

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



Université Ibn-Khaldoun de Tiaret

Faculté des Sciences de la Matière

Département de Physique

Mémoire

Présenté Par:

Daradji Elhadja Nedjma

Sahraoui Fatima

Pour obtenir le diplôme de

Master

Filière : Physique

Spécialité: **Physique Médicale**

Thème :

Délimitation des volumes cibles en radiothérapie

Soutenance le : /06/2025

Devant le jury composé de :

M. RABAH Riane

M. HALIS Ladjel

Mme. MOKEDDEM Fatima

M. SOUIDI Abed El Hakim

Professeur

MCB

MCB

Dr

Président

Examineur

Encadrant

Invité

ANNEE UNIVERSITAIRE 2024/2025

Remerciement

Avant tout, nous rendons grâce à Allah, le Tout-Puissant, qui nous a accordé le courage, la patience et la persévérance nécessaires tout au long de la réalisation de ce travail.

*Nous tenons à exprimer nos remerciements les plus sincères à notre encadrante, **Dr. MOKEDDEM Fatima**, pour la qualité de son accompagnement, la pertinence de ses conseils, sa disponibilité et ses encouragements continus.*

*Nous exprimons également notre profonde gratitude aux membres du jury qui ont accepté d'évaluer notre travail, en particulier M. **RABAH Riane**, Président du jury, et M. **HALIS Ladjel**, Examineur, pour l'intérêt qu'ils ont porté à notre projet.*

Nos remerciements vont également à l'ensemble des enseignants qui ont contribué à notre formation tout au long de notre parcours universitaire.

*Nous remercions tout particulièrement **Dr. SOUIDI Abed El Hakim** pour son aide précieuse, sa disponibilité et ses conseils avisés, qui ont joué un rôle déterminant dans la préparation de notre projet de fin d'études.*

Enfin, nous adressons notre gratitude la plus sincère à nos familles, ainsi qu'à toutes les personnes qui nous ont soutenus et encouragés, aussi bien dans les moments difficiles que dans ceux de réussite.

Dédicace :

*Je dédie ce travail avec toute ma reconnaissance et mon respect à **Mes chers parents**, pour l'amour, les sacrifices et le soutien inconditionnel qu'ils m'ont toujours offerts tout au long de mon parcours académique. Leur présence constante, leurs conseils avisés et leurs prières sincères ont été la lumière guidant mes pas et la force sur laquelle je me suis appuyée dans les moments de doute et de fatigue.*

*J'exprime également ma profonde gratitude à mes **frères et sœurs**, ainsi qu'à mon amie précieuse **Kaouter**, dont la fidélité, la générosité et le soutien continu ont été une source précieuse de réconfort et d'encouragement.*

*Je tiens à remercier tout particulièrement **Mon fiancé** pour sa patience, son écoute attentive et son appui indéfectible malgré la distance et les difficultés rencontrées.*

*Enfin, je remercie chaleureusement ma seconde famille, composée de **Mes camarades d'études** avec qui j'ai partagé efforts, défis et succès, ainsi que **Mes proches** de cette wilaya, qui m'ont entourée d'affection, de générosité et d'humanité, allégeant ainsi le poids de l'éloignement et m'offrant un véritable second foyer.*

*Je tiens également à saluer mes propres efforts et la persévérance dont j'ai fait preuve tout au long de ce parcours, car la détermination et le travail acharné ont été les piliers de cette réussite. J'adresse aussi mes sincères remerciements à **Mon binôme**, qui a partagé ce travail avec sérieux et engagement. Notre collaboration a joué un rôle essentiel dans l'aboutissement de ce projet. Ce succès est le fruit de nos efforts conjoints, et j'espère qu'il marquera le début de nombreuses réussites à venir.*

Sahraoui Fatima .

Dédicace

Je dédie ce travail à :

*À l'âme pure de mon **Grand-père**, celui qui a laissé dans mon cœur une trace ineffaçable, des souvenirs empreints de tendresse et de sagesse..., Que Dieu te couvre de Sa miséricorde et t'accorde une place au paradis éternel.*

*À ma chère **Maman**, source inépuisable de don et de sérénité, celle dont les prières silencieuses m'ont toujours accompagnée, lumière constante sur mon chemin..., Chaque réussite que je vis aujourd'hui est le prolongement de ta patience et de tes sacrifices.*

*À mon **père adoré**, celui qui a semé en moi la force de la volonté, qui m'a inspiré la patience et la persévérance..., Merci pour ta présence fidèle et ton soutien inébranlable.*

*À mon cher frère **Abed El Hadi**, compagnon de mon chemin depuis l'enfance, dont les paroles ont été un baume pour l'âme et le soutien un réconfort dans les moments de doute...
Reste toujours aussi proche et précieux à mon cœur.*

*À ma tante bien-aimée **BELKISSARIA Fatma**, la première à avoir tenu ma main sur le chemin du savoir, celle qui a éveillé en moi l'amour de l'apprentissage et fut la première enseignante de mon cœur avant mon esprit... ,Je te dois une reconnaissance infinie.*

*À mon amie chère **FADAH Roumaïssa**, ma sœur de cœur, présente dans toutes les étapes de ma vie, soutien fidèle, refuge dans les moments d'épuisement...
Merci pour ta loyauté et ton amour rare.*

*À **Mon binôme**, compagne de route dans la réalisation de ce mémoire, celle avec qui j'ai partagé la fatigue, les idées, les doutes et les joies..., Ta présence a donné à ce parcours une couleur unique et inoubliable.*

*À **Mes belles amies**, celles avec qui j'ai partagé rêves et ambitions, qui ont été là tout au long de ces années d'études, ensemble nous avons écrit des chapitres de souvenirs impérissables..., Vous avez une place à jamais gravée dans mon cœur.*

*Et enfin, À **Moi-même**, À toi qui as cru malgré les difficultés, persévéré malgré la fatigue, et su te relever après chaque chute. Je suis fière de toi, car tu n'as jamais abandonné. Aujourd'hui, tu écris la dernière page d'un long combat, avec gratitude et sérénité.*

Dradji Nedjma

TABLE DES MATIERES

Introduction général :	1
Chapitre I:Anatomopathologiques du pancréas	1
I.1 Introduction :	3
I.2. Le pancréas :	3
I.2.1. structure de l'organe et leur localisation :	3
I.2.2. l'anatomie du pancréas :	4
I.2.3. Histophysiologie du pancréas :[5]	9
I.3. Le cancer du pancréas :	10
I.3.1. Définition :	10
I.3.2. Les catégories de cancer pancréatique: [8]	11
I.3.3. Facteurs de risque et causes du cancer du pancréas	12
I.3.4. diagnostique :	14
I.3.4.1. Imagerie médicale :	14
I.4. Conclusion.....	17
Chapitre II :Apport de la Tomodensitométrie à la Radiothérapie	17
II.1 Introduction :	18
II.2. la radiothérapie.....	18
II.2.1.definition.....	18
II.2.2.les types de RT :	19
II.2.3.les particules utilisées.....	21
II.3. La tomodensitométrie (TDM).....	22
II.3.1. principe physique	22
II.3.2. Qualité de l'image en TDM:	34
II.4.Rôle de TDM en radiothérapie	39

II.5. Conclusion	48
Chapitre III: Revue des méthodes de segmentation dans le contexte du cancer du pancréas ..	50
III.1.Introduction à la délimitation en radiothérapie.....	50
III.2.Les méthodes de segmentation du cancer de pancréas dans la littérature	52
III.3.Analyse comparative des méthodes existantes de segmentation du cancer du pancréas	57
III.4.Synthèse et justification du choix méthodologique adopté	58
III.5. Conclusion	59
CHAPITRE IV :Évaluation expérimentale	61
IV.1. Introduction :	61
IV.2. Notion à l'intelligence artificielle.....	61
IV.2.1. L'Intelligence Artificielle « IA » :	61
IV.2.2. Apprentissage automatique (Machine Learning).....	62
IV.2.3. Apprentissage profond (Deep Learning - DL).....	62
IV.3. Approche utilisée	72
IV.4.les résultats	81
IV.4.1. Visualisation des résultats.....	81
IV.4.2. Évaluation des performances des modèles U-Net et Attention U-Net	82
IV.4.3. Comparaison des performances avec les approches existantes:	83
IV.5.Discussion :	84
IV.6.Conclusion.....	85

LISTE DES FIGURES

Figure I.1 : la localisation de la pancréas [2].	4
Figure I.2 : les différentes parties anatomiques du pancréas [3]	6
Figure I. 3 : Vaisseau au tour du pancréas [5].	7
Figure I.4 : Drainage veineux [5].	8
Figure I.5 : Drainage lymphatique du pancréas [5].	9
Figure I.6 : Vue axiale et coronale en tomodensitométrie d'un patient présentant une masse de 2 cm dans le corps du pancréas [9]	15
Figure I.7 : Techniques d'imagerie multimodale utilisées pour un patient présentant un cancer de la tête du pancréas de 2,8 cm (flèche bleue) avec invasion de la veine porte et de la veine mésentérique supérieure	16
Figure II.1 : la scanographie [16].	22
Figure II.2: Schéma illustrant Effet photoélectrique [18].	23
Figure II.3: Schéma illustrant l'Effet Compton [19].	24
Figure II.4: Schéma illustrant Création de pair [20].	25
Figure II.5: Domaine des trois phénomènes d'interaction [20].	26
Figure II.6: Principe de production des rayons X : tube de Coolidge [27].	29
Figure II.7:Scanner à rayons X. Le tube et les détecteurs tournent autour du patient. De multiples mesures d'atténuations sont effectuées selon différents angles de rotation du tube. D'après CERF, Bases physiques des rayons X, Solacroup, Boyer, Le Marec, Schouman, et Claey, 2001.	30
Figure II.8: Rangées de détecteurs alignées en face du tube à rayons X. D'après CERF, Bases physiques des rayons X, Solacroup, Boyer, Le Marec, Schouman, et Claey, 2001.	31
Figure II.9: Représentation des pixels dans une image [34].	35
Figure II.10 : le voxel [34].	36
Figure II.11: Distribution des valeurs Hounsfield (HU) et des numéros atomiques effectifs (Le) pour différents tissus biologiques et matériaux en imagerie TDM [54]	38
Tableau II .1 : Ce tableau présente différents types d'artefacts en imagerie, leurs causes principales ainsi que les méthodes de correction utilisées pour améliorer la qualité des images médicales.	39
Figure II.12: Code des couleurs proposé par ICRU 62 [37]	43
Figure II.13: scanner abdominal du pancréas avec segmentation du PDAC : (A) Scanner abdominal non segmenter, (B) Pancréas segmenté en bleu, tumeur en rouge et canal pancréatique en vert [38].	44
Tableau III.1 : Comparaison des méthodes de segmentation du cancer du pancréas.	58
	62
Figure IV.1 : Hiérarchie des sous-domaines de l'intelligence artificielle [1].	62
Figure IV.2: Illustration des analogies entre un neurone biologique et un neurone artificiel [4].	63

Figure IV.3 : illustration du perceptron [5].	64
Figure IV.4: Architecture d'un Perceptron Multicouche contenant 2 couches cachées [4].	65
Figure IV.5: Architecture de CNN [8].	65
Figure IV.6 : opération d'un filtre sur une image [9]	66
Figure IV.7: Max-pooling avec un filtre 2×2 et un pas (stride) de 2 [7].	68
Figure IV.8 : courbe sigmoïde et courbe ReLU [5].	69
Figure IV.9 : Couche entièrement connectée sur une matrice.	69
Figure IV.10 : Architecture de base de l'U-Net[8].	70
Figure IV.11 : Organigramme du processus de délimitation automatique des tumeurs sur des images CT basé sur un modèle Attention U-Net.	73
Figure IV.12 : L'histogramme illustre la répartition des images par catégorie.	74
Figure IV.13 : Deux exemples d'images brutes extraites du dataset.	75
Figure IV.14 : Architecture de l'attention U-Net.	78
Tableau IV. 1 : Principaux paramètres d'entraînement utilisé.	80
Figure IV.15: Exemple de résultat de délimitation sur une coupe TDM.	82
Tableau 2 : Résultats d'évaluation des métriques pour U-Net et Attention U-Net.	83
Tableau IV.3 : Résultats comparés avec la littérature,	83

Liste des Tableaux

Tableau II .1 : Ce tableau présente différents types d'artefacts en imagerie, leurs causes principales ainsi que les méthodes de correction utilisées pour améliorer la qualité des images médicales.	39
Tableau III.1 : Comparaison des méthodes de segmentation du cancer du pancréas.	58
	62
Tableau IV. 1 : Principaux paramètres d'entraînement utilisé.	80
Tableau IV.2 : Résultats d'évaluation des métriques pour U-Net et Attention U-Net.	83
Tableau IV.3 : Résultats comparés avec la littérature,	83

Liste des abréviations

CP : Cancer du pancréas.

MDCT : Multi-Detector Computed Tomography (Tomodensitométrie multi-détecteurs).

CT : Computed Tomography (Scanner, tomodensitométrie).

PET : Positron Emission Tomography (Tomographie par émission de positons).

PET-CT : PET couplé à CT pour une double imagerie fonctionnelle et anatomique.

IRM : Imagerie par Résonance Magnétique.

DWI : Diffusion Weighted Imaging (Imagerie pondérée par diffusion).

EUS : Endoscopic Ultrasound (Échographie endoscopique).

ERCP : Endoscopic Retrograde Cholangiopancreatography (Cholangiopancréatographie rétrograde endoscopique).

CEA : Carcinoembryonic Antigen (Antigène carcino-embryonnaire).

CA19-9 : Carbohydrate Antigen 19-9 (Marqueur tumoral pancréatique courant).

CA125 : Cancer Antigen 125 (Marqueur tumoral utilisé dans plusieurs cancers).

CA242 : Cancer Antigen 242 (Autre marqueur tumoral).

CfDNA : Cell-free DNA (ADN libre circulant, marqueur tumoral potentiel).

CftDNA : Circulating free tumor DNA (ADN tumoral libre circulant).

NET : Neuroendocrine Tumor (Tumeur neuroendocrine du pancréas).

VIPoma : Tumeur produisant du Vasoactive Intestinal Peptide (VIP).

KRAS, TP53, BRCA1/2, CDKN2A, SMAD4 : Gènes liés aux mutations dans le cancer du pancréas.

T1/T2 : Types de séquences IRM pondérées.

L1-L2 : Niveaux vertébraux lombaires (localisation anatomique du pancréas).

TDM : Tomodensitométrie (appelée aussi CT – Computed Tomography).

RT : Radiothérapie.

3D-CRT : 3D Conformal Radiotherapy – Radiothérapie conformationnelle tridimensionnelle.

IMRT : Intensity-Modulated Radiotherapy – Radiothérapie à modulation d'intensité.

IGRT : Image-Guided Radiotherapy – Radiothérapie guidée par l'image.

VMAT : Volumetric Modulated Arc Therapy – Thérapie par arc modulé.

RIV : Radiothérapie Interne Vectorisée.

RIT : Radioimmunothérapie.

SIRT : Selective Internal Radiation Therapy – Radiothérapie interne sélective du foie.

GTV : Gross Tumor Volume – Volume tumoral macroscopique.

CTV : Clinical Target Volume – Volume cible anatomoclinique.

PTV : Planning Target Volume – Volume cible prévisionnel.

OAR : Organs At Risk – Organes à risque.

ICRU : International Commission on Radiation Units and Measurements.

TEP/TDM : Tomographie par émission de positons couplée à la tomodensitométrie.

CBCT : Cone Beam Computed Tomography – Tomodensitométrie à faisceau conique.

RI : Reconstruction Itérative.

RPF : Rétroprojection Filtrée.

CNN : Convolutional Neural Network – Réseau de neurones convolutionnels.

U-Net : Architecture de réseau neuronal utilisée pour la segmentation d'images.

GAN / NAG : Generative Adversarial Network – Réseau antagoniste génératif.

HU : Hounsfield Unit – Unité d'atténuation en TDM.

MV : MégaVolt – unité d'énergie pour les photons en radiothérapie.

TPS : Treatment Planning System – Système de planification de traitement.

MRgOART : MRI-guided Online Adaptive Radiotherapy – Radiothérapie adaptative en ligne guidée par IRM.

DCE-IRM : Dynamic Contrast Enhanced IRM – IRM avec rehaussement dynamique par contraste.

DSC : Dice Similarity Coefficient – Coefficient de similarité de Dice.

HD ou HD95 : Hausdorff Distance – Distance de Hausdorff (HD95 = 95e percentile).

MSD / MDA : Mean Surface Distance / Mean Distance Agreement – Distance moyenne de surface ou d'accord.

PPU-Net : Pyramid Pooling U-Net – U-Net amélioré avec pyramide de mise en commun.

BConvLSTM : Bi-directional Convolutional Long Short-Term Memory – Mémoire à long terme convolutionnelle bidirectionnelle.

TDSMask R-CNN : Tumor Detection and Segmentation Mask Region-based CNN.

MRgART : MRI-guided Adaptive Radiotherapy – Radiothérapie adaptative guidée par IRM.

SwinUNETR : Swin Transformer + UNETR – Architecture hybride pour segmentation médicale.

OAR(s) : Organs At Risk – Organes à risque.

GWO : Grey Wolf Optimization – Algorithme d'optimisation méta-heuristique.

BCO : Border Collie Optimization – Autre méthode méta-heuristique.

Tversky : Fonction de perte de Tversky – utilisée pour gérer le déséquilibre de classes.

DSMask R-CNN : Variante de Mask R-CNN avec fusion multi-échelle.

Snakes : Modèle de contours actifs (Active Contours).

CT scan : Scanner – Tomodensitométrie.

ML : Machine Learning (Apprentissage automatique).

DL : Deep Learning (Apprentissage profond).

RNA : Réseaux de Neurones Artificiels.

MLP : Multilayer Perceptron (Perceptron multicouche).

ReLU : Rectified Linear Unit (fonction d'activation).

RGB : Red Green Blue (format d'image couleur).

AG : Attention Gate (porte d'attention dans les modèles).

Q, K, V : Query, Key, Value (composants du mécanisme d'attention).

DSC : Dice Similarity Coefficient (coefficient de similarité de Dice).

TP : True Positives (vrais positifs).

FP : False Positives (faux positifs).

FN : False Negatives (faux négatifs).

TN : True Negatives (vrais négatifs).

F-score : Mesure harmonique entre précision et sensibilité.

PNG : Portable Network Graphics (format d'image).

DICOM : Digital Imaging and Communications in Medicine (format médical standard).

PyTorch : Bibliothèque Python pour le deep learning.

kV / mA : Kilovolt / Milliampère – Paramètres du tube à rayons X.

Introduction générale

Le cancer du pancréas, bien que représentant une proportion relativement modeste parmi les tumeurs digestives, est particulièrement grave en raison de son pronostic défavorable et des diagnostics souvent tardifs. Sa localisation profonde et l'absence de symptômes précoces compliquent sa détection. L'adénocarcinome pancréatique, forme la plus fréquente, est responsable de la majorité des décès, soulignant la nécessité d'améliorer les diagnostics et les traitements.

La radiothérapie joue un rôle clé en ciblant précisément la tumeur tout en épargnant les tissus sains. Toutefois, la complexité anatomique du pancréas impose une planification rigoureuse, reposant sur des images TDM de haute qualité, indispensables pour la délimitation exacte des volumes cibles.

Cette étape critique, traditionnellement effectuée manuellement, présente une forte variabilité inter-observateur et constitue une tâche particulièrement chronophage pour les cliniciens. L'intelligence artificielle, et notamment les réseaux de neurones convolutifs comme l'Attention U-Net, offre aujourd'hui des solutions prometteuses d'automatisation. Grâce à ses mécanismes d'attention, ce modèle améliore la précision de la segmentation tumorale sur les images TDM, facilitant ainsi une planification radiothérapeutique plus efficace et personnalisée.

Dans **le chapitre 1**, on va s'intéresser à l'anatomie et à la physiologie du pancréas, puis on abordera les aspects cliniques et épidémiologiques du cancer pancréatique. On mettra l'accent sur les facteurs de risque, les méthodes de diagnostic et les principales options thérapeutiques.

Le **chapitre 2** sera consacré aux principes fondamentaux de la radiothérapie, avec une attention particulière portée à l'imagerie médicale notamment la tomodensitométrie et à son rôle essentiel dans la planification et l'optimisation des traitements.

Dans **le chapitre 3**, on va présenter un état de l'art complet des méthodes de délimitation des volumes cibles en radiothérapie. On verra comment ces techniques ont évolué, en passant des approches manuelles aux méthodes automatisées basées sur l'intelligence artificielle, tout en soulignant les défis spécifiques liés à la segmentation des tumeurs pancréatiques.

Enfin, dans **le chapitre 4**, on réalisera une étude expérimentale pour évaluer l'efficacité du modèle **Attention U-Net** dans la segmentation automatique des tumeurs pancréatiques à partir d'images TDM. On présentera le protocole utilisé, les résultats obtenus, puis on discutera les perspectives d'amélioration.

Ce travail s'inscrit donc dans une démarche d'intégration de l'intelligence artificielle au service de la radiothérapie, avec pour ambition de renforcer la précision, la reproductibilité et l'efficacité de la délimitation tumorale chez les patients atteints de cancer pancréatique.

Chapitre I:

Anatomopathologiques du pancréas

I.1 Introduction :

Le pancréas est un organe essentiel du système digestif et endocrinien, jouant un rôle clé dans la digestion et la régulation de la glycémie. Il est constitué de deux parties fonctionnelles : une portion exocrine, responsable de la sécrétion d'enzymes digestives, et une portion endocrine, qui produit des hormones telles que l'insuline et le glucagon.

Le cancer du pancréas est une maladie redoutable en raison de son diagnostic souvent tardif et de son pronostic sombre. Il se manifeste généralement de manière asymptomatique à ses débuts, ce qui complique sa détection précoce. Parmi les formes les plus fréquentes, l'adénocarcinome pancréatique, issu des cellules exocrines, représente plus de **90 %** des cas.

L'identification et la prise en charge du cancer du pancréas nécessitent une approche multidisciplinaire combinant des examens d'imagerie avancés, des marqueurs tumoraux spécifiques et des analyses histologiques. Ce chapitre vise à explorer l'anatomie du pancréas ainsi que les caractéristiques du cancer pancréatique, en mettant en lumière les facteurs de risque, les méthodes de diagnostic et les stratégies thérapeutiques actuelles.

I.2. Le pancréas :

I.2.1. Structure de l'organe et leur localisation :

Le pancréas est une glande allongée et la deuxième plus grande glande digestive accessoire du corps. Il est composé d'une portion exocrine, qui produit le suc pancréatique riche en enzymes digestives, et d'une portion endocrine, représentée par les îlots de Langerhans, plus abondants dans la queue du pancréas. Ces derniers sécrètent l'insuline et le glucagon, régulant ainsi le taux de glucose dans le sang et assurant son utilisation comme source d'énergie. Le pancréas situé en position rétropéritonéale, principalement dans les régions épigastrique et hypochondriaque gauche, s'étendant transversalement devant les vertèbres lombaires L1 et L2. Il mesure environ 17 à 20 cm de long, 3 à 5 cm de large et 1,5 à 2,5 cm d'épaisseur avec un poids variant entre 82 et 117 grammes [1]

La figure ci-dessous montre la localisation du pancréas dans la cavité abdominale




Figure I.1 : la localisation de la pancréas [2].

I.2.2. L'anatomie du pancréas :

I .2.2.1. division morphologique: [2]

Le pancréas se subdivise en quatre parties distinctes : la tête, le col, le corps et la queue, selon le plan anatomique et descriptif.

I .2.2.1.1. La tête du pancréas :

La tête du pancréas constitue la portion la plus large de l'organe et est encastrée dans la courbure du duodénum, en contact étroit avec ses parties descendante et horizontale. Elle est située légèrement à droite de la ligne médiane, en regard de la veine cave inférieure et des veines rénales droite et gauche.

Un prolongement inférieur et médial de la tête, appelé processus unciné, s'insinue derrière les vaisseaux mésentériques supérieurs (artère et veine). Cette disposition anatomique est d'une grande importance en chirurgie pancréatique, car elle implique une relation intime avec les structures vasculaires majeures.

I .2.2.1.2. Le col du pancréas :

Le col est une portion plus étroite reliant la tête au corps du pancréas. Il est situé en avant de l'origine de la veine porte, qui est formée par la confluence de la veine splénique et de la veine mésentérique supérieure.

- En avant, le col est en contact avec la paroi postérieure de l'estomac, séparé par la bourse omentale.
- En arrière, il est en relation avec les vaisseaux mésentériques supérieurs, qui forment une empreinte marquée sur sa face postérieure.

I .2.2.1.3. Le corps du pancréas :

Le corps du pancréas est la partie la plus longue et la plus volumineuse de la glande. Il s'étend transversalement devant la colonne vertébrale, en regard de L1-L2, et s'incline légèrement vers le haut à mesure qu'il se prolonge vers la gauche pour rejoindre la queue.

- Relations antérieures : le corps du pancréas est séparé de l'estomac par la bourse omentale, ce qui en fait une partie du lit de l'estomac.
- Relations postérieures : il recouvre plusieurs structures vasculaires et viscérales, dont l'aorte abdominale, l'artère mésentérique supérieure, la glande surrénale gauche et le rein gauche.
- Relations supérieures : le corps du pancréas est en rapport avec le tronc coélique et ses branches, notamment l'artère splénique, qui longe son bord supérieur

I .2.2.1.4. La queue du pancréas :

La queue du pancréas est la partie la plus étroite et distale de la glande. Elle s'étend vers la gauche et se termine au niveau du hile de la rate, en passant à travers le ligament pancréato-splénique. Contrairement aux autres segments du pancréas, la queue est intrapéritonéale, ce qui la rend relativement mobile.

- Relations postérieures : elle est en contact avec le rein gauche et l'artère rénale gauche.

- Relations latérales : elle est adjacente à la rate, ce qui peut impliquer des risques de lésion vasculaire lors d'une splénectomie.

La figure ci-dessous présente les quatre parties du pancréas [3].




Figure I.2 : les différentes parties anatomiques du pancréas [3] .

I .2.2.2. Vascularisation et drainage veineux :

La vascularisation et le drainage veineux du pancréas reposent sur un réseau anatomique complexe, assurant un apport sanguin adéquat et un retour veineux efficace, indispensables au bon fonctionnement de cet organe vital.

I .2.2.2.1. Vascularisation artérielle du pancréas :

La vascularisation artérielle du pancréas repose sur un réseau anastomotique riche, assurant une perfusion adéquate de ses différentes parties. La tête et le col du pancréas sont irrigués par deux arcades pancréaticoduodénales, l'une antérieure et l'autre postérieure, qui entourent le cadre duodéal. Ces arcades sont alimentées par les artères pancréaticoduodénales supérieures, branches de l'artère gastroduodénale issue de l'artère hépatique commune, et par les artères pancréaticoduodénales inférieures, premières branches de l'artère mésentérique supérieure. Cette configuration crée une anastomose entre le tronc cœliaque et l'artère mésentérique supérieure, assurant non seulement l'irrigation du pancréas mais également celle du duodénum adjacent. Le corps et la queue du pancréas reçoivent quant à eux leur apport sanguin via de multiples branches de l'artère splénique, une branche

terminale du tronc coeliaque, qui longe le bord supérieur du pancréas avant d'atteindre le hile splénique [4].




Figure I. 3 : Vaisseau au tour du pancréas [5].

I .2.2.2.3. Drainage veineux du pancréas :

Le drainage veineux du pancréas suit une organisation similaire à celle de la vascularisation artérielle, avec une convergence vers le système porte. La tête et le col du pancréas se drainent par les veines pancréaticoduodénales supérieures, qui se jettent en partie dans la veine gastroépiploïque droite et en partie directement dans la veine porte, et par les veines pancréaticoduodénales inférieures, qui rejoignent la veine mésentérique supérieure. Le corps et la queue du pancréas sont drainés par la veine splénique, qui longe la face postérieure du pancréas, recevant plusieurs affluents veineux avant de se fusionner avec la veine mésentérique supérieure pour former la veine porte. Cette organisation garantit un retour sanguin efficace vers le foie, essentiel pour le métabolisme pancréatique et systémique [4].




Figure I.4 : Drainage veineux [5].

I.2.2.3. Innervation et drainage lymphatique :

I .2.2.3.1. Innervation du pancréas :

L'innervation du pancréas est assurée par le système nerveux autonome, comprenant des fibres sympathiques et parasympathiques. Les fibres sympathiques proviennent du plexus coélique, où elles accompagnent les vaisseaux sanguins pancréatiques, jouant un rôle essentiel dans la modulation de la sécrétion endocrine et exocrine, ainsi que dans la vasomotricité. Les fibres parasympathiques, issues du nerf vague (X), favorisent principalement la sécrétion des enzymes digestives et participent au contrôle de la motricité du canal pancréatique. Cette double innervation assure un équilibre dynamique entre les besoins digestifs et métaboliques de l'organisme [4].

I.2.2.3.2. Drainage lymphatique du pancréas :

Le drainage lymphatique du pancréas suit étroitement le trajet des artères pancréatiques. La lymphe issue du corps et de la queue du pancréas est dirigée vers les nœuds lymphatiques rétropancréatiques, tandis que la partie supérieure de la tête et du col draine vers les nœuds lymphatiques cœliaques. En revanche, la partie inférieure de la tête se draine principalement dans les nœuds mésentériques supérieurs. De là, la lymphe progresse vers les nœuds lymphatiques préaortiques, contribuant à la surveillance immunitaire et à l'élimination des cellules tumorales potentielles. Ce réseau lymphatique joue un rôle crucial non seulement dans le maintien de l'homéostasie, mais également dans la dissémination des pathologies pancréatiques, notamment les cancers [4].




Figure I.5 : Drainage lymphatique du pancréas [5].

I.2.3. Histophysiologie du pancréas [5] :

Le pancréas est un organe clé qui intervient à la fois dans la digestion des aliments et dans la régulation du métabolisme énergétique. Il remplit deux fonctions complémentaires : une fonction enzymatique (exocrine) qui permet la digestion, et une fonction endocrine qui régule la glycémie.

I.2. 3. 1. Fonction enzymatique (exocrine) :

- Le pancréas exocrine constitue environ 95 % du tissu pancréatique et est organisé en acini, qui sont de petits groupes de cellules acineuses spécialisées dans la production des enzymes digestives.
- Il synthétise et sécrète un suc pancréatique riche en enzymes telles que les protéases (par exemple, la trypsine, la chymotrypsine et l'élastase), l'amylase, la lipase et les nucléases, chacune jouant un rôle spécifique dans la dégradation des protéines, glucides, lipides et acides nucléiques.
- Ce suc est acheminé vers le duodénum via un système de canaux, principalement le conduit de Wirsung (et parfois le conduit accessoire de Santorini), permettant ainsi la libération des enzymes au site de digestion.

- La présence de bicarbonate dans le suc pancréatique neutralise l'acidité du chyme gastrique, créant un environnement optimal pour l'action enzymatique dans l'intestin grêle et favorisant l'absorption des nutriments.

I.2.3. 2. Fonction endocrine :

- La fonction endocrine représente environ 1 à 2 % du tissu pancréatique et se réalise dans les îlots de Langerhans, de petits amas cellulaires disséminés dans le pancréas.
- Les cellules β (bêta) des îlots sécrètent l'insuline, hormone hypoglycémiante qui facilite la captation du glucose par les cellules du foie, du muscle et des adipocytes, favorisant son stockage sous forme de glycogène ou son utilisation comme source d'énergie.
- Les cellules α (alpha) produisent le glucagon, hormone hyperglycémiante qui stimule la dégradation du glycogène hépatique et la néoglucogenèse, libérant ainsi du glucose dans le sang en cas d'hypoglycémie.
- D'autres cellules, telles que les cellules δ (delta) et les cellules PP, sécrètent respectivement la somatostatine et le polypeptide pancréatique, qui modulent la sécrétion d'autres hormones et participent à la régulation fine du métabolisme.
- L'équilibre entre l'action de l'insuline et celle du glucagon est essentiel pour maintenir une glycémie stable et assurer l'homéostasie énergétique de l'organisme.

I.3. Le cancer du pancréas :

I.3.1. Définition :

Le cancer du pancréas est une tumeur maligne qui résulte de la transformation d'une cellule normale du pancréas en une cellule anormale qui se divise de manière irrégulière. Cette prolifération aboutit à la formation d'une masse qui peut rester localisée dans le pancréas ou s'étendre pour envahir les tissus voisins. Ce cancer peut se développer soit à partir des cellules productrices d'insuline, entraînant des troubles hormonaux, soit à partir des cellules exocrines, ce qui donne lieu à un adénocarcinome affectant les fonctions digestives [6]. Parmi, les symptômes de ce cancer sont :

- **Fatigue** persistante

- Perte d'appétit et perte de poids inexpliquée
- Troubles digestifs, incluant diarrhées, nausées ou vomissements
- Jaunisse (jaunissement de la peau et du blanc des yeux, urine foncée), parfois accompagnée de démangeaisons
- Selles anormales : pâles, grasses et flottantes
- Douleurs abdominales ou douleurs dorsales

I.3.2. Les catégories de cancer pancréatique [7] :

I.3.2.1. Cancer du pancréas exocrine (non endocrinien) :

Ce cancer prend naissance dans les cellules exocrines qui composent la glande exocrine et les canaux du pancréas. Cette glande sécrète des enzymes responsables de la digestion des glucides, des graisses, des protéines et des acides dans le duodénum. Les différents types de cancer exocrine du pancréas représentent plus de 95 % de tous les cancers du pancréas. Ils comprennent les types suivants :

- **Adénocarcinome (carcinome canalaire)** : Représente plus de 90 % des cancers pancréatiques exocrines et se développe dans les cellules tapissant les canaux du pancréas.
- **Carcinome à cellules acineuses** : Constitue environ 1 % à 2 % des cancers pancréatiques exocrines et provient des cellules acineuses responsables de la production des enzymes pancréatiques.
- **Carcinome à cellules squameuses** : Extrêmement rare, il se forme dans les canaux pancréatiques à partir de cellules squameuses, qui ne sont normalement pas présentes dans cet organe.
- **Carcinome adénosquameux** : Représente entre 1 % et 4 % des cancers pancréatiques exocrines et combine les caractéristiques de l'adénocarcinome et du carcinome à cellules squameuses dans les canaux pancréatiques.
- **Carcinome colloïde** : Constitue environ 1 % à 3 % des cancers pancréatiques exocrines et se développe à partir de tumeurs kystiques mucineuses situées dans les canaux du pancréas.

I.3.2.2. Tumeur Neuroendocrine du Pancréas (NET) :

Une tumeur neuroendocrine du pancréas (NET) est un type de cancer qui se forme dans le pancréas. Les cellules productrices d'hormones du pancréas se regroupent en petits ensembles appelés îlots, qui sont répartis dans tout le pancréas. Lorsqu'une tumeur se forme dans l'un de ces ensembles, on parle de tumeur NET pancréatique ou de carcinome des cellules des îlots. Les tumeurs NET pancréatiques peuvent être bénignes (non cancéreuses) ou malignes (cancéreuses), bien que les deux types puissent entraîner des problèmes de santé graves. Ils comprennent les types suivants :

- **Gastrinome** : La gastrine est une hormone qui aide à la digestion des aliments. Lorsqu'une tumeur se forme dans les cellules productrices de gastrine, elle est appelée gastrinome.
- **Insulinome** : L'insuline aide à réguler le niveau de sucre ou de glucose dans le sang. Lorsqu'une tumeur se développe dans ces cellules, elle est appelée insulinome.
- **Glucagonome** : Le glucagon joue également un rôle dans la régulation du glucose sanguin, et dans le cas du glucagonome, il augmente le niveau de glucose. Ce type de tumeur se forme dans les cellules produisant du glucagon.
- **Autres types** : Il existe d'autres tumeurs des cellules des îlots qui produisent des hormones régulant l'équilibre de l'eau, du sucre et du sel dans le corps, telles que les VIPomas, qui affectent les peptides intestinaux vasoactifs, et les somatostatines, qui affectent la somatostatine. Ces types de tumeurs sont souvent regroupés, car elles sont traitées de manière similaire.

I.3.3. Facteurs de risque et causes du cancer du pancréas :[4]

Le cancer du pancréas (CP) est une pathologie à la fois complexe et multifactorielle, influencée par des facteurs de risque modifiables et non modifiables. Une compréhension approfondie de ces facteurs est essentielle pour une meilleure prévention et détection précoce de la maladie.

I.3.3.1. Facteurs de risque non modifiables :

Certains facteurs intrinsèques au patient jouent un rôle déterminant dans la survenue du cancer du pancréas :

- **Âge** : L'incidence du CP augmente avec l'âge, la majorité des cas étant diagnostiqués après 55 ans, avec un pic entre 70 et 80 ans. Il est extrêmement rare chez les individus de moins de 30 ans.
- **Sexe** : Une différence de prévalence est observée entre les genres , avec une incidence plus élevée chez les hommes. Cette disparité pourrait être attribuée aux effets protecteurs des hormones stéroïdiennes chez la femme.
- **Zone géographique** : L'incidence varie en fonction des régions du monde, avec des taux plus élevés en Amérique du Nord et en Europe, tandis que l'Afrique présente les taux les plus faibles. Ces différences pourraient être liées à des facteurs environnementaux et au mode de vie.
- **Groupe sanguin** : Des études récentes ont mis en évidence une association entre le groupe sanguin et le risque de CP. Les individus des groupes A, AB et B présentent un risque accru par rapport au groupe O, potentiellement en raison de la régulation des processus inflammatoires et des interactions cellulaires favorisant la carcinogenèse.
- **Facteurs génétiques et hérédité** : La présence d'antécédents familiaux de CP constitue un facteur de risque majeur. Plusieurs mutations génétiques spécifiques ont été identifiées, notamment dans les gènes K-RAS, TP53, BRCA1, BRCA2, CDKN2A et SMAD4, qui sont impliqués dans les mécanismes de régulation de la croissance cellulaire et de la réparation de l'ADN.
- **Diabète** : Le diabète, en particulier de type 2, est un facteur de risque reconnu du cancer du pancréas. Les patients atteints de diabète depuis plus de 10 ans présentent un risque 5 à 10 fois plus élevé de développer cette pathologie.

I.3.3.2. Facteurs de risque modifiables :

Certains facteurs liés au mode de vie et aux expositions environnementales peuvent être modulés afin de réduire le risque de **CP** :

- **Microbiote intestinal et pancréatique** : Des altérations de la flore microbienne ont été corrélées à un risque accru de CP. Certaines bactéries pathogènes, notamment

Helicobacter pylori, pourraient jouer un rôle indirect via des mécanismes inflammatoires chroniques.

- **Tabagisme** : Le tabac représente le principal facteur de risque modifiable, augmentant de 74 % la probabilité de développer un CP. La nicotine et ses dérivés carcinogènes favorisent des altérations cellulaires et la progression tumorale.
- **Alcool** : Une consommation excessive d'alcool (supérieure à 30 g par jour) est associée à une augmentation significative du risque de CP, en raison de son effet toxique sur le pancréas et de l'inflammation chronique qu'elle engendre.
- **Pancréatite chronique** : Une inflammation récurrente et prolongée du pancréas induit un processus fibrotique et des altérations génétiques favorisant la transformation maligne des cellules pancréatiques.
- **Obésité** : L'excès de masse grasse est impliqué dans la modulation de divers processus métaboliques et inflammatoires contribuant à la tumorigenèse pancréatique. L'adiposité centrale est particulièrement associée à un risque accru de CP, via l'activation de mutations oncogéniques telles que KRAS.
- **Facteurs alimentaires** : Une alimentation riche en graisses saturées et pauvre en fibres a été identifiée comme un facteur favorisant l'apparition du CP. Les régimes hypercaloriques et la consommation excessive de viandes transformées sont notamment incriminés.
- **Infections** : Certaines infections chroniques, notamment celles impliquant *Helicobacter pylori*, ont été suggérées comme des cofacteurs de risque, bien que les mécanismes sous-jacents nécessitent encore des recherches approfondies.

I.3.4. Diagnostique :

Le diagnostic du cancer du pancréas repose sur une approche multimodale combinant l'imagerie médicale, l'acquisition de tissus pour confirmation histologique et l'utilisation de biomarqueurs tumoraux. Cette approche vise à détecter la tumeur à un stade précoce afin d'améliorer les chances de traitement curatif.[8]

I.3.4.1. Imagerie médicale :

I.3.4.1.1. Tomodensitométrie (CT Scan) et Tomographie par émission de positons (PET) :

La tomodensitométrie multi-détecteur (MDCT) est la méthode d'imagerie la plus couramment utilisée pour le diagnostic du cancer du pancréas. Elle permet une évaluation précise de la taille de la tumeur, de son extension locale et de la présence de métastases.

➤ Protocole spécifique au pancréas :

- Acquisition d'images avec un contraste iodé.
- Phase parenchymateuse pancréatique (40-50 secondes après injection).
- Phase portale veineuse (65-70 secondes après injection) [9-11].

Avantages : large disponibilité, haute résolution spatiale, bonne détection des lésions.

Inconvénients : exposition aux radiations, néphrotoxicité potentielle du produit de contraste.




Figure I.6 : Vue axiale et coronale en tomodensitométrie d'un patient présentant une masse de 2 cm dans le corps du pancréas [8] .

Par ailleurs, la tomographie par émission de positons couplée à la tomodensitométrie (PET-CT) permet une identification précoce des lésions tumorales en exploitant l'absorption accrue de traceurs métaboliques par les cellules cancéreuses [12].

I.3.4.1.2. Imagerie par Résonance Magnétique (IRM) [13-15] :

L'IRM est un examen complémentaire au CT, notamment pour les tumeurs de petite taille et les lésions indéterminées.

➤ Séquences utilisées :

- T1 et T2 pondérées.
- Diffusion-Weighted Imaging (DWI) pour différencier les tissus tumoraux des tissus normaux.
- Séquence avec injection de gadolinium pour améliorer la détection des lésions.

Avantages : absence de radiation, meilleure caractérisation des tissus mous.

Inconvénients : coût élevé, accessibilité limitée, contre-indication chez les patients porteurs d'implants métalliques.




Figure I.7 : Techniques d'imagerie multimodale utilisées pour un patient présentant un cancer de la tête du pancréas de 2,8 cm (flèche bleue) avec invasion de la veine porte et de la veine mésentérique supérieure

I.3.4.1.3. Échographie Endoscopique (EUS) :

L'EUS présente une sensibilité accrue par rapport à la MDCT dans la détection des tumeurs pancréatiques, notamment pour l'obtention de biopsies tissulaires à des fins diagnostiques[16, 17].

I.3.4.1.4. holangiopancréatographie rétrograde endoscopique (ERCP) :

L'ERCP employée pour les cancers de la tête du pancréas et pour les prélèvements cytopathologiques [18, 19].

I.3.4.2. Marqueurs Tumoraux :[4]

Les biomarqueurs sériques sont essentiels pour le dépistage et le suivi du cancer. Parmi les plus utilisés figurent CA19-9, CA242, CEA, CA125, microARNs et les mutations du gène K-RAS.

- **CA19-9 et CA125** : améliorent la sensibilité diagnostique.
- **CA19-9 et CEA** : augmentent la spécificité à 84 %.
- **cfDNA et cftDNA** : étudiés comme indicateurs du volume tumoral et de la réponse au traitement.

I.3.3.3. Examen Histologique et Cytologique [4] :

L'analyse histopathologique et/ou cytologique constitue le "gold standard" pour le diagnostic du cancer du pancréas. Les méthodes courantes pour l'obtention d'échantillons comprennent :

- Biopsie guidée par échographie endoscopique (EUS) ou tomodensitométrie (CT)
- Cytologie du liquide d'ascite
- Biopsie exploratoire par laparoscopie ou chirurgie ouverte.

I.4. Conclusion :

Le cancer du pancréas représente un défi médical majeur en raison de son diagnostic souvent tardif, de son évolution agressive et de son faible taux de survie. La complexité anatomique du pancréas, sa proximité avec des structures vasculaires critiques et son réseau lymphatique dense contribuent à la difficulté du dépistage et à la rapidité de la progression tumorale. Bien que les avancées en imagerie médicale et en biomarqueurs tumoraux aient amélioré la détection précoce, la prise en charge thérapeutique demeure un enjeu considérable.

Les options de traitement actuelles reposent principalement sur la chirurgie, la chimiothérapie et les thérapies ciblées, mais leur efficacité reste limitée, en particulier aux stades avancés de la maladie. Dans ce contexte, la radiothérapie apparaît comme une stratégie complémentaire prometteuse, permettant de réduire la masse tumorale, renforcer le contrôle locorégional et accroître l'efficacité des traitements systémiques.

Chapitre II :

Apport de la Tomodensitométrie à la Radiothérapie

II.1 Introduction :

La radiothérapie constitue une modalité thérapeutique essentielle dans le traitement des cancers, reposant sur l'utilisation de rayonnements ionisants afin d'éradiquer les cellules tumorales tout en préservant les tissus sains environnants. Pour garantir une administration précise de la dose et optimiser l'efficacité du traitement, l'imagerie médicale joue un rôle clé, notamment à travers la tomodensitométrie (TDM). Cette technique d'imagerie, basée sur l'atténuation des rayons X, permet d'obtenir des coupes transversales détaillées du corps humain, offrant ainsi une visualisation optimale des volumes cibles et des organes à risque. Son intégration dans les systèmes de planification en radiothérapie a révolutionné la prise en charge des patients, en améliorant la précision du ciblage tumoral et en réduisant les marges d'incertitude lors de l'irradiation. L'évolution des technologies de la TDM, couplée aux avancées en intelligence artificielle et en imagerie multimodale, a permis d'améliorer significativement la qualité des images et la délimitation des volumes tumoraux. De plus, la TDM joue un rôle fondamental dans la dosimétrie, en facilitant la modélisation de la distribution de dose et en contribuant à l'optimisation des protocoles thérapeutiques.

Ce chapitre explore ainsi les principes physiques et techniques de la TDM, ses applications en radiothérapie et son impact sur la précision et l'efficacité du traitement des cancers.

II.2. La radiothérapie :

II.2.1. Définition :

La radiothérapie (RT) est une modalité thérapeutique utilisée dans le traitement des cancers, reposant sur l'utilisation des rayonnements ionisants pour éradiquer les cellules tumorales tout en préservant, autant que possible, les tissus sains avoisinants. Son principe fondamental consiste à induire des dommages au niveau de l'ADN des cellules malignes, entraînant ainsi leur apoptose ou leur incapacité à se diviser[20].

II.2.2.les types de RT :

La radiothérapie peut être classée en deux types principaux en fonction de la position de la source de rayonnement par rapport au corps :

II.2.2.1. Radiothérapie externe [21-26] :

Ce type de radiothérapie consiste à diriger des faisceaux de rayonnement à haute énergie depuis une source externe vers la tumeur, en utilisant des équipements spécialisés tels que les accélérateurs linéaires. Plusieurs techniques avancées sont employées afin d'améliorer la précision du ciblage et de réduire l'exposition des tissus sains au rayonnement, parmi lesquelles :

- **Radiothérapie conformationnelle tridimensionnelle (3D-CRT – 3D Conformal Radiotherapy)** : Elle repose sur une planification tridimensionnelle du rayonnement afin qu'il épouse la forme de la tumeur, ce qui permet d'optimiser le ciblage et de minimiser les effets secondaires sur les tissus sains.
- **Radiothérapie à modulation d'intensité (IMRT – Intensity-Modulated Radiotherapy)** : Cette technique utilise des faisceaux de rayonnement dont l'intensité est modulée, permettant d'augmenter la dose délivrée à la tumeur tout en réduisant l'exposition des tissus environnants, améliorant ainsi la répartition de la dose.
- **Radiothérapie guidée par l'image (IGRT – Image-Guided Radiotherapy)** : Elle repose sur l'utilisation d'outils d'imagerie médicale, tels que le scanner (CT) et l'imagerie par résonance magnétique (IRM), pour surveiller la tumeur en temps réel durant le traitement et effectuer des ajustements précis à chaque séance.
- **Radiothérapie par protons (Proton Therapy)** : Contrairement aux techniques classiques utilisant des photons, cette approche emploie des protons, ce qui permet une délivrance plus ciblée du rayonnement, réduisant ainsi l'irradiation des tissus sains adjacents à la tumeur.

- **Radiothérapie synchronisée avec la respiration (Respiratory-Gated Radiotherapy) :** Utilisée dans le traitement des tumeurs mobiles, telles que le cancer du poumon, cette technique synchronise l'administration du rayonnement avec le cycle respiratoire du patient, garantissant ainsi un ciblage plus précis de la tumeur.

II.2.2.2. Radiothérapie interne :

Ce type de radiothérapie implique l'introduction d'une source radioactive à l'intérieur du corps afin d'administrer directement le rayonnement aux cellules tumorales. Il se divise en deux catégories principales :

- **Curiethérapie (En anglais, Brachytherapy) :** La curiethérapie est une technique de radiothérapie interne qui consiste à insérer une source radioactive scellée à l'intérieur ou à proximité immédiate de la tumeur, permettant ainsi d'administrer une dose ciblée de rayonnement aux cellules cancéreuses tout en réduisant l'irradiation des tissus sains environnants. Elle est principalement utilisée pour traiter le cancer de la prostate, du col de l'utérus et du sein. Selon la localisation de la tumeur, elle peut être réalisée sous deux formes : la curiethérapie endocavitaire, où la source radioactive est placée dans une cavité naturelle du corps, comme l'utérus ou le vagin, pour traiter le cancer du col de l'utérus, et la curiethérapie interstitielle, qui consiste à implanter directement la source radioactive dans la tumeur à l'aide d'aiguilles fines, notamment pour le traitement du cancer de la prostate[27-31].
- **La radiothérapie interne vectorisée (RIV) :** est une technique qui consiste à administrer un agent radioactif par voie intraveineuse ou orale, lequel se dirige spécifiquement vers les cellules cancéreuses en fonction de leurs caractéristiques biologiques. Elle comprend plusieurs approches, notamment le traitement par l'iode radioactif (Iode-131), utilisé principalement pour le cancer de la thyroïde, qui exploite la capacité des cellules thyroïdiennes à capter l'iode afin de détruire sélectivement les cellules tumorales. Une autre méthode est la radio-immunothérapie (RIT), qui associe des anticorps monoclonaux à des particules radioactives pour cibler précisément les cellules

cancéreuses, notamment dans le traitement des lymphomes. Enfin, la radiothérapie interne sélective du foie (SIRT) est employée dans le traitement des tumeurs hépatiques et repose sur l'injection de microsphères radioactives dans les artères alimentant la tumeur, permettant une irradiation localisée tout en préservant le tissu hépatique sain[32].

II.2.3.les particules utilisées [33] :

Les particules utilisées dans la radiothérapie sont :

- **Photons** : En radiothérapie, les photons gamma et les photons X sont les principales particules utilisées pour le traitement des tumeurs. Les photons gamma sont émis lors de la désintégration d'éléments radioactifs naturels ou artificiels, notamment l'iridium-192 (Ir^{192}) et le césium-137 (Cs^{137}), employés en curiethérapie. Les photons X, quant à eux, sont produits par interaction des électrons avec la matière au sein des accélérateurs linéaires, qui représentent aujourd'hui la source prédominante d'irradiation en radiothérapie externe. Ces particules interagissent de manière illimitée avec la matière et génèrent un faisceau de sortie, dont l'impact est maîtrisé grâce aux avancées technologiques.
- **Électrons** : Les électrons sont des particules élémentaires chargées négativement. Ils sont également générés par les accélérateurs linéaires et se caractérisent par une action principalement superficielle, en raison de leur faible pénétration dans la matière, où ils sont rapidement stoppés.
- **Protons** : Les ions carbone sont produits à l'aide de cyclotrons et ont la capacité de pénétrer profondément dans le corps, à l'image des photons. Cependant, leur principal avantage réside dans le fait qu'ils ne génèrent pas de rayonnement au-delà de la zone ciblée. Cela leur permet de combiner les atouts des protons et des électrons : une efficacité radiobiologique comparable, tout en étant plus sensibles aux variations des tissus traversés. Grâce à ces caractéristiques, ils offrent une meilleure protection des organes sains éloignés de la tumeur, puisqu'ils ne laissent aucun rayonnement résiduel en dehors de la zone de traitement.

II.3. La tomodensitométrie (TDM) :

La tomodensitométrie (TDM), ou scanographie, désignée en anglais sous le terme *computed tomography* (CT), est une technique d'imagerie médicale basée sur l'analyse des coefficients d'atténuation des rayons X pour reconstruire des coupes axiales du volume exploré. Son évolution technologique continue au cours des deux dernières décennies a considérablement renforcé son rôle dans le domaine du diagnostic médical. Afin d'assurer une interprétation précise des images et une prise en charge optimale des patients, il est essentiel de veiller à l'application de protocoles d'acquisition rigoureux et au contrôle de la qualité des examens réalisés[34].



Figure II.1 : la scanographie [16].

II.3.1. Principe physique :

II.3.1.1. Interaction des rayons X avec la matière :

L'interaction des rayons X avec la matière est un phénomène fondamental en imagerie médicale (TDM) et en radiothérapie. Lorsqu'un photon X traverse un milieu matériel, il peut

interagir avec les électrons ou les noyaux des atomes du matériau selon trois processus principaux : l'effet photoélectrique, diffusion de Compton et la création de paires[35].

II.3.1.1.1. Phénomènes physiques de l'interaction rayonnement-matière :

- **L'effet photoélectrique** : C'est un phénomène caractérisé par l'absorption complète d'un photon par un électron atomique. Cette interaction entraîne l'éjection de l'électron de son orbite, ionisant ainsi l'atome (**Figure II.2**). Pour que ce phénomène se produise, l'énergie du photon incident doit être supérieure à l'énergie de liaison de l'électron cible[36].

$$T = h\nu_0 - E_\ell \quad \text{II.1}$$

E_ℓ : est l'énergie de liaison.

h : est la constante de Planck.

ν_0 : est la fréquence du photon.




Figure II.2: Schéma illustrant Effet photoélectrique [18].

- **L'effet Compton** : Ce phénomène repose sur la diffusion inélastique d'un photon par un électron faiblement lié. Au cours de cette interaction, le photon incident transfère une fraction de son énergie à l'électron, entraînant une modification de sa trajectoire ainsi qu'une variation de son énergie

(Figure II.3). Découvert par Arthur Compton en 1922, ce mécanisme constitue le processus dominant dans le domaine des énergies intermédiaires [37].

$$\mathbf{P} = \mathbf{m} \cdot \mathbf{v} \quad \text{II.2}$$

Où :

$\mathbf{P}$: la quantité de mouvement

$\mathbf{m}$: la masse

$\mathbf{v}$: vitesse




Figure II.3: Schéma illustrant l'Effet Compton [19].

- **La création de paires (e^- , e^+) :** Ce phénomène se produit lorsque l'énergie du photon excède 1,022 MeV dans cette situation, le photon interagit avec le champ coulombien d'un noyau et donne lieu à la création d'une paire électron-positon (Figure II.4). Après avoir perdu son énergie cinétique par interactions successives, le positon s'annihile avec un électron, générant ainsi deux photons gamma de 511 keV, émis dans des directions opposées [38] .




Figure II.4: Schéma illustrant Création de pair [20].

II.3.1.1.2. Domaines de prédominance des interactions photon-matière [38]:

En fonction du numéro atomique du matériau et de l'énergie du rayonnement électromagnétique, il est possible d'identifier trois zones principales où chaque mécanisme d'interaction est dominant comme illustrés dans la **Figure II.5** :

1. **L'effet photoélectrique** est prépondérant pour les basses énergies et dans les matériaux à numéro atomique élevé (Z élevé), notamment en imagerie médicale utilisant les rayons X de faible énergie.
2. **L'effet Compton** domine dans la gamme des énergies intermédiaires, couramment utilisées en imagerie médicale et en radiothérapie, et concerne principalement les matériaux de faible numéro atomique (Z faible), tels que les tissus biologiques.
3. **La production de paires** devient le mécanisme d'interaction principal lorsque l'énergie des photons dépasse plusieurs mégaelectronvolts (MV). Ce processus est favorisé dans les matériaux à numéro atomique élevé et joue un rôle important en radiothérapie à haute énergie.




Figure II.5: Domaine des trois phénomènes d'interaction [20].

II.3.1.1.3. L'atténuation des photons :

Lorsqu'un photon traverse un matériau absorbant, la probabilité d'interaction dépend de plusieurs facteurs, notamment son énergie, la composition et l'épaisseur du matériau. Après une interaction, le photon peut soit être totalement absorbé, soit être dévié en perdant une partie de son énergie. Si l'on considère un faisceau de photons d'intensité initiale I_0 traversant une couche de matériau d'épaisseur x , l'intensité transmise $I(x)$ diminue en raison des interactions photon matière. Cette atténuation est modélisée par la loi de **Beer-Lambert** :

$$I(x) = I_0 \cdot e^{-\mu x} \quad \text{II.3}$$

Cette atténuation suit donc une loi exponentielle et dépend du coefficient d'atténuation du milieu, dont l'inverse correspond au libre parcours moyen. Ce coefficient résulte de la somme des contributions liées aux différents types d'interactions des photons avec la matière[39].

$$\mu = \tau + \sigma + \pi \quad \text{II.4}$$

τ : Coefficient d'atténuation associé à l'effet photoélectrique.

σ : Coefficient d'atténuation lié à l'effet Compton.

π : Coefficient d'atténuation correspondant à la création de paires.

La probabilité d'occurrence de chaque type d'interaction est caractérisée par une grandeur appelée section efficace σ , qui varie en fonction de l'énergie du photon et de la nature du matériau traversé [40]. Afin de faciliter les comparaisons entre différents matériaux, les coefficients d'atténuation sont souvent exprimés sous forme normalisée en les rapportant à la densité du matériau, donnant ainsi les coefficients d'atténuation massiques (μ/ρ). Ceux-ci, généralement tabulés [41], restent néanmoins fortement dépendants de la composition atomique du milieu [42].

II.3.1.2. Principe d'acquisition des images en tomodensitométrie (TDM) [43, 44] :

L'acquisition des images en tomodensitométrie, illustré dans la figure (**Figure II.6**), repose sur deux étapes principales :

II.3.1.2.1. Génération des rayons X par un tube à rayons X :

Le système tube-détecteur, associé à la translation du lit, joue un rôle fondamental dans l'acquisition des images en imagerie médicale. Le tube à rayons X est un dispositif sous vide spécialement conçu pour produire un faisceau de rayons X de manière contrôlée et optimisée. Sa structure repose sur trois composants essentiels : la cathode, qui émet les électrons, l'anode, qui les accélère et les convertit en rayons X, et l'enveloppe sous vide, qui permet de maintenir les conditions optimales de fonctionnement en minimisant les interactions avec l'air ambiant.

La génération du rayonnement s'effectue en plusieurs phases, notamment :

- **Émission des Électrons par la Cathode :**

La cathode est un élément chauffé qui permet l'émission d'électrons. Ce phénomène repose sur l'effet thermoélectronique, qui stipule qu'un matériau porté à une température élevée libère des électrons. La cathode est généralement constituée d'un filament de

tungstène, matériau choisi pour son point de fusion élevé (environ 3 422 °C) et sa bonne conductivité thermique. Lorsque le filament est traversé par un courant électrique, il chauffe et libère des électrons par agitation thermique. Ces électrons sont alors attirés vers l'anode grâce à une différence de potentiel créée par une génératrice haute tension.

- **Accélération des Électrons vers l'Anode :**

Une différence de potentiel, généralement comprise entre 80 et 140 kV, est appliquée entre la cathode et l'anode. Sous l'effet de ce champ électrique intense, les électrons sont accélérés et atteignent une vitesse très élevée avant d'impacter la cible métallique de l'anode.

- **Interaction des Électrons avec l'Anode et Production des Rayons X :**

Lorsque les électrons frappent l'anode, ils subissent une décélération brutale, ce qui entraîne l'émission de rayons X selon deux mécanismes physiques distincts :

1. Le Rayonnement de Freinage (En anglais, Bremsstrahlung) :

Le rayonnement de freinage, ou Bremsstrahlung, est produit lorsque les électrons sont ralentis en interagissant avec le champ électrostatique des noyaux d'atomes de l'anode. Cette interaction entraîne une perte d'énergie qui se traduit par l'émission d'un photon X dont l'énergie varie de 0 jusqu'à l'énergie maximale de l'électron incident.

Ce rayonnement est polychromatique, ce qui signifie que le faisceau de rayons X émis contient un spectre continu d'énergies. L'intensité du rayonnement est proportionnelle au carré de la tension appliquée [45] :

$$I \propto U^2 \quad \text{II.5}$$

Ce qui donne :

$$I = k \cdot Z \cdot i \cdot U^2 \quad \text{II.6}$$

Où :

I : est l'intensité du rayonnement (ou le débit de dose dans certains contextes),

U : est la tension appliquée (en kilovolts, kV)

Z : Numéro atomique de la cible (anode)

i : Courant du tube

k : est une constante de proportionnalité qui dépend d'autres paramètres du système (comme le courant du tube, le matériau de l'anode, etc.).

2. Le Rayonnement Caractéristique :

Le rayonnement caractéristique est produit lorsqu'un électron incident éjecte un électron d'une couche interne (généralement K ou L) d'un atome de l'anode. Cette ionisation crée une vacance qui est comblée par un électron provenant d'une couche externe, entraînant l'émission d'un photon X dont l'énergie correspond à la différence entre les niveaux d'énergie des couches concernées. Le spectre du rayonnement caractéristique est discret, avec des pics d'intensité correspondant aux énergies spécifiques des transitions électroniques propres au matériau de l'anode. En TDM, l'anode est généralement en tungstène (W), dont les pics d'émission caractéristiques se situent autour de 59 et 67 keV.




Figure II.6: Principe de production des rayons X : tube de Coolidge [27].

II.3.1.2.2.Détection et Formation du Signal (DéTECTEURS et Conversion du Signal) [34]:

La détection et la formation du signal en tomodensitométrie reposent sur la conversion des rayons X en un signal exploitable permettant la reconstruction d'une image. Après avoir traversé le corps du patient, les rayons X sont captés par des détecteurs, qui varient selon leur

technologie. Les détecteurs à scintillation avec photodiodes, largement utilisés, convertissent les rayons X en lumière visible grâce à un matériau scintillateur tel que l'iodure de césium, puis une photodiode transforme cette lumière en un signal électrique, offrant une haute sensibilité et un faible bruit électronique. Les détecteurs à semi-conducteurs, à base de sélénium amorphe, assurent une conversion directe des rayons X en un signal électrique, permettant une meilleure résolution spatiale et une réduction du flou d'image. Les chambres d'ionisation, bien que moins utilisées aujourd'hui, fonctionnent en ionisant un gaz comme le xénon sous l'effet des rayons X, les charges produites étant collectées pour générer un signal électrique, mais leur efficacité demeure inférieure aux détecteurs modernes.

Le processus de conversion du signal comprend plusieurs étapes, à commencer par la numérisation, où le signal analogique est transformé en données numériques exploitables par ordinateur. Ensuite, une correction des artefacts est appliquée afin de compenser les effets de dispersion des rayons X et le durcissement du faisceau. Enfin, la reconstruction de l'image repose sur des algorithmes avancés, tels que la rétroprojection filtrée ou les méthodes itératives, permettant d'obtenir des coupes transversales précises du volume exploré.




Figure II.7: Scanner à rayons X. Le tube et les détecteurs tournent autour du patient. De multiples mesures d'atténuations sont effectuées selon différents angles de rotation du tube.

D'après CERF, Bases physiques des rayons X, Solacroup, Boyer, Le Marec, Schouman, et Claeys, 2001.




Figure II.8: Rangées de détecteurs alignées en face du tube à rayons X. D'après CERF, Bases physiques des rayons X, Solacroup, Boyer, Le Marec, Schouman, et Claeys, 2001.

II.3.1.3. Reconstruction des images :

La reconstruction d'images en TDM repose sur des méthodes mathématiques avancées qui transforment les données brutes acquises par le scanner en images interprétables par le radiologue. Deux grandes catégories de méthodes sont employées : la reconstruction par itérations et la rétroprojection filtrée, et il existe une autre méthode en utilisant l'intelligence artificielle.

II.3.1.3.1. Reconstruction par itérations (RI) [46, 47]:

La reconstruction itérative en tomodensitométrie (TDM) est une technique avancée permettant d'améliorer la qualité des images tout en réduisant l'exposition aux rayonnements ionisants. Elle constitue une alternative aux méthodes conventionnelles de reconstruction,

telles que la rétroprojection filtrée basée sur la transformée de Fourier, qui sont susceptibles d'être altérées par le bruit et les artéfacts résultant de données incomplètes.

- **Principe de la RI :**

La reconstruction itérative repose sur un processus algorithmique structuré en plusieurs étapes :

1. Une première image est reconstruite à partir des données brutes acquises par le scanner, généralement en utilisant une technique de rétroprojection filtrée.
2. Cette image est ensuite confrontée aux projections initiales captées par le détecteur du scanner.
3. Les écarts entre les projections mesurées et celles calculées sont analysés et corrigés, permettant ainsi de réduire les artéfacts et d'améliorer le contraste de l'image.
4. Ce processus est répété de manière itérative jusqu'à atteindre une convergence optimale, garantissant une image de haute qualité avec un niveau de bruit réduit au minimum.

II.3.1.3.2.Rétroprojection Filtrée (RPF) en TDM [48]:

La rétroprojection filtrée est une méthode analytique de reconstruction d'images en TDM. Elle repose sur des principes mathématiques permettant de transformer les données acquises sous forme de projections en une image exploitable avec une bonne précision spatiale. Cette méthode, historiquement privilégiée en raison de sa rapidité et de son efficacité, s'appuie principalement sur la transformée de radon et la transformée de Fourier pour optimiser la qualité des images obtenues.

- **Principe de la RPF :**

Lors d'un examen en tomodensitométrie, le scanner enregistre des projections radiographiques sous divers angles autour du patient, mesurant ainsi l'atténuation des rayons X à travers les structures anatomiques. L'image est ensuite reconstruite en coupe transversale à partir de ces projections, suivant un processus en deux étapes :

a) Rétroprojection des projections acquises :

Dans un premier temps, les valeurs d'atténuation enregistrées sont projetées dans le plan de l'image en attribuant à chaque point une intensité correspondant aux mesures effectuées sous différents angles. Cette méthode permet de reconstruire une image approximative, mais engendre un flou caractérisé par des artéfacts en halo, altérant ainsi la précision des contours anatomiques.

b) Filtrage des projections (déconvolution) :

Pour corriger cet effet de flou, un filtrage mathématique est appliqué aux projections avant la rétroprojection. Ce processus repose sur :

1. **La transformée de Radon** : qui décrit mathématiquement la reconstruction d'une image à partir de ses projections obtenues sous différents angles.
2. **La transformée de Fourier** : qui convertit ces projections en fréquence spatiale afin d'appliquer un filtre adapté. Le filtre de Ram-Lak (Ramachandran-Lakshminarayanan)[49], couramment utilisé, permet d'atténuer les basses fréquences responsables du flou et de renforcer les hautes fréquences, améliorant ainsi la netteté des contours de l'image.

II.3.1.3. 3. Reconstruction d'Images TDM par Intelligence Artificielle [50] :

L'intégration de l'intelligence artificielle (IA), et plus particulièrement des techniques d'apprentissage profond (deep learning), constitue une avancée significative dans le domaine de la reconstruction d'images en TDM. Cette approche vise à améliorer la qualité des images reconstruites tout en réduisant la dose de rayonnement administrée aux patients, répondant ainsi aux exigences croissantes de radioprotection.

- **Principe de la Reconstruction d'Images par IA :**

La reconstruction d'images en tomodensitométrie (TDM) utilisant l'intelligence artificielle repose sur l'utilisation de modèles d'apprentissage automatique capables d'établir une correspondance entre les données acquises (sinogrammes) et les images reconstruites dans le domaine anatomique. Les sinogrammes, qui sont des ensembles de mesures d'intensité obtenues en fonction des coordonnées spatiales (x, y, z) et angulaires, servent de données d'entrée pour ces modèles. Ces systèmes traitent ces données brutes, où chaque valeur

représente l'atténuation des rayons X à un point donné dans une direction spécifique. L'apprentissage est effectué en exposant le modèle à de nombreux exemples d'entrées (données mesurées) et de sorties (images de référence), ce qui permet au modèle d'estimer les valeurs des pixels ou des voxels correspondants dans l'image reconstruite, en fonction de chaque combinaison d'intensité et de position spatiale.

Parmi les approches les plus couramment utilisées :

1. **Les réseaux de neurones convolutionnels (CNN)** : qui analysent et extraient des caractéristiques des images médicales à travers des couches de traitement hiérarchisées.
2. **Les architectures de type U-Net** : combinant une phase d'encodage et de décodage afin d'optimiser la reconstruction en préservant les détails anatomiques.
3. **Les réseaux antagonistes génératifs (NAG)** : qui permettent d'améliorer la fidélité des images reconstruites en opposant un générateur (création d'images) à un discriminateur (validation de la qualité des images).

II.3.2. Qualité de l'image en TDM :

La qualité de l'image en tomodensitométrie est déterminée par plusieurs facteurs interdépendants, notamment la résolution spatiale, le contraste, le bruit et les artefacts. Ces éléments sont influencés par les paramètres d'acquisition et les caractéristiques du système de reconstruction[51] :

II.3.2.1. Résolution spatiale [52]:

La résolution spatiale désigne la capacité du scanner à distinguer deux structures adjacentes comme étant distinctes. Elle est influencée par plusieurs facteurs techniques du scanner et des paramètres d'acquisition.

- **Facteurs influençant la résolution spatiale :**

- 1. Taille du foyer des rayons X :**

La taille du foyer des rayons X influence directement la résolution spatiale des images en TDM. Un foyer plus petit (0.3 - 2 mm) permet d'obtenir des images plus nettes, mais engendre une concentration excessive de chaleur sur l'anode du tube, pouvant limiter sa puissance et sa durée d'utilisation. Pour contrer cet effet, les scanners modernes utilisent des anodes rotatives et des systèmes de refroidissement avancés, garantissant une meilleure dissipation thermique et une plus grande durabilité du tube à rayons X.

- 2. Type de détecteurs et matrice d'acquisition :**

Les détecteurs en TDM convertissent les rayons X en signaux exploitables pour la reconstruction des images. Deux types existent : les détecteurs solides (CdWO_4 , $\text{Gd}_2\text{O}_2\text{S}$) offrant une meilleure efficacité d'absorption des rayons X, et les détecteurs à gaz (Xénon), moins performants. Les scanners modernes utilisent des détecteurs multi-barrettes, permettant l'acquisition simultanée de plusieurs coupes et réduisant le temps d'examen.

La matrice de reconstruction (512×512 pixels ou plus) influence la précision des images : une matrice plus grande améliore la finesse des détails, mais peut augmenter le bruit si les pixels sont trop petits.




Figure II.9: Représentation des pixels dans une image [34].

3. Taille des voxel et épaisseur de coupe :

Un voxel est défini par :

$$\text{Taille du voxel} = \frac{\text{Champ de vue (FOV)}}{\text{Matrice de reconstruction}} \times \text{épaisseur de coupe} \quad \text{II.7}$$

Un petit voxel améliore la résolution mais augmente le bruit. L'épaisseur de coupe standard varie entre 0.5 mm et 10 mm selon l'examen (ex : 1 mm en neuro-imagerie, 5 mm en thoracique).




Figure II.10 : le voxel [34].

4. Effet du Pitch :

Le pitch est le rapport entre l'avancement de la table par rotation et la largeur du faisceau X.

$$\text{Pitch} = \frac{\text{Avancement table par rotation}}{\text{largeur de faisceau en Z}} \quad \text{II.8}$$

Un pitch élevé (>1.5) accélère l'acquisition et réduit la dose de rayonnement, mais diminue la résolution spatiale axiale et peut provoquer des artefacts de sous-échantillonnage. À l'inverse, un pitch faible (<1) améliore la résolution et la précision diagnostique, particulièrement en angiographie CT et imagerie cardiaque, mais augmente la dose

d'irradiation. En pratique, un pitch entre 1.0 et 1.5 représente un compromis optimal entre qualité d'image et limitation de la dose pour le patient.

II.3.2.2. Contraste en TDM [52]:

Le contraste représente la différence d'atténuation entre les structures tissulaires, exprimée en unités Hounsfield (UH).

- **Facteurs influençant le contraste :**

- **Tension du tube (kV) :**

- 80 kV → Améliore le contraste des tissus mous, mais augmente le bruit.

- 120-140 kV → Utilisé pour les tissus denses (ex : os, métal), réduit le contraste des tissus mous.

- **Courant du tube (mA) :**

- Faible mA → Plus de bruit, moins de contraste.

- Élevé mA → Moins de bruit, mais augmentation de la dose.

- **Produits de contraste iodés :**

- Les produits de contrastes sont injectés par voie intraveineuse (IV) pour augmenter la densité des vaisseaux et des tissus vascularisés. Ce faisant, permet la distinction des structures ayant une atténuation proche de l'eau (ex : pancréas vs tumeur).

- **Fenêtrage (En anglais, Windowing) :**

- L'œil humain perçoit 256 niveaux de gris, alors qu'un scanner produit 4096 niveaux. L'échelle Hounsfield est donc recentrée sur la structure d'intérêt.

- Fenêtre osseuse : [800, 3000 UH].

Fenêtre cérébrale : [30, 80 UH].

Fenêtre pulmonaire : [-500, 500 UH].




Figure II.11: Distribution des valeurs Hounsfield (HU) et des numéros atomiques effectifs (Le) pour différents tissus biologiques et matériaux en imagerie TDM [53] .

II.3.2.3. Bruit en TDM :[51]

Le bruit est une fluctuation aléatoire de l'intensité des pixels, affectant la qualité de l'image.

- **Origines du bruit :** La diminution du courant en mA réduit le nombre de rayons X produits, ce qui augmente le bruit de l'image. De même, les coupes fines et la haute résolution spatiale entraînent une baisse du signal capté par voxel, accentuant le bruit. Ces facteurs illustrent l'équilibre délicat entre qualité d'image et paramètres d'acquisition en imagerie médicale.
- **Réduction du bruit :** Les techniques de traitement d'image, comme la reconstruction itérative et le filtrage numérique, permettent de réduire le bruit, avec un compromis entre préservation des détails et netteté des contours.

II.3.2.4. Artefacts et corrections : [52, 54, 55]

Type d'artefact	Cause	Correction
Volume partiel	Inclusion de plusieurs densités dans un voxel	Coupes plus fines
Durcissement du faisceau	Atténuation différentielle des photons	Filtrage des basses énergies
Métalliques	Forte absorption par implants dentaires, prothèses	Acquisition double énergie, interpolation
Mouvement	Respiration, battements cardiaques	Temps d'acquisition plus court, gating ECG
Anneau	Défaut d'un détecteur	Calibration du scanner
Sous-échantillonnage	Trop peu de projections	Augmentation du nombre de vues
Diffusion (scatter)	Déviation des rayons X	Collimation anti-diffusion

Tableau II .1 : Ce tableau présente différents types d'artefacts en imagerie, leurs causes principales ainsi que les méthodes de correction utilisées pour améliorer la qualité des images médicales.

II.4. Rôle de TDM en radiothérapie :

La TDM est une technique d'imagerie essentielle en radiothérapie. Elle permet une délimitation précise des volumes cibles, une visualisation optimale des organes à risque (OAR) et une planification dosimétrique précise. Son intégration dans les systèmes de planification permet d'améliorer la précision des traitements et de minimiser les effets secondaires[56].

II.4.1.Définition des volumes cible selon L'IRCU [22]:

L'ICRU a standardisé la définition des volumes cibles en radiothérapie afin d'optimiser l'administration des doses tout en limitant l'irradiation des tissus sains. Trois principaux volumes sont définis :

- **Volume Tumoral Macroscopique (GTV – Gross Tumor Volume) :**

Le GTV correspond à la masse tumorale identifiable sur les examens d'imagerie médicale (TDM, IRM, TEP/TDM) ou détectée cliniquement. Il inclut : la tumeur primitive et ses extensions locales visibles.

- **Volume Cible Anatomoclinique (CTV – Clinical Target Volume) :**

Le CTV inclut le GTV ainsi qu'une marge de sécurité destinée à englober l'extension microscopique de la tumeur, qui n'est pas forcément visible en imagerie. Sa définition dépend de plusieurs facteurs : Les mécanismes de propagation tumorale, La biologie tumorale et son agressivité et la localisation anatomique.

- **Volume Cible Prévisionnel (PTV – Planning Target Volume) :**

Le PTV correspond au CTV élargi pour prendre en compte : Les incertitudes de positionnement du patient lors des séances de radiothérapie, Les mouvements internes des organes (respiration, battements cardiaques, digestion) et les variations morphologiques de la tumeur au fil du traitement.

II.4.2. Contribution de la TDM à la délimitation des volumes cibles :

La tomodensitométrie joue un rôle central dans la définition des volumes cibles en radiothérapie, en raison de sa capacité à fournir une imagerie détaillée des structures anatomiques et des tissus tumoraux [39] .

- **Précision anatomique et visualisation en trois dimensions (3D) :**

La TDM permet d'obtenir des images en coupes transversales avec une résolution spatiale élevée, ce qui facilite la différenciation entre la tumeur et les tissus sains environnants. Grâce aux reconstructions 3D, les volumes tumoraux peuvent être visualisés sous différents angles, ce qui améliore l'adaptation des faisceaux d'irradiation[38].

- **Quantification de la densité des tissus avec les unités de Hounsfield (HU) :[39]**

La TDM fournit des valeurs en unités de Hounsfield (HU) qui permettent d'identifier la densité des tissus et d'optimiser les calculs de dose en radiothérapie.

Une cartographie précise des densités tissulaires permet une meilleure estimation de l'atténuation des rayonnements à travers le corps du patient.

- **Fusion avec d'autres modalités d'imagerie** :[40]

La TDM est souvent combinée avec l'IRM et la TEP-TDM pour améliorer la précision de la délimitation des volumes cibles.

L'IRM offre une meilleure visualisation des tissus mous et est particulièrement utile pour les tumeurs cérébrales et pelviennes.

La TEP-TDM fournit des informations métaboliques sur la tumeur et aide à différencier les tissus tumoraux actifs des tissus nécrosés ou inflammatoires.

- **Amélioration des techniques de planification du traitement** :[41]

L'intégration des images TDM dans les logiciels de planification permet de créer un plan d'irradiation personnalisé et de moduler l'intensité des faisceaux pour s'adapter aux contours de la tumeur (radiothérapie conformationnelle 3D, IMRT).

II.4.3. Définition des OAR selon l'ICRU:[22]

Les organes à risque sont des structures anatomiques sensibles aux radiations. L'ICRU les classe en trois catégories selon la gravité des dommages potentiels :

Classe 1 : Organes critiques (complications graves, voire fatales)

Exemples : Moelle épinière (risque de paralysie), tronc cérébral (troubles neurologiques sévères), cœur (insuffisance cardiaque).

Classe 2 : Organes à risque modéré (effets secondaires réversibles ou partiellement invalidants)

Exemples : Reins (insuffisance rénale), poumons (pneumopathie radique), foie (hépatopathie).

Classe 3 : Organes à risque faible (effets transitoires ou légers)

Exemples : Peau (érythème), glandes salivaires (xérostomie), muqueuse intestinale (troubles digestifs temporaires).

II.4.4. Rôle de la TDM dans la visualisation et la protection des organes à risque (OAR) :

La tomodensitométrie (TDM) constitue un outil fondamental en radiothérapie pour la visualisation précise et la protection efficace des organes à risque (OAR) [34, 38, 39]. Grâce à sa résolution spatiale élevée, la TDM permet de différencier les structures anatomiques proches de la tumeur, facilitant ainsi l'orientation optimale des faisceaux d'irradiation. Les valeurs en unités Hounsfield (HU) offrent une évaluation fine de la densité tissulaire, utile pour la modulation de la dose et la réponse à l'irradiation.

La reconstruction 3D et la segmentation automatique des images TDM dans les logiciels de planification permettent un repérage précis des OAR, notamment après injection de produit de contraste, qui améliore la visualisation des tissus mous comme les structures digestives ou vasculaires.

Au-delà de la visualisation, la TDM joue un rôle essentiel dans la protection des OAR en permettant :

- Une localisation anatomique précise des organes critiques et une meilleure différenciation des structures adjacentes ;
- Une adaptation personnalisée du plan d'irradiation afin de limiter l'exposition des tissus sains ;
- Une meilleure prise en compte des variations anatomiques (remplissage vésical, respiration, perte de poids...) ;
- L'optimisation des techniques avancées telles que l'IMRT et la VMAT, qui permettent une distribution plus ciblée de la dose grâce à la modulation de l'intensité du faisceau à partir des données TDM.




Figure II.12: Code des couleurs proposé par ICRU 62 [37] .

II.4.5. Application au cancer du pancréas :

La tomodensitométrie (TDM) joue un rôle central dans la délimitation du cancer du pancréas et des organes à risque, en fournissant une imagerie de haute résolution qui permet de visualiser avec précision les lésions pancréatiques, les tissus sains, ainsi que les structures avoisinantes comme les vaisseaux, le foie ou les reins. Grâce aux différences de densité tissulaire et aux contrastes vasculaires, le TDM est l'examen de choix pour l'identification des tumeurs pancréatiques et l'évaluation de leur extension locale. Cependant, la délimitation manuelle des volumes cibles (comme le GTV ou le CTV) à partir du TDM reste complexe, notamment à cause des contours flous et de la variabilité anatomique du pancréas. Pour pallier cela, l'intelligence artificielle (IA), notamment via des méthodes de segmentation automatique basées sur des réseaux de neurones convolutifs (CNN), permet une détection et une segmentation précises du pancréas et des tumeurs pancréatiques. Des modèles comme U-Net, Attention U-Net ou encore des architectures hybrides sont utilisés pour segmenter les structures d'intérêt tout en épargnant les organes à risque. Ces outils automatisés, souvent entraînés sur des bases de données TDM, améliorent la fiabilité, la rapidité et la reproductibilité des délimitations, tout en facilitant la planification du traitement en radiothérapie [57] .




Figure II.13: scanner abdominal du pancréas avec segmentation du PDAC : (A) Scanner abdominal non segmenter, (B) Pancréas segmenté en bleu, tumeur en rouge et canal pancréatique en vert [38].

II.4.6. Contribution de la TDM en dosimétrie :

La dosimétrie des rayonnements ionisants est un domaine clé en radio-oncologie. Elle désigne soit la mesure et la quantification des effets des rayonnements ionisants, soit le processus d'élaboration d'une distribution de dose personnalisée à administrer aux patients atteints de cancer dans le cadre de la planification des traitements en radiothérapie. Son rôle principal est d'assurer que la dose absorbée est précisément mesurée et contrôlée afin de maximiser l'efficacité du traitement tout en minimisant les effets secondaires. Étroitement liée à cette approche, la tomodensitométrie (TDM) joue un rôle crucial en affinant le calcul de dose et en renforçant la précision et la sécurité des traitements en radiothérapie[58]. Nous distinguons cette contribution sur quatre aspects essentiels :

II.4.6.1. Détermination de la dose de rayonnement :

La tomodensitométrie (TDM) est essentielle pour la détermination de la dose de rayonnement en raison de sa capacité à fournir des images précises en trois dimensions des structures internes du patient. Ces images sont utilisées pour définir avec exactitude les volumes cibles et les organes à risque, ce qui permet une planification optimale du traitement. De plus, la TDM influence directement les choix dosimétriques en radiothérapie en aidant à modéliser la distribution de la dose et en améliorant la précision des calculs des doses délivrées[58].

II.4.6.2. Détermination des Paramètres Physiques pour le Calcul de Dose [59]:

L'intégration de la TDM dans les Systèmes de Planification de Traitement (TPS) permet :

- Définir précisément la géométrie du patient, en générant des coupes transversales du volume cible et des organes à risque.
- Attribuer de propriétés physiques aux tissus à partir de l'échelle de Hounsfield, permettant d'évaluer la densité électronique relative.
- Optimiser les calculs de dose, en adaptant la distribution du rayonnement en fonction des caractéristiques spécifiques des tissus traversés.

Ceci est possible en exploitant la relation entre les unités Hounsfield (UH) et la dose de rayonnement. Les unités Hounsfield (UH) constituent une échelle numérique permettant de quantifier la densité radiologique des tissus en TDM. Elles jouent un rôle déterminant en radiothérapie en facilitant :

- **Conversion en densité électronique** : Les UH permettent d'estimer la densité électronique relative des tissus, qui est essentielle pour ajuster le coefficient d'atténuation du rayonnement.
- **Correction des effets d'hétérogénéité** : en convertissant les UH en densité équivalente à l'eau, il devient possible d'améliorer la précision des calculs de dose
- **L'optimisation des algorithmes de calcul de dose** : les relations UH-densité sont utilisées pour affiner la modélisation du transport des photons et des électrons à travers les tissus.

Dans les milieux de faible densité, tels que les poumons, la réduction de l'absorption des photons peut entraîner une surestimation de la dose en l'absence de corrections adéquates. Par ailleurs, la TDM contribue à la correction des effets de dispersion et de rayonnement secondaire. En radiothérapie, la distribution de la dose est influencée non seulement par l'absorption directe, mais également par la dispersion des rayonnements. Il est donc essentiel que les Systèmes de Planification de Traitement (TPS) intègrent ces phénomènes afin d'assurer une délivrance de dose conforme à la prescription médicale.

- **Effets de dispersion (diffusion Compton et Rayleigh) :**

Lorsque les photons interagissent avec les tissus, une partie de leur énergie est transférée aux électrons (effet Compton), modifiant ainsi leur trajectoire et créant des rayonnements diffusés. Cette dispersion peut induire une dose supplémentaire dans les zones adjacentes à la cible, nécessitant des modèles précis pour estimer son impact.

- **Rayonnement secondaire et transport des électrons :**

Certains photons peuvent engendrer des électrons secondaires, entraînant un dépôt d'énergie au-delà du volume cible. Afin d'assurer une estimation précise de la dose, des algorithmes avancés, tels que la convolution-superposition et les méthodes Monte Carlo, modélisent ces interactions en tenant compte de la densité électronique extraite des images TDM. Ces approches permettent de corriger les erreurs d'estimation de la dose, en particulier aux interfaces air-tissu et os-tissu, où les variations de densité influencent significativement la propagation des rayonnements.

II.4.6.3. Rôle de la TDM dans la planification du traitement et l'optimisation des doses [60]:

La tomodensitométrie (TDM) est un outil essentiel en radiothérapie, permettant d'acquérir des images précises du patient indispensables à la planification et à l'optimisation des doses. Elle est particulièrement utilisée dans les techniques d'irradiation modernes telles que la radiothérapie conformationnelle tridimensionnelle (3D-CRT), la modulation d'intensité (IMRT) et la thérapie par arc modulé (VMAT).

II.4.6.3.1. Planification 3D de la distribution de dose (3D-CRT, IMRT, VMAT) :

Grâce à la TDM, une cartographie détaillée de l'anatomie du patient est élaborée, permettant de définir avec précision les structures tumorales et les organes à risque :

- **3D-CRT** : Conformation des faisceaux à la forme de la tumeur pour limiter l'irradiation des tissus sains.

- **IMRT** : Modulation optimisée de l'intensité du faisceau à partir des données de densité de la TDM, assurant un dépôt de dose précis.
- **VMAT** : Administration continue de la dose en arc, améliorant la couverture tumorale et la protection des tissus sains.

II.4.6.3.2. Modélisation du faisceau et calcul de dose (Beam Modeling, Dose Calculation)

:

La TDM fournit des informations essentielles sur la composition et la densité des tissus, qui sont intégrées dans les algorithmes de calcul de dose. Cette étape comprend :

- **Modélisation du faisceau** : Ajustement des caractéristiques physiques des faisceaux de rayonnement (énergie, spectre, distribution spatiale) pour un calcul précis de la dose.
- **Correction des effets d'hétérogénéité** : Intégration des variations de densité pour améliorer la précision des calculs et minimiser les erreurs liées à la dispersion et au rayonnement secondaire.

II.4.6.4. Importance de la TDM dans les techniques de correction et de contrôle dosimétrique [59]:

La tomodensitométrie (TDM) joue un rôle essentiel dans la correction et le contrôle dosimétrique en radiothérapie. Elle permet d'assurer une administration précise de la dose en intégrant des informations anatomiques détaillées, réduisant ainsi les incertitudes liées au positionnement du patient et aux mouvements internes

II.4.6.4.1. TDM et vérification de la dose (Image-Guided Radiotherapy - IGRT) :

La radiothérapie guidée par l'image (IGRT) repose sur l'acquisition d'images avant ou pendant l'irradiation afin d'ajuster le positionnement du patient et d'assurer une délivrance précise de la dose. La TDM intervient à plusieurs niveaux :

- **Localisation optimisée de la tumeur** : Acquisition d'images 3D précises avant chaque séance pour corriger les erreurs de positionnement.

- **Vérification en temps réel de la dose** : Intégration de détecteurs spécifiques permettant d'adapter l'intensité du faisceau aux variations anatomiques.
- **Amélioration des calculs dosimétriques** : Utilisation des données de densité tissulaire pour réduire l'écart entre la dose prescrite et la dose réellement délivrée.

Dans ce contexte, la tomodensitométrie à faisceau conique (CBCT) est couramment employée pour guider l'irradiation et contrôler la distribution de la dose avant le traitement.

II.4.6.4.2. Gestion des mouvements et impact sur la dose (Motion Management) :

Les mouvements internes du patient, tels que les mouvements respiratoires, peuvent avoir un impact significatif sur la distribution de la dose. La TDM permet d'anticiper ces variations grâce à des approches spécifiques :

- **Techniques de suivi du mouvement** :

La TDM 4D analyse les déplacements tumoraux au cours du cycle respiratoire, facilitant ainsi la mise en place de modèles prédictifs, notamment pour les tumeurs pulmonaires et abdominales.

- **Optimisation du calcul de dose en fonction du mouvement** :

L'intégration des données TDM dans les algorithmes de planification permet de compenser les erreurs induites par les mouvements tumoraux. Les techniques adaptatives modernes ajustent la dose en temps réel sur la base des images acquises.

Ces avancées permettent d'améliorer la précision des traitements, de réduire l'irradiation des tissus sains et d'assurer une meilleure efficacité thérapeutique.

II.5. Conclusion :

La tomodensitométrie (TDM) joue un rôle central en radiothérapie, principalement dans les phases de planification et de suivi du traitement, grâce à sa capacité à fournir des images anatomiques précises avec une excellente résolution spatiale. Toutefois, la TDM se

limite à l'acquisition et à la reconstruction des images ; l'identification des structures cliniquement pertinentes, telles que les volumes cibles et les organes à risque (OAR), nécessite une étape supplémentaire de segmentation. C'est dans ce cadre que les systèmes automatiques de segmentation, basés sur l'intelligence artificielle, interviennent en apportant une réelle valeur ajoutée.

Ces outils automatisés permettent une délimitation rapide, reproductible et précise des structures anatomiques, ce qui améliore considérablement l'efficacité du processus de planification. En plus de réduire le temps nécessaire à cette étape critique, l'automatisation facilite également une estimation plus rigoureuse des doses délivrées aux volumes cibles et aux OAR, contribuant ainsi à une meilleure personnalisation du traitement et à une réduction des effets secondaires. L'intégration de ces systèmes intelligents dans les plateformes de planification accentue l'impact clinique de la TDM, en la transformant en un vecteur essentiel d'optimisation thérapeutique.

Ainsi, combinée à des systèmes de segmentation intelligents, la TDM constitue un pilier technologique incontournable dans la mise en œuvre d'une radiothérapie plus précise, efficace et sécurisée.

Chapitre III :

Revue des méthodes de segmentation dans le contexte du cancer du pancréas

III.1. Introduction à la délimitation en radiothérapie :

La délimitation des volumes cibles en radiothérapie représente une étape cruciale dans la planification des traitements, car elle conditionne directement la précision de l'irradiation et la préservation des tissus sains. Historiquement, ce processus reposait exclusivement sur des méthodes manuelles, largement utilisées entre les années 1970 et 1990. Bien que ces approches aient permis des traitements efficaces dans de nombreux cas, elles étaient grevées par des limites notables : une forte variabilité inter-observateurs, une dépendance à l'expertise clinique, ainsi qu'un investissement en temps considérable. L'introduction des premières méthodes semi-automatisées dans les années 1980, comme les contours actifs (snakes) proposés par Kas, M., et al., [61] a marqué un tournant important dans ce domaine. Ces algorithmes reposaient sur des modèles énergétiques visant à minimiser une fonction afin de détecter les contours des objets dans les images médicales. Malgré leur intérêt théorique, leur sensibilité au bruit et leur dépendance à une bonne qualité d'image limitaient leur efficacité clinique.

À partir des années 2000, les algorithmes d'auto-contourage ont gagné en maturité. Des techniques plus robustes, telles que l'appariement multi-modèles et l'enregistrement d'images déformables, ont été développées pour mieux s'adapter à la complexité anatomique. Des études comme celle de Fastet. M.F., al., [62] ont montré que ces outils pouvaient générer des contours proches de ceux d'experts humains dans le cadre du cancer du poumon, en s'appuyant sur des IRM ciné. Cependant, des obstacles persistaient, notamment une sensibilité aux mouvements physiologiques (respiratoires ou digestifs), qui altéraient la reproductibilité des contours.

L'avènement de l'intelligence artificielle (IA), en particulier des réseaux neuronaux convolutionnels (CNN), a transformé le paysage de la segmentation en imagerie médicale. À partir de 2010, les architectures comme le U-Net se sont imposées comme références grâce à leur capacité à capturer à la fois les détails locaux et les structures globales des images. Les travaux de Xu, Quan et leurs collaborateurs [63] ont démontré la supériorité des modèles IA en termes de précision, de rapidité et de réduction des biais subjectifs, notamment dans des localisations complexes comme le pancréas, le foie ou le cerveau. De plus, l'apparition

d'approches hybrides combinant les avantages des méthodes traditionnelles (connaissances anatomiques a priori) et des modèles IA (apprentissage à partir de données massives) a permis de pallier certaines lacunes des systèmes purement neuronaux.

Parallèlement à ces évolutions techniques, la problématique de l'incertitude de délimitation a également été adressée. Bernstein et al. [64] ont introduit une approche probabiliste basée sur des fonctions de densité de probabilité pour modéliser l'incertitude interobservateur. Cette méthode permet d'adapter dynamiquement les marges de volume cible de planification (PTV) aux caractéristiques individuelles du patient, améliorant ainsi la précision et la sécurité des traitements personnalisés.

La segmentation des tumeurs pancréatiques représente un défi majeur en imagerie médicale, en raison de la complexité anatomique du pancréas et de la grande variabilité morphologique et histologique des tumeurs. Les contours tumoraux sont souvent mal définis sur les images médicales, rendant leur délimitation précise difficile et sujette à une variabilité interobservateur importante. Cette variabilité impacte directement l'extraction des caractéristiques radiomiques, en particulier celles liées à la texture, qui se révèlent très sensibles aux différences de segmentation. Les résultats suggèrent que l'utilisation exclusive de méthodes manuelles peut compromettre la fiabilité des données, soulignant ainsi la nécessité d'adopter des protocoles standardisés ou de recourir à des outils semi-automatiques voire entièrement automatisés, afin de renforcer la cohérence et d'améliorer la reproductibilité éléments essentiels lorsque les radiomics sont utilisés à des fins diagnostiques ou prédictives dans le cadre du cancer du pancréas[57].

La complexité inhérente aux problématiques rencontrées a suscité un intérêt croissant pour le développement continu de méthodes innovantes. Depuis 2019, de nombreuses approches ont été proposées. Ce chapitre présente une synthèse des travaux récents et pertinents dans le domaine de la délimitation automatique du cancer pancréatique.

III.2. Les méthodes de segmentation du cancer de pancréas dans la littérature :

Y. Liang et al. Ont proposé une méthode de segmentation automatique du volume tumoral pancréatique (GTV) à partir d'IRM, visant à répondre aux limites des contours manuels, souvent chronophages et sujets à variabilité interobservateur. Les auteurs ont développé un modèle entièrement automatique basé sur un réseau de neurones convolutifs (CNN) à quatre blocs de couches convolutives, recevant en entrée des patches 3D extraits d'IRM pondérées en T1, associés aux contours manuels de référence établis par des experts. Après classification voxel par voxel, les cartes de probabilité générées ont été affinées par floutage gaussien, seuillage et opérations morphologiques 3D pour produire des contours binaires du GTV. Le modèle a été entraîné à partir de 88 131 patches de tissu pancréatique sain et 64 754 patches tumoraux, extraits de 36 ensembles d'IRM obtenus chez 27 patients. Il a été évalué sur 8 ensembles supplémentaires. Les résultats ont montré des performances solides avec un DSC moyen de 0,72, une spécificité de 0,94, une sensibilité de 0,79, une distance de Hausdorff moyenne de 7,7 mm et une distance moyenne d'accord (MDA) de 1,9 mm. Ces métriques traduisent une bonne capacité du modèle à éviter les faux positifs, comme en témoigne la spécificité élevée. Toutefois, le DSC et la sensibilité, bien que raisonnables, restent limités par certains facteurs cliniques et techniques : la faible différenciation de certaines tumeurs pancréatiques sur les images pondérées en T1, la variabilité anatomique entre patients, et la complexité des contours réels peuvent affecter la précision de la prédiction voxel par voxel. De plus, la performance s'améliore avec l'augmentation du nombre de coupes IRM utilisées en entrée, suggérant que la richesse spatiale de l'information est cruciale pour une bonne détection tumorale [65].

Dans un autre travail, Ying Liang et al. ont développé un modèle de segmentation automatique du volume tumoral total (GTV) dans le cancer du pancréas en s'appuyant sur les réseaux de neurones convolutifs (CNN) et l'imagerie par résonance magnétique multiparamétrique (IRM). L'objectif principal est d'améliorer la précision et la rapidité du processus de segmentation, un élément clé dans la radiothérapie adaptative guidée par IRM (MRgOART), en raison des limites des méthodes traditionnelles qui requièrent une expertise

clinique avancée et un travail manuel intensif. La méthodologie repose sur un modèle CNN à trois couches convolutionnelles, entraîné sur environ 475 000 patches (dont 245 000 normaux et 230 000 tumoraux) extraits de 37 IRM DCE pondérées en T1 acquises chez 27 patients. L'évaluation des performances a été réalisée à l'aide de métriques quantitatives telles que le coefficient de similarité de Dice (DSC), la distance de Hausdorff (HD) et la distance moyenne de surface (MSD). Les résultats obtenus indiquent un DSC de 0,73, une HD de 8,11 mm et une MSD de 1,82 mm, mettant en évidence des performances comparables à celles des experts en oncologie. Cette valeur du DSC, bien que modérée, est jugée satisfaisante compte tenu de la petite taille des tumeurs pancréatiques, de leurs contours souvent mal définis et de l'hétérogénéité anatomique du pancréas, ce qui rend la tâche de segmentation particulièrement difficile, même pour les cliniciens. De plus, les écarts observés dans les métriques restent proches de la variabilité inter-observateurs, suggérant que le modèle atteint un niveau de performance équivalent à celui des experts humains. Toutefois, certaines limites doivent être soulignées, notamment la taille réduite de l'échantillon (27 patients pour l'entraînement et 13 pour le test), ce qui pourrait compromettre la généralisation des résultats. De plus, l'absence d'une validation sur des bases de données issues de plusieurs centres hospitaliers limite l'évaluation de la robustesse du modèle dans des environnements cliniques diversifiés. Ainsi, des études complémentaires à plus grande échelle sont nécessaires pour confirmer la fiabilité et l'applicabilité clinique de cette approche [66].

Feng Jiang et ses collaborateurs ont développé un modèle de segmentation avancé pour le cancer du pancréas dans les images de tomodensitométrie abdominale (CT scan), appelé DLU-Net (Déformable convolution, Long Short-Term Memory (LSTM), U-Net architecture). Ce modèle vise à améliorer la précision de la segmentation, en particulier pour les contours irréguliers du pancréas, là où les approches existantes montrent des limites. Pour cela, plusieurs techniques innovantes ont été intégrées : les convolutions déformables, permettant une meilleure adaptation aux structures complexes, et les convolutions denses, favorisant une meilleure transmission des caractéristiques extraites. De plus, une architecture Bi-Directional Convolutional Long Short-Term Memory (BConvLSTM) a été ajoutée pour renforcer la fusion d'informations spatiales et contextuelles à différentes échelles. L'évaluation du DLU-Net a été réalisée sur les bases de données Medical Segmentation

Decathlon (MSD) et sur des images issues de l'Hôpital de Shanghai. Les résultats montrent que DLU-Net atteint des scores de Dice Similarity Coefficient (DSC) plus élevés que les modèles classiques, notamment grâce à sa capacité à mieux détecter et suivre les contours tumoraux. Toutefois, certaines variations des scores, en particulier dans les cas de tumeurs de très petite taille ou présentant des formes très irrégulières, révèlent que la précision du modèle peut diminuer face à des structures extrêmement complexes, affectant ainsi légèrement les métriques comme le DSC et l'IoU [67].

Dans le cadre de l'amélioration de la précision de la segmentation des tumeurs pancréatiques en vue de la radiothérapie adaptative, Yao Yao et ses collaborateurs ont proposé le modèle TDSMask R-CNN, conçu pour répondre aux défis posés par la forte variabilité morphologique du pancréas, la petite taille des tumeurs, ainsi que leur faible contraste par rapport aux tissus environnants. Ce modèle s'appuie sur une approche multi-échelle combinée à un mécanisme d'attention (Attention Mechanism) pour exploiter de manière synergique les informations issues de l'imagerie par émission de positrons (PET) et de l'imagerie par résonance magnétique (IRM). Cette combinaison permet d'améliorer la détection des tumeurs et de limiter les faux positifs. Les résultats expérimentaux ont révélé des performances prometteuses, avec un Dice Similarity Coefficient (DSC) de 78,33%, une sensibilité (SEN) de 78,56% et une spécificité (SPE) de 99,72%. Ces scores traduisent la capacité du modèle à segmenter efficacement les tumeurs, en particulier grâce à l'exploitation de la forte complémentarité entre les modalités PET et IRM. Toutefois, le niveau de sensibilité indique que certaines petites lésions ou tumeurs présentant des frontières floues peuvent encore échapper à la détection complète, ce qui affecte modérément les scores de DSC [68].

Zhang et al., ont proposé un modèle de segmentation automatique du volume tumoral pour le cancer du pancréas en utilisant un U-Net enrichi par une pyramide de mise en commun et un mécanisme d'attention intégré. Ce modèle vise à surmonter les défis liés à la variabilité interobservateur et à améliorer la précision de la segmentation dans un contexte d'imagerie par IRM multiparamétrique. La méthode repose sur un réseau PPU-Net, qui intègre des modules d'attention spatiale et de canaux afin de mieux capter les caractéristiques contextuelles complexes de la tumeur. Le modèle a été entraîné et validé sur des ensembles

d'images IRM provenant de 136 patients, avec un total de 1792 images IRM utilisées pour construire le modèle CNN. Son efficacité a été évaluée à l'aide de métriques standards telles que le coefficient de Dice (DSC), la distance de Hausdorff (HD) et la distance moyenne de surface (MSD). Les résultats ont montré une amélioration significative des performances de segmentation par rapport aux modèles U-Net classiques, avec un DSC moyen atteignant 0,792, ce qui indique une meilleure concordance globale avec les contours annotés par des experts. Cependant, il est important de noter que, bien que ce DSC reflète une performance encourageante, des variations dans la précision de la segmentation peuvent exister, comme le suggèrent les autres métriques. De plus, la généralisation du modèle reste limitée par la diversité restreinte des données utilisées, ce qui peut potentiellement influencer les métriques d'évaluation en limitant la capacité du modèle à bien performer sur des données plus variées[69].

Dans le cadre de l'optimisation du flux de travail en radiothérapie adaptative guidée par IRM (MRgART) pour les cancers du pancréas, H. Nourzadeh et son équipe ont évalué l'efficacité de trois architectures de modèles d'apprentissage profond (SegResNet, SegResNet 2D et SwinUNETR) pour la segmentation automatique du volume tumoral brut (GTV) et des organes à risque (OARs). L'étude, réalisée sur 126 images IRM issues de 21 patients traités par MRgART, visait à limiter les contraintes liées au recontouring manuel. Parmi les modèles évalués, SwinUNETR a obtenu les meilleurs résultats, avec un score de Dice moyen de 0,78 et une évaluation qualitative de 1,6 sur 4, traduisant une concordance globalement satisfaisante avec les contours cliniques. Les structures telles que les reins, le foie et la moelle épinière ont présenté des scores de Dice élevés, ce qui peut s'expliquer par la relative stabilité anatomique et la définition nette de leurs contours en IRM. À l'inverse, des performances moindres ont été observées pour l'intestin grêle et le duodénum, probablement en raison de la variabilité morphologique et de la faible différenciation tissulaire de ces organes sur les images IRM. Concernant la segmentation du GTV, le score de Dice de 0,79 et l'évaluation qualitative de 2,2 révèlent une certaine difficulté à capturer avec précision les contours tumoraux, souvent flous et irréguliers, caractéristiques des cancers du pancréas. Ainsi, malgré des résultats encourageants, l'analyse fine des métriques met en évidence des marges d'amélioration, notamment pour les structures anatomiquement complexes [70].

Dans le but d'améliorer la précision de la segmentation du pancréas et des tumeurs pancréatiques sur les images médicales, Himali Ghorpade et al. ont proposé un modèle hybride en deux étapes reposant sur une architecture U-Net. Ce modèle a été entraîné et évalué à partir d'images d'IRM pondérées en T1 et T2 ainsi que d'images de tomodensitométrie (CT), avec pour objectif de favoriser un diagnostic et une prise en charge précoces des patients. Afin d'optimiser les performances, les auteurs ont intégré des stratégies d'optimisation méta-heuristiques telles que Grey Wolf Optimization (GWO) et Border Collie Optimization (BCO), contribuant à une amélioration significative de la précision de segmentation. Sur un ensemble de 282 images CT, le modèle a atteint un Coefficient de Similarité de Dice (DSC) de 93,33 % pour le pancréas et de 91,46 % pour les tumeurs. Ces résultats élevés peuvent être attribués à la clarté anatomique du pancréas et des tumeurs sur les modalités d'imagerie utilisées, ainsi qu'à l'efficacité des techniques d'optimisation dans le réglage des hyperparamètres du réseau. Toutefois, bien que les valeurs de DSC soient globalement élevées, la légère diminution observée dans la segmentation des tumeurs par rapport au pancréas pourrait refléter la plus grande hétérogénéité morphologique des lésions tumorales, rendant leur délimitation plus complexe[71].

Dans le cadre de l'amélioration de la segmentation du volume tumoral pancréatique (GTV), Cengi Yu et al., ont proposé un outil semi-automatique s'appuyant sur des techniques d'estimation d'incertitude, combinées à un ensemble de modèles entraînés avec la fonction de perte de Tversky. Cette approche vise à surmonter les défis liés à la variabilité morphologique importante des tumeurs pancréatiques et à l'absence d'une vérité terrain parfaitement définie. En utilisant les données du Médicale Segmentation Decathlon (282 patients), les auteurs ont entraîné cinq modèles de segmentation présentant des tendances de contourage différentes, afin de générer une carte de probabilité calibrée pixel par pixel. L'objectif était d'offrir une segmentation adaptable aux préférences cliniques, notamment pour les zones frontières où l'incertitude est élevée. Les résultats obtenus (DSC : 0,47 ; HD95 : 12,7 mm ; MSD : 3,24 mm) indiquent une amélioration par rapport au modèle de référence Swin-UNETR, bien que le score de Dice relativement modeste souligne la complexité inhérente à la délimitation précise du GTV dans les images pancréatiques. La faible valeur du DSC peut s'expliquer par la grande hétérogénéité des contours tumoraux et la faible distinction tissulaire dans les

modalités d'imagerie utilisées. De plus, la possibilité d'ajuster le seuil de probabilité confère au modèle une flexibilité appréciable, permettant aux cliniciens d'affiner les contours selon les besoins spécifiques, ce qui s'inscrit dans une approche interactive « human-in-the-loop ». Toutefois, une certaine tendance à la sous-segmentation est observée, probablement en raison d'une approche conservatrice face à l'incertitude. Les auteurs suggèrent que l'intégration d'informations textuelles issues des comptes rendus cliniques pourrait améliorer la détection des limites tumorales. En conclusion, cette méthode constitue une avancée notable vers une segmentation fiable et personnalisable du GTV, bien qu'une validation qualitative à large échelle soit nécessaire pour confirmer sa robustesse en pratique clinique[72].

III.3. Analyse comparative des méthodes existantes de segmentation du cancer du pancréas :

Le tableau ci-dessous récapitule les travaux remarquables dans le cadre de la segmentation du pancréas, du cancer pancréatique et des organes à risques. Les métriques d'évaluation de performances adoptées sont le coefficient de similarité de Dice.

Étude	Type de modèle	Modalité(s) d'imagerie	Performance (DSC)	Points forts
Y. Liang (1er modèle) en 2019	CNN à 4 blocs, classification voxel par voxel	IRM T1	0,72	Rapidité (34 s), transformation efficace en contours
Y. Liang (2e modèle) en 2020	CNN à 3 couches, IRM multiparamétrique (DCE-IRM)	IRM multiparamétrique	0,73	Résultats comparables aux experts, rapide
Feng Jiang et al. en 2020	DLU-Net, convolutions déformables + BConvLSTM	CT scan	Non précisé	Bonne détection des bords, meilleure que modèles conventionnels
Yao Yao et al. en 2023	TDSMask R-CNN, attention multi-échelle, fusion PET + IRM	PET + IRM	0,7833	Très haute spécificité (99,72%), réduction des faux positifs

Zhang et al. en 2023	PPU-Net, U-Net amélioré avec pyramide + attention	IRM multiparamétrique	0,792	Bonne capture du contexte, surpassant U-Net classique
H. Nourzadehet al. en 2023	SegResNet, SegResNet 2D, SwinUNETR	IRM	0,79 (SwinUNETR)	Remplace contourage manuel, bon pour reins/foie/moelle
HimaliGhorpade et al. en 2024	U-Net hybride optimisé par GWO et BCO	IRM T1/T2 + CT	Pancréas : 93,33% tumeur : 91,46%	Très haute précision, optimisation méta-heuristique
CenjiYu et al. en 2025	Ensemble de 5 modèles avec estimation d'incertitude (Tversky)	CT (Décathlon de segmentation)	0,47	Ajustement flexible des bords, carte de probabilité utile

Tableau III.1 : Comparaison des méthodes de segmentation du cancer du pancréas.

III.4. Synthèse et justification du choix méthodologique adopté :

L'analyse des méthodes de segmentation automatique du cancer du pancréas met en évidence une évolution progressive des approches, passant des contours manuels aux techniques de segmentation assistée par l'intelligence artificielle. Les méthodes classiques, souvent fondées sur une intervention humaine ou sur des modèles semi-automatiques (comme les snakes)[61], souffrent de limites importantes telles que la variabilité inter-observateur, la lenteur de traitement et une faible robustesse face à la complexité anatomique du pancréas.

Avec l'essor des réseaux de neurones convolutifs (CNN), des modèles performants ont vu le jour, exploitant diverses modalités d'imagerie telles que l'IRM multiparamétrique, le PET-CT ou encore la tomodensitométrie (TDM). Plusieurs architectures ont été proposées, notamment DLU-Net, SwinUNETR, ou encore TDSMask R-CNN, incorporant des modules d'attention, des mécanismes de fusion multi-échelle ou encore des convolutions déformables pour mieux capter la variabilité des formes tumorales[67, 68, 70]. Ces méthodes ont montré des résultats prometteurs en termes de précision (DSC > 0.75 dans plusieurs études), et ont permis une meilleure délimitation des volumes tumoraux et des organes à risque. Toutefois, la

complexité algorithmique, le besoin en ressources de calcul, et la disponibilité limitée de certaines modalités d'imagerie (comme le PET) constituent encore des freins à leur généralisation.

Dans ce contexte, le choix d'une architecture de type **U-Net enrichie par un mécanisme d'attention** s'impose comme une stratégie méthodologiquement cohérente, en particulier pour la segmentation de tumeurs pancréatiques sur **images TDM**, qui constituent la modalité utilisée dans notre étude. Le U-Net est une architecture largement validée en imagerie médicale, reconnue pour sa capacité à extraire efficacement les caractéristiques locales et globales, même à partir de jeux de données de taille modérée. L'ajout d'un mécanisme d'attention comme le montrent les travaux de Zhang et al.[69], Permet de renforcer cette performance en guidant le réseau vers les régions d'intérêt, ce qui est particulièrement bénéfique en TDM, où le contraste entre la tumeur et les tissus sains est souvent faible et les bords peu nets.

De plus, le U-Net avec attention présente un bon compromis entre performance, simplicité d'implémentation, et temps de calcul raisonnable, ce qui en fait un choix adapté aux contraintes cliniques de la radiothérapie adaptative. Contrairement à d'autres architectures plus complexes, cette méthode permet une intégration plus directe dans les pipelines de traitement, tout en assurant une précision suffisante pour la délimitation des volumes cibles.

Pour conclure, le modèle U-Net avec attention a été retenu pour son efficacité en segmentation d'images médicales, en l'adaptant aux spécificités du cancer du pancréas sur des images TDM. La suite du travail sera consacrée à l'évaluation pratique de ce modèle.

III.5. Conclusion :

L'examen des travaux antérieurs mené dans cette partie a permis de mettre en évidence les enjeux et avancées liés à la segmentation d'images médicales, en particulier dans le contexte du cancer du pancréas sur imagerie TDM. Les approches classiques ont progressivement cédé la place à des méthodes plus performantes basées sur l'apprentissage profond, dont les architectures U-Net, notamment avec l'intégration de mécanismes d'attention, ont démontré une efficacité notable. Ces modèles offrent des performances

accrues en termes de précision et de robustesse pour la délimitation des structures tumorales complexes. Les éléments développés dans ce chapitre constituent ainsi le socle théorique sur lequel s'appuiera la phase suivante du travail, dédiée à la mise en œuvre expérimentale du modèle proposé.

CHAPITRE IV :

Évaluation expérimental

IV.1. Introduction :

Dans le cadre de la radiothérapie, la délimitation précise des volumes tumoraux constitue une étape cruciale pour garantir une irradiation ciblée tout en épargnant les tissus sains avoisinants. Cette exigence est particulièrement marquée dans le cas du cancer du pancréas, où la complexité anatomique et le faible contraste des tissus rendent la segmentation manuelle difficile et sujette à l'erreur.

L'émergence des techniques d'apprentissage profond, et notamment le modèle Attention U-Net, a permis de développer des outils performants pour la segmentation automatique des images tomodensitométriques (TDM). Ce modèle, en intégrant des mécanismes d'attention au sein de l'architecture U-Net, améliore la détection des structures tumorales en se concentrant sur les zones les plus pertinentes d'un point de vue clinique.

IV.2. Notion à l'intelligence artificielle :

IV.2.1. L'Intelligence Artificielle « IA » :

L'intelligence artificielle (IA) constitue le domaine scientifique et technique visant à concevoir des machines capables de simuler l'intelligence humaine en pensant et en prenant des décisions de manière autonome[73]. Son application est en expansion constante, notamment dans les secteurs de la recherche biomédicale et des services de santé.

Parmi Les principaux avantages de l'IA sont les suivants :

- Réduction des erreurs grâce à une grande précision.
- Accélération du processus décisionnel en aidant les humains à prendre des décisions rapides et fiables.
- Fonctionnement continu sans besoin de repos, contrairement aux humains.

Elle se divise en deux grands sous-domaines : Machine Learning (ML) , Deep Learning (DL)

Comme illustré dans **Figure IV.1**, le Deep Learning (DL) est un sous-ensemble du Machine Learning (ML), qui s'inscrit lui-même dans le domaine plus large de l'Intelligence Artificielle (IA).




Figure IV.1 : Hiérarchie des sous-domaines de l'intelligence artificielle [1].

IV.2.2. Apprentissage automatique (Machine Learning) :

L'apprentissage automatique constitue un sous-domaine fondamental de l'intelligence artificielle, consacré à l'étude, au développement et à l'évaluation d'algorithmes et de méthodes permettant aux machines d'acquérir des connaissances à partir de données [74]. Ce processus d'apprentissage, qui repose sur l'exploitation d'expériences antérieures à travers des données d'entrée ou des instructions connues, vise à améliorer progressivement les performances des systèmes. L'objectif de l'apprentissage automatique est de permettre aux ordinateurs d'adapter et d'optimiser leurs actions de manière autonome afin d'accroître leur précision au fil du temps[75].

IV.2.3. Apprentissage profond (Deep Learning - DL) :

L'apprentissage profond (DL) est une sous-catégorie de l'intelligence artificielle qui imite le fonctionnement du cerveau humain .Il constitue une forme avancée de l'apprentissage automatique (Machine Learning), reposant sur le développement de réseaux de neurones

artificiels[74]. Actuellement, il est largement utilisé dans divers domaines tels que la détection de fraude, le blanchiment d'argent ou la reconnaissance d'objets. Dans le domaine médical, l'apprentissage profond facilite la détection des maladies et aide à des décisions cliniques précises et personnalisée [74].

IV.2.3.1. Les réseaux de neurones :

- **Réseaux de neurones artificiels (RNA) :**

Les réseaux de neurones artificiels (RNA) s'inspirent du mode de fonctionnement des systèmes neuronaux biologiques, tels que le cerveau [76] .Ils reposent sur un ensemble de nœuds de traitement, appelés neurones, fortement interconnectés, qui coopèrent pour résoudre des problématiques spécifiques. À l'instar des systèmes biologiques, les RNA apprennent par l'exemple, leur processus d'apprentissage reposant sur l'ajustement progressif des connexions synaptiques entre neurones.




Figure IV.2: Illustration des analogies entre un neurone biologique et un neurone artificiel [4].

- **Le perceptron :**[76]

Le perceptron est un modèle de neurone artificiel à couche unique qui transforme des entrées pondérées à l'aide de poids(W) et d'un biais (b), puis applique une fonction d'activation pour produire une sortie bornée $\hat{y}$. Équation d'un neurone formel :

$$\hat{Y} = f((W, x) + b). \quad \text{IV.1}$$

Où :

$\mathbf{x}$: est le vecteur des entrées.

$\mathbf{W}$: est le vecteur des poids.

b : est le biais.

f : est la fonction d'activation.

$\hat{Y}$: est la sortie du perceptron.




Figure IV.3 : illustration du perceptron [5].

- **Les réseaux de neurones multicouches :**

Les réseaux de neurones multicouches (Perceptron Multicouche (MLP)) sont utilisés pour des tâches complexes qui ne peuvent être accomplies par un seul neurone. Un MLP de base se compose d'une couche d'entrée, d'une couche cachée et d'une couche de sortie, avec des connexions entre chaque couche [77], (voir la Figure IV.4). Ces réseaux sont utilisés pour la classification, comme celle des chiffres, et génèrent la probabilité d'appartenance à chaque classe après activation.




Figure IV.4: Architecture d'un Perceptron Multicouche contenant 2 couches cachées [4].

IV.2.3.2. Réseaux de neurones convolutifs (CNN):

Les réseaux de neurones convolutifs (CNN), dérivés des perceptrons multicouches, sont couramment utilisés en vision par ordinateur pour l'analyse et la reconnaissance d'images[78] . Ils s'appuient sur l'opération de convolution, définie comme l'interaction entre deux fonctions produisant une troisième fonction traduisant leur modification mutuelle [79]. Grâce à des opérations successives de convolution et de pooling appliquées à une image d'entrée, les CNN extraient automatiquement des caractéristiques discriminantes essentielles à l'identification d'objets.

La figure ci-dessous illustre l'architecture d'un réseau neuronal convolutif (CNN).




Figure IV.5: Architecture de CNN [8].

Un réseau de neurones convolutif est généralement structuré autour de quatre types de couches principales :

1. la couche de convolution : [79]

La couche de convolution est un élément fondamental des réseaux de neurones convolutifs (CNN), largement utilisés en vision par ordinateur. Elle permet l'extraction automatique de caractéristiques locales d'une image en appliquant des filtres (ou noyaux) qui parcourent l'image selon une opération de convolution suivant :

$$(f * g)(x) = \int_{-\infty}^{+\infty} f(\tau) \cdot g(x - \tau) d\tau = (f * g)(k) = \sum_{n=-\infty}^{+\infty} f(k) \cdot g(n - k) \quad \text{IV.2}$$

Où :

$f(\tau)$: Fonction d'entrée (image).

$g(x - \tau)$: Filtre (ou noyau de convolution).

τ : Variable d'intégration (c'est une variable muette représentant un décalage temporel ou spatial).

x : Position actuelle à laquelle on calcule la convolution.

n : est l'indice où la convolution est évaluée,

k : est l'indice de sommation.

$(f * g)(k)$: est le résultat de la convolution en n .

Dans les CNN, cette opération consiste à faire glisser un filtre sur l'image d'entrée afin de produire une carte de caractéristiques. Comme illustré dans la (**Figure IV.6**):




Figure IV.6 : opération d'un filtre sur une image [9] .

Les dimensions spatiales de la carte de sortie sont données par les formules suivantes :

$$N_{i+1} = \frac{N_i - F + 2P}{S} + 1 \quad \text{IV.3}$$

$$H_{i+1} = \frac{H_i - F + 2P}{S} + 1 \quad \text{IV.4}$$

$$C_{i+1} = K \quad \text{IV.5}$$

Où :

N_i , H_i : Largeur et hauteur de l'image d'entrée.

F : Taille du filtre (kernel).

P : Padding (remplissage autour de l'image).

S : Stride (pas de déplacement du filtre).

K : nombre de filtres appliqués (donc de cartes de caractéristiques).

L'activation d'un neurone de la carte est ensuite calculée par :

$$y_i = b_i + \sum w_{ij} \cdot x_j \quad \text{IV.6}$$

Avec : x_j sont les entrées, w_{ij} les poids du filtre et b_i le biais.

2. la couche de pooling (sous-échantillonnage) :[78]

La couche de pooling vise à réduire les dimensions spatiales des entrées pour simplifier le traitement dans les couches suivantes. Parmi Les types les plus courants sont :

- **Max-Pooling** : sélectionne la valeur maximale dans chaque sous-région. (Voir la Figure IV.7)
- **Average-Pooling** : calcule la moyenne des valeurs dans chaque sous-région.

La réduction des dimensions peut entraîner une perte partielle d'informations spatiales.



Figure IV.7: Max-pooling avec un filtre 2×2 et un pas (stride) de 2 [7].

3. La couche d'activation :

La compréhension du cerveau humain repose sur une cartographie complexe et non linéaire. L'une des composantes essentielles des réseaux de neurones est la transformation des entrées et des sorties entre les neurones. Pour reproduire ce comportement cognitif non linéaire, les réseaux de neurones utilisent des fonctions d'activation non linéaires[79]. Parmi les fonctions les plus couramment employées figurent la fonction sigmoïde, la fonction tangente hyperbolique (tanh), ainsi que la fonction de rectification linéaire (ReLU), définies comme suit :

$$\text{Sigmoïde : } f(x) = \frac{1}{1+e^{-x}} \quad \text{IV.7}$$

$$\text{ReLU : } f(x) = \max(0, x) \quad \text{IV.8}$$

$$\text{Tanh : } f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \text{IV.9}$$




Figure IV.8 : courbe sigmoïde et courbe ReLU [5].

4. la couche entièrement connectée (en anglais ,fully connected) : [80]

La couche entièrement connectée est similaire à celle des réseaux de neurones traditionnels, où chaque neurone est relié à tous les neurones de la couche précédente. Son apprentissage suit le même mécanisme d'optimisation décrit précédemment, et son fonctionnement est illustré dans la (Figure IV.9) :




Figure IV.9 : Couche entièrement connectée sur une matrice.

IV.2.3.3. U- Net :[81]

U-Net est un réseau de neurones convolutif introduit par Ronneberger et al., en 2015 conçu pour la segmentation d'images, notamment en imagerie médicale. Il se caractérise par sa capacité à générer des segmentations précises à partir d'un petit nombre d'images annotées. Son architecture en « U » comme illustrée dans (Figure IV.10), comprend une phase

d'encodage, une phase de décodage, et des connexions latérales (skip connections) qui facilitent le transfert d'informations spatiales, améliorant ainsi la précision des résultats.

La phase d'encodage (En anglais, contracting path) : cette phase vise à extraire les caractéristiques contextuelles globales de l'image. Elle repose sur une succession de blocs combinant des convolutions 3×3 avec activation ReLU, suivies d'un sous-échantillonnage par max pooling 2×2 . Ce processus permet une réduction progressive de la résolution spatiale tout en enrichissant la représentation sémantique.

La phase de décodage (En anglais, expanding path) : L'objectif de cette phase est de restaurer la résolution initiale de l'image tout en améliorant la localisation des structures d'intérêt. Cette opération commence par des up-convolutions 2×2 (aussi appelée convolution transposée), suivies d'une concaténation avec les cartes de la phase d'encodage via des skip connections, permettant de conserver les détails fins. Ensuite, deux convolutions 3×3 avec activation ReLU sont appliquées pour affiner les résultats. Enfin, une convolution 1×1 est utilisée en sortie pour ajuster le nombre de canaux aux classes cibles de la segmentation, générant ainsi une carte de sortie de même taille que l'entrée mais annotée au niveau du pixel.




Figure IV.10 : Architecture de base de l'U- Net[8].

Les flèches représentent les différentes opérations, les boîtes bleues représentent la carte de caractéristiques à chaque couche, et les boîtes grises représentent les cartes de caractéristiques découpées provenant du chemin de contraction.

IV.2.3.4. Mécanisme d'attention :

1. principe du mécanisme d'attention :[82]

Le mécanisme d'attention est un élément central des architectures de type Transformer. Il permet au modèle de se focaliser sur les parties les plus pertinentes d'une séquence d'entrée, en fonction du contexte ou de la tâche. Concrètement, chaque requête (Q) est comparée à un ensemble de clés (K) pour en évaluer la pertinence via une fonction de compatibilité. Les scores obtenus sont normalisés par une fonction softmax, puis utilisés pour effectuer une combinaison pondérée des valeurs (V) correspondantes. Cela produit une sortie contextualisée. Ce processus, appelé attention par produit scalaire mesuré (En anglais, Scaled Dot-Product Attention), s'écrit :

$$\text{Attention (Q, K, V)} = \text{softmax}\left(\frac{Q K^T}{\sqrt{d_k}}\right) V \quad \text{IV.10}$$

Où :

Q : est matrice des zones de focalisation (requêtes).

K : est matrice des zones de référence (clés).

V : est la matrice des caractéristiques visuelles (valeurs).

d_k : est la dimension des K, utilisée pour stabiliser l'apprentissage.

2. Intégration du mécanisme d'attention dans le modèle Attention U-Net :[83]

L'Attention U-Net représente une extension avancée de l'architecture U-Net classique, spécifiquement conçue pour améliorer la segmentation d'images médicales grâce à l'intégration d'un mécanisme d'attention adaptatif. Dans l'architecture U-Net traditionnelle, les

connexions de saut (skip connections) assurent le transfert direct des caractéristiques extraites entre l'encodeur et le décodeur, sans différenciation entre les informations pertinentes et les éléments superflus. Ce processus peut entraîner la propagation d'activations provenant de zones bruitées ou non informatives, ce qui limite la capacité du modèle à se focaliser sur les structures d'intérêt (tumeurs). Pour pallier cette limitation, l'Attention U-Net introduit des modules appelés Attention Gates (AGs), intégrés au sein des connexions de saut. Ces AGs agissent comme des filtres adaptatifs, capables d'apprendre à identifier automatiquement les régions pertinentes dans l'image. Ce processus repose sur l'exploitation des caractéristiques locales (extraites des premières couches) ainsi que du contexte global (provenant des couches plus profondes).

Le mécanisme d'attention, fondé sur une approche additive, consiste à calculer des coefficients d'attention α , en fonction de la similarité entre les activations de l'encodeur et celles du décodeur. Les zones importantes de l'image, identifiées par les AGs, reçoivent ainsi des poids plus élevés, tandis que les informations jugées non pertinentes, telles que celles provenant de zones bruitées, sont atténuées ou éliminées.

Cette approche permet au modèle de mieux se concentrer sur les structures anatomiques d'intérêt (tumeurs), en particulier celles présentant des contours flous ou un faible contraste par rapport aux tissus voisins (tels que le pancréas ou la rate). En filtrant les activations non pertinentes et en renforçant celles qui sont utiles, l'Attention U-Net améliore la précision de la segmentation, réduit les erreurs dues aux artefacts d'imagerie, et optimise l'efficacité de l'apprentissage, tout en éliminant la nécessité d'intégrer des modules externes de localisation d'organes.

IV.3. Approche utilisée :

Dans le cadre de cette étude, nous avons mis en œuvre une approche fondée sur les réseaux de neurones convolutifs pour réaliser la segmentation automatique des images TDM du pancréas. Le modèle développé repose sur une architecture U-Net améliorée par l'intégration de mécanismes d'attention, permettant de mieux focaliser l'apprentissage sur les régions d'intérêt tout en réduisant l'impact du bruit. L'ensemble du processus a été implémenté à l'aide du langage **Python 3**, en s'appuyant sur les bibliothèques de deep learning adaptées. La méthodologie adoptée suit un déroulement structuré, depuis la collecte

des données jusqu'à la visualisation des résultats, comme illustré dans l'organigramme ci-après :




Figure IV.11 : Organigramme du processus de délimitation automatique des tumeurs sur des images CT basé sur un modèle Attention U-Net.

IV.3.1. Description des données (images) collectées :

Dans le cadre de cette étude, nous avons exploité la base de données Pancréas Cancer Dataset, accessible publiquement via la plateforme Kaggle [84]. La base se compose de 19287 images CT en coupes axiales. Les images sont proposées en format PNG, résultant d'une conversion depuis le format DICOM d'origine, avec une résolution standardisée de 512×512 pixels. Chaque image est associée à un masque binaire d'annotation, destiné à identifier la présence ou l'absence de lésions pancréatiques. L'ensemble comprend 80

examens de patients uniques, avec une distribution déséquilibrée entre les deux catégories, comme illustré dans l'histogramme :

- **12815 images normales**, sans annotation tumorale,
- **6472 images pathologiques**, contenant des lésions pancréatiques annotées.




Figure IV.12 : L'histogramme illustre la répartition des images par catégorie.

La figure montre deux exemples du jeu de données : une image normale et une image pathologique, chacune accompagnée de son masque.




Figure IV.13 : Deux exemples d'images brutes extraites du dataset.

IV.3.2. Préparation des images :

Le prétraitement constitue une étape fondamentale pour garantir la compatibilité et la qualité des données d'entrée du modèle de segmentation. Il permet d'harmoniser les images en termes de dimensions, de format et d'intensité, facilitant ainsi l'apprentissage du réseau. Les principales opérations appliquées sont décrites comme suit :

1. **Redimensionnement des images :** Afin d'assurer une cohérence spatiale entre les différentes images du jeu de données, chaque image est redimensionnée à une taille fixe de 128×128 pixels. Cette opération vise à réduire la charge

computationnelle tout en préservant les caractéristiques anatomiques essentielles.

2. **Conversion au format compatible (RGB) :** Les images initiales étant en niveaux de gris (1 canal), une conversion vers le format RGB à 3 canaux est effectuée. Cette adaptation est indispensable pour permettre le traitement par le modèle U-Net utilisé, qui attend des images en trois canaux en entrée.
3. **Transformation en tenseur :** Chaque image est ensuite convertie en tenseur PyTorch, ce qui permet son exploitation directe dans le cadre de l'apprentissage profond. Cette étape est réalisée à l'aide de la fonction ToTensor de la bibliothèque torchvision.transforms.
4. **Normalisation implicite :** Lors de la transformation en tenseur, les valeurs des pixels sont automatiquement normalisées dans l'intervalle [0, 1], en divisant chaque valeur par 255. Cette normalisation relative favorise la convergence du modèle durant l'entraînement. Cette opération s'exprime par la formule suivante [85]:

$$I_{\text{nom}(x,y)} = \frac{I_{(x,y)} - I_{\text{min}}}{I_{\text{max}} - I_{\text{min}}} \quad \text{IV.10}$$

Où :

$I_{(x,y)}$: Valeur du pixel à la position (x, y).

I_{min} : Valeur minimale des pixels dans l'image.

I_{max} : Valeur maximale des pixels dans l'image.

$I_{\text{nom}(x,y)}$: Valeur normalisée entre 0 et 1.

5. **Augmentation du dataset :** En raison d'un déséquilibre significatif entre le nombre d'images pathologiques et celui des images normales, comme le montre l'histogramme présenté à la **Figure IV.12**, il a été jugé nécessaire de recourir à une stratégie d'augmentation de données afin de pallier ce

déséquilibre. Cette opération consiste à générer des versions supplémentaires des images pathologiques, accompagnées de leurs masques segmentés correspondants, à l'aide de différentes techniques de transformation, notamment :

- **Translations** : décalages appliqués dans une plage de -1,5 mm à +1,5 mm
- **Rotations** : rotations selon divers angles, en particulier $\pm 45^\circ$.

6. Partitionnement de la base :

La base de données a été partitionnée en deux sous-ensembles distincts : 80 % des données ont été allouées à l'étape d'apprentissage du modèle (ensemble d'entraînement), tandis que les 20 % restants ont été réservés à l'étape de validation. Cette répartition permet d'évaluer la capacité du modèle à généraliser sur des données non vues lors de l'apprentissage.

IV.3.3. Architecture U-Net avec mécanisme d'attention :

Dans ce travail, nous avons opté pour l'architecture Attention U-Net afin de segmenter automatiquement les tumeurs pancréatiques à partir d'images TDM. L'Attention U-Net est structuré selon un schéma encodeur-décodeur symétrique comme illustrées dans **Figure IV.14** :

- La partie **encodeur** est composée de plusieurs blocs de convolution (ConvBlock) associant convolutions 3×3 , normalisation en lots (Batch Normalization) et activation ReLU, permettant d'extraire progressivement des caractéristiques de bas niveau à haut niveau.
- La **bottleneck** centralise les informations globales et sert de goulot d'étranglement au réseau.
- La partie **décodeur** reconstruit la segmentation finale par des étapes suréchantillonnage, de fusion des caractéristiques via concaténation, et de raffinement des détails.

- Chaque connexion de saut est modulée par un Attention Gate, qui pondère les caractéristiques en fonction de leur pertinence pour la segmentation. Ce mécanisme combine les informations locales et globales afin de générer un masque d'attention, focalisant l'analyse sur les zones d'intérêt. Enfin, une convolution 1×1 suivie d'une fonction sigmoïde produit une carte de probabilité binaire pour la segmentation des tumeurs.




Figure IV.14 : Architecture de l'attention U-Net.

- **Evaluation du modèle :**

Pour évaluer notre modèle nous avons adoptés les métriques suivantes [71] :

1. Coefficient de similarité de Dice (En anglais Dice Similarity Coefficient DSC) :

Le coefficient de Dice est une métrique couramment utilisée pour mesurer la similarité entre deux ensembles, en particulier dans le cadre de la segmentation d'images médicales. Il est défini comme :

$$\text{DSC (A, B)} = \frac{2|A \cap B|}{|A| + |B|} \quad \text{IV.11}$$

Où :

A et **B** représentent les ensembles de pixels prédits et annotés respectivement. En segmentation, un score de Dice élevé signifie que la prédiction correspond bien à l'annotation de référence. Ce score varie entre 0 et 1 : 0 indique qu'il n'y a pas de similarité, tandis que 1 correspond à un chevauchement parfait.

2. précision :

La précision mesure la proportion des prédictions positives qui sont correctes. Elle se définit comme :

$$\text{Précision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad \text{IV.12}$$

Où :

TP : le nombre de vrais positifs (véritables détections correctes)

FP : le nombre de faux positifs (faux positifs détectés à tort).

3. sensibilité (En anglais, Recall ou Sensitivity) :

La sensibilité, aussi appelée rappel ou "true positive rate", évalue la capacité du modèle à détecter toutes les occurrences positives réelles (pixels tumorales). Elle se calcule par :

$$\text{Sensibilité} = \frac{TP}{TP + FN} \quad \text{IV.13}$$

Où :

FN : le nombre de faux négatifs (éléments positifs non détectés).

Une haute sensibilité indique que le modèle détecte bien les cas positifs, ce qui est crucial en imagerie médicale, notamment pour ne pas manquer des lésions ou tumeurs.

4. spécificité (En anglais, Specificity) :

La spécificité mesure la capacité du modèle à identifier correctement les cas négatifs (absence de pathologie). Elle est exprimée par :

$$\text{Spécificité} = \frac{TN}{TN + FP} \quad \text{IV.14}$$

Où :

TN : représente les vrais négatifs. Une spécificité élevée signifie que peu de faux positifs sont générés, ce qui réduit les alertes injustifiées.

- **Tableaux hyperparamètre :**

Paramètre	Valeur
Nombre des Epochs	100
Taille de l'image	128×128
Taille du noyau de convolution	3 ×3
Max polling	2× 2
Python	3

Tableau IV. 1 : Principaux paramètres d'entraînement utilisé.

IV.4.les résultats :

IV.4.1. Visualisation des résultats :

Dans cette section, nous présentons des exemples illustrant la segmentation des tumeurs pancréatiques à l'aide du modèle Attention U-Net. Chaque série d'images permet de comparer l'image TDM originale, le masque réel, le masque prédit après traitement des données, et l'image TDM avec superposition des contours prédits (en vert). Pour chaque exemple, quatre éléments sont illustrés :

- L'image TDM d'origine.
- Le masque réel.
- Le masque prédit, ainsi que l'image TDM originale sur laquelle est superposé le contour du masque prédictif (en vert).

La figure ci-après illustre quelque exemple des résultats de segmentation de notre modèle (**Figure IV.15**) :




Figure IV.15: Exemple de résultat de délimitation sur une coupe TDM.

IV.4.2. Évaluation des performances des modèles U-Net et Attention U-Net :

Afin d'évaluer l'évolution des performances entre les modèles U-Net et Attention U-Net, leurs résultats ont été comparés sur un même jeu de données en utilisant les métriques classiques suivantes : **Dice, précision, sensibilité et spécificité.**

Le tableau ci-dessous regroupe les valeurs obtenues pour ces métriques à différentes étapes de l'apprentissage.

modèle	DSC (%)	Précision (%)	Sensibilité (%)	Spécificité (%)
U-Net	81,64	97 ,33	70,31	99,99
AttentionU-Net	82	96	98	99

Tableau 2 : Résultats d'évaluation des métriques pour U-Net et Attention U-Net.

IV.4.3. Comparaison des performances avec les approches existantes :

Pour évaluer la performance de notre modèle, nous avons comparé nos résultats à ceux rapportés dans des études antérieures sur la segmentation du pancréas. Le tableau suivant présente les principales métriques utilisées, permettant de positionner notre méthode par rapport aux approches existantes.

Étude	Modèle utilisé	Dice (%)	Précision (%)	Sensibilité (%)	Spécificité (%)
Y. Liang (1er modèle) en 2019	CNN à 4 blocs, classification voxel par voxel	72	/	79	94
HimaliGhorpade et al. en 2024	U-Net hybride optimisé par GWO et BCO	91.46	86.29	88.74	97.25
H. Nourzadehet al. en 2023	SegResNet, SegResNet 2D, SwinUNETR	79	81.1	74.0	/
Notre contribution	Attention U-Net	82	96	98	99

Tableau IV.3 : Résultats comparés avec la littérature.,

IV.5. Discussion :

Au cours de cette étude, deux architectures de réseaux de neurones convolutifs ont été expérimentées pour la segmentation des tumeurs pancréatiques à partir d'images TDM : le modèle **U-Net classique**, suivi du modèle **Attention U-Net**. Cette démarche comparative visait à évaluer l'apport du mécanisme d'attention dans l'amélioration de la précision de la délimitation des lésions.

Le modèle **Attention U-Net** a permis d'atteindre un **Dice score** de 82 %, contre 81,64 % pour U-Net. Cette valeur indique une forte similarité entre le masque prédit et le masque réel, ce qui reflète une bonne précision de délimitation (**voir Figure IV.15**).

La **sensibilité**, qui mesure la capacité à détecter les vraies régions tumorales, a significativement augmenté, passant de 70,31 % (U-Net) à 98 % avec Attention U-Net. Cela montre que notre modèle détecte presque toutes les zones tumorales, ce qui est crucial en contexte clinique. La **précision** (96 %) confirme que la majorité des zones identifiées comme tumorales le sont réellement, réduisant ainsi les faux positifs. Enfin, la **spécificité** (99 %) traduit la capacité du modèle à **ne pas confondre le tissu sain avec des lésions**, garantissant ainsi une bonne fiabilité du modèle.

Les résultats visuels (**voir Figure IV.15**) renforcent ces constats. La superposition du contour prédictif (en rouge) sur l'image TDM montre une concordance marquée avec les contours réels. Toutefois, dans certains cas, le contour prédictif déborde légèrement sur le tissu sain, ce qui souligne un phénomène de **sur-segmentation**.

Malgré ces bonnes performances, une difficulté persiste : **la séparation précise entre pancréas et tumeur**. Les deux modèles tendent à englober une partie du tissu pancréatique sain dans la segmentation tumorale. Cette confusion peut s'expliquer par :

- Le **faible contraste** entre tissu tumoral et sain sur les images TDM.
- La **morphologie complexe** et les contours flous du pancréas.
- La **texture similaire** entre certaines régions saines et pathologiques.
- Un **déséquilibre** dans les données, limitant la généralisation du modèle.

En comparaison avec les études antérieures, notre modèle présente des **résultats compétitifs**. Il surpasse le Dice obtenu par Y. Liang (72 %) et H. Nourzadeh et al. (79 %), et se rapproche des meilleures performances obtenues par Himali Ghorpade et al. (91,46 %), tout en présentant une sensibilité nettement supérieure (98 % contre 88,74 %). Cette forte sensibilité positionne notre modèle comme un outil pertinent dans le contexte clinique, où l'objectif principal reste de ne pas **omettre de lésions**.

IV.6. Conclusion :

Les résultats de cette étude ont clairement mis en lumière l'efficacité du modèle Attention U-Net, spécifiquement conçu pour la segmentation des tumeurs pancréatiques à partir d'images tomodensitométriques. L'intégration des mécanismes d'attention a significativement amélioré la capacité du modèle à localiser avec précision les zones cliniquement pertinentes, ce qui s'est traduit par une augmentation notable des performances, notamment en termes de sensibilité, confirmant ainsi son potentiel pour la détection précoce des tumeurs.

Par ailleurs, ces observations soulignent le rôle prometteur des réseaux de neurones profonds enrichis par des mécanismes d'attention dans l'optimisation de la qualité de segmentation des images médicales, ouvrant la voie au développement de systèmes intelligents et fiables destinés à soutenir la prise de décision clinique en oncologie.

Conclusion générale

Le présent travail s'inscrit dans le contexte d'un enjeu médical majeur : la détection précoce, la caractérisation et la prise en charge optimale du cancer du pancréas, une pathologie redoutable tant par son agressivité que par sa complexité anatomique. En mobilisant des compétences à l'interface de l'anatomopathologie, de la radiophysique et de l'intelligence artificielle, cette étude a permis d'explorer de manière approfondie les potentialités offertes par les techniques de segmentation automatique dans un cadre oncologique précis.

Dans un premier temps, une analyse rigoureuse de la structure anatomique et fonctionnelle du pancréas a été entreprise, mettant en évidence les particularités morphologiques et histologiques de l'organe, ainsi que les caractéristiques cliniques et épidémiologiques du cancer pancréatique. Ce socle théorique a permis de mieux appréhender les contraintes liées à la délimitation tumorale et à la planification des traitements.

Par la suite, l'attention a été portée sur la tomodensitométrie (TDM), modalité d'imagerie de référence en radiothérapie, dont le rôle est central dans l'identification des structures anatomiques et l'optimisation des volumes cibles. L'accent a été mis sur les principes physiques, les techniques d'acquisition et les modalités de reconstruction d'images, dans le but de garantir une modélisation dosimétrique fiable et reproductible.

Dans la continuité de cette démarche, une revue systématique des méthodes de segmentation appliquées au cancer du pancréas a permis de dresser un état de l'art exhaustif, mettant en lumière les apports et les limites des approches conventionnelles et de celles fondées sur l'intelligence artificielle. Ce cadre théorique a conduit au choix du modèle Attention U-Net, dont l'architecture, enrichie par des mécanismes d'attention, s'avère particulièrement adaptée aux images médicales complexes.

L'évaluation expérimentale menée sur un jeu de données tomodensitométriques a permis de valider les performances du modèle proposé. Les résultats obtenus avec un coefficient de Dice de 82 %, une sensibilité de 98 % et une spécificité de 99 % témoignent de la pertinence de l'approche adoptée, notamment en termes de précision, de robustesse et de capacité à capter les régions d'intérêt clinique. Comparé aux méthodes classiques, le modèle

Attention U-Net a montré une amélioration notable de la qualité de la segmentation, bien que certaines limites subsistent, notamment en ce qui concerne la variabilité inter-patients et la généralisation à des données hétérogènes.

En définitive, ce mémoire met en évidence la valeur ajoutée des techniques d'apprentissage profond dans le domaine de la radiothérapie assistée par imagerie. Il ouvre des perspectives prometteuses quant à l'intégration de ces outils dans la routine clinique, notamment pour automatiser la délimitation des volumes tumoraux et améliorer la reproductibilité des plans de traitement.

Dans une visée prospective, plusieurs axes d'amélioration peuvent être envisagés, notamment :

- **L'élargissement** du dataset à des images multi-institutionnelles pour renforcer la robustesse du modèle,
- **L'intégration d'images multimodales** (IRM, PET-CT) pour une meilleure précision diagnostique,
- **L'extension de la segmentation** aux structures critiques (organes à risque) afin d'optimiser la balance bénéfice/risque en radiothérapie.

Ce travail s'inscrit ainsi pleinement dans la dynamique actuelle de médecine personnalisée et assistée par l'IA, visant à allier innovation technologique et exigence clinique pour une prise en charge plus précise, plus rapide et mieux adaptée des patients atteints de cancers complexes.

Références bibliographiques

- [1] Q. Yuan, A. Pan, Y. Fu, and Y. Dai, "Chapter 1 - Anatomy and physiology of the pancreas," in *Integrative Pancreatic Intervention Therapy*, M. Li, L. Lu, Y. Xiao, D. Fu, and H. Zhang, Eds., ed: Elsevier, pp. 3-21, 2021.
- [2] V. Mahadevan, "Anatomy of the pancreas and spleen," *Surgery (Oxford)*, vol. 37, pp. 297-301, 2019/06/01/ 2019.
- [3] S. Egels and O. Lucidarme, "Chapitre 8 - Pancréas normal," in *Echographie en pathologie digestive*, O. Lucidarme, Ed., ed Paris: Elsevier Masson, 2017, pp. 217-232.
- [4] Z. Zhao and W. Liu, "Pancreatic cancer: a review of risk factors, diagnosis, and treatment," *Technology in cancer research & treatment*, vol. 19, p. 1533033820962117, 2020.
- [5] F. Bessagnet and A. Desmoulière, "Le pancréas," *Actualités Pharmaceutiques*, vol. 60, pp. 55-59, 2021/06/01/ 2021.
- [6] D. B. wahiba and D. B. cherifa, "Cancer du PancrÉas," *Faculté de Médecine ´ Dr. Benzerdjeb a tlemcen* 2015.
- [7] *Pancreatic Cancer Types*. Available: <https://www.hopkinsmedicine.org/health/conditions-and-diseases/pancreatic-cancer/pancreatic-cancer-types>, (17févrie 2025 , à 11h51).
- [8] L. Zhang, S. Sanagapalli, and A. Stoita, "Challenges in diagnosis of pancreatic cancer," *World journal of gastroenterology*, vol. 24, p. 2047, 2018.
- [9] D. D. Brennan, G. A. Zamboni, V. D. Raptopoulos, and J. B. Kruskal, "Comprehensive preoperative assessment of pancreatic adenocarcinoma with 64-section volumetric CT," *Radiographics*, vol. 27, pp. 1653-1666, 2007.
- [10] N. C. C. Network, "NCCN guidelines version 3.2017," *Neuroendocrine tumors of the gastrointestinal tract, lung and thymus (carcinoid tumors)* Available from: https://www.nccn.org/professionals/physician_gls/pdf/neuroendocrine.pdf, 2017.
- [11] M. M. Al-Hawary, I. R. Francis, S. T. Chari, E. K. Fishman, D. M. Hough, D. S. Lu, M. Macari, A. J. Megibow, F. H. Miller, and K. J. Morteale, "Pancreatic ductal adenocarcinoma radiology reporting template: consensus statement of the Society of

- Abdominal Radiology and the American Pancreatic Association," *Radiology*, vol. 270, pp. 248-260, 2014.
- [12] P. Ghaneh, R. Hanson, A. Titman, G. Lancaster, C. Plumptre, H. Lloyd-Williams, S. T. Yeo, R. T. Edwards, C. Johnson, and M. A. Hilal, "PET-PANC: multicentre prospective diagnostic accuracy and health economic analysis study of the impact of combined modality 18fluorine-2-fluoro-2-deoxy-d-glucose positron emission tomography with computed tomography scanning in the diagnosis and management of pancreatic cancer," *Health technology assessment (Winchester, England)*, vol. 22, p. 1, 2018.
- [13] T. Ichikawa, S. M. Erturk, U. Motosugi, H. Sou, H. Iino, T. Araki, and H. Fujii, "High-b value diffusion-weighted MRI for detecting pancreatic adenocarcinoma: preliminary results," *American Journal of Roentgenology*, vol. 188, pp. 409-414, 2007.
- [14] J. C. Wong and D. S. Lu, "Staging of pancreatic adenocarcinoma by imaging studies," *Clinical gastroenterology and hepatology*, vol. 6, pp. 1301-1308, 2008.
- [15] R. Fattahi, N. C. Balci, W. H. Perman, E. C. Hsueh, S. Alkaade, N. Havlioglu, and F. R. Burton, "Pancreatic diffusion-weighted imaging (DWI): comparison between mass-forming focal pancreatitis (FP), pancreatic cancer (PC), and normal pancreas," *Journal of Magnetic Resonance Imaging: An Official Journal of the International Society for Magnetic Resonance in Medicine*, vol. 29, pp. 350-356, 2009.
- [16] T. Kamisawa, L. D. Wood, T. Itoi, and K. Takaori, "Pancreatic cancer," *The Lancet*, vol. 388, pp. 73-85, 2016.
- [17] S. J. Yeo, C. M. Cho, M. K. Jung, A. N. Seo, and H. I. Bae, "Comparison of the diagnostic performances of same-session endoscopic ultrasound-and endoscopic retrograde cholangiopancreatography-guided tissue sampling for suspected biliary strictures at different primary tumor sites," *The Korean Journal of Gastroenterology*, vol. 73, pp. 213-218, 2019.
- [18] R. Mikata, T. Ishihara, M. Tada, K. Tawada, M. Saito, J. Kurosawa, H. Sugiyama, Y. Sakai, T. Tsuyuguchi, and M. Miyazaki, "Clinical usefulness of repeated pancreatic juice cytology via endoscopic naso-pancreatic drainage tube in patients with pancreatic cancer," *Journal of gastroenterology*, vol. 48, pp. 866-873, 2013.

- [19] S. D. Rustgi, S. P. Amin, M. K. Kim, S. Nagula, N. A. Kumta, C. J. DiMaio, P. Boffetta, and A. L. Lucas, "Age, socioeconomic features, and clinical factors predict receipt of endoscopic retrograde cholangiopancreatography in pancreatic cancer," *World journal of gastrointestinal endoscopy*, vol. 11, p. 133, 2019.
- [20] F. Debordeaux, A. Govindoorazoo, and N. Rizzo-Padoin, "Chapitre 6 - Radiothérapie**M. Chaussard et B. Hosten ont participé à la rédaction de ce chapitre dans la précédente édition," in *Pharmacie Clinique Pratique en Oncologie (Deuxième Édition)*, c. l'Association nationale des enseignants de pharmacie, Ed., ed Paris: Elsevier Masson, pp. 48-55.e4, 2020.
- [21] R. Dale and A. Carabe-Fernandez, "The radiobiology of conventional radiotherapy and its application to radionuclide therapy," *Cancer biotherapy & radiopharmaceuticals*, vol. 20, pp. 47-51, 2005.
- [22] J. Chavaudra and A. Bridier, "Définition des volumes en radiothérapie externe: rapports ICRU 50 et 62," *Cancer/Radiothérapie*, vol. 5, pp. 472-478, 2001.
- [23] J. S. Welsh, "Basics of particle therapy: introduction to hadrons," *American journal of clinical oncology*, vol. 31, pp. 493-495, 2008.
- [24] D. Schulz-Ertner, O. Jäkel, and W. Schlegel, "Radiation therapy with charged particles," in *Seminars in radiation oncology*, pp. 249-259, 2006.
- [25] P. Coucke, C. Louis, and S. Bolle, "Innovations technologiques en radiothérapie-oncologie," *Revue médicale de Liège*, vol. 62, 2007.
- [26] J. J. Lagendijk, B. W. Raaymakers, C. A. Van den Berg, M. A. Moerland, M. E. Philippens, and M. Van Vulpen, "MR guidance in radiotherapy," *Physics in Medicine & Biology*, vol. 59, p. R349, 2014.
- [27] D. Peiffert and J.-M. Hannoun-Lévi, "Évolution de la curiethérapie en France et perspectives," *Cancer/Radiothérapie*, vol. 17, pp. 76-80, 2013.
- [28] C. Hennequin and J.-J. Mazeron, "Radiobiologie de la curiethérapie," *Cancer/Radiothérapie*, vol. 17, pp. 81-84, 2013.
- [29] V. Marchesi, M. Gautier, N. Villani, J. Feuillade, and C. Dejean, "Radioéléments, appareillages et contrôle de qualité en curiethérapie," *Cancer/Radiothérapie*, vol. 17, pp. 85-88, 2013.
- [30] L. Poupon, B. Castelain, and E. Lartigau, "La curiethérapie de débit pulsé: optimisation et place de l'imagerie," *Cancer/Radiothérapie*, vol. 7, pp. 136-146, 2003.

- [31] J. Cosset, L. Pinillos-Ashton, and F. Mettler, "Recommandations de la Commission internationale de protection radiologique (CIPR) pour la curiethérapie de haut débit de dose et la curiethérapie de prostate," *Cancer radiothérapie*, vol. 8, pp. S50-S55, 2004.
- [32] E. B. Silberstein, L. Eugene, and S. Saenger, "Painful osteoblastic metastases: the role of nuclear medicine," *Oncology (Williston Park, NY)*, vol. 15, pp. 157-63; discussion 167, 2001.
- [33] A. Laprie and L. Claude, "Chapitre 7 - Radiothérapie," in *Cancérologie de L'enfant*, Y. Pérel and D. Plantaz, Eds., ed Paris: Elsevier Masson, pp. 83-101, 2017.
- [34] A. Jankowski and G. Ferretti, "Tomodensitométrie volumique: principe, paramètres," *Revue des maladies respiratoires*, vol. 27, pp. 964-969, 2010.
- [35] Z. Francis, "Simulations Monte-Carlo et étude microdosimétrique pour des irradiations cellulaires à faibles doses en neutrons de 14 MeV," Université Blaise Pascal-Clermont-Ferrand II, 2007.
- [36] D. L. Bailey and A. A. o. P. i. Medicine, "Nuclear medicine physics: A handbook for teachers and students," (*No Title*), 2014.
- [37] A. H. Compton, "A quantum theory of the scattering of X-rays by light elements," *Physical review*, vol. 21, p. 483, 1923.
- [38] F. M. Khan and J. P. Gibbons, *Khan's the physics of radiation therapy*: Lippincott Williams & Wilkins, 2014.
- [39] A. Frezza, "Quantification en thérapie radionucléique par radiopeptides au ^{177}Lu ," 2021.
- [40] F. H. Attix, *Introduction to radiological physics and radiation dosimetry*: John Wiley & Sons, 2008.
- [41] M. J. Berger, J. H. Hubbell, S. M. Seltzer, J. S. Coursey, and D. S. Zucker, "XCOM: Photon cross section database (version 1.2)," 1999.
- [42] C. E. Kahn, J. A. Carrino, M. J. Flynn, D. J. Peck, and S. C. Horii, "DICOM and radiology: past, present, and future," *Journal of the American College of Radiology*, vol. 4, pp. 652-657, 2007.
- [43] W. A. Kalender, "X-ray computed tomography," *Physics in Medicine & Biology*, vol. 51, p. R29, 2006.
- [44] A. C. Kak and M. Slaney, *Principles of computerized tomographic imaging*: SIAM, 2001.

- [45] J. T. Bushberg, J. A. Seibert, E. M. Leidholdt, J. M. Boone, and L. Frank, "The essential physics of medical imaging," *AJR-American Journal of Roentgenology*, vol. 163, pp. 1338-1338, 1994.
- [46] D. T. Ginat and R. Gupta, "Advances in computed tomography imaging technology," *Annual review of biomedical engineering*, vol. 16, pp. 431-453, 2014.
- [47] J. D. Evans, D. G. Politte, B. R. Whiting, J. A. O'Sullivan, and J. F. Williamson, "Noise-resolution tradeoffs in x-ray CT imaging: a comparison of penalized alternating minimization and filtered backprojection algorithms," *Medical physics*, vol. 38, pp. 1444-1458, 2011.
- [48] "Chapitre 2 - Technique TDM en pathologie tumorale abdominale," in *TDM des tumeurs abdominales (Troisième Édition)*, E. Delabrousse, Ed., ed Paris: Elsevier Masson, pp. 7-26, 2013.
- [49] G. Ramachandran and A. Lakshminarayanan, "Three-dimensional reconstruction from radiographs and electron micrographs: application of convolutions instead of Fourier transforms," *Proceedings of the National Academy of Sciences*, vol. 68, pp. 2236-2240, 1971.
- [50] M. Zhang, S. Gu, and Y. Shi, "The use of deep learning methods in low-dose computed tomography image reconstruction: a systematic review," *Complex & intelligent systems*, vol. 8, pp. 5545-5561, 2022.
- [51] T. M. Buzug, "Computed tomography," in *Springer handbook of medical technology*, ed: Springer, pp. 311-342, 2011.
- [52] J. Hsieh, "Computed tomography: principles, design, artifacts, and recent advances," 2003.
- [53] J. T. Bushberg and J. M. Boone, *The essential physics of medical imaging*: Lippincott Williams & Wilkins, 2011.
- [54] S. Ens, J. Müller, B. Kratz, and T. Buzug, "Sinogram-based motion detection in transmission computed tomography," in *4th European Conference of the International Federation for Medical and Biological Engineering: ECIFMBE 2008 23–27 November 2008 Antwerp, Belgium*, pp. 505-508, 2009.
- [55] M. Oehler and T. Buzug, "Statistical image reconstruction for inconsistent CT projection data," *Methods of information in medicine*, vol. 46, pp. 261-269, 2007.

- [56] P. Hobday, N. J. Hodson, J. Husband, R. P. Parker, and J. S. Macdonald, "Computed tomography applied to radiotherapy treatment planning: techniques and results," *Radiology*, vol. 133, pp. 477-482, 1979.
- [57] H. Ghorpade, J. Jagtap, S. Patil, K. Kotecha, A. Abraham, N. Horvat, and J. Chakraborty, "Automatic segmentation of pancreas and pancreatic tumor: a review of a decade of research," *IEEE Access*, vol. 11, pp. 108727-108745, 2023.
- [58] T. Kron, J. Lehmann, and P. B. Greer, "Dosimetry of ionising radiation in modern radiation oncology," *Physics in Medicine & Biology*, vol. 61, p. R167, 2016.
- [59] W. Bulski, K. Chełmiński, and J. Rostkowska, "Dosimetry audit of radiotherapy treatment planning systems," *Radiation protection dosimetry*, vol. 165, pp. 472-476, 2015.
- [60] C. H. Clark, E. G. Aird, S. Bolton, E. A. Miles, A. Nisbet, J. A. Snaith, R. A. Thomas, K. Venables, and D. I. Thwaites, "Radiotherapy dosimetry audit: three decades of improving standards and accuracy in UK clinical practice and trials," *The British journal of radiology*, vol. 88, p. 20150251, 2015.
- [61] M. Kass, A. Witkin, and D. Terzopoulos, "Snakes: Active contour models," *International journal of computer vision*, vol. 1, pp. 321-331, 1988.
- [62] M. F. Fast, B. Eiben, M. J. Menten, A. Wetscherek, D. J. Hawkes, J. R. McClelland, and U. Oelfke, "Tumour auto-contouring on 2d cine MRI for locally advanced lung cancer: A comparative study," *Radiotherapy and Oncology*, vol. 125, pp. 485-491, 2017/12/01/ 2017.
- [63] Y. Xu, R. Quan, W. Xu, Y. Huang, X. Chen, and F. Liu, "Advances in Medical Image Segmentation: A Comprehensive Review of Traditional, Deep Learning and Hybrid Approaches," *Bioengineering*, vol. 11, p. 1034, 2024.
- [64] D. Bernstein, A. Taylor, S. Nill, and U. Oelfke, "New target volume delineation and PTV strategies to further personalise radiotherapy," *Physics in Medicine & Biology*, vol. 66, p. 055024, 2021.
- [65] Y. Liang, D. Schott, Y. Zhang, W. Hall, P. Knechtges, E. Paulson, B. Erickson, and A. Li, "On the Development of MRI-Based Auto-Segmentation of Pancreatic Tumor Using Deep Neural Networks," *International Journal of Radiation Oncology, Biology, Physics*, vol. 105, p. S201, 2019.

- [66] Y. Liang, D. Schott, Y. Zhang, Z. Wang, H. Nasief, E. Paulson, W. Hall, P. Knechtges, B. Erickson, and X. A. Li, "Auto-segmentation of pancreatic tumor in multi-parametric MRI using deep convolutional neural networks," *Radiotherapy and Oncology*, vol. 145, pp. 193-200, 2020.
- [67] F. Jiang, X. Zhi, X. Ding, W. Tong, and Y. Bian, "DLU-Net for pancreatic cancer segmentation," in *2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, pp. 1024-1028, 2020.
- [68] Y. Yao, Y. Chen, S. Gou, S. Chen, X. Zhang, and N. Tong, "Auto-segmentation of pancreatic tumor in multi-modal image using transferred DSMask R-CNN network," *Biomedical Signal Processing and Control*, vol. 83, p. 104583, 2023/05/01/ 2023.
- [69] Z. Zhang, H. Tian, Z. Xu, Y. Bian, and J. Wu, "Application of a pyramid pooling Unet model with integrated attention mechanism and Inception module in pancreatic tumor segmentation," *Journal of applied clinical medical physics*, vol. 24, p. e14204, 2023.
- [70] W. Choi, H. Nourzadeh, Y. Chen, C. Ainsley, V. Desai, A. Kubli, Y. Vinogradskiy, K. Mooney, M. Werner-Wasik, and A. Mueller, "Novel Deep Learning Segmentation Models for Accurate GTV and OAR Segmentation in MR-Guided Adaptive Radiotherapy for Pancreatic Cancer Patients," *International Journal of Radiation Oncology, Biology, Physics*, vol. 117, p. e462, 2023.
- [71] H. Ghorpade, S. Kolhar, J. Jagtap, and J. Chakraborty, "An optimized two stage U-Net approach for segmentation of pancreas and pancreatic tumor," *MethodsX*, vol. 13, p. 102995, 2024/12/01/ 2024.
- [72] C. Yu, S. S. Gay, A. C. Gupta, R. M. Martin-Paulpeter, E. B. Ludmir, Y. Zhao, J. Duryea, X. Chen, C. E. Cardenas, and J. Yang, "Uncertainty-guided pancreatic tumor auto-segmentation with Tversky ensemble," *Physics and Imaging in Radiation Oncology*, p. 100740, 2025.
- [73] I. BOULEFRAKH, "La segmentation d'organes à partir d'images médicales," 2022.
- [74] C. Bhatt, I. Kumar, V. Vijayakumar, K. U. Singh, and A. Kumar, "The state of the art of deep learning models in medical science and their challenges," *Multimedia Systems*, vol. 27, pp. 599-613, 2021.
- [75] N. K. Chauhan and K. Singh, "A review on conventional machine learning vs deep learning," in *2018 International conference on computing, power and communication technologies (GUCON)*, pp. 347-352, 2018.

- [76] B. Nadjib and S. M. Raid, "Image segmentation using deep learning," university center of abdalhafid boussouf-MILA, 2021.
- [77] S. I. Gallant, "Perceptron-based learning algorithms," *IEEE Transactions on neural networks*, vol. 1, pp. 179-191, 1990.
- [78] C. Sarah, A. Mohamed, and L. H. Eddine, "Master's Degree Thesis."
- [79] S. Aoulia, "Segmentation des images médicales par apprentissage profond," Université laarbi tebessi tebessa, 2021.
- [80] Y. LeCun, "LeNet-5, convolutional neural networks," URL: <http://yann.lecun.com/exdb/lenet>, vol. 20, p. 14, 2015.
- [81] N. Siddique, P. Sidike, C. Elkin, and V. Devabhaktuni, "U-Net and its variants for medical image segmentation: theory and applications," *arXiv preprint arXiv:2011.01118*, 2020.
- [82] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, "Attention is all you need," *Advances in neural information processing systems*, vol. 30, 2017.
- [83] O. Oktay, J. Schlemper, L. L. Folgoc, M. Lee, M. Heinrich, K. Misawa, K. Mori, S. McDonagh, N. Y. Hammerla, and B. Kainz, "Attention u-net: Learning where to look for the pancreas," *arXiv preprint arXiv:1804.03999*, 2018.
- [84] P. Saha. (2023). Available: <https://www.kaggle.com/datasets/piyansusaha/pancreas-cancer-dataset>
- [85] R. C. Gonzalez, *Digital image processing*: Pearson education india, 2009.

Résumé

Le cancer du pancréas est l'un des cancers les plus agressifs, caractérisé par un diagnostic souvent tardif et une complexité anatomique qui rend difficile la délimitation tumorale pour la radiothérapie. Ce mémoire vise à étudier l'apport de la tomographie assistée par ordinateur (TDM) à la planification des traitements et à explorer les méthodes de segmentation automatique, en particulier les modèles d'apprentissage profond comme l'Attention U-Net. Après une revue des concepts anatomiques, radiophysiques et des méthodes de segmentation, une étude expérimentale a été menée afin d'évaluer les performances de modèles U-Net et Attention U-Net sur des images TDM. Les résultats montrent une amélioration significative en termes de précision et de robustesse pour la délimitation tumorale. Cette recherche confirme la pertinence de l'intelligence artificielle pour améliorer la qualité et la reproductibilité des traitements en radiothérapie.

المخلص

يُعدّ سرطان البنكرياس من أكثر أنواع السرطان عدوانية، ويتميّز غالباً بتشخيص متأخر وبتركيب تشريحي معقد يصعب يهدف هذا العمل إلى دراسة مساهمة التصوير المقطعي المحوسب. تحديد حدود الورم بدقة في سياق العلاج الإشعاعي في تخطيط العلاجات، واستكشاف طرق التقسيم الآلي، لا سيما النماذج المعتمدة على التعلم العميق مثل نموذج (TDM) بعد مراجعة للمفاهيم التشريحية والفيزيائية الإشعاعية وتقنيات التقسيم، تم إجراء دراسة تجريبية. Attention U-Net. أظهرت النتائج تحسناً ملحوظاً من حيث الدقة. TDM على صور Attention U-Net و U-Net لتقييم أداء نماذج والموثوقية في تحديد حدود الورم، مما يؤكد أهمية الذكاء الاصطناعي في تحسين جودة العلاجات الإشعاعية وقابليتها لإعادة الإنتاج.

Abstract :

Pancreatic cancer is one of the most aggressive cancers, often diagnosed at an advanced stage due to its anatomical complexity. This thesis investigates the contribution of Computed Tomography (CT) to radiotherapy planning and explores the potential of automatic segmentation methods, with a focus on deep learning models such as Attention U-Net. After reviewing anatomical, radiophysical, and segmentation approaches, an experimental study was conducted to evaluate the performance of U-Net and Attention U-Net models on CT images. The results demonstrate significant improvements in segmentation accuracy and

consistency. This work highlights the relevance of artificial intelligence in enhancing the precision and reproducibility of radiotherapy treatments,