » sélectionne la valeur maximale dans une région donnée ; le « average pooling » calcule la moyenne des valeurs dans chaque région de la carte de caractéristiques (figure III.24).

Ce mécanisme contribue aussi à rendre le réseau plus tolérant aux petites variations dans la position ou l'orientation des objets dans l'image.




Figure III. 24 Exemple de max pooling et de average pooling à partir d'une carte de caractéristique intermédiaire (Liang Minfei, 2022)

5.3.1.d. Couches de corrélation

La fonction d'activation constitue un élément fondamental au sein des réseaux de neurones, car elle permet au modèle d'apprendre et d'identifier des structures complexes dans les

Chapitre III : Segmentation du foie

données (figure III.25). Son rôle est de transformer les signaux d'entrée en une sortie non linéaire, ce qui rend possible la prise de décision ou la prédiction par le réseau.




Figure III. 25 Apprentissage d'un réseau de neurones.

Dans un réseau neuronal, chaque neurone est conçu pour réaliser une opération mathématique spécifique sur la somme pondérée des signaux qu'il reçoit des nœuds de la couche précédente. Cette opération correspond à ce que l'on appelle une fonction d'activation. Les fonctions d'activation jouent un rôle crucial dans l'introduction de non-linéarité au sein du modèle. Cette non-linéarité est indispensable, car elle permet au réseau de capturer des relations complexes et non triviales entre les données d'entrée. En outre, elle facilite la génération de gradients exploitables lors de la phase d'optimisation, condition essentielle à l'apprentissage efficace du modèle. À l'inverse, si l'on se limite à l'usage de fonctions d'activation linéaires, le réseau perd cette capacité à modéliser la complexité et se comporte alors comme une simple régression linéaire, limitant considérablement sa puissance prédictive.

Chapitre III : Segmentation du foie

Parmi les fonctions d'activation les plus couramment utilisées, on retrouve la fonction ReLU (Rectified Linear Unit)(Yamashita, 2018), la tangente hyperbolique(Loris Nanni, 2020), la sigmoïde logistique(Lars Nieradzic, 2021), la Softmax(Pawan Kumar Mall, 2023),

Le choix de la fonction d'activation est déterminant (**figure III.26**), chacune à sa propre formule mathématique. Ce choix influence directement la capacité du réseau à capturer l'information, tout en limitant la perte de signal lors de la propagation directe (forward propagation) et les problèmes de disparition du gradient pendant la rétropropagation (backpropagation). (**Voir partie apprentissage de réseau de neurones convolutifs**)

d.1 Choix de la fonction d'activation :

d.1.1. Fonctions d'activation pour les cas simples :

Pour les cas simples (comme la régression logistique), on utilise généralement des fonctions d'activation classiques :

- **Sigmoïde** : Fournit une sortie comprise entre 0 et 1. Idéale pour prédire des probabilités dans des problèmes de classification binaire. Toutefois, elle peut poser des problèmes lors de l'optimisation car elle n'est pas centrée en zéro, ce qui complique les mises à jour du gradient. Elle est aussi sujette au problème du gradient qui disparaît, donc à éviter dans les réseaux profonds.
- **Tanh** : Similaire à la sigmoïde, mais centrée entre -1 et 1. Elle offre une meilleure symétrie pour les entrées négatives et positives. Elle est adaptée aux tâches de classification binaire, mais reste aussi vulnérable au problème de gradient faible dans les réseaux profonds.
- **Softmax** : Généralisation de la sigmoïde pour la classification multi-classes. Elle convertit les sorties en une distribution de probabilité (la somme des sorties est égale à 1). Utilisée typiquement en couche de sortie d'un classificateur à plusieurs classes.

Chapitre III : Segmentation du foie

Pour résumer dans les simples, nous choisirons :

- Softmax pour la classification multi-classes
- Sigmoid et Tanh pour la classification binaire
- Aucune fonction d'activation pour les régressions linéaires, car on prédit directement des valeurs numériques.

d.1.2 Fonctions d'activation pour les cas complexes :

La fonction **ReLU** (Rectified Linear Unit) est aujourd'hui la plus utilisée dans les réseaux de neurones profonds (notamment les CNN). Elle est à la fois simple, rapide, et surtout évite le problème du gradient qui disparaît, ce qui la rend particulièrement efficace pour les modèles complexes et profonds.





Figure III. 26 Fonction d'activation les plus utilisés dans le domaine médical.

5.3.1.e. Les couches entièrement connectées

Cette couche intervient en fin de réseau pour interpréter l'ensemble des caractéristiques extraites. À ce stade, chaque neurone est relié à tous les neurones de la couche précédente, permettant ainsi de combiner les informations en vue d'une prise de décision. Ces couches

Chapitre III : Segmentation du foie

apprennent à établir des relations complexes entre les différentes caractéristiques pour produire des prédictions précises (figure III.27).



(a) (b)

(a)-Sa connexion avec la couche précédente

(b)-Opération au sein de chaque neurone.

Figure III. 27Couche entièrement connectée.

5.3.1.f. La couche de perte

Elle est située à l'extrémité du réseau de neurones et joue un rôle fondamental en évaluant l'écart entre les prédictions du modèle et les valeurs réelles. Dans le cadre des tâches de classification binaire, où la variable cible est discrète, elle ne peut prendre que la valeur 0 ou 1.

Chapitre III : Segmentation du foie

La fonction de perte la plus pertinente est l'entropie croisée. Issue de la théorie de l'information, cette fonction mesure la divergence entre deux distributions de probabilité : celle prédite par le modèle et celle observée. Elle permet ainsi de quantifier avec précision l'erreur globale de prédiction, en pénalisant fortement les écarts entre les classes prédites et les classes réelles.

5.3.1.g. Couche de sortie

Elle contient autant de neurones qu'il y a de classes possibles dans la tâche de classification. Chaque neurone produit une probabilité associée à une classe, ce qui permet d'identifier la classe à laquelle appartient l'image en entrée. C'est donc cette couche qui délivre la réponse finale du CNN, sous forme d'une estimation probabiliste.

5.4 Apprentissage du CNN

Les réseaux de neurones convolutifs (CNN) apprennent eux-mêmes quelles caractéristiques extraire.

Par exemple, dans la tâche de segmentation du foie à partir d'images médicales (IRM ou scanner TDM), le réseau peut apprendre à détecter automatiquement les contours du foie, sa forme globale, ou des variations d'intensité caractéristiques dans l'image. Ces éléments lui permettent de distinguer le foie des autres organes et tissus environnants, sans qu'on ait besoin de définir manuellement ces critères.

Pour qu'un CNN apprenne, il faut remplir les conditions suivantes :

- ✓ Disposer d'un « data-set »(X, Y) où X sont les « features » (images à segmenter et Y sont les « targets » (sorties désirées).
- ✓ Développer un modèle de réseaux de neurones dont les paramètres sont à trouver.

Chapitre III : Segmentation du foie

- ✓ Définir une fonction coût qui mesure l'erreur entre les sorties du model et les valeurs de Y du « data-set ».
- ✓ Algorithme de minimisation de la fonction de coût (chercher les paramètres qui minimisent cette fonction).

La fonction coût :

La fonction de perte dans l'apprentissage automatique dépend de la problématique à résoudre (régression ou classification) (figure III.28).




Figure III. 28 Comparaison entre une classification et une régression

Soit D , un ensemble de données composé de N échantillons étiquetés (x_i, y_i) et C le nombre de classes.

Désignons la sortie du modèle $M_{(b,\omega)}$ avec b : *biais*, ω : *weight* on a :

$$\forall i, \hat{y}_i = M_{(b,\omega)}(x_i) \quad \dots\dots\dots \text{(Équation III.2)}$$

- **Erreur quadratique moyenne**

Chapitre III : Segmentation du foie

L'erreur quadratique moyenne (ou *MeanSquaredError*, MSE) est la fonction de perte la plus utilisée dans les contextes de régression. Elle est définie comme suit :

$$fonctiondecoût(MSE) = \frac{1}{N} \sum_{i=0}^N (y_i - y_{ipred})^2 \dots\dots\dots (\text{Équation III.3})$$

Soit en remplaçant y_{ipred} selon l'équation III.3

$$fonctiondecoût(MSE) = \frac{1}{N} \sum_{i=0}^N (y_i - M_{(b,\omega)}(x_i))^2 \dots\dots\dots (\text{Équation III.4})$$

- **Cross Entropy**

La fonction de perte cross entropy est utilisée dans le cas de la classification binaire ou multi-classes. Elle calcule l'erreur entre les prédictions du modèle et les valeurs désirées afin d'ajuster les paramètres du réseau de neurones. On distingue la fonction de perte cross entropy binaire « Binary Cross Entropy Loss » et la cross entropy pour le cas général c'est-à-dire les multi-classes.

- **Binary Cross Entropy Loss**

Valable pour le cas binaire c.-à-d. 2 classes. Elle est définie comme suit :

$$l = -\frac{1}{N} \sum_{i=1}^N y_i \log(\hat{y}) + (1 - y_i) \log(1 - \hat{y}) \dots\dots\dots (\text{Équation III.5})$$

Dans la classification binaire on a :

- y_i L'ensemble des images étiquète des données n (ayant pour valeurs 0 ou 1)
- $\hat{y}$ la probabilité prédite de la classe positive (classe 1) pour l'échantillon n .

- **Cross entropyLoss :**

Pour une classification multi-classes :

$$l = -\frac{1}{N} \sum_i^N \sum_j^C y_{ij} \log(\hat{y}_{ij}) \dots\dots\dots (\text{Équation III.6})$$

Chapitre III : Segmentation du foie

- y_{ij} l'ensemble des images étiquette des données.
- $\hat{y}_{ij}$ est la probabilité prédite de la classe positive (classe 1) pour l'échantillon n

5.4.1 Entraînement et Apprentissage des CNN

L'entraînement des réseaux de neurones convolutifs repose sur un processus itératif fondé sur l'algorithme de rétropropagation. Il sert à minimiser une fonction de perte ou fonction de coût (comme expliquée ci-dessus), reflétant l'écart entre les prédictions du modèle et les valeurs réelles des données d'entraînement, afin d'améliorer la capacité de généralisation tout en évitant le sur-apprentissage et le sous-apprentissage (**Figure III.29**).




Figure III. 29 Qualités d'apprentissage

Le tableau III.3 résume les caractéristiques d'un CNN dans le cas du sous-apprentissage et du sur-apprentissage

Critère	Sous-apprentissage (Underfitting)	Sur-apprentissage (Overfitting)
---------	--------------------------------------	---------------------------------

Chapitre III : Segmentation du foie

Définition	Le modèle est trop simple pour capturer les structures des données.	Le modèle est trop complexe et s'ajuste excessivement aux données d'entraînement.
Cause principale	Modèle sous-paramétré ou entraînement insuffisant.	Modèle sur-paramétré ou entraînement excessif sans régularisation.
Performance sur les données d'entraînement	Mauvaise (grande erreur).	Très bonne (faible erreur).
Performance sur les nouvelles données (test)	Mauvaise également.	Mauvaise, car le modèle ne généralise pas bien.
Symptômes	Prédictions trop simplistes, erreurs systématiques.	Prédictions instables, sensibles au bruit ou aux valeurs aberrantes.
Solution courante	- Utiliser un modèle plus complexe - Augmenter le temps d'entraînement	- Réduire la complexité du modèle - Appliquer des techniques de régularisation
Exemple typique	Un modèle linéaire pour un problème non linéaire.	Un réseau de neurones avec trop de couches apprenant parfaitement un petit jeu de données.

Tableau III. 3 Comparaison entre Sous-apprentissage et Sur-apprentissage.

5.4.1.a Rétropropagation et Mise à Jour des Poids

L'entraînement d'un modèle d'apprentissage profond nécessite l'ajustement des paramètres de chaque couche neuronale. La rétropropagation du gradient de l'erreur (ou back propagation) est un algorithme d'optimisation permettant d'ajuster les paramètres d'un réseau de neurones multicouches pour mettre en correspondance des entrées et des sorties référencées dans une base d'apprentissage.

Le mécanisme de rétropropagation débute par le calcul d'une erreur entre Y (sortie désiré) et la sortie des réseaux de neurones, quantifiée par une fonction de perte adaptée à la tâche (par exemple, cross Entropyloss pour la classification ou l'erreur quadratique moyenne(MSE) pour

Chapitre III : Segmentation du foie

la régression. Cette erreur est ensuite utilisée pour ajuster les poids du réseau à l'aide de l'algorithme de descente de gradient.

Ce processus comprend :

- **Calcul du gradient** : Détermination du gradient de la fonction de perte par rapport à chaque paramètre du réseau via des dérivées partielles, en prenant la dérivée en fonction de nos paramètres ω et b :

$$\frac{\partial}{\partial \omega} = \frac{2 \sum_{i=1}^n -x_i(y_i - (\omega x_i + b))}{N} \dots\dots\dots (\text{Équation III.7})$$

$$\frac{\partial}{\partial b} = \frac{2 \sum_{i=1}^n -(y_i - (\omega x_i + b))}{N} \dots\dots\dots (\text{Équation III.8})$$

- **Mise à jour des poids** : Ajustement des poids dans le sens opposé au gradient, en fonction d'un **taux d'apprentissage** (avec un nombre d'itérations max avant que l'algorithme de descente de gradient converge) prédéfini.
 - Un taux faible favorise une convergence lente mais stable.
 - Un taux élevé peut accélérer la convergence mais risque d'induire une instabilité.

Ce cycle d'évaluation de la perte et de mise à jour des poids est répété sur l'ensemble des données d'entraînement pendant plusieurs **épques** (itérations), permettant d'ajuster les paramètres ω et b et d'obtenir la plus petite erreur, rendant ainsi le modèle prêt à résoudre des problèmes similaires de manière automatisée. Le taux d'apprentissage et le nombre d'époques doivent être constants dans un algorithme de gradient (figure III.30).

Chapitre III : Segmentation du foie




Figure III. 30 Algorithme de descente de gradient montrant la minimisation de la fonction de coût.

5.4.2. Importance de l'Entraînement

Ce processus est fondamental pour permettre au CNN d'apprendre à partir des données d'entraînement, d'extraire des caractéristiques discriminantes. Il consiste pratiquement à trouver des poids synaptiques tels que la couche de sortie permette de classer avec précision les valeurs observées d'un ensemble d'entraînement et pouvoir classer de nouvelles entrées non vues (Mpia, 2021). Grâce à la rétropropagation, le réseau s'adapte progressivement aux structures sous-jacentes des données, améliorant ainsi ses performances prédictives et donne de bons résultats dans la partie de validation où le réseau doit répondre à notre problématique d'une façon autonome.

5.5. Optimisation et Régularisation

Afin de maximiser l'efficacité de l'apprentissage et de garantir la robustesse du modèle, plusieurs stratégies d'optimisation et de régularisation sont mises en œuvre lors de l'entraînement.

Chapitre III : Segmentation du foie

5.5.1 Techniques d'Optimisation

Les optimiseurs contrôlent le processus de mise à jour des poids, les plus utilisés sont :

- **Adam (Adaptive Moment Estimation)** : Combine les avantages de deux autres méthodes (AdaGrad et RMSprop), en adaptant le taux d'apprentissage pour chaque paramètre via la moyenne mobile des gradients et des gradients au carré.
- **RMSprop** : Adapte dynamiquement le taux d'apprentissage en normalisant le gradient par la racine carrée de sa moyenne mobile au carré, ce qui le rend particulièrement efficace pour les données non stationnaires.

5.5.2 Méthodes de Régularisation

Pour prévenir le surapprentissage (ou overfitting), les techniques de régularisation limitent la complexité du modèle. On peut citer :

- **Dropout** : Technique consistant à désactiver aléatoirement une fraction des neurones durant l'entraînement (souvent entre 20 % et 50 %), ce qui empêche le réseau de trop dépendre de certains neurones spécifiques.
- **Régularisation L2** (ou pénalisation de poids) : Ajoute un terme à la fonction de perte proportionnel à la somme des carrés des poids du modèle, incitant ceux-ci à rester faibles et stables.

L'efficacité des réseaux de neurones convolutifs repose autant sur leur capacité à apprendre les caractéristiques des données que sur les mécanismes d'optimisation et de régularisation qui encadrent cet apprentissage.

Une bonne maîtrise de ces techniques est donc essentielle pour concevoir des modèles à la fois performants et généralisables.

Chapitre III : Segmentation du foie

6. Méthodes d'apprentissage profond

Ces dernières années, de nombreux travaux basés sur l'apprentissage profond (Deep Learning, DL) ont été développées pour résoudre les problèmes de segmentation hépatique. Parmi les approches les plus utilisées, les réseaux de neurone convolutionnel (CNNs) ont été largement adoptés pour apprendre des représentations de caractéristiques utiles à la segmentation du foie et des lésions hépatiques.

Voici un état de l'art visant à présenter les approches existantes en matière de segmentation automatique du foie et des tumeurs hépatiques, dans le but d'identifier les méthodes les plus pertinentes, simples et efficaces pour résoudre notre problématique, à savoir la segmentation automatique en vue d'une reconstruction 3D précise et fiable.

- **Vivanti et al** (R. Vivanti, 2015) propose un algorithme entièrement automatique pour la segmentation des tumeurs hépatiques sur des scanners CT de suivi. La méthode combine une détection basée sur l'évolution temporelle avec une segmentation par CNN entraîné sur le scan de référence. Testée sur 67 tumeurs, elle atteint une erreur moyenne de recouvrement de 16,26 %, validée par un radiologue.
- **Ben-Cohen et al.** (Ben-Cohen, 2016) utilise un réseau neuronal entièrement convolutionnel (**FullyConvolutional Network**, FCN) pour la segmentation du foie et la détection des métastases. Trois coupes CT adjacentes sont utilisées pour former une image à trois canaux en entrée.
- **Zhang et al.** (Zhang, 2017) entraîne un FCN pour la segmentation du foie, suivi d'une étude comparative sur l'étape de post-traitement pour affiner les résultats. Le model est appliqué sur la base de données 3DIRCADb et donne des résultats suffisants.

Chapitre III : Segmentation du foie

- **Lin Han et al**(Lin Han, 2021)propose le 2.5D Perpendicular-UNet (P-UNet), un modèle innovant pour la segmentation du foie et des tumeurs hépatiques, combinant la précision des modèles 3D avec la légèreté des modèles 2D. Il adopte une approche hybride 2.5D, capturant implicitement la structure 3D via des vues perpendiculaires. Ce modèle est hautement personnalisable, intégrant différentes fonctions de perte, techniques d’augmentation de données et options de post-traitement.
- **Muhammad Awaludin Djohar et al**(Muhammad Awaludin Djohar, 2022)applique le modèle U-Net CNN pour la segmentation automatique du foie, une alternative rapide et efficace à la méthode manuelle par radiographie. Grâce à sa structure en encodeur-décodeur, le modèle atteint une précision de 99 %, avec une sensibilité, spécificité et F1-score supérieures à 98 %. Les résultats montrent qu’U-Net est très performant et robuste pour identifier les anomalies hépatiques.

7. Conclusion

Dans ce chapitre, consacré à la segmentation, nous avons survolé les principales techniques classiques et récentes en citant les avantages et les inconvénients de chaque approche. Les méthodes classiques sont encore efficaces mais difficilement automatisable a cause de paramètres manuels qu’il faut choisir judicieusement. Nous avons donnée des exemples d’application de ces méthodes. Ces exemples représentent les premiers pas de notre travail de recherche avant de nous tourner vers les méthodes de machine Learning et en particulier de Deeplearning. En effet, selon l’état de l’art, les méthodes de Deep Learning ont montré un potentiel considérable en surpassant les performances des techniques conventionnelles, notamment grâce aux architectures de réseaux neuronaux convolutifs (CNN) et aux modèles avancés comme U-Net.

Chapitre III : Segmentation du foie

Ces modèles permettent une segmentation plus précise et automatisée en apprenant directement des caractéristiques complexes des images médicales, réduisant ainsi la nécessité d'une ingénierie des caractéristiques manuelle. De plus, leur capacité à exploiter de grandes bases de données annotées améliore leur robustesse et leur généralisation.

Cependant, les approches de Deep Learning présentent encore certains défis, notamment le besoin d'un grand volume de données annotées, la forte consommation de ressources computationnelles et la difficulté d'interprétabilité des modèles.

Malgré ces difficultés, nous avons conclu que le Deep Learning est pour nous la solution la plus performante pour la segmentation du foie : en particulier le modèle U-Net qui est largement reconnu pour sa robustesse en imagerie médicale. Cette solution offre un excellent compromis entre précision, simplicité et rapidité d'exécution.

Chapitre IV : Méthode proposée, Résultats et discussion.

Chapitre IV : Méthode proposée, Résultats et Discussion

Structure de chapitre

Nous structurons ce chapitre comme suit :

Nous commençons par une description globale de la méthode proposée qui a fait l'objet d'une publication scientifique (notre contribution). Ensuite nous détaillerons les différents points en commençant par l'environnement de programmation, suivi des bases de données sur lesquelles s'appuie notre modèle. Ensuite nous détaillerons le fonctionnement du modèle U-Net avec l'ajustement des hyper paramètres qui nous ont permis d'atteindre la segmentation visée. On enchainera avec les résultats de segmentation et une discussion sur ces derniers. La méthode utilisée pour la Reconstruction 3D du volume hépatique, ainsi que les résultats obtenus avec discussion de ces derniers, seront l'objet de la dernière partie de ce chapitre. On terminera avec une conclusion.

1. Introduction

Dans le cadre de la chirurgie hépatique, la compréhension précise de l'anatomie du foie est essentielle pour planifier des interventions sûres et efficaces. Les images CT abdominales constituent une source précieuse pour visualiser les structures internes, mais leur interprétation manuelle est chronophage et donne des erreurs.

L'objectif est d'extraire avec précision le contour hépatique à partir de coupes 2D, afin de générer une reconstruction 3D exploitable dans le contexte chirurgical.

Chapitre IV : Méthode proposée, Résultats et Discussion

Dans ce Chapitre nous présentons notre contribution dans le domaine d'imagerie médical, basée sur l'un des modèles de Deep Learning le plus populaire pour la segmentation des images médicales « U-Net Model ».

2. Méthode proposée

Notre algorithme de reconstruction 3D du foie est composé de deux grandes étapes

- La première étape est la segmentation automatique du volume hépatique, elle-même divisée en deux étapes : l'extraction de l'enveloppe du foie par apprentissage profond (deep Learning) avec le modèle U-Net, suivi par l'identification des vaisseaux hépatiques avec un double seuillage basé sur l'échelle Hounsfield.
- La Reconstruction 3D avec l'algorithme Marching cubes pour générer un modèle 3D à partir des séquences d'images 2D segmentées. Cet algorithme extrait une isosurface reliant les voxels ayant une valeur spécifique (isovalue), ici pour délimiter l'enveloppe du foie. L'application du seuil approprié permet également d'extraire des structures internes telles que les vaisseaux hépatiques.

La figure IV.1 illustre les différentes séquences de traitement que nous allons détailler dans la suite de ce chapitre.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 1 Flow chart pour la segmentation et la reconstruction 3D du foie et de son réseaux vasculaire (Amina Benahmed, 2024)

Chapitre IV : Méthode proposée, Résultats et Discussion

3. Environnement de développement

Ces dernières années, le langage de programmation Python a gagné en popularité dans le domaine du calcul scientifique. Il remplace souvent des outils conventionnels tels que Matlab (matrix laboratory). Python est accessible gratuitement, car il s'agit d'un logiciel libre, et sa portabilité permet son utilisation sur de nombreuses plateformes. Le langage est à la fois léger, concis et particulièrement adapté au prototypage rapide. Il est également suffisamment robuste pour développer des applications complexes (Zena A. Aziz, 2021). De plus, les frameworks de python, permettent aux chercheurs de mettre en place rapidement un pipeline complet de segmentation d'images médicales en quelques lignes de code (Dominik Müller, 2021).

Python est un langage de programmation interprété, multi paradigme et multiplateforme. Il encourage différents styles de programmation, notamment la programmation impérative structurée, fonctionnelle et orientée objet. Grâce à la richesse de ses bibliothèques spécialisées, Python peut être utilisé dans une grande variété de domaines d'application. Aujourd'hui, il occupe une place centrale dans des secteurs de pointe tels que l'informatique quantique, l'intelligence artificielle, le traitement des Big Data et l'apprentissage automatique. En particulier, dans le domaine de la segmentation d'images médicales, Python s'impose comme un outil de choix en raison de sa flexibilité, de la disponibilité d'outils avancés tels que TensorFlow, PyTorch et Scikit-image, et de sa capacité à faciliter le développement rapide de modèles performants

Chapitre IV : Méthode proposée, Résultats et Discussion

Citons à présent, les différentes bibliothèques dédiées au traitement des images médicales et à la segmentation par les techniques de Deep Learning.

NiBabel

- ✓ Permet de lire et écrire des fichiers de neuroimagerie (IRM, scanner, etc.) aux formats NIfTI, Analyze, et autres.
- ✓ Utilisé surtout en neurosciences pour traiter des images médicales.

NumPy

- ✓ Fournit des structures de données puissantes (notamment les tableaux multidimensionnels) pour faire du calcul scientifique rapide.
- ✓ C'est la base de presque toutes les autres bibliothèques Python en data science et machine Learning.

OpenCV

- ✓ Bibliothèque dédiée au traitement d'image et à la vision par ordinateur.
- ✓ Permet de faire des tâches comme la détection de visages, d'objets, ou encore le traitement vidéo en temps réel.

TensorFlow

- ✓ Framework complet de machine Learning et deep Learning développé par Google.
- ✓ Sert à construire, entraîner et déployer des modèles à grande échelle (notamment pour IA, NLP, computer vision).

Keras

- ✓ Interface haut niveau pour construire et entraîner des modèles de deep Learning (réseaux de neurones).
- ✓ Simplifie l'utilisation de TensorFlow, avec un code clair et rapide à écrire.

scikit-image (skimage)

- ✓ Outils simples et performants pour l'analyse et la transformation d'images en Python.
- ✓ Basé sur NumPy et SciPy, pratique pour le prétraitement d'images.

Chapitre IV : Méthode proposée, Résultats et Discussion

Matplotlib

- ✓ Bibliothèque de visualisation de données.
- ✓ Permet de créer des graphiques, des courbes et des figures scientifiques de manière personnalisée




Figure IV.2python le langage de la recherche et programmation IA (intelligence artificiel) dans la segmentation médicale(Richter, 10/3/2020)

4. Base de données

Nous avons utilisé dans notre étude deux bases données hépatiques : Task03_Liver (**Figure IV.1**) et 3Dircadb01CT (**Figure IV.2**) pour l'entraînement dumodèle, et la base de donnéesTask08_hepaticvessel (**Figure IV.3**) pour tester la fiabilité de notre modèle U-Net.

4.1 La Base de données « Task03_Liver »

Un ensemble de données public contenant 201 volumes 3D (131 pour l'entraînement et 70 pour le test). Il est disponible sur le site web de l'organisateur du Medical Segmentation Decathlon(Amber L. Simpson, 2019). La taille de chaque image 2D est de (512 × 512).

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 3 Images CT abdominal de la base de données « Task03_Liver » avec annotation de l'expert en dessous de chaque image source.

4.2 La Base de données « 3D-IRCADb (3D Image Reconstruction for Comparaison of Algorithm Database) »:

C'est une base de données regroupant des images médicales anonymisées de plusieurs groupes de patients (10 femmes et 10 hommes atteints de tumeurs hépatiques).

Cette base contient des images CT en 3D ainsi que des segmentations manuelles de diverses structures d'intérêt, réalisées par des experts cliniques. La résolution intra-plan varie entre 0,57 mm et 0,87 mm, avec un espacement entre les coupes compris entre 1,6 mm et 4,0 mm. Tous les examens ont été réalisés en phase artérielle, en position d'inspiration (Soler, 2010).

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 4Images CT abdominales de la base de données « 3D-IRCADb »avec l'annotation de l'expert en dessous de chaque image source.

4.3 La Base de données « Hepatic Vessel »

Cette base de données est spécifiquement conçue pour l'évaluation des méthodes de segmentation des vaisseaux hépatiques et des tumeurs à partir d'images tomographiques (CT)(Amber L. Simpson, 2019).Elle contient443 volumes 3D(303pour l'entraînement et140pour le test).

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 5 Images CT abdominales de la base de données « HepaticVessel ».

5. Description du modèle de la segmentation automatique

5.1. Architecture du Modèle U-Net

Introduction

Au cours de ces dernières années, la relation entre le domaine de la vision par ordinateur (Computer Vision) et l'imagerie médicale est devenue très puissante car plusieurs architectures de réseaux de neurones ont été créés, permettant ainsi d'automatiser des tâches bien spécifiques dans le domaine de l'imagerie médicale telle que la segmentation sémantique.

La segmentation sémantique est une segmentation basée sur la répartition des pixels d'une façon intelligente, chaque pixel de l'image à une étiquette bien précise (NG, position, les pixels voisinages).

D'après l'état de l'art (chapitre 3), U-Net est le meilleur réseau de neurone intelligent pour la segmentation sémantique. C'est pour cela que nous nous sommes intéressés à U-Net, à son fonctionnement, son architecture de base et comment ce réseau peut apprendre le mappage des fonctionnalités d'une image. Nous allons répondre à toutes ces questions dans la partie suivante.

Définition

U-Net, issu du réseau de neurones CNN traditionnel, a été conçu et appliqué pour la première fois en 2015 pour traiter les images biomédicales. Il est capable de localiser et de distinguer

Chapitre IV : Méthode proposée, Résultats et Discussion

les frontières des éléments composant une certaine image en faisant la classification sur chaque pixel. Détaillons l'architecture de ce modèle afin de comprendre son fonctionnement et ce qui fait qu'il soit aussi précis et adapté à ces situations complexes.

U-Net est sous la forme de « U » avec une symétrie de ses parties qui le distingue et se compose de trois sections (**Figure IV.6**) :

- ✓ La section contraction (Encoder).
- ✓ Le goulot d'étranglement (Bottleneck).
- ✓ La section d'expansion (Decoder).




Figure IV. 6 Architecture U-Net (Olaf Ronneberger, 2015)

5.2. Le fonctionnement d'U-Net

La **Figure IV.7** illustre le principe de la segmentation binaire avec U-Net. L'objectif est de reconstruire une carte sémantique qui répond à la question "à quelle classe appartient chaque pixel". Ainsi pour chaque pixel de l'image d'entrée, on associe un vecteur de probabilités

Chapitre IV : Méthode proposée, Résultats et Discussion

d'appartenance aux différentes classes. Ce vecteur va nous permettre de synthétiser l'image segmentée en choisissant la classe correspondant à la probabilité maximale.

Nous allons expliquer de manière structurée les différents tâches complexes accomplies pour atteindre l'objectif final c'est à dire une segmentation précise pour chaque pixel.

5.2.1 Au sein du premier bloc (contraction)

Le rôle du bloc de contraction est de capture des caractéristiques contextuelles globales tout en réduisant la taille de l'image (la résolution), c'est-à-dire l'extraction des motifs locaux (bords, textures).

Ce bloc consiste en un assemblage de couches de convolution et Relu. Chaque couche apprend avec des filtres (poids) permettant de capturer les caractéristiques de l'image et un biais qui introduit un décalage dans la réponse du neurone (figure IV.7). Cette couche est suivie de la couche max pooling qui permet de réduire la taille de l'image de façon à diminuer le nombre de paramètres du réseau. Cela concentre les caractéristiques les plus importantes dont les couches (convolution +ReLU+Max pooling). Cette opération est répétée tout au long de ce bloc et à chaque niveaux le nombre de filtres est doublé pour capter plus de complexité tout en gardant à la fin un vecteur dense de caractéristiques (contracté).

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 7 Opération de convolution : chaque image 3D va être scannée par un filtre 3D de convolution, chaque filtre a un poids et un biais propre (f1, f2) : [weight (w0, w1), biais (b1, b2)].

5.2.2 Au sein du goulot d'étranglement

C'est la partie la plus profonde du U-Net (512 ou 1024 filtres) qui permet de comprendre la forme globale de l'objet à segmenter.

Le goulot d'étranglement est composé de deux couches de convolutions, chaque couche est suivie d'une fonction d'activation Relu. Après ces opérations le réseau choisit les informations importantes à transmettre vers le bloc de reconstruction (expansion).

5.2.3 Au sein du bloc d'expansion

Chapitre IV : Méthode proposée, Résultats et Discussion

Ce bloc produit une image de sortie où chaque pixel est un vecteur de probabilités sur les classes possibles.

Il commence par un sur-échantillonnage de la carte des caractéristiques suivi d'une couche de convolution transposée afin d'agrandir les dimensions.

L'encodeur capture les détails fins au niveau des skip connections (copy and crop) (figure IV.6), aide le décodeur à reconstruire l'image en fusionnant les informations globales avec les informations précises. Il s'agit donc de réintroduire les détails locaux perdus pendant le Max pooling.

Après, la concaténation, nous appliquons deux fois la convolution (taille 3 x3) suivie par la fonction d'activation ReLU.

A ce stade nous aurons des cartes de dimensions [Hauteur, Largeur, 1] où chaque pixel aura une valeur comprise entre 0 et 1.

La sortie de ce dernier décodeur est un heatmap qui va passer par une couche de convolution (taille : 1x1) avec une fonction d'activation sigmoïde (**Figure VI.8**).




Figure IV. 8 La fonction d'activation sigmoid.

Chapitre IV : Méthode proposée, Résultats et Discussion

À chaque couche, U-Net extrait des représentations de plus en plus abstraites. Ces cartes sont des matrices (ou images) où chaque pixel indique la présence d'une certaine caractéristique (ex : texture du foie, contour, etc.)

Grâce à des milliers d'exemples (images et vérité terrain), il ajuste ses filtres pour reconnaître les zones pertinentes (ROI : region of Interest).

Une couche de convolution 1×1 est appliquée pour combiner les C canaux $\rightarrow$ sortie avec 1 canal, Une fonction sigmoïde est appliquée pixel par pixel.


L'adaptation dynamique du seuil se fait en maximisant des métriques comme le Dice coefficient. Une telle métrique est surtout intéressante quand les images présentent des variations inter-patients en intensité et texture.

Avant la validation (ou même à chaque époque), on enregistre les poids (weights) et biais (biais) appris par le modèle durant l'entraînement. Ces valeurs représentent ce que le modèle a réellement appris.


Elles sont initialement aléatoires, puis mis à jour à chaque batch via la descente de gradient (optimiseur comme Adam ou SGD). Elles sont exploitées pendant l'entraînement (training) pour sélectionner automatiquement le modèle le plus performant et après l'entraînement pour réutiliser le modèle sur de nouvelles images sans le ré-entraîner.

La sortie après la sigmoïde est une carte de probabilité de l'appartenance de chaque pixel à la classe cible (**Figure VI.9**). Cette sortie est comparée à la vérité terrain (ground truth) binaire. Dans notre cas nous utilisons une fonction de perte (loss). Enfin nous minimisons la perte en utilisant l'algorithme de Rétro-propagation (back propagation).

Chapitre IV : Méthode proposée, Résultats et Discussion



(a)



(b)

(a) - Carte de probabilité du foie.

(b) - Masque binaire reconstruit.

Figure IV. 9Sorties du Modèle U-Net

Nous expliquons, dans ce qui va suivre, comment cet algorithme parvient à ajuster les poids et les biais.

Chapitre IV : Méthode proposée, Résultats et Discussion

5.3.L'algorithme de rétro propagation, appliqué aux résultats de l'U - Net

La mise à jour des poids du réseau de neurones d'U-Net fonctionne comme suit :

- ✓ Propagation avant (forwardpass) : L'image passe à travers le réseau U-Net afin de produire une carte de segmentation.
- ✓ Rétro propagation (backwardpass) : La descente de gradient de perte est calculée par rapport à chaque paramètre du réseau, elle indique dans quelle direction et avec quelle intensité chaque paramètre doit être ajusté pour réduire la perte.

À l'aide du gradient calculé, on met à jour les poids avec la formule suivante :

$$\omega_{nouveau} = \omega_{ancien} - \eta \cdot \nabla_{\omega} \dots \dots \dots (IV. 1)$$

Où :


$\nabla_{\omega} p$: Le gradient de la fonction de perte par rapport au poids ω .

η : Le taux d'apprentissage (Learning rate).

p : Fonction de perte.

Chapitre IV : Méthode proposée, Résultats et Discussion

La **figure VI.10** illustre le processus de segmentation suivi par le modèle U-Net en neuf étapes depuis l'image d'entrée jusqu'à la prédiction du masque binaire de sortie. Ce masque est le résultat recherché qui identifie automatiquement la région correspondant au foie.



Chapitre IV : Méthode proposée, Résultats et Discussion

↓
Étape 2 : Prédiction ($\hat{y}$)

+-----+

| 0.1 0.3 0.8 0.7 | → Probabilité que chaque pixel soit foie

| 0.2 0.9 0.9 0.3 |

| 0.1 0.8 0.9 0.2 |

+-----+

↓
Étape 3 : Masque Réel (y)

+-----+

| 0 0 1 1 | → Vérité terrain (ground truth)

| 0 1 1 0 |

| 0 1 1 0 |

+-----+

↓
Étape 4 : Fonction de Perte

Binary Cross Entropy + Dice Loss

$$L = \alpha \cdot L_{\text{BCE}} + \beta \cdot L_{\text{Dice}}$$

↓

Chapitre IV : Méthode proposée, Résultats et Discussion

Étape 5 : Rétropropagation

$dL/dW \leftarrow$ Calcul des gradients
via dérivées partielles et règle de chaîne



Étape 6 : Mise à jour des poids

$W \leftarrow W - \eta \cdot \nabla L$
(η = learning rate)



Étape 7 : Nouvelle Prédiction

$\hat{y}$ (amélioré à chaque epoch)



Étape 8 : Masque Binaire Final

$y_final = (\hat{y} > 0.5).astype(int)$

```
+-----+
| 0  0  1  1 | → Masque foie prédictif (0 ou 1)
| 0  1  1  0 |
| 0  1  1  0 |
+-----+
```

Étape 9 : Visualisation de foie prédit par U-Net
Avec meilleurs poids et biais.



Figure IV. 10 les Etapes de segmentation supervisées par le modèle U-Net.

Chapitre IV : Méthode proposée, Résultats et Discussion

5.4. Hyper- paramètres du modèle

5.4.1 Compilation du Modèle

La compilation du modèle est réalisée via la méthode `model.compile()`. Elle intègre l'optimiseur Adam, la fonction de perte `dice_loss`, et une métrique d'évaluation `Dice_coefficient`. Cette combinaison permet au modèle d'être spécifiquement ajusté pour des tâches de segmentation, où la précision des contours est essentielle.

5.4.2 Optimiseur Adam

L'optimiseur Adam est choisi pour ses capacités adaptatives à ajuster les taux d'apprentissage pendant l'entraînement. Il combine les avantages de deux autres méthodes populaires, AdaGrad et RMSProp, pour offrir une convergence rapide et efficace et qui particulièrement utile pour des réseaux profonds.

5.4.3 Fonction de Perte : DiceLoss

Le `dice_loss` est adapté aux tâches de segmentation d'images, car il mesure directement le recouvrement entre les prédictions et les masques réels.

Nous avons utilisé un $\text{dice_loss} = (1 - \text{Dice coefficient})$. Autrement dit, la minimisation de la fonction de perte représente l'augmentation du Dice coefficient. Ces deux paramètres indiquent la similarité désirée entre les prédictions et les masques réels.

Chapitre IV : Méthode proposée, Résultats et Discussion

5.4.4 Fonction d'Activation

Les fonctions d'activation sont essentielles pour introduire la non-linéarité dans le réseau de neurones. Dans ce modèle U-Net, bien que non spécifiées explicitement dans le code fourni, les couches internes utilisent généralement ReLU (RectifiedLinear Unit). ReLU est populaire pour sa simplicité et sa capacité à éviter le problème du gradient nul, ce qui accélère et stabilise l'apprentissage.

Pour la dernière couche du réseau, une fonction d'activation sigmoïde est utilisée. Elle est particulièrement adaptée aux tâches de segmentation binaire, comme ici pour la segmentation du foie, car elle permet de produire une probabilité comprise entre 0 et 1 pour chaque pixel. Cela permet de classer chaque pixel comme appartenant ou non à la classe cible (le foie), facilitant ainsi l'interprétation des résultats de sortie sous forme de masque binaire.

5.4.5 Métriques : Dice Coefficient

La métrique utilisée est le coefficient de Dice, complémentaire à la fonction de perte. Il offre une vision claire de la performance du modèle en termes de segmentation, en mesurant la similarité entre les zones segmentées et les annotations réelles.

5.4.6 Entraînement du Modèle (Epochs)

Le modèle est entraîné sur 8 et 20 époques, avec un jeu de validation défini à 20 % des données. Cette approche garantit que le modèle n'est pas simplement ajusté aux données d'entraînement, mais qu'il généralise correctement sur des données nouvelles.

Chapitre IV : Méthode proposée, Résultats et Discussion

5.4.7 Taille de Batch

Une taille de batch de 6 est utilisée, permettant un compromis entre vitesse d'entraînement et stabilité du gradient. Des batches trop petits peuvent introduire du bruit, tandis que des batches trop grands nécessitent beaucoup de mémoire.

5.4.8 Callback : ModelCheckpoint

Un callback ModelCheckpoint est intégré pour sauvegarder les poids du modèle uniquement lorsque la performance de validation s'améliore. Cela garantit la conservation du meilleur modèle rencontré pendant l'entraînement, limitant ainsi le risque de surapprentissage.

6. Implémentation du modèle de Segmentation

6.1. Préparation des données

Il est impératif de structurer les données en un ensemble cohérent de coupes représentant le volume hépatique, pour permettre au modèle U-Net d'apprendre efficacement les caractéristiques anatomiques de ce dernier (le foie). Pour y parvenir nous avons appliqué une suite de Pré-traitements sur les images sources. Nous allons maintenant détailler ces traitements étape par étape.

6.1.1 Redimensionnement des images

Les images d'entrée sont redimensionnées de 512×512 pixels à 256×256 pixels de manière à réduire la complexité computationnelle et à accélérer l'entraînement du modèle. En effet, ce redimensionnement permet de diminuer le nombre de paramètres traités par le réseau sans

Chapitre IV : Méthode proposée, Résultats et Discussion

altérer significativement les structures anatomiques d'intérêt c'est à dire diminuer le nombre de pixels traités par le réseau tout en préservant suffisamment de détails spatiaux pour que les structures anatomiques essentielles, notamment les contours du foie, restent exploitables pour la segmentation.

6.1.2 Fenêtrage centré sur le foie

Un fenêtrage est appliqué aux images dans le but de rehausser le contraste au niveau du foie. Cette opération consiste à ajuster la plage des intensités en se focalisant sur les valeurs caractéristiques du tissu hépatique, ce qui améliore la visibilité des structures pertinentes et facilite la segmentation.

6.1.3 Normalisation des intensités


Un prétraitement standard en vision par ordinateur est ensuite appliqué aux images. Celui-ci consiste à centrer les données autour de zéro, en soustrayant la moyenne, puis à normaliser les intensités par l'écart-type. Cette transformation permet de standardiser la distribution des valeurs d'intensité, ce qui favorise la stabilité numérique du modèle et accélère la convergence lors de l'entraînement du réseau de neurones convolutifs.

a) Entraînement avec la Base de données « 3Dircadb »

Dans la section suivante, nous procédons à l'entraînement du modèle de segmentation en utilisant la base de données « 3Dircadb ».

Chapitre IV : Méthode proposée, Résultats et Discussion

La figure (Figure VI.11) illustre les résultats obtenus à l'issue des différentes étapes de prétraitement mentionné ci-dessus. Ce prétraitement s'avère crucial pour uniformiser les données. En effet si on visualise les coupes abdominales couvrant le volume hépatique, on remarque une variation anatomique d'une coupe à l'autre. Il faut donc uniformiser ces informations pour permettre au réseau de détecter de manière fiable les pixels appartenant au foie.



Chapitre IV : Méthode proposée, Résultats et Discussion



Figure IV. 11 Préparation de base de données (3Dircadb) de la partie d'apprentissage de modèle U-Net.

6.2 Entraînement et validation

Dans la section suivante, nous procédons à l'ajustement des hyper paramètres, notamment le dropout et le taux d'apprentissage (Learning rate), dans le but d'améliorer la qualité de segmentation obtenue par le modèle U-Net.

Ces deux hyper paramètres jouent un rôle crucial: Learning rate conditionne la vitesse et la stabilité de l'apprentissage, tandis que le dropout agit comme un mécanisme de régularisation pour éviter le sur apprentissage, Ces réglages permettent d'équilibrer la capacité de généralisation du modèle tout en conservant une précision optimale sur la région d'intérêt.

6.2.1 Réglage des Hyper paramètre


Afin d'évaluer l'impact des hyperparamètres sur les performances du modèle, trois configurations différentes ont été testées.

Chaque cas varie selon le taux de dropout et le taux d'apprentissage de l'optimiseur Adam.

Chapitre IV : Méthode proposée, Résultats et Discussion

i. Cas 01 (Figure VI.12)

- Une couche de Dropout : Dropout (0.1)
- Optimizer=Adam (learning_rate=1e-2)



Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 12:Variation du Dice coefficient pendant le training et pendant la validation (dropout : 10%des neurones sont désactivés et Learning rate Grand) et image prédite par le model.

Analyse et Interprétation

Lors de l'entraînement initial du modèle U-Net, nous avons utilisé un taux d'apprentissage fixé à $1e-2$. Cependant, les résultats obtenus ont montré que le modèle n'apprenait pratiquement rien. En effet, les valeurs du Dice coefficient et du val_ Dice_coefficient sont restées extrêmement faibles, de l'ordre de $2.3e-05$ à $8.2e-05$, ce qui indique que la segmentation produite est équivalente à du bruit aléatoire.

Rappelons que la valeur idéale du Dice se situe au voisinage de 1, ce qui souligne ici l'absence totale de performance du modèle sur les données d'apprentissage comme de validation.

Chapitre IV : Méthode proposée, Résultats et Discussion

Par ailleurs, nous avons observé que la fonction de perte (loss) est restée bloquée autour de 1.0000, sans aucune diminution significative au fil des epochs (de la 3e à la 8e).

Ce comportement traduit une absence de convergence du modèle, et suggère que les poids et biais du réseau ne sont pas mis à jour efficacement.

Nous en déduisons que le taux d'apprentissage $lr=1e-2$ est excessif pour ce type de tâche de segmentation médicale. À cette valeur, le réseau effectue des mises à jour trop violentes dans l'espace des paramètres, sautant autour des minima locaux sans jamais les atteindre. Ce phénomène empêche toute dynamique d'apprentissage et empêche le modèle de minimiser la fonction de perte ou d'améliorer la qualité des masques prédits.

ii Cas02 (Figure VI.13)

- Une couche de Dropout : Dropout (0.1)
- Optimizer=Adam (learning_rate=1e-3)

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 13 Variation du Dice coefficient et fonction perte (loss) pendant le training et la validation (dropout : 10%des neurones sont désactivés et Learning rate moyen).

✓ Préparation de base de données de test :

Chapitre IV : Méthode proposée, Résultats et Discussion

La **Figure VI.14** illustre le prétraitement des données de test.




Figure IV. 14 Pré-traitement sur trois coupes CT abdominales à différentes profondeurs : premières sections du foie(a), partie centrale du foie(b), fin du volume hépatique(c).

La **Figure VI.15** illustre les résultats de segmentation dans la partie de test.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 15 Résultats de segmentation avec U-Net (avec le meilleur ajustement d'hyper paramètres)

Chapitre IV : Méthode proposée, Résultats et Discussion

6.3 Interprétation des résultats

6.3.1 Performance du modèle

- Le Dice coefficient atteint **0.97**, preuve que le modèle apprend très bien la structure du foie sur l'ensemble d'entraînement.
- Le validation_Dice coefficient monte jusqu'à **0.92 (ép. 17)** puis redescend légèrement (**~0.90**), ce qui indique :
 - Bonne capacité de généralisation
 - Mais début de sur apprentissage au-delà de l'époque 15–17

6.3.2 Impact du Learning_rate (LR) de $1e-3$

- Ce taux d'apprentissage constitue un choix pertinent pour U-Net, car il a permis d'obtenir des performances satisfaisantes :
 - Une convergence rapide et stable
 - Évite les oscillations ou stagnations observées avec un LR trop grand ou trop petit
- La montée fluide de Dice coefficient (et validation_Dice coefficient) valide que l'optimisation est bien réglée.

6.3.3 Impact du dropout = 0.1

- Dropout faible (10%) :
 - Assez bas pour ne pas ralentir l'apprentissage
 - Suffisant pour limiter le sur apprentissage léger observé après l'époque 17

Chapitre IV : Méthode proposée, Résultats et Discussion

iii Cas03 (Figure VI.15)

- Une couche de Dropout : Dropout (0.2)
- Optimizer=Adam (learning_rate=1e-3)



Figure IV. 16 Variation du Dice coefficient pendant le training et pendant la validation (dropout : 20%des neurones sont désactivés et Learning rate moyen avec 8 Epoch d'entraînement).

La Figure VI.17 illustre les résultats de segmentation.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 17 Résultats de segmentation avec U-Net (partie test), Dropout=0.2 (20% des neurones sont désactivés)

Discussion

Avec un dropout fixé à 0.1, le modèle U-Net atteint une segmentation plus précise et fidèle de la région d'intérêt (ROI), en limitant l'inclusion de structures indésirables. On remarque à titre comparatif, qu'un dropout de 0.2 détériore légèrement la qualité en introduisant des zones parasites issues d'organes adjacents. Cela montre que, dans ce cas, une régularisation trop forte nuit à la précision anatomique. Le choix du dropout doit donc équilibrer robustesse et fidélité des contours.

Nous avons donc retenu un Dropout de **0.1**, permettant de régulariser légèrement le modèle sans compromettre la précision de segmentation, et un Learning rate de $1e-3$, considéré comme un compromis optimal entre vitesse de convergence et stabilité de l'apprentissage.

Chapitre IV : Méthode proposée, Résultats et Discussion


Ces hyper paramètres ont été choisis après plusieurs essais empiriques visant à maximiser la qualité des résultats tout en assurant une bonne généralisation.

b) Entraînement avec la Base de données « Task03_Liver »

A présent on s'intéresse à l'entraînement du modèle de segmentation en utilisant la base de données « Task03_Liver »

Préparation des données d'apprentissage :

La **Figure VI.18** illustre les résultats de prétraitement des données d'apprentissage de ModèleU-Net.



Chapitre IV : Méthode proposée, Résultats et Discussion



Figure IV. 18 Préparation de la base de données *Task03_Liver* pour l'apprentissage du modèle U-Net

La configuration du modèle est un taux d'apprentissage fixé à 10^{-3} , un choix équilibré pour assurer une convergence stable et rapide, une couche de dropout =0.1 et un nombre d'époques (epochs) de 20, permettant au modèle de s'entraîner sur plusieurs itérations tout en évitant le surapprentissage. Enfin, la taille des batchs est de 6, ce qui favorise une bonne utilisation de la mémoire et un apprentissage stable.

Les Figures **VI.17** et **VI.18** illustrent les résultats de test du modèle de segmentation obtenus sur diverses coupes du volume hépatique et avec le réglage optimal des hyperparamètres, comme mentionné ci-dessus.

Chapitre IV : Méthode proposée, Résultats et Discussion





Figure IV. 19 Résultats de segmentation (partie test) des images CTabdominales (premières coupes du volume hépatique avec un ajustement optimal des hyper paramètres).



Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 20 Résultats de segmentation (partie test) des images CT abdominales (les dernières coupes du volume hépatique et ajustement optimal des hyper paramètres).

c) Entraînement avec les Bases de données combinées « *Task03_Liver* » et « *3Dircadb01CT* »

Le but de cette section est de viser la généralisation du modèle U-Net c'est-à-dire pour qu'il réussisse à segmenter correctement des données nouvelles (jamais vues pendant l'entraînement), après un prétraitement de données d'apprentissage et par la suite l'apprentissage du modèle.

Dans un premier temps nous allons utiliser la configuration qui nous a donné les meilleurs résultats qualitatifs et quantitatifs (meilleur Dice _ coefficient). La figure VI.19 illustre les tracés de Dice coefficient et validation Dice après 8 epochs:

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 21 Variation du Dice coefficient pendant l’entraînement et pendant la validation (dropout : 10%des neurones sont désactivés et Learning rate moyen avec 8 Epoch d’entraînement).

Après la diminution du Dice de validation, une couche de Batch Normalisation a été intégrée afin d’améliorer la stabilité et la convergence du réseau. La figure VI.20 illustre les tracés de Dice coefficient et validation Dice après 20 epochs.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 22 Variation du Dice coefficient pendant l'entraînement et pendant la validation (dropout : 10%des neurones sont désactivés, Learning rate moyen, Batch Normalisation avec 20 Epochs d'entraînement).

- **Remarque :**

À chaque époque, le modèle U-Net ajuste ses poids et ses biais de manière à minimiser la fonction de perte, à travers la rétro propagation. Il est important de noter que la performance ne suit pas nécessairement une progression monotone : par exemple, un modèle peut atteindre un Dice coefficient de 0.55 à l'époque 12, puis redescendre à 0.50 à l'époque 13, en raison d'un sur apprentissage ou de la variabilité des données. Ainsi, il est essentiel de sauvegarder

Chapitre IV : Méthode proposée, Résultats et Discussion


automatiquement le modèle correspondant à la meilleure performance de validation, généralement sous forme de fichier .h5 pour garantir la meilleure généralisation possible.

7. Résultats de Segmentation

Dans cette section, nous procédons au test du modèle de segmentation en utilisant la base de données « *HepaticVessel* »


La configuration du modèle est comme suit après 20 Epochs d'entraînement le modèle U-Net (**Figure IV.6**) de base avec des couche dropout : 10% des neurones sont désactivés, Learning rate moyen, et couche de Batch Normalisation, nous sauvegardons automatiquement le modèle correspondant à la meilleure performance de validation, puis nous l'utilisons pour segmenter automatiquement les coupes représentant le volume hépatique.

Les résultats ainsi obtenus sont illustrés dans **la Figure VI.23** sur diverses coupes abdominales. On constate, in-visu, que malgré la complexité des structures anatomiques et de leurs différences d'une coupe à l'autre le modèle parvient à segmenter correctement le foie.




a. Images CT originales

Chapitre IV : Méthode proposée, Résultats et Discussion



b. Images CT après prétraitement



c. Images Segmentées

Figure IV. 23 Test de la Segmentation du foie par le modèle U-Net sur différentes coupes abdominales

8. Analyse quantitative des résultats & Discussion

8.1 Les critères d'évaluations

En segmentation d'images, chaque pixel peut être correctement ou incorrectement classé : on parle alors de vrais positifs (TP), faux positifs (FP), faux négatifs (FN) et vrais négatifs (TN). Ces quatre catégories (**Figure VI.24**) permettent de calculer des indicateurs clés, connus sous le nom de critères d'évaluations. Chacun de ces critères donne une indication sur la performance du modèle. Les critères réunis sont complémentaires et indiquent la performance globale du modèle.

Chapitre IV : Méthode proposée, Résultats et Discussion

Nous allons définir les éléments fondamentaux de mesure de performances.

8.2.1 Définitions de TP, TN, FP, FN en segmentation

- **True Positive (TP) – Vrai Positif**

Un pixel est considéré comme TP si le modèle prédit la classe « positif », et que le masque de vérité terrain contient également ce pixel comme « positif ». Ce sont les pixels correctement segmentés dans la région d'intérêt.

- **False Positive (FP) – Faux Positif**

Un FP correspond à un pixel que le modèle a prédit comme appartenant à la région cible, mais qui est absent dans le masque de référence, en d'autres termes, ce sont les zones faussement détectées comme positives.

- **False Negative (FN) – Faux Négatif**

Un FN est un pixel qui devrait faire partie de la segmentation (présent dans le masque de vérité terrain) mais que le modèle a ignoré ou mal classé. Cela signifie que le modèle a raté une partie de la zone cible.

- **True Negative (TN) – Vrai Négatif**

Un pixel est TN lorsqu'il est correctement identifié comme négatif, c'est-à-dire qu'il est absent à la fois dans la prédiction du modèle et dans la vérité terrain. Cela concerne les zones de fond correctement ignorées.

La figure VI.22 illustre les notions de TP, TN, FP, FN

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 24 Illustration imagée des notions de TP, FP, FN, TN.

8.2.2 Définitions des critères d'évaluations de la segmentation des images médicales par un modèle d'apprentissage profond

Dice Coefficient

Chapitre IV : Méthode proposée, Résultats et Discussion

Le coefficient de Dice est une métrique de similarité utilisée pour évaluer la qualité de segmentation. Il mesure le chevauchement entre la prédiction et le masque de vérité terrain. Il est défini par :

$$\text{Dicecoefficient} = \frac{2 \times TP}{FN + (2 \times TP) + FP} \text{ (équation IV. 1)}$$

Un score de 1 indique un chevauchement parfait. Cette métrique est particulièrement adaptée aux tâches médicales où l'équilibre entre faux positifs et faux négatifs est crucial.

Loss (fonction de perte)

La fonction de perte mesure la différence entre la sortie du modèle et la vérité terrain. Dans le cas du Dice, est souvent définie comme :

$$LOSS = 1 - \text{Dice coefficient} \text{ (équation IV. 2)}$$

Minimiser cette perte revient donc à maximiser le Dice coefficient. Elle guide l'optimisation du modèle.

Sensitivity (sensibilité)

La sensibilité mesure la capacité du modèle à détecter les vrais positifs. Elle est donnée par :

$$\text{Sensitivity} = \frac{TP}{TP + FN} \text{ (équation IV. 3)}$$

Elle est cruciale dans les contextes chirurgicaux assistés par l'image, où rater une structure anatomique ou une lésion critique peut compromettre la précision de l'acte opératoire. Par exemple, une faible sensibilité dans la segmentation du foie ou d'une tumeur hépatique

Chapitre IV : Méthode proposée, Résultats et Discussion

pourrait conduire à une résection incomplète ou à une atteinte involontaire de tissus sains. Une détection exhaustive est donc essentielle pour garantir la sécurité et l'efficacité de l'intervention.

- **Spécificity (spécificité)**

La spécificité mesure la proportion de vrais négatifs bien identifiés tel que :

$$\text{Specificity} = \frac{TN}{FP+TN} \text{ (équation IV. 4)}$$

- **Accuracy (exactitude)**

L'accuracy (exactitude) mesure la proportion globale de bonnes prédictions tel que :

$$\text{Accuracy} = \frac{TP+TN}{(TP+TN+FP+FN)} \text{ (équation IV. 5)}$$

Bien que populaire, elle peut être trompeuse si les classes sont déséquilibrées, comme c'est souvent le cas en segmentation binaire.

- **La précision**

La précision indique la proportion de vraies détections parmi toutes les zones détectées. Elle est donnée par :

$$\text{Precision} = \frac{TP}{TP+FP} \text{ (équation IV. 6)}$$

- **Volumetric Similarity (VS)**

Le Volumetric Similarity mesure la proximité des volumes entre la prédiction et la vérité terrain, sans tenir compte de leur position spatiale. Elle est donnée par :

$$\text{VolumetricSimilarity} = 1 - \frac{|FN-FP|}{(2 \times TP + FP + FN)} \text{ (équation IV. 7)}$$

Une valeur proche de 1 indique que le modèle a segmenté un volume équivalent à celui du foie réel. Il indique si la quantité de pixels segmentés est similaire, même si certains sont mal localisés.

Chapitre IV : Méthode proposée, Résultats et Discussion

- **La matrice de confusion pixel-wise**

La **Figure IV.25** représente la matrice de confusion pixel-wise obtenue après la segmentation du foie à l'aide d'un modèle U-Net. La segmentation atteint un Dice coefficient de 0.98, ce qui indique un chevauchement quasi parfait entre la prédiction et le masque de vérité terrain.




Figure IV. 25 Matrice de confusion.

Cette matrice confirme que le modèle est à la fois précis (faibles FP) et sensible (faibles FN), deux qualités indispensables en imagerie médicale.

Le modèle a appris comme suit :

Chapitre IV : Méthode proposée, Résultats et Discussion

- Pixel prédit région foie et est réellement de la région foie : 22475 pixels.
- Pixel prédit région fond et est réellement région fond : 43011 pixels.
- Pixel prédit région fond et est réellement région foie : 25 pixels.
- Pixel prédit région foie et est réellement région fond : 25 pixels

8.3 Evaluation du modèle de segmentation

Afin d'évaluer de manière quantitative les performances du modèle de segmentation, plusieurs métriques ont été calculées.

Ces indicateurs permettent de mesurer la précision, la sensibilité, la similarité volumique ainsi que la qualité globale des segmentations obtenues.

La **Figure IV.26** illustre le tracé des valeurs calculées pour chaque métrique d'évaluation, permettant de visualiser les performances globales du modèle de segmentation.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 26 Tracé des valeurs des métriques d'évaluation du modèle de segmentation

Afin d'évaluer la méthode proposée, nous avons choisi la métrique Dice Similarity Coefficient (DSC) qui mesure le degré de similarité entre les segmentations prédites et les annotations de référence. Ce qui nous a permis de comparer nos résultats avec ceux de **YiZang et al** ,Cette équipe de recherche a travaillé sur le même base de données **3D-IRCADb** mais également sur la base **LiTS 2017**.

La **Figure VI.27** illustre la comparaison des différentes méthodes de segmentation en fonction de leur performance mesurée par le Dice Similarity Coefficient (DSC), mettant en évidence la supériorité de la méthode proposée.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 27 Comparaison des méthodes de segmentation de différents chercheurs sur la base du Dice Similarity Coefficient (DSC)

8.4 Evaluation de la Segmentation sur la base de l'annotation de Couinaud

Après la segmentation du foie à l'aide du modèle U-Net, une évaluation a été réalisée en confrontant les résultats obtenus avec les annotations manuelles des segments de Couinaud, fournies par un expert médical. Ces annotations incluent à la fois le parenchyme hépatique et les structures vasculaires intra-hépatiques.


Les images annotées, intitulées « Segments et annotations de Couinaud », sont issues du dépôt associé à la publication '*Anatomical-Aware Point-Voxel Network for Couinaud Segmentation*

Chapitre IV : Méthode proposée, Résultats et Discussion

in Liver CT’, présentée à la conférence MICCAI 2023. Ces images représentent les annotations des segments hépatiques selon la classification de Couinaud (xukun-zhang, 2023)

Une étape de superposition (overlay) entre les coupes du foie segmenté automatiquement comme vu précédemment à partir des coupes CT abdominales (parenchyme et vaisseaux hépatiques) et l’annotation experte a été réalisé.

La **figure VI.28** représente la superposition du foie extrait sur l’une des coupes CT à l’annotation de l’expert qui divise le foie en segments de Couinaud.



(a) (b) (c)

Figure IV. 28 Contours anatomiques des segments de Couinaud superposés à l’image segmentée
(a) Foie segmentée à partir des coupes CT abdominales
(b) Annotation de Couinaud
(c) Superposition

Les résultats obtenus ont montré une bonne précision dans la délimitation des segments de Couinaud, en particulier au niveau du parenchyme. Toutefois, certaines limitations ont été observées au niveau de la segmentation vasculaire. Rappelons que l’Algorithme que nous

Chapitre IV : Méthode proposée, Résultats et Discussion

avons présenté en Figure IV.1 permet d'Extraire les vaisseaux hépatiques par simple seuillage basé sur les unités de Hounsfield.

A présent et compte tenu de cette limitation, une analyse plus poussée est réalisée, celle des composantes connexes à 8-voisins. Cette approche permet d'extraire efficacement les structures vasculaires en s'appuyant sur leur intensité distincte (en particulier après injection de produit de contraste) et leur continuité spatiale.

Chaque composante connexe peut ensuite être visualisée avec une couleur distincte, de manière similaire à une classification de type K-means. Cette méthode est particulièrement adaptée aux vaisseaux hépatiques en raison de leur forme tubulaire et de leur intensité généralement bien marquée dans les images contrastées. Cette segmentation est très intéressante car elle permet de visualiser distinctement les segments vasculaires, e qui représente un apport précieux d'information pour la planification pré-opératoire de la chirurgie hépatique.

La **figure IV.29** représente, la superposition des vaisseaux hépatiques extraits par cette nouvelle approche à l'annotation de l'expert.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 29 Contours anatomiques des vaisseaux de Couinaud superposés à l'image des vaisseaux segmentée en régions connexes.

(a) Vaisseaux segmentée en région connexes

(b) Annotation par l'expert des vaisseaux selon les segments de Couinaud

(c) Superposition.

Une analyse visuelle de l'image de superposition de **la figure IV.29** nous permet d'affirmer la puissance relative de notre segmentation vasculaire basée sur les composantes connexes. En effet, bien que les gros vaisseaux soient correctement segmentés, ce qui est très encourageant et très prometteur pour une reconstruction 3D idéale, on constate cependant, une insuffisance au niveau des petits vaisseaux, notamment ceux visibles uniquement sur quelques coupes fines. En conséquence, certaines branches vasculaires n'ont été que partiellement segmentées et apparaissent donc fragmentées lors de la reconstruction 3D (session suivante). Cette perte d'information est principalement liée à la taille réduite des vaisseaux périphériques, au faible contraste local, ainsi qu'aux limites de la connectivité 3D lorsqu'une branche n'est pas suffisamment représentée en volume pour être identifiée comme une composante connexe complète.

Chapitre IV : Méthode proposée, Résultats et Discussion

En conclusion, les résultats obtenus montrent que la méthode proposée permet une segmentation précise des structures vasculaires hépatiques, avec une bonne cohérence topologique par rapport au segment anatomique définis selon Couinaud.

Cette validation visuelle et anatomique prédit un nouveau potentiel d'application clinique de l'approche développée celui de la segmentation détaillée du foie et en conséquence, une reconstruction et visualisation 3D détaillée également. En d'autres termes nous aurons un outil de planification chirurgicale qui visualise les différents segments hépatiques ainsi que leurs systèmes vasculaires avec différentes couleurs permettant au chirurgien de choisir judicieusement et toute sécurité, le volume d'exérèse que ce soit pour un greffon ou une tumeur. Il s'agit là d'un projet en perspective, le projet actuel ne différencie ni les segments de Couinaud ni les différentes branches de l'arbre vasculaire lors de la reconstruction 3D.

9. Reconstruction 3D du foie

Dans le cadre de cette étude, une approche de reconstruction volumique 3D a été mise en œuvre afin de visualiser le foie humain et son réseau vasculaire à partir de données d'imagerie médicale 2D (coupes axiales CT ou IRM).

Rappelons que dans un premier temps, la segmentation du foie a été réalisée à l'aide d'un modèle U-Net, permettant d'extraire automatiquement la région d'intérêt (ROI) correspondant au parenchyme hépatique. Cette étape est essentielle, car les images CT abdominales contiennent de nombreux organes voisins présentant des intensités similaires, rendant la segmentation directe des vaisseaux moins précise.

Chapitre IV : Méthode proposée, Résultats et Discussion

Une fois le foie segmenté, les différentes coupes 2D ont été concaténées pour reconstituer un volume 3D du foie. À partir de ce volume, une reconstruction des structures vasculaires a été effectuée à l'aide de l'algorithme Marching Cubes. Celui-ci permet d'extraire une isosurface à partir du volume segmenté, générant ainsi une représentation 3D du foie et de son réseau vasculaire. Cette approche permet d'obtenir une visualisation réaliste et précise des vaisseaux intra-hépatiques tout en limitant les interférences dues aux structures anatomiques adjacentes (figure VI.30).




Figure IV. 30 Schéma descriptif de la Reconstruction 3D du foie et des vaisseaux hépatiques.

La figure IV.31 illustre l'étape de concaténation des coupes segmentées.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 31Concaténation des coupes ct abdominal segmentées représentant un foie humain.

L'étape suivante est la reconstruction 3D à l'aide de l'algorithme Marching Cubes. Cet algorithme largement reconnu en imagerie médicale, permet de reconstruire une isosurface à partir de données volumiques en identifiant des seuils d'intensité spécifiques.

Cette méthode présente plusieurs avantages majeurs : elle produit des surfaces triangulées précises et continues à partir de données brutes, elle est indépendante de la résolution des images originales, et elle permet une visualisation intuitive des structures internes complexes.

L'intégration de pipeline « PyVista » de Python permet une reconstruction fiable, rapide et adaptable de données médicales en 3D, sans dépendre de solutions logicielles propriétaires. Cela favorise non seulement la reproductibilité scientifique, mais ouvre également la voie à des traitements avancés en imagerie médicale ou la simulation chirurgicale

Chapitre IV : Méthode proposée, Résultats et Discussion

Afin de guider la segmentation des structures anatomiques dans les volumes 3D, il est essentiel d'analyser la distribution des intensités dans l'image. Cette section présente la notion d'isovalue, ainsi que l'interprétation de l'histogramme des intensités (**Figure VI.32**), permettant d'identifier les seuils caractéristiques associés aux différentes structures, telles que le parenchyme hépatique ou ses vaisseaux.




Figure IV. 32 Histogramme des intensités du volume segmenté.

- En extrayant une isosurface correspondant à une Isovaleur donnée, il est possible de générer un maillage triangulaire qui représente fidèlement la structure anatomique segmentée
- Une isovalue désigne une valeur d'intensité caractéristique utilisée pour la visualisation d'une structure anatomique dans un volume 3D (ex. scanner ou IRM).

Chapitre IV : Méthode proposée, Résultats et Discussion

- Elle sert de seuil d'intensité : tous les voxels ayant une intensité égale ou supérieure à cette valeur sont considérés comme appartenant à la structure cible (ex. : foie, vaisseaux).
- L'histogramme des intensités du volume segmenté permet de repérer visuellement les isovalues candidates. Selon la figure VI.32 :
 - ✓ Les pics dans l'histogramme indiquent les zones où les intensités sont les plus fréquentes.
 - ✓ Le pic autour de 0.3 correspond au foie, compte tenu de son intensité moyenne faible (foie sombre en comparaison avec les vaisseaux) suggérant la valeur 0.3 comme intensité moyenne typique pour cette structure (le foie).
 - ✓ Le pic autour de 0.6 correspond aux vaisseaux hépatiques, ce pic représente leur intensité caractéristique.

Dans ce projet, deux seuils ont été choisis empiriquement pour extraire respectivement le foie et les vaisseaux.

Nous avons reconstruit aussi bien des foies sains que des foies pathologiques.

La figure IV.33 illustre des visualisations 3D sous différents angles de vue d'un foie humain sain après reconstruction avec l'algorithme Marching cubes.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 33 Visualisation 3D d'un foie humain segmenté puis Reconstruit avec l'algorithme Marching Cubes.




Figure IV. 34 Visualisation 3D du système vasculaire d'un foie humain segmenté puis Reconstruit avec l'algorithme Marching Cubes.

D'autre part et bien que nous ne l'ayons pas souligné lors de la phase de segmentation automatique par Deep Learning des coupes 2D abdominales, la segmentation du foie met en évidence les pathologies tel que les tumeurs. A l'instar de l'extraction des vaisseaux, il est donc facile de délimiter ces zones pathologiques. La figure IV.35 illustre des visualisations des coupes de foie segmentée mettant en évidence une tumeur hépatique.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 35 Foie segmentée à partir des coupes CT abdominale avec présence de tumeurs

Dans cette nouvelle situation (présence d'une pathologie) l'analyse de l'histogramme des intensités précédant l'application de l'algorithme Marching cube, est-elle aussi différente (Figure VI.36).




Figure IV. 36 Histogramme des intensités du volume hépatique malade.

Après analyse des pics de l'histogramme, nous remarquons que :

L'isovaleur du tissu hépatique est de 0.5

L'isovaleur des vaisseaux hépatiques est de 0.6

L'isovaleur des tissus cancéreux est de 0.1

La figure VI.37 illustre la visualisation 3D d'un foie humain malade après segmentation puis reconstruction 3D par marching cubes. De même que pour le foie sain, nous représentons dans la figure VI.38, le système vasculaire en 3D du foie malade.

Chapitre IV : Méthode proposée, Résultats et Discussion




Figure IV. 37 Visualisations 3D après Reconstruction 3D par L'algorithme Marching Cubes d'un foie humain malade segmenté.




Figure IV. 38 Visualisations 3D, après Reconstruction 3D avec L'algorithme Marching Cubes, de l'arbre vasculaire d'un foie humain malade mettant en évidence les zones tumorales.

Chapitre IV : Méthode proposée, Résultats et Discussion

10. Conclusion

Dans ce chapitre nous avons exposé puis détaillé notre algorithme de reconstruction 3D du foie et de son réseau vasculaire, travail qui s'inscrit dans une dynamique d'assistance préopératoire, visant à fournir aux chirurgiens une visualisation personnalisée, précise et en trois dimensions de l'un des organes les plus complexes à appréhender en chirurgie. L'étape la plus importante de cet algorithme est l'extraction du foie à partir des coupes CT abdominales. Nous avons vu que la segmentation par apprentissage profond (Deep Learning, DL) et en particulier avec le modèle U-Net est une solution potentielle car ce modèle a la capacité à effectuer une segmentation précise au niveau du pixel. Nous avons expliqué en détail son fonctionnement. Nous l'avons entraîné avec deux bases de données : « Task03_Liver » et « 3Dircadb01 ». Nous avons configuré notre modèle avec un choix équilibré du taux d'apprentissage pour assurer une convergence stable et rapide, une couche de dropout et un nombre d'époques convenablement choisi permettant au modèle de s'entraîner sur plusieurs itérations tout en évitant le surapprentissage et une taille de batchs favorisant une bonne utilisation de la mémoire et un apprentissage stable. Nous avons testé notre modèle sur la base de données Task08_hepaticvessel, les résultats de la segmentation sont très satisfaisants et sont confirmés avec les métriques d'évaluation. Ces derniers, en particulier le Dice Similarity Coefficient, nous ont permis de comparer nos résultats avec ceux de la littérature. La deuxième grande étape de notre travail est la reconstruction 3D, elle fut réalisée à l'aide de l'algorithme Marching Cube et a produit des résultats visuellement convaincants que ce soit pour la reconstruction du foie sain ou du foie malade.

Nous avons également abordé, dans le but d'évaluer la qualité de la segmentation du foie, la superposition de nos résultats avec les annotations manuelles des segments de Couinaud. Ce

Chapitre IV : Méthode proposée, Résultats et Discussion

nouveau travail nous a révélé une relative insuffisance dans la détection des petits vaisseaux et nous a permis d'entreprendre une amélioration de détection de ces derniers par une l'approche basée sur les composantes connexes. La méthode proposée permet une segmentation précise des structures vasculaires hépatiques, avec une bonne cohérence topologique par rapport au segment anatomique définis selon Couinaud. Cette validation prédit un meilleur potentiel d'application clinique de l'approche développée, permettant de visualiser en 3D pour chaque patient et de manière différenciée les VII segments hépatiques ainsi que leurs vascularisations.

CONCLUSION GENERALE

Conclusion générale

Ce travail de thèse s'inscrit dans le cadre des avancées technologiques appliquées à la chirurgie assistée par ordinateur, et plus particulièrement dans le domaine de la planification chirurgicale hépatique. Il répond à un besoin croissant d'outils numériques performants permettant d'assister les cliniciens dans la prise de décision préopératoire, en proposant une représentation tridimensionnelle personnalisée, précise et exploitable du foie humain, un organe à la fois complexe dans sa morphologie, sa vascularisation et ses fonctions.

L'approche adoptée dans cette recherche a été résolument pluridisciplinaire, à l'interface entre les sciences médicales et l'intelligence artificielle, mobilisant des connaissances en anatomie, en physiopathologie hépatique, en imagerie médicale, ainsi qu'en vision par ordinateur et en apprentissage profond. Ce croisement des disciplines a permis de concevoir un pipeline complet de traitement de données tomodensitométriques, allant de la segmentation automatique des structures anatomiques à leur reconstruction 3D interactive.

L'algorithme développé combine plusieurs techniques avancées : la segmentation automatique du foie par un réseau de neurones convolutif de type U-Net, le seuillage d'intensité basé sur l'échelle de Hounsfield pour l'identification des structures vasculaires, et la reconstruction de surface via l'algorithme Marching Cubes. Cette méthode a démontré des performances robustes et reproductibles, validées quantitativement par des métriques standards telles que le Dice Similarity Coefficient et la fonction de perte (Loss), attestant d'une excellente adéquation entre la segmentation automatisée et les données de référence. L'approche s'est montrée particulièrement efficace pour traiter les volumes 3D de manière

CONCLUSION GENERALE

coupe-à-coupe tout en assurant une cohérence spatiale inter-tranches, élément critique pour une exploitation clinique.

Les résultats obtenus constituent une avancée significative par rapport aux méthodes classiques de segmentation manuelle ou semi-automatique, en réduisant considérablement le temps de traitement, tout en augmentant la précision et la reproductibilité. Le modèle proposé est également robuste aux variabilités inter-patients et à l'hétérogénéité des images issues de protocoles d'acquisition différents, ce qui renforce son potentiel de généralisation.

Cependant, plusieurs limites ont été identifiées. D'une part, la détection fine des vaisseaux de petit calibre reste imparfaite, notamment en raison des limites du double seuillage utilisé pour extraire l'arbre vasculaire. D'autre part, la segmentation ne permet pas encore une différenciation fonctionnelle entre les structures vasculaires : artères hépatiques, veines portes, veines sus-hépatiques, ce qui limite certaines applications chirurgicales avancées comme la cartographie fonctionnelle segmentaire selon Couinaud. Ces limites orientent naturellement les perspectives de recherche vers des approches plus raffinées, incluant la segmentation par régions connexes, l'apprentissage supervisé sur des bases annotées plus riches ou encore l'intégration de modèles de vascularisation hépatique plus physiologiquement réalistes.

À court terme, la poursuite du développement passera par l'entraînement de modèles plus spécialisés à partir de bases de données annotées selon la classification de Couinaud, permettant d'identifier précisément les segments hépatiques et d'adapter la planification à chaque anatomie individuelle. À moyen terme, l'intégration d'un module de simulation opératoire avec retour haptique, couplé à l'environnement de visualisation 3D, ouvrira la voie

CONCLUSION GENERALE

à un véritable simulateur chirurgical, outil pédagogique et clinique à la fois. Enfin, à plus long terme, une validation en situation réelle par des essais cliniques multicentriques sera indispensable pour évaluer l'impact de cette technologie sur les résultats post-opératoires, en particulier dans les contextes complexes comme la greffe hépatique à partir de donneur vivant ou l'exérèse tumorale à visée curative.

En définitive, cette thèse apporte une contribution originale et méthodologiquement rigoureuse à la problématique de la modélisation 3D des structures hépatiques, en exploitant les capacités récentes de l'intelligence artificielle pour répondre à un besoin clinique réel. Elle constitue une base scientifique solide pour le développement de futures applications en chirurgie guidée par image, et ouvre également des perspectives vers d'autres organes et d'autres contextes cliniques, dans une logique de médecine personnalisée, prédictive et assistée par les technologies numériques.

BIBLIOGRAPHIE

Bibliographie

- A. Mostafa, M. A.-H. (2015). Region Growing Segmentation with Iterative K-means for CT Liver Images. " 2015 4th International Conference on Advanced Information Technology and Sensor Application (AITS),, (pp. 88-91). Harbin, China, 2015.
- A. Paisant, K. B. (2018). Imaging in the assessment and follow-up of the liver transplant. *Journal d'imagerie diagnostique et interventionnelle* , Volume 1, Issue 5, Pages 319-337.
- AbdelazizDaoudi. (2015, 06). Segmentation des régions d'intérêts dans des images médicales. telemcen, Université Abou Bekr Belkaid,Faculté des Sciences,Département Informatique, Algeria.
- Adly, E. A. (2022). Multi-detector High Resolution CT of Interstitial Lung Disease: Role of Different Post Processing Imaging Techniques. Department of Radiology, El-Minia Faculty of Medicine: MJMR.
- Aishwarya, K. A. (2025). A survey on comparative study of lung nodules applying machine learning and deep learning techniques. *Multimed Tools Appl* , 84, 2127–2181.
- Akyildiz Beyza, O. C. (2024-01-01). Graph Cuts in Image Segmentation: A Review. *International Conference on Information Technologies and Their Applications (ITTA 2024)* .
- Amber L. Simpson, M. A. (2019). A large annotated medical dataset for the development and evaluation of segmentation algorithms. *cs.CV eess.IV* , 1902.1902.
- Amina Benahmed, K. K. (2024). A whole 3D liver reconstruction for personalised preoperative surgery based on FCN U-net model segmentation. *Int. J. Biomedical Engineering and Technology* , Vol. 44, No. 2, pp 103-119.
- Araújo, J. D. (2022). Liver segmentation from computed tomography images using cascade deep learning. *Computers in Biology and Medicine* , Volume 140.
- BABA, I. (2022). *Rôles des cellules de Kupffer dans la physiopathologie*. France: Maladies infectieuses, Sorbonne Université.
- BELHADJ, F. (2009). *RECONSTRUCTION TRIDIMENSIONNELLE A PARTIR DE COUPES SERIEES Application aux Images Médicales*. algeria: UNIVERSITE * MOHAMED BOUDIAF * DE M'SILA FACULTE DES SCIENCES ET SCIENCES DE L'INGENIEUR DEPARTEMENT D'INFORMATIQUE.
- Ben-Cohen, A. &. (2016). *Fully Convolutional Network for Liver Segmentation and Lesions Detection*. Récupéré sur [10.1007/978-3-319-46976-8_9](https://doi.org/10.1007/978-3-319-46976-8_9)
- Berkache, S. B. (2013, 12 /4). Reconstruction 3D surfacique du fémur proximal à partir de quelques radiographies. Français, laboratoire PRISME, Orléans.
- Bischof, R. A. (1994). Seeded Region Growing. (pp. Vol. 16, pp. 641-647). IEEE Transactions On Pattern Analysis and Machine Intelligence.
- Blanc JF, B. J. (2015). «Carcinome hépatocellulaire». Récupéré sur <http://www.tncd.org>

BIBLIOGRAPHIE

BOUDRAA, O. (2022). Segmentation of 3D Dental Images Using Deep learning . *arXiv* , 2207.09582V1.

Bouhlel, W. A. (2009). "Reconstruction 3D des Images Médicales par Utilisation de l'Algorithme « Marching Cubes » ". *presented at the Sciences of Electronic Technologies of Information and Telecommunications Tunisie* .

BRANDOU, V. (2008). Stéréovision Locale et Reconstruction 3D/4D. ,Automatique, Traitement du Signal et des Images,l'Université de Nice-Sophia Antipolis.

CNRS, B. N. (2002). *Imagerie Médicale 3D Visualisations, segmentations et reconstructions*. – CNRS.

Colnet, A. d. (2024, 08 22). NASH : quelle est cette « maladie du foie gras » ? Quels sont ses symptômes et son traitement ? Pharma GDD.

danielilett. (2020, 03 28). *2D Metaballs and Custom Post Process in Unity URP ,Flaunting a fast fluid simulation technique*.Récupéré sur daniel ilett: <https://danielilett.com/2020-03-28-tut5-2-urp-metaballs/>

Dominik Müller, F. K. (2021). a framework for medical image segmentation with convolutional neural networks and deep learning. *BMC Med Imaging* 21 , Volume 21, article number 12,<https://doi.org/10.1186/s12880-020-00543-7>.

Dr. E. Vibert. (2014). *centre-hepato-biliaire paul Brousse*. Récupéré sur cancers du foie et du pancréas » Carcinome hépatocellulaire (CHC): <https://www.centre-hepato-biliaire.org/maladies-foie/cancers-foie/carcinome-hepatocellulaire/diagnostic-chc.html>

Ehsani Rad, A. &. (2017). Morphological region-based initial contour algorithm for level set methods in image segmentation. (pp. 76. 10.1007/s11042-015-3196-y). *Multimedia Tools and Applications*.

EL Serag, H. (2007). *Gastroenterology*.

Esteves, S. C. (2024). Segmentation des vaisseaux sanguins par approche variationnelle et apprentissage profond. Français: Bio-informatique [q-bio.QM]. Université Clermont Auvergne.

F. BEN-BOUALLEGUE, D. M.-G. (2017). RECONSTRUCTION TOMOGRAPHIQUE. *Université à Montpellier, France* .

F. Brunelle, P. B. (2019). Intelligence artificielle et imagerie médicale : définition, état des lieux et perspectives,. *Bulletin de l'Académie Nationale de Médecine* , Volume 203, Issues 8–9.

Farah, F. (2021, 6 ,30). Reconstruction hiérarchique 3D pour la visualisation volumique et surfacique. 30. Biskra, Informatique, Algeria.

Fei Tong, M. N. (2020). X-ray2Shape: Reconstruction of 3D Liver Shape from a Single 2D Projection Image. *IEEE* , 1608.

ferlay J, h. H. (2010). Estimate of world wide burden of cance 2008. *GLOBOCAN 2008,Int j cancer* .

BIBLIOGRAPHIE

- Fischer, L., Cardenas, C., Thorn, M., Benner, A., Grenacher, L., Vetter, M., et al. (November 2002.). Limits of Couinaud's Liver Segment Classification: A Quantitative Computer-Based Three-Dimensional Analysis. *Journal of Computer Assisted Tomography* , 26(6):p 962-967, .
- Flavien Bessaguet, A. D. (2021). *Le foie*. France: Faculté de pharmacie.
- George Noussios, I. D. (2017). The Main Anatomic Variations of the Hepatic Artery and Their Importance in Surgical Practice: Review of the Literature. *J Clin Med Res* , PMID: 28270883; PMCID: PMC5330766.
- Gérard Abadjian, G. (2008). *HISTOLOGIE DU FOIE ET DU PANCREAS*.
- Gilgenkrantz, H. (2022). The liver remains a young organ even in old age. *Med Sci* , Paris.
- HABIB, B. M. (2022). chapitreII La segmentation dans l'imagerie médicale. L'université des sciences et de la technologie d'Oran, Algérie.
- Hulin, A. (2008, mars). Mécanismes moléculaires de l'activité des immunosuppresseurs actuels en transplantation : rôles du pharmacien. *Annales Pharmaceutiques Françaises* , pp. Volume 66, Issue 2, Pages 102-114.
- Jean H. D. Fasel, A. S. (2013). Concepts for Liver Segment Classification: Neither Old Ones nor New Ones, but a Comprehensive One. *PubMed* .
- Kanan, A. (2023.). Comparaison de la détection des métastases hépatiques au scanner entre reconstruction itérative et reconstruction basée sur l'apprentissage profond. Médecine humaine et pathologie.dumas-04394564.
- KHEROUBI Ghania, A. C. (2011). Traitement d'une image médicale Application à la segmentation. Tizi-Ouzou, Université Mouloud MAMMERI, Faculté de Génie Electrique et d'Informatique Département d'Electronique, algeria.
- L. Sulpice, V. D. (2013). Techniques de transplantation hépatique chez l'adulte. *EMC - Techniques chirurgicales - Appareil digestif* , 8(2):1-27 [Article 40-790].
- Lars Nieradzick, G. S. (2021). Effect of the output activation function on the probabilities and errors in medical image segmentation . *Electrical Engineering and Systems Science, Image and Video Processing* .
- Lê Sylvie, M. M.-B. (2024). Microbiote buccal et foie. *Med Sci* , 40 : 42–48.
- Li, X. (21–22 December 2008). Research on Text Clustering Algorithm Based on K_means and SOM. Washington, DC, USA: In Proceedings of the 2008 International Symposium on Intelligent Information Technology Application Workshops.
- Liang Minfei, Y. G. (2022). Microstructure-informed deep convolutional neural network for predicting short-term creep modulus of cement paste. *Cement and Concrete Research* .
- Lin Han, Y. C. (2021). Liver segmentation with 2.5D perpendicular UNets. *Computers & Electrical Engineering* , Volume 91.

BIBLIOGRAPHIE

Loris Nanni, A. L. (2020). Comparisons among different stochastic selection of activation layers for convolutional neural networks for healthcare. *Computer Vision and Pattern Recognition* .

Mama, R. I. (2016, 05 ,12). DETECTION DES LESIONS DE L'ABDOMEN et RECONSTRUCTION TRIDIMENSIONNELLE. Tlemcen, Génie Bio Médical, Algeria.

MEDDABER, H. (2013). Segmentation d'images Par Les Contours Actifs. ORAN, Faculté des Sciences, Spécialité : Informatique, Imagerie, Vision Artificielle, Algeria.

Moghbel, M. M. (2018). Review of liver segmentation and computer assisted detection/diagnosis methods in computed tomography. *Artif Intell Rev* 50 , 497–537.

Mohammad Hesam Hesamian, W. J. (2019). Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. *Journal of Digital Imaging* .

Moussawi, A. A. (2014, 18 /17). Reconstruction 3D de vaisseaux sanguins, p24. Toulon, Mathématiques appliquées.

Mpia, H. &. (2021). L'algorithme de rétro-propagation de gradient dans le perceptron multicouche: Bases et étude de cas. *International Journal of Innovation and Applied Studies* , 32. 271-290.

Muhammad Awaludin Djohar, A. D. (2022). Liver Segmentation Using Convolutional Neural Network Method with U-Net Architecture. *JOURNAL OF INFORMATICS AND TELECOMMUNICATION ENGINEERING* , Vol. 6 No. 1.

Olaf Ronneberger, P. F. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Computer Vision and Pattern Recognition (cs.CV)* .

Oliveira, D. F. (2011). Segmentation of liver, its vessels and lesions from CT images for surgical planning. *BioMed Eng OnLine* 10 , 30.

Olivier Gourmel, A. P. (2010,3). Fitted BVH for Fast Raytracing of Metaballs. *Computer Graphics Forum* , pp.7 - 288.10.1111/j.1467-8659.2009.01597.x.hal-01516266.

Osher, S. e. (1988). Fronts propagating with curvature-dependent speed : Algorithms based on hamilton-jacobi formulations. *Journal of computational physics*.

Pawan Kumar Mall, P. K. (2023). A comprehensive review of deep neural networks for medical image processing: Recent developments and future opportunities. *Healthcare Analytics* , Volume 4.

Petru Bordei, C. D. (2019). Particularités anatomiques de la terminaison des veines hépatiques. *Morphologie* , , Volume 103, Issue 342, Page 92.

Prasad, D. P. (2024). A Comprehensive Review on Neural Networks. *International Research Journal of Engineering and Technology (IRJET)* , Volume: 11 Issue: 06.

R. Vivanti, A. E.-C. (2015). Automatic liver tumor segmentation in follow-up CT studies using Convolutional Neural Networks. *In Proc. patch-based methods in medical image processing workshop* , Vol. 2, p. 2.

BIBLIOGRAPHIE

- Rakotomalala, R. (2018). Descente de gradient pour le machine learning. *Tutoriels Tanagra pour le Data Mining, le Machine Learning et la Data Science*.
- Ran Gu, G. W. (2020). CA-Net: Comprehensive Attention Convolutional Neural Networks for Explainable Medical Image segmentation . *arXiv* .
- Ran Wei, J. C. (2022, 5 13). Real-time 3D MRI reconstruction from cine-MRI using unsupervised network in MRI-guided radiotherapy for liver cancer. *Medical Physics* .
- Richter, F. (10/3/2020). *python remains most popular programming language*. Récupéré sur statista: <https://www.statista.com/chart/21017/the-most-popular-programming-languages>
- S. Favelier, T. G.-Y.-P. (June 2015). Anatomy of liver arteries for interventional radiology. *Diagnostic and Interventional Imaging* , Volume 96, Issue 6,, Pages 537-546.
- S. M. Aqil Burney, H. T. (June 2014). K-Means Cluster Analysis for Image Segmentation. *International Journal of Computer Applications (0975 – 8887)* , Volume 96– No.4.
- S. Pla-Alemany, J. A. (2021). Automatic Multi-Atlas Liver Segmentation and Couinaud Classification from CT Volumes. *43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* (pp. pp. 2826-2829). Mexico: IEEE.
- Sarmah, a. ((2023)). Survey of methods and principles in three-dimensional reconstruction from two-dimensional medical images. *Visual Computing for Industry Biomedicine, and Art* , 6:15.
- Scoazec, J.-Y. (2002). *Physiologie et physiopathologie des vaisseaux hépatiques*. france: Laboratoire central d'anatomie et cytologie pathologiques, hôpital Édouard Herriot.
- segmentation hépatique*. (2020). Récupéré sur <https://urologie-fonctionnelle.com/documents/Cours%20anatomie/APPAREIL%20DIGESTIF/15%20SEGM%20HEPATIQUE.pdf>
- Soler, L. A. (2010). Reconstruction d'images 3D pour la comparaison d'une base de données d'algorithmes : une base de données d'images anatomiques et médicales spécifiques au patient. *IRCAD, Strasbourg, France, Tech. Représentant* .
- Soopil Kim, S. A. (2020). Bidirectional RNN-based Few Shot Learning for 3D Medical Image Segmentation. *arXiv* .
- Suhuai Luo, X. L. (2014). Review on the Methods of Automatic Liver Segmentation from Abdominal Images. (p. Vol.2 No.2). *Computer and Communications*.
- Wafa ABID, M. S. (2009). Reconstruction 3D des Images Médicales par Utilisation de l'Algorithme « Marching Cubes ». *5 th International Conference: Sciences of Electronic, Technologies of Information and Telecommunications* .TUNISIE.
- Wei, D., Jiang, Y., Zhou, X., Wu, D., & Feng, X. (2024). A Review of Advancements and Challenges in Liver Segmentation. *Journal of Imaging* , 10(8):202. <https://doi.org/10.3390/jimaging10080202>.

BIBLIOGRAPHIE

xukun-zhang. (2023). *xukun-zhang/Couinaud-Segmentation*. Récupéré sur github.com:
<https://github.com/xukun-zhang/Couinaud-Segmentation>

Yamashita, R. N. (2018). Convolutional neural networks: an overview and application in radiology. *Insights Imaging* 9, 611–629 , 9, 611–629.

Yen-Wei Chen, K. T. (2010). Liver Segmentation from Low Contrast Open MR Scans Using K-Means Clustering and Graph-Cuts. In: *Zhang, L., Lu, BL., Kwok, J. (eds) Advances in Neural Networks - ISNN 2010. ISNN 2010* (pp. Lecture Notes in Computer Science, vol 6064.). Springer. Berlin, Heidelberg.https://doi.org/10.1007/978-3-642-13318-3_21.

Youcef, M. D. (2017). Deep Learning pour la classification des images . telemcen, GBM, algeria: Université Abou Bakr Belkaid, faculté des sciences .

Yousr, R. (2023). *Etudes d'ultrastructures hépatiques par microscopie électronique 3D de type FIB-SEM*. Français: Biologie cellulaire. Université Grenoble Alpes .

Yunji Chen, L. L. (2024). Chapter 3 - Deep learning. *Morgan Kaufmann* .

Zena A. Aziz, D. N. (2021). Python Parallel Processing and Multiprocessing: A Review. *Academic Journal of Nawroz University (AJNU)* , Vol.10, No.3.

Zhang, Y. &. (2017). Fully convolutional neural network with post-processing methods for automatic liver segmentation from CT.