République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université 20 août 1955-Skikda

Faculté des Sciences

Département de Physique

N° : D02P202602M

Mémoire de Master

Filière : Physique

Spécialité : Physique médicale

Thème

Traitement du flou de mouvement en imagerie à rayons X par des techniques robustes de filtrage basées sur l'intelligence artificielle

Présenté par :

Lemmouchi Djihane

Boumediane Loubna

Soutenu le :22/06/2026 devant le jury composé de :

M. Boukedjane	MCA	Université de Skikda	Président
S. Dekar	MAA	Université de Skikda	Rapporteur
R. Chikh	MCA	Université de Skikda	Co-Rapporteur
S. Djelleb	MCA	Université de Skikda	Examinateur

Année Universitaire : 2025/2026

Remerciements

Avant tout, je remercie Allah le Tout-Puissant de m'avoir accordé la force, la patience et la volonté nécessaires pour mener à bien ce travail.

Je tiens à exprimer ma profonde gratitude à mes encadrants, Madame Dekkar Souhila et Monsieur Cheikh Ramdane, pour leur disponibilité, leurs précieux conseils, leur accompagnement ainsi que leurs orientations pertinentes tout au long de la réalisation de ce mémoire. Leurs encouragements, leur soutien scientifique et leurs remarques constructives ont grandement contribué à l'aboutissement de ce travail.

J'adresse également mes sincères remerciements aux membres du jury qui ont accepté d'examiner et d'évaluer ce mémoire, ainsi que de consacrer une partie de leur temps à l'appréciation de ce travail.

Je remercie chaleureusement l'ensemble des enseignants du département de Physique, en particulier ceux de la spécialité Physique Médicale, pour la qualité de la formation qu'ils m'ont dispensée tout au long de mon parcours universitaire.

Mes remerciements vont également à toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce mémoire, par leurs conseils, leurs encouragements et leur soutien.

Enfin, j'adresse ma plus profonde reconnaissance à ma famille pour son amour, sa confiance, sa patience et son soutien inconditionnel durant toutes mes années d'études. Je remercie également mes amis et collègues pour leur aide, leur présence et leurs encouragements.

À toutes celles et tous ceux qui ont participé, même modestement, à l'accomplissement de ce travail, j'exprime ma sincère gratitude.

Dédicace

﴿ وَآخِرُ دَعْوَاهُمْ أَنِ الْحَمْدُ لِلَّهِ رَبِّ الْعَالَمِينَ ﴾

الحمد لله حبًّا وشكرًا وامتنانًا، فما كنت لأصل إلى هذه اللحظة لولا فضل الله وتوفيقه. فالحمد لله على البدء وعلى الختام. وها أنا اليوم أقف على عتبة تخرجي، بعد مسار طويل من الجهد والتعب، أقطف ثمرة ما بذلته خلال سنوات دراستي. ورغم الصعوبات التي واجهتني، أرفع رأسي بكل فخر وامتنان، فاللهم لك الحمد على توفيقك لي لإتمام هذا العمل وتحقيق هذا الحلم.

أهدي هذا التخرج إلى والدي العزيز وأخي الغالي عامر رحمهما الله، راجيةً من الله أن يتغمدهما بواسع رحمته وأن يسكنهما فسيح جناته.

وإلى أمي الحبيبة، إلى القلب الحنون والشمعة التي كانت لي في الليالي المظلمة، سر قوتي ونجاحي، التي كانت سندًا لي بدعائها في الشدائد، حفظها الله وأطال في عمرها.

وإلى إخوتي وأخواتي الأعزاء: حنان، هشام، فيصل، أميرة، وزين الدين، ضلعي الثابت وأمان أيامي، ومن شددت عضدي بهم فكانوا لي ينابيع أرتوي منها، وخيرة أيامي وصفوتها وقرة عيني.

كما أتوجه بخالص الشكر والتقدير إلى زميلتي جيهان التي شاركتني إنجاز هذا العمل، تقديرًا لتعاونها وجهودها، مع أصدق تمنياتي لها بدوام النجاح والتوفيق.

كما أتوجه بالشكر إلى كل من ساهم من قريب أو بعيد في إنجاز هذا العمل، ولو بكلمة طيبة أو دعوة صادقة، فله مني كل التقدير والامتنان.

نسأل الله أن يجعل هذا العمل خالصًا لوجهه الكريم.

بومدين لبنى

Dédicace

﴿ وَمَا تَوْفِيقِي إِلَّا بِاللَّهِ عَلَيْهِ تَوَكَّلْتُ وَإِلَيْهِ أُنِيبُ ﴾

الحمد لله حباً وشكراً وامتناناً على البدء والختام، فلكل بداية نهاية، ولكل جهد طيب ثمرة طيبة.

ها أنا اليوم أتوج لحظاتي الأخيرة في ذلك الطريق الذي كان يحمل في باطنه الأشواك والعثرات، لكنني فعلتها، فالحمد لله الذي يسّر البدايات وبلغنا النهايات بفضله وكرمه.

أهدي هذا النجاح لنفسي الطموحة أولًا ، بدأت بطموح وانتهت بنجاح، ثم إلى كل من سعى معي لإتمام مسيرتي الجامعية. دمتم لي سنداً لا عمر له، أبي وأمي، بكل حب أود أن أخبركما أن هذا الإنجاز هو انعكاس لتعبكما ودعمكما الذي لم يتوقف أبداً.

إخوتي وأخواتي، كنتم دائماً الداعم الأول وسندي والفرحة التي أحتاجها للاستمرار، أهديكم هذا النجاح الذي هو بفضلكم بعد الله.

كما أهدي هذا النجاح إلى زميلتي في هذا العمل، تقديراً لتعاونها ومرافقتها لي خلال هذه التجربة، فشكراً لها على دعمها ومساهمتها في إنجاز هذا العمل.

وإلى عائلتي وأصدقائي، الذين شاركوني لحظات التعب قبل الفرح، وكانوا نوراً يضيء طريقي كلما أثقلته الصعاب، أهديكم هذا العمل بكل محبة وامتنان.

ما كنت لأصل إلى هذه اللحظة لولا توفيق الله، فالحمد لله الذي ملأ دربي خيراً وأملًا، واغرقنا سروراً وفرحاً ينسيني مشقتي.

لموشي جيهان

Résumé :

Le flou de mouvement est l'une des causes majeures de dégradation de la qualité des images médicales à rayons X, réduisant la netteté des structures anatomiques et pouvant affecter la précision du diagnostic. Ce travail propose une approche basée sur le Deep Learning pour restaurer les images dégradées. Une base de données d'images médicales a été préparée puis dégradée artificiellement par flou de mouvement pour simuler des conditions réelles d'acquisition. Un modèle Residual U-Net a ensuite été développé pour restaurer les images altérées, entraîné à l'aide d'une fonction de perte combinée visant à préserver la qualité visuelle et les détails anatomiques. Les performances ont été évaluées via les métriques PSNR, SSIM et RMSE, démontrant une amélioration notable de la qualité de restauration et de la préservation des détails, confirmant l'efficacité des techniques de filtrage basées sur l'IA pour la correction du flou de mouvement et l'amélioration des images médicales.

Mots-clés : Intelligence artificielle, Deep Learning, Residual U-Net, flou de mouvement, restauration d'images médicales, PSNR, SSIM.

Abstract :

Motion blur is one of the major causes of quality degradation in medical X-ray images, reducing the sharpness of anatomical structures and potentially affecting diagnostic accuracy. This work proposes a deep learning-based approach to restore degraded images. A medical image database was prepared and artificially degraded with motion blur to simulate real acquisition conditions. A Residual U-Net deep learning model was then developed to restore the altered images, trained using a combined loss function to preserve visual quality and anatomical details. Model performance was evaluated using PSNR, SSIM, and RMSE metrics, showing notable improvement in restoration quality and detail preservation, confirming the effectiveness of AI-based filtering techniques for motion blur correction and medical image enhancement.

Keywords: Artificial Intelligence, Deep Learning, Residual U-Net, motion blur, medical image restoration, PSNR, SSIM.

الملخص

يُعد ضبابية الحركة من أهم أسباب تدهور جودة صور الأشعة السينية الطبية، إذ تقلل من وضوح التراكيب التشريحية وقد تؤثر على دقة التشخيص. يقترح هذا العمل نهجًا قائمًا على الذكاء الاصطناعي والتعلم العميق لاستعادة الصور المتأثرة بضبابية الحركة. ثم إعداد قاعدة بيانات للصور الطبية وتشويهها اصطناعيًا (بإضافة ضبابية حركة) لمحاكاة ظروف التصوير الحقيقية. ثم طُوّر نموذج تعلم عميق من نوع Residual U-Net لاستعادة الصور المشوهة، باستخدام دالة خسارة مركبة للحفاظ على الجودة البصرية والتفاصيل التشريحية. تم تقييم أداء النموذج باستخدام مقايس PSNR وSSIM وRMSE، وأظهرت النتائج تحسنًا ملحوظًا في جودة الاستعادة والحفاظ على التفاصيل التشريحية، مما يؤكد فعالية تقنيات الترشيح القائمة على الذكاء الاصطناعي في تصحيح ضبابية الحركة وتحسين جودة الصور الطبية.

الكلمات المفتاحية: الذكاء الاصطناعي، التعلم العميق، Residual Unet، ضبابية الحركة، استعادة الصور الطبية،PSNR، SSIM.

Table des Matières

Liste des Figures

Liste des Tableaux

Liste des abréviations

INTRODUCTION GÉNÉRALE.....18

CHAPITRE I : BASES PHYSIQUES DE L'IMAGERIE À RAYONS X

I.1. Introduction.....20

I.2. Production des rayons X.....20

I.2.1. Principe de production des rayons X.....20

I.2.2. Rayonnement de freinage (Bremsstrahlung).....20

I.2.3. Rayonnement caractéristique.....21

I.2.4Tube à rayons X.....22

I.2.4.1. La cathode:.....22

I.2.4.2. L'anode:.....22

I.3. Interactions des rayons X avec la matière.....24

I.3.1. Effet photoélectrique.....24

I.3.2. Effet Compton.....25

I.3.3 Création de paires.....26

I.4. Atténuation des rayonnements.....27

I.5 Effets biologiques des rayonnements.....28

I.5.1 Effets directs et indirects des rayonnements ionisants :.....28

I.5.2.Destin cellulaire après irradiation:.....28

I.5.3 Facteurs modulant la réponse biologique:.....28

I.6. Imagerie médicale à rayons X.....29

I.6.1. Radiographie conventionnelle.....29

I.6.2 Tomodensitométrie (TDM).....30

I.6.2.1 Matériel du scanner.....30

I.6.2.2 Principe de fonctionnement.....31

I.6.2.3 Reconstruction des images.....32

I.6.3 Mammographie.....33

I.6.4 Radiographie dentaire.....34

I.7. Conclusion.....34

CHAPITRE II : FLOU DE MOUVEMENT EN IMAGERIE À RAYONS X

II.1. Introduction....36
II.2. Notions fondamentales sur la qualité de l'image radiologique....36
II.2.1. Résolution spatiale....37
II.2.2. Contraste....37
II.2.3. Bruit....37
II.2.4. Netteté de l'image....37
II.3. Définition du flou de mouvement....38
II.4. Origines du flou de mouvement....38
II.4.1. Mouvements volontaires du patient....38
II.4.2. Mouvements physiologiques involontaires....39
II.4.3. Autres mouvements physiologiques....41
II.4.4. Mouvements du système d'acquisition....41
II.5. Modélisation mathématique du flou de mouvement....41
II.5.1. Modèle de dégradation de l'image....42
II.5.2. Fonction d'étalement du point (PSF)....43
II.5.3. Cas d'un mouvement rectiligne uniforme....43
II.5.4. Représentation fréquentielle du flou....45
II.6. Effets du flou de mouvement sur la qualité de l'image....46
II.6.1. Diminution de la résolution spatiale....46
II.6.2. Réduction du contraste....46
II.6.3. Risque d'erreurs diagnostiques et répétition des examens....47
II.7. Méthodes de réduction du flou de mouvement....47
II.7.1. Réduction du temps d'exposition....48
II.7.2. Immobilisation du patient....48
II.7.3. Contrôle respiratoire....49
II.7.4. Synchronisation cardiaque (ECG-gating)....49
II.7.5. Utilisation des détecteurs numériques rapides....50
II.7.6. Compensation numérique du mouvement....50
II.8. Techniques de restauration et de correction du flou de mouvement....50
II.8.1. Déconvolution....51
II.8.2. Filtre de Wiener....51
II.8.3. Déconvolution aveugle....52
II.8.4. Méthodes basées sur l'intelligence artificielle....52
II.9. Applications cliniques du flou de mouvement et de sa correction....53

II.9.1. Radiographie thoracique.....53
II.9.2. Mammographie.....53
II.9.3. Angiographie.....54
II.9.4. Tomodensitométrie (CT).....54
II.9.5. Imagerie pédiatrique.....55
II.10. Conclusion.....55

CHAPITRE III : TRAITEMENTS DES IMAGES MÉDICALES À L'AIDE DE L'INTELLIGENCE ARTIFICIELLE

III.1. Introduction.....57
III.2. Introduction à l'IA en imagerie médicale.....57
III.2.1. Définition de l'intelligence artificielle.....57
III.2.2. Rôle de l'IA en médecine.....58
III.2.3. Rôle de l'IA dans l'imagerie médicale contemporaine.....58
III.3. Apprentissage automatique et Deep Learning.....59
III.3.1. Notions d'apprentissage automatique (Machine Learning).....59
III.3.2. Apprentissage supervisé et non supervisé.....59
III.3.3. Introduction au Deep Learning.....60
III.3.3.4. Importance des réseaux de neurones dans l'analyse d'images.....61
III.4. Intelligence artificielle pour le filtrage et la restauration d'images.....61
III.4.1. Réduction du bruit (Denoising).....61
III.4.2. Correction du flou (Deblurring).....62
III.4.3. Super-résolution.....62
III.4.4. Amélioration de la qualité d'image (Image Enhancement).....62
III.5. Réseaux de neurones convolutifs et architecture U-Net.....63
III.5.1. Notions essentielles des réseaux de neurones convolutifs (CNN).....63
III.5.2. Limites des CNN dans les tâches d'analyse d'images médicales.....63
III.5.3. Architecture U-Net : principe général et structure encodeur-décodeur.....64
III.5.4. Skip connections et préservation des détails.....65
III.5.5. Applications du modèle U-Net en segmentation et restauration d'images médicales.....65
III.6. Réseaux résiduels et architecture Residual U-Net.....66
III.6.1. Réseaux résiduels (ResNet).....66
III.6.2. Blocs résiduels (Residual Blocks).....66
III.6.3. U-Net avec blocs résiduels (Residual U-Net).....67

III.7. Fonctions de perte pour la restauration d'images....67
III.7.1. Fonctions de perte classiques....67
III.7.2. Edge Loss (perte sur les contours)....68
III.7.3. Frequency Loss (perte en domaine fréquentiel)....69
III.7.4. Fonction de perte combinée....69
III.8. Métriques d'évaluation des performances....70
III.8.1. PSNR (Peak Signal-to-Noise Ratio)....70
III.8.2. SSIM (Structural Similarity Index)....71
III.8.3. RMSE (Root Mean Squared Error)....71
III.9. Optimiseur (AdamW)....72
III.10. Autres architectures profondes utilisées en imagerie médicale....72
III.10.1. GAN (Generative Adversarial Networks) et amélioration d'images....72
III.10.2. Vision Transformers (ViT) : notions générales....73
III.10.3. Comparaison générale des architectures....74
III.11. Importance de l'IA pour l'amélioration des images médicales....75
III.11.1. Amélioration de la qualité des images médicales....75
III.11.2. Réduction du bruit et des artefacts....76
III.11.3. Contribution à l'aide au diagnostic médical....76
III.12. Conclusion....76
CHAPITRE IV : IMPLÉMENTATION ET ÉVALUATION DES PERFORMANCES DU MODÈLE
IV.1. Introduction....78
IV.2. protocole expérimental....78
IV.2.1. Description du jeu de données....79
IV.2.2. phase de génération du flou de mouvement (motion blur)....80
IV.2.2.1. Illustration de la dégradation des images par flou de mouvement....80
IV.2.3. Préparation des données....83
IV.2.3.1. Constitution des paires d'images originales et floutées....83
IV.3. Entraînement du modèle et restauration des images pulmonaires....84
IV.3.1. Répartition des données d'entraînement et de validation....84
IV.3.2. Prétraitement des images....84
IV.3.3. Environnement matériel et logiciel....85
IV.3.4. Paramétrage du modèle Residual U-Net....85
IV.3.5. Fonction de perte hybride....86

IV.3.6. Configuration de l'optimisation....86
IV.3.7. Stratégie d'entraînement progressive....87
IV.3.8. Gestion des points de sauvegarde (checkpoints)....88
IV.3.9. Procédure d'entraînement et de validation du modèle....89
IV.4. Évaluation des performances....90
IV.4.1. Peak Signal-to-Noise Ratio (PSNR)....90
IV.4.2. Structural Similarity Index Measure (SSIM)....90
IV.4.3. Root Mean Square Error (RMSE)....91
IV.5. Résultats et discussion....92
IV.5.1. Résultats quantitatifs de la restauration....92
IV.5.1.1. Discussion des résultats....93
IV.5.2. Analyse de l'évolution de l'apprentissage....94
IV.5.3. Évaluation qualitative des images restaurées....96
IV.5.4. Résultats d’entraînement :....98
IV.6. Discussion des résultats....99
IV.7. Conclusion du chapitre....100
CONCLUSION GÉNÉRALE....101
LISTE DES RÉFÉRENCES....103

Liste des Figures

Figure I.1: Le rayonnement de freinage.....21
Figure I.2 : Rayonnement caractéristique.....22
Figure I.3 : Tube à rayons X.....23
Figure I.4 : Un spectre global d'émission des rayons X.....24
Figure I.5 : L'effet photoélectrique.....25
Figure I.6 : Effet Compton.....26
Figure I.7 : Création de paires.....27
Figure I.8 : Radiographie conventionnelle.....30
Figure I.9 : Principaux composants d'un système de tomodensitométrie (scanner CT).....31
Figure I.10 : Rotation du tube à rayons X et des détecteurs autour du patient lors d'un examen TDM.....32
Figure I.11 : Principe d'acquisition des projections et de reconstruction de l'image en tomodensitométrie.....33
Figure I.12 : Valeurs des unités Hounsfield (UH) pour différents tissus.....33
Figure I.13 : Unité de mammographie numérique plein champ (FFDM).....34
Figure III.1 : Relation hiérarchique entre l'intelligence artificielle (IA), le Machine Learning (ML) et le Deep Learning (DL).....59
Figure III.2 : Comparaison entre l'apprentissage supervisé (classification) et le clustering (apprentissage non supervisé).....60
Figure III.3 : Architecture simplifiée d'un réseau de neurones profond.....61
Figure III.4 : Illustration du processus de convolution dans un réseau CNN appliqué à une image médicale.....63
Figure III.5 : Architecture du modèle Residual U-Net 2D proposé.....64
Figure III.6 : Structure du réseau U-Net : encodeur, décodeur et connexions de saut (skip connections).....65
Figure III.7 : Générateur et discriminateur du réseau GAN.....73
Figure III.8 : Schéma de l'architecture d'un Vision Transformer (ViT).....74
Figure IV.1 : Quelque Images avec flou de mouvement (motion blur).....82
Figure IV.2 : illustre l'évolution des métriques de performance utilisées pour évaluer le modèle durant la phase d'entraînement. Ces résultats permettent d'analyser la qualité de la reconstruction ainsi que la capacité de généralisation du réseau.....95

Figure IV.3 : présente cinq exemples d'images restaurées par le modèle proposé. Pour chaque échantillon, l'image floue en entrée est comparée à l'image de référence (Ground Truth) et à l'image reconstruite..... 97

Liste des Tableaux

Tableau III.1 : Comparaison générale des architectures d'intelligence artificielle utilisées en imagerie médicale..... 75

Tableau IV.1 : Valeurs de référence du PSNR et leur interprétation.....90

Tableau IV.2 : Valeurs de référence du SSIM et leur interprétation.....91

Tableau IV.3 : Valeurs de référence du RMSE et leur interprétation.....92

Tableau IV.4 : Valeurs de PSNR, SSIM et RMSE obtenues avant et après restauration des images test.....93

Tableau IV.5 : Résultats d'entraînement et de validation du modèle.....98

Liste des abréviations

ALARA : As Low As Reasonably Achievable

CCD : Charge-Coupled Device

CNN : Convolutional Neural Network

CMOS : Complementary Metal-Oxide-Semiconductor

CT : Computed Tomography

DL : Deep Learning

DQE : Detective Quantum Efficiency

DSA : Digital Subtraction Angiography

ECG : Electrocardiogram

FFDM : Full-Field Digital Mammography

GAN : Generative Adversarial Network

IA : Intelligence Artificielle

kVp : Kilovoltage Peak

mA : Milliampère

MDCT : Multi-Detector Computed Tomography

ML : Machine Learning

MTF : Modulation Transfer Function

OTF : Optical Transfer Function

PSF : Point Spread Function

PSNR : Peak Signal-to-Noise Ratio

RMSE : Root Mean Square Error

ResNet : Residual Neural Network

SNR : Signal-to-Noise Ratio

SSIM : Structural Similarity Index Measure

TDM : Tomodensitométrie

U-Net : U-Shaped Neural Network

UH : Unités Hounsfield

INTRODUCTION GÉNÉRALE

L'imagerie par rayons X constitue un outil essentiel en physique médicale et en diagnostic clinique. Elle offre la possibilité de visualiser les organes et les structures anatomiques, notamment dans les domaines de l'imagerie thoracique, cardiovasculaire et interventionnelle. Toutefois, la qualité des images obtenues peut être dégradée par l'apparition d'un flou de mouvement, principalement dû aux mouvements respiratoires et cardiaques, ainsi qu'aux déplacements involontaires du patient au cours de l'acquisition.

Dans le cadre de ce travail, une approche basée sur l'intelligence artificielle a été développée afin de réduire les effets du flou de mouvement dans les images médicales. Une base de données d'images médicales a été préparée, puis un flou de mouvement a été artificiellement appliqué afin de reproduire les dégradations observées lors des acquisitions réelles. Un modèle d'apprentissage profond (Deep Learning), fondé sur une architecture U-Net améliorée par l'intégration de blocs résiduels, a ensuite été conçu et entraîné pour restaurer les images dégradées. L'objectif principal est d'améliorer la qualité des images reconstruites et de préserver les informations anatomiques essentielles nécessaires à une interprétation clinique fiable.

Les résultats expérimentaux obtenus mettent en évidence une amélioration notable de la qualité des images restaurées, accompagnée d'une progression significative des indicateurs quantitatifs d'évaluation, notamment le PSNR (Peak Signal-to-Noise Ratio) et le SSIM (Structural Similarity Index). Ces performances démontrent l'efficacité des approches basées sur l'intelligence artificielle pour la correction du flou de mouvement et l'amélioration de la qualité des images médicales. Cette étude souligne ainsi le potentiel de ces méthodes dans le domaine de l'imagerie médicale et ouvre la voie à de futures applications cliniques visant à renforcer la précision diagnostique et la qualité des soins.

CHAPITRE I :
BASES PHYSIQUES DE L'IMAGERIE À RAYONS X

I.1. Introduction

Les rayons X sont un rayonnement électromagnétique d'énergie élevée qui peut pénétrer les tissus biologiques. Depuis qu'ils ont été « découverts » par Wilhelm Conrad Röntgen en 1895, ils jouent un rôle central dans le domaine de l'imagerie médicale grâce à leur propriété de fournir des informations essentielles sur les structures internes de l'organisme humain sans être invasifs. Le principe repose sur l'absorption différentielle du faisceau de rayons X lors de sa traversée des tissus et sur la formation d'une image qui peut être utilisée pour établir un diagnostic. Les systèmes d'imagerie à rayons X ont beaucoup progressé au cours des dernières décennies, en fournissant une image de meilleure qualité, un diagnostic plus précis et en diminuant progressivement la dose de rayonnement administrée au patient.

I.2. Production des rayons X

I.2.1. Principe de production des rayons X

Les rayons X sont générés par les électrons qui ont une très haute énergie en interaction avec la matière. Au cours de cette interaction, une partie de l'énergie cinétique des électrons est transformée en rayonnement électromagnétique de haute énergie (rayons X) qui est généré par le tube radiogène. En collision avec les atomes du matériau de l'anode, ils se combinent aux atomes du matériau pour créer les rayons X, par deux mécanismes physiques principaux, lorsqu'ils atteignent la cible métallique de l'anode.[1][2]

- Rayonnement de freinage (Bremsstrahlung).
- Rayonnement caractéristique.

I.2.2. Rayonnement de freinage (Bremsstrahlung)

Le rayonnement de freinage (également appelé Bremsstrahlung) est l'un des principaux modes de génération des rayons X dans un tube radiogène. Il se produit lorsqu'un électron de haute énergie interagit avec le champ électrique des noyaux atomiques du matériau cible, résultant en sa décélération ou déviation de sa trajectoire,

et donc en sa perte d'énergie cinétique, laquelle est convertie en photons de rayons X. L'efficacité de ce processus dépend de l'énergie de l'électron incident et du numéro atomique du matériau qui constitue la cible (anode). C'est la raison pour laquelle les matériaux tels que le tungstène sont souvent utilisés en radiologie, en partie grâce à sa grande résistance thermique et à son très haut numéro atomique.[1]

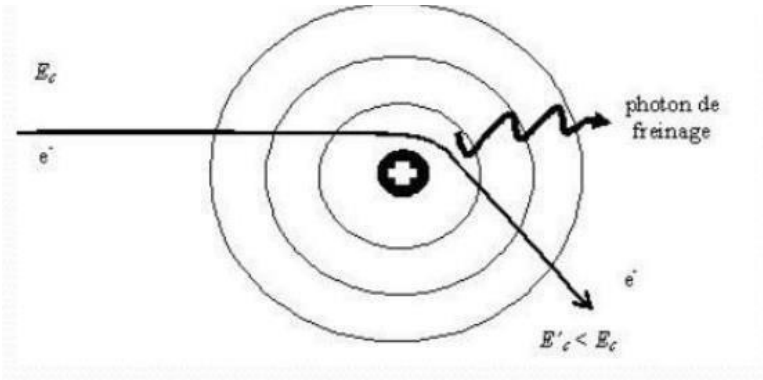


Figure I.1: Le rayonnement de freinage

I.2.3. Rayonnement caractéristique

Le second mécanisme fondamental de production des rayons X est le rayonnement caractéristique, qui se produit quand un électron incident a une énergie suffisante pour expulser un électron d'une couche électronique interne de l'atome cible. Son éjection laisse une lacune électronique dans l'atome, qui se trouve alors dans un état excité et instable. Afin de retrouver un état énergétique plus stable, un électron provenant d'une couche plus externe effectue une transition vers la couche interne afin de combler cette lacune. Cette transition s'accompagne de l'émission d'un photon X dont l'énergie est égale à la différence entre les niveaux d'énergie des deux couches concernées. Contrairement au rayonnement de freinage, le rayonnement caractéristique possède un spectre discret, avec des raies nettes et bien définies, caractéristiques de chaque élément chimique. Le rayonnement caractéristique est le rayonnement d'un photon d'énergie fixée par la structure électronique du tungstène si l'on utilise une cible de tungstène. [1]

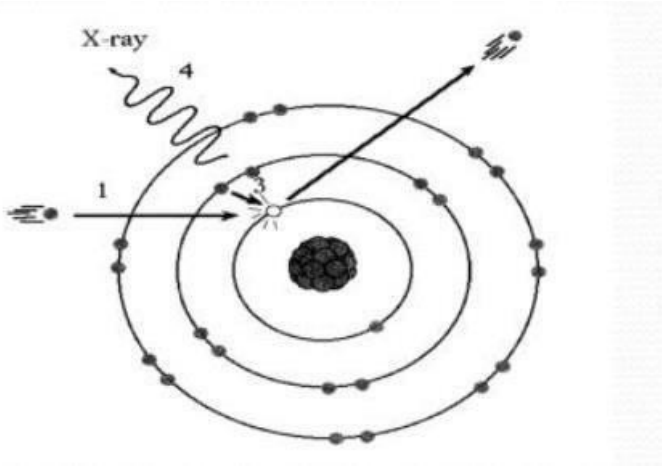


Figure I.2 : Rayonnement caractéristique

I.2.4Tube à rayons X

Le tube à rayons X est un dispositif essentiel utilisé pour ON-RAYS inside medical imaging systems. Il assure la conversion de l'énergie électrique en rayonnement X et en chaleur. Afin d'éviter la dispersion des électrons et les phénomènes d'ionisation avec les molécules d'air, le tube radiogène est placé dans une enceinte sous vide. Le dispositif est principalement constitué de deux éléments fondamentaux : la cathode et l'anode, garantissant ainsi une production efficace et contrôlée du rayonnement X. [3]

I.2.4.1. La cathode:

Le rôle de la cathode est de générer les électrons. Le filament est porté à une température très élevée, typiquement au-dessus de 2200 °C, ce qui fait qu'il émet des électrons par le phénomène d'émission thermoïonique. Ces électrons sont ensuite focalisés et orientés vers l'anode par l'intermédiaire d'une coupelle de focalisation chargée négativement, ce qui permet d'avoir un faisceau électronique précis et bien dirigé.[3]

I.2.4.2. L'anode:

L'anode a pour fonction de convertir l'énergie cinétique des électrons incidents en rayonnement X tout en assurant l'évacuation de la chaleur générée lors de leur impact. Lorsque les électrons accélérés frappent la cible de l'anode, un faible pourcentage de l'énergie est converti en rayons X tandis que le reste de l'énergie est dissipé sous forme de chaleur. C'est la raison pour laquelle l'anode est souvent

construite avec des matériaux qui ont un point de fusion élevé, comme le tungstène, qui est également un matériau avec un grand numéro atomique, favorable pour la production efficace des rayons X. Le tube à rayons X assure ainsi la production du faisceau de rayonnement employé en radiologie pour la formation des images médicales.[3]

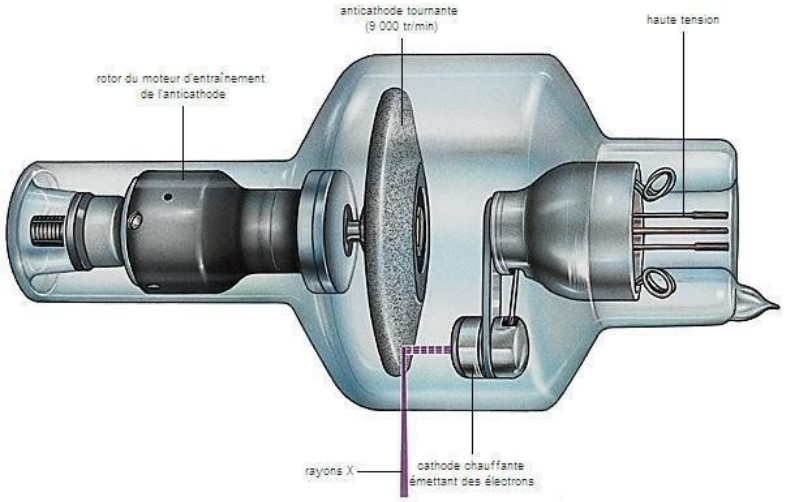


Figure I.3 : Tube à rayons X

I.2.5. Spectre des rayons X

Le spectre des rayons X est une distribution des énergies des photons émis par le tube radiogène. Il est formé de deux parties principales : un spectre continu et des raies discrètes caractéristiques. Le spectre continu correspond au rayonnement de freinage (Bremsstrahlung), et est large en énergie des photons émis. Les pics discrets du spectre correspondent au rayonnement caractéristique et ont une énergie spécifique qui dépend de la substance dont les tubes radiogènes médicaux sont faits, en particulier le tungstène. La tension qui est appliquée au tube radiogène affecte directement l'énergie maximale du spectre. L'augmentation de la tension (kV) produit des photons d'énergie plus élevée, et donc des rayons X plus capables de pénétrer les tissus.[2]

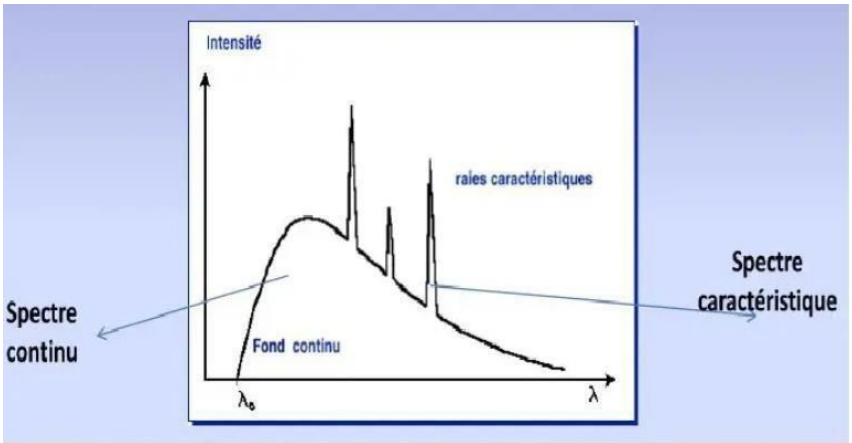


Figure I.4 : Un spectre global d'émission des rayons X

I.3. Interactions des rayons X avec la matière

En traversant les tissus biologiques, le rayonnement X interagit avec les atomes de ces tissus, absorbant une partie ou la totalité de l'énergie des photons incidents. Cela est d'une grande importance pour la formation de l'image radiologique, mais aussi pour la dose déposée dans les tissus. Les principales interactions du rayonnement X avec la matière sont l'effet photoélectrique, la diffusion Compton et la création de paires.

I.3.1. Effet photoélectrique

L'effet photoélectrique, qui se produit principalement pour des photons de faible énergie (quelques keV, typiquement < 100 keV), correspond à une interaction où le photon incident est absorbé par un électron des couches internes de l'atome (typiquement K ou L), ce qui engendre l'éjection de l'électron, appelé photoélectron, avec une énergie cinétique donnée par la relation ci-dessous :

$$Ec = h\nu - Eb$$

où :

• hν : représente l'énergie de la particule incidente.

• Eb : énergie de liaison de l'électron.

La probabilité de l'effet photoélectrique croît fortement en fonction du numéro atomique Z du matériau, et est proportionnelle à environ Z^4.

Les os, riches en calcium, sont donc très différents des tissus mous en radiologie conventionnelle. Après l'éjection du photoélectron, l'atome est instable et retrouve son état d'équilibre en émettant un rayonnement X de fluorescence ou un électron Auger.[4]

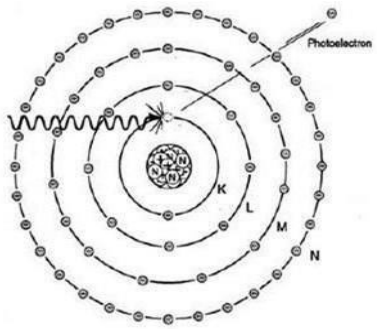


Figure I.5 : L'effet photoélectrique

I.3.2. Effet Compton

Dans la gamme d'énergie utilisée en radiodiagnostic, la diffusion Compton devient progressivement dominante lorsque l'énergie des photons augmente. Dans ce cas, le photon incident cède une partie de son énergie à un électron périphérique faiblement lié à l'atome. Celui-ci est projeté dans le sens de l'incident avec une énergie plus faible et sous un angle de diffusion. La variation de longueur d'onde du photon diffusé est donnée par la relation :

$$\Delta\lambda = (h / m_0 c) \times (1 - \cos\theta)$$

où :

• h : constante de Planck.

• m_0 : représente la masse au repos de l'électron.

• c : vitesse de la lumière dans le vide.

La diffusion Compton est moins dépendante du numéro atomique, ce qui contribue à la répartition relativement homogène de la dose dans les tissus biologiques. [4]

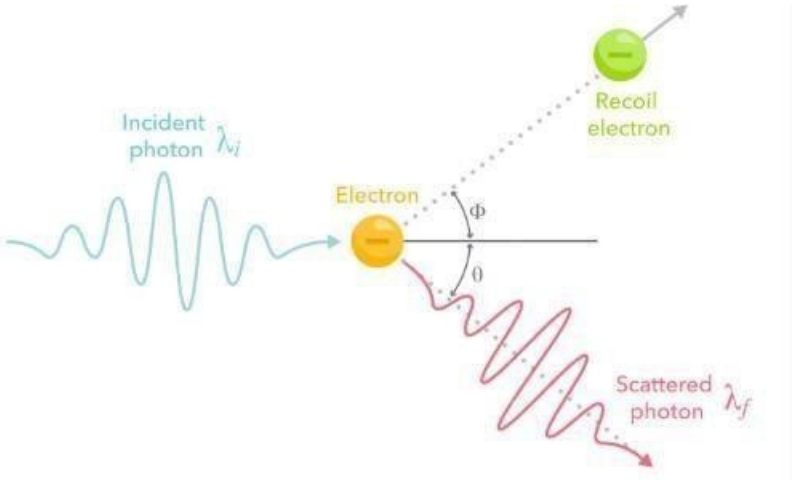


Figure I.6 : Effet Compton

I.3.3 Création de paires

Lorsque l'énergie du photon incident est supérieure à 1,022 MeV, le photon interagit avec le champ de Coulomb nucléaire et crée une paire électron-positon. L'énergie minimale requise pour cette interaction correspond à la somme des énergies de masse au repos de l'électron et du positon, et est donnée par la relation:

$$Emin = 2 \times 0{,}511\ MeV = 1{,}022\ MeV \quad (1.3)$$

Le positon produit est une antiparticule de l'électron. Il se détruit après une brève traversée de la matière, dans le milieu, par annihilation avec un électron, émettant deux photons de 511 keV dans des directions opposées. C'est le principe physique de la tomographie par émission de positons (TEP).[2]

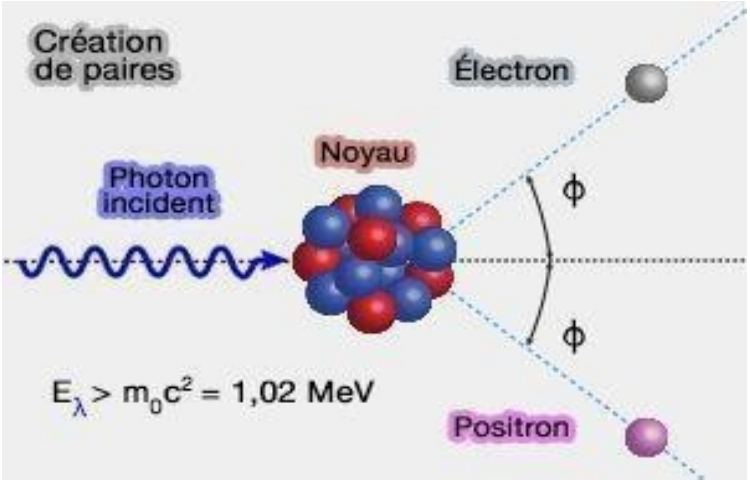


Figure I.7 : Création de paires

I.4. Atténuation des rayonnements

L'intensité d'un faisceau de rayons X traversant un milieu homogène décroît exponentiellement selon la loi de Beer-Lambert :

$$I = I_0 \times e^{(-\mu x)}$$

où :

a) I_0 est l'intensité initiale du faisceau.

b) I est l'intensité de l'onde après sa traversée du milieu.

c) x est l'épaisseur du milieu traversé par le faisceau.

d) μ est le coefficient d'atténuation linéaire total.

Ce coefficient combine les effets des trois mécanismes d'interaction et dépend à la fois de l'énergie du photon et du matériau traversé.[2]

I.5 Effets biologiques des rayonnements

I.5.1 Effets directs et indirects des rayonnements ionisants :

Les effets biologiques des rayonnements ionisants résultent de leurs interactions avec la matière, où les électrons secondaires générés induisent des dommages cellulaires, qui se présentent sous deux formes : la première (directe) est celle de l'ionisation directe des molécules d'ADN par le rayonnement, et représente environ 30 à 40 % des lésions ; elle engendre des cassures simple brin, généralement réparables. La seconde (indirecte) est due à la radiolyse (interaction avec la matière) de l'eau intracellulaire, formant des radicaux libres, notamment OH·, qui ont une forte activité de lésion rapide des molécules d'ADN et représentent environ 60 à 70 % des lésions.[5][6][7]

I.5.2.Destin cellulaire après irradiation:

Selon la gravité des lésions et l'efficacité des mécanismes de réparation, la cellule peut être destinée à différents sorts une réparation totale des lésions, une apoptose (mort cellulaire programmée), une sénescence cellulaire (arrêt permanent de la division), ou encore des mutations persistantes et la possibilité de devenir une cellule cancéreuse.[5][6][7]

I.5.3 Facteurs modulant la réponse biologique:

La réponse biologique aux rayonnements dépend de plusieurs paramètres : l'efficacité biologique relative (EBR) qui varie selon le type de rayonnement, l'oxygénation des tissus où les tissus hypoxiques sont plus résistants avec un facteur OER pouvant atteindre 3, le cycle cellulaire où les cellules en mitose sont les plus radiosensibles, ainsi que le débit de dose car en radiothérapie le fractionnement des doses permet aux tissus sains de réparer partiellement les dommages entre les séances. [5][6][7]

I.6. Imagerie médicale à rayons X

Les techniques d'imagerie médicale utilisant les rayons X regroupent l'ensemble des techniques utilisant des rayons X pour visualiser les structures internes du corps humain. En fonction de la densité et de la composition des tissus traversés, les rayons X sont absorbés à des degrés différents, permettant la formation d'images médicales utiles au diagnostic et au suivi thérapeutique. Les techniques principales d'imagerie médicale utilisant les rayons X sont la radiographie conventionnelle, la tomodensitométrie (TDM), la mammographie et la radiographie dentaire.[4]

I.6.1. Radiographie conventionnelle

La radiologie conventionnelle (radiographie standard) est une technique d'imagerie médicale qui utilise un tube à rayons X et un système de détection (un film radiographique ou un capteur numérique) visant à créer des images utilisables en diagnostic. Elle est utilisée pour examiner différentes parties du corps, y compris os, le thorax, l'abdomen, et est souvent une première étape dans l'exploration médicale. Le principe de base est que les tissus de différentes densités absorbent différentes quantités de rayons X, ce qui fait qu'ils apparaissent en différentes nuances de gris sur la radiographie et les structures denses (les os) apparaissent en blanc. C'est ainsi que les structures anatomiques peuvent être bien définies, ce qui permet d'identifier de possibles anomalies.[7]

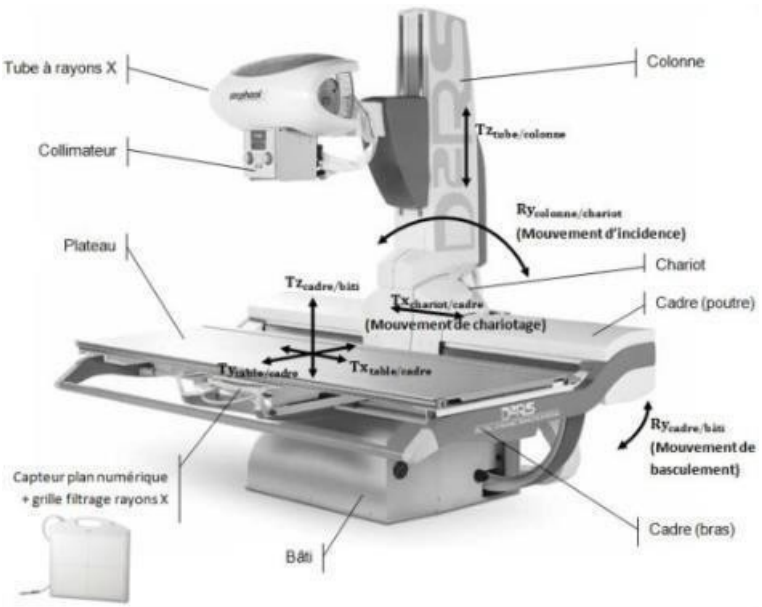


Figure I.8 : Radiographie conventionnelle

I.6.2 Tomodensitométrie (TDM)

La tomodensitométrie, ou scanographie, utilise les rayons X pour créer des images en coupe du corps humain. Les images sont numérisées sous différents angles du corps pour être reconstituées par un ordinateur, et permettent de fournir des informations plus détaillées que la radiographie standard sur les structures internes.[4][8]

I.6.2.1 Matériel du scanner

Les composants d'un scanner sont principalement :

- **Le statif** : il constitue la structure principale du scanner et contient le tube à rayons X ainsi que les détecteurs responsables de la collecte des données lors de l'acquisition des images.
- **Le tube à rayons X et les détecteurs :** ils sont situés à l'intérieur du statif et effectuent une rotation autour du patient afin de permettre l'acquisition des projections sous différents angles.
- **La table d'examen mobile** : elle permet de positionner le patient et de le déplacer progressivement à l'intérieur du statif durant l'examen.

- **Le système informatique** : il assure le traitement des données acquises ainsi que la reconstruction des images en coupes transversales.
- **Les systèmes électriques** : ils fournissent l'énergie nécessaire au fonctionnement de l'ensemble des composants du scanner.
- **Le système de refroidissement** : il permet de dissiper la chaleur produite par le tube à rayons X afin de garantir la stabilité et la sécurité du fonctionnement. [4]

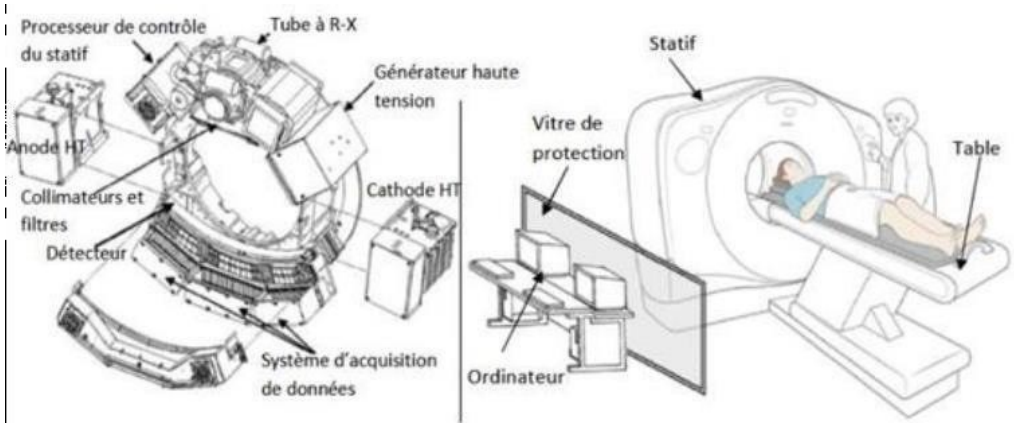


Figure I.9 : Principaux composants d'un système de tomodensitométrie (scanner CT)

I.6.2.2 Principe de fonctionnement

Lors de l'examen, le patient est en position couchée sur une table d'examen mobile qui est amenée progressivement à l'intérieur du statif. Il est important que la table mobile soit fixée afin d'assurer une bonne qualité d'image sans artéfacts dus au mouvement du patient. Dans certains cas, un produit de contraste peut être utilisé pour améliorer la visibilité de l'organe ou des vaisseaux sanguins. Le faisceau de rayons X effectue alors une rotation autour de la région étudiée et un grand nombre d'images sont prises sous différents angles, chacune créant une mesure de la quantité d'absorption des rayons X par le tissu traversé. [4]

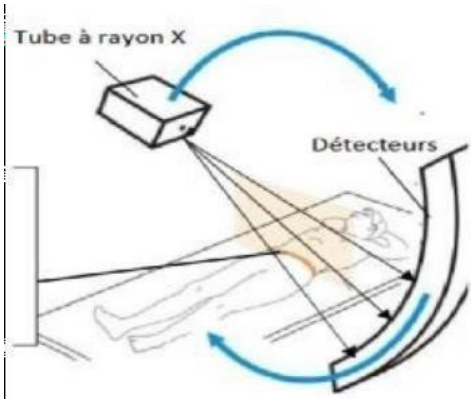


Figure I.10 : Rotation du tube à rayons X et des détecteurs autour du patient lors d'un examen TDM

I.6.2.3 Reconstruction des images

L'acquisition des projections est suivie de la reconstruction des images par traitement informatisé qui consiste à calculer les coefficients d'atténuation des différents éléments du volume exploré, à partir des projections acquises. La reconstruction repose sur des algorithmes mathématiques.

L'utilisation de la tomodensitométrie est large, notamment dans la neurologie, l'imagerie thoracique, abdominale et vasculaire, la radiothérapie, en raison notamment de sa très bonne résolution spatiale, sa bonne visualisation des organes internes, de l'acquisition rapide des images et de la possibilité de reconstruction tridimensionnelle. [4]

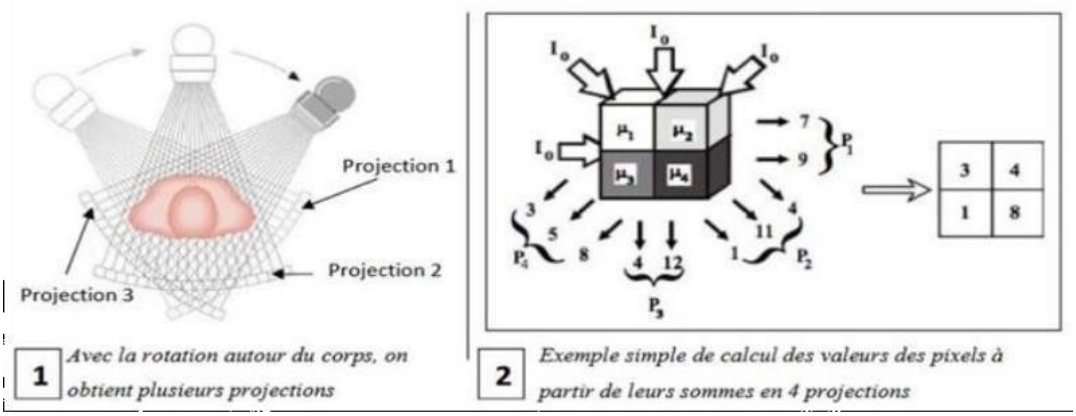


Figure I.11 : Principe d'acquisition des projections et de reconstruction de l'image en tomodensitométrie

Les densités des différents tissus sont exprimées en unités Hounsfield (UH). L'air possède une valeur d'environ −1000 UH, l'eau 0 UH, tandis que les os et certains métaux présentent des valeurs positives pouvant dépasser +1000 UH.

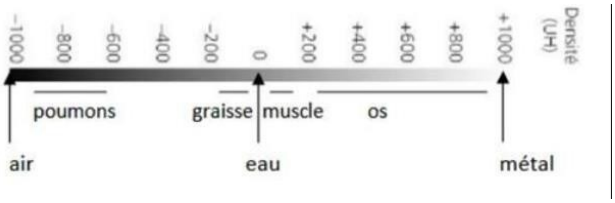


Figure I.12 : Valeurs des unités Hounsfield (UH) pour différents tissus

I.6.3 Mammographie

La mammographie fait partie des examens d'imagerie spécialisés qui utilisent des rayons X à faible énergie pour identifier les anomalies du sein, en particulier les tumeurs mammaires. Elle offre une image détaillée des tissus mammaires et est une part cruciale du dépistage du cancer du sein. [9]



Figure I.13 : Unité de mammographie numérique plein champ (FFDM)

I.6.4 Radiographie dentaire

La radiographie dentaire est une technique d'imagerie qui permet d'explorer les dents, les mâchoires, les structures osseuses qui leur sont associées, et qui peut inclure la radiographie panoramique dentaire (panorex) qui donne une image de l'ensemble de la dentition. Cette technique est utile pour la détection de caries dentaires, d'infections, d'anomalies de position des dents et de lésions osseuses. Elle est en outre un outil indispensable pour planifier les soins dentaires et orthodontiques, car elle apporte des données fiables sur l'état des structures bucco-dentaires. [9]

I.7. Conclusion

Ce chapitre a apporté les bases de l'imagerie à rayons X: production des rayons X, interactions avec la matière, principales techniques d'imagerie médicale à rayons X.

CHAPITRE II :
FLOU DE MOUVEMENT
EN IMAGERIE À RAYONS X

II.1. Introduction

L'imagerie à rayons X est la technique d'imagerie utilisée en diagnostic clinique le plus souvent en raison des nombreux avantages qu'elle offre : acquisition rapide, ubiquité, prix relativement bas. De nombreuses conditions physiques et techniques cependant conditionnent la qualité diagnostique des images obtenues. Le flou de mouvement est l'une des principales sources de dégradation de l'image, lorsqu'il existe un déplacement de l'objet à examiner ou du système d'acquisition pendant l'exposition aux rayons X.

Le flou de mouvement diminue la netteté des structures anatomiques, réduit la résolution spatiale et peut compromettre la détection de petites lésions. Dans certaines situations, il peut conduire à la répétition de l'examen, et ainsi à une augmentation de la dose reçue par le patient. Comprendre le mécanisme à la base de ce phénomène et développer des techniques afin de limiter ce phénomène est un défi important en physique médicale et en radiologie.

Ce chapitre fournit une discussion détaillée de l'effet de flou de mouvement sur l'imagerie à rayons X et analyse en profondeur le fondement physique, la formation de flou de mouvement, l'impact sur la qualité diagnostique, et les techniques de correction de flou de mouvement actuellement disponibles, pour préparer la discussion des techniques avancées utilisant l'IA dans le chapitre suivant.

II.2. Notions fondamentales sur la qualité de l'image radiologique

La qualité d'une image radiologique se caractérise par la fidélité à laquelle l'image reproduit les structures anatomiques étudiées. Elle est essentiellement fonction de quatre paramètres :

- La résolution spatiale ;
- Le contraste ;

- Le bruit ;
- La netteté de l'image ;

II.2.1. Résolution spatiale

La résolution spatiale caractérise la capacité d'un système d'imagerie à distinguer deux structures voisines de petite taille. Ceci est typiquement donné en paires de lignes par millimètre (pl/mm) et dépend du type de détecteur, de la géométrie du faisceau et du flou propre au système. La résolution spatiale maximale théorique dépend de la taille du foyer du tube à rayons X et du pas de pixel du détecteur numérique. [10]

II.2.2. Contraste

Le contraste radiologique représente la différence de densité optique (ou de niveau de gris en numérique) entre deux zones contiguës de l'image. Il est sous l'influence de l'énergie du faisceau de rayons X (kVp), du coefficient d'atténuation des tissus, de la diffusion Compton, et du traitement numérique de l'image. Des lésions de faible densité peuvent être manquées, telles que les infiltrats pulmonaires ou les micro-calcifications mammaires. [10]

II.2.3. Bruit

Le bruit dans les images radiologiques est principalement d'origine quantique (fluctuations statistiques du nombre de photons X détectés), mais inclut également le bruit électronique du détecteur. Le rapport signal-sur-bruit (SNR) et l'efficacité de détection quantique (DQE) sont les deux moyens de le quantifier. Le bruit quantique est inversement proportionnel à la racine carrée de la dose reçue par le détecteur, ce qui entraîne un compromis entre la réduction du bruit (et donc de la dose) et la qualité d'image. [10]

II.2.4. Netteté de l'image

La netteté globale de l'image radiologique est une combinaison de la netteté intrinsèque du système, du flou géométrique (associé au foyer du tube), du flou de diffusion (dans le détecteur à écran) et du flou de mouvement. La fonction de transfert de

modulation (MTF) est une mesure quantitative de la netteté qui caractérise le passage des fréquences spatiales au travers de l'ensemble du système d'imagerie. [10]

II.3. Définition du flou de mouvement

Le flou de mouvement est caractérisé par une perte de netteté due à la translation relative entre l'objet imagé et le système de détection lors de l'acquisition de l'image.

Si un point anatomique change de position pendant l'exposition, l'information est enregistrée sur plusieurs éléments du détecteur, et non sur un seul. On observe une dispersion spatiale, qui se traduit par un étalement des contours et une perte de détails.

Le flou observé est principalement lié :

- de la vitesse du mouvement ;
- du temps d'exposition ;
- de la direction du mouvement ;
- de la résolution intrinsèque du système. [11]

II.4. Origines du flou de mouvement

II.4.1. Mouvements volontaires du patient

Les causes principales de flou de mouvement en imagerie à rayons X sont les mouvements volontaires du patient, qui sont ceux que le patient peut effectuer volontairement ou involontairement pendant l'exposition radiologique. Même pour de faibles amplitudes, ces mouvements peuvent affecter de manière importante la qualité de l'image, notamment pour des temps d'acquisition relativement longs et/ou lorsque l'examen doit être réalisé à haute résolution spatiale.

Ils peuvent être reliés :

- à l'inconfort ;
- à la douleur ;

- à l'anxiété ;
- à l'incapacité du patient à rester immobile.

Les examens pédiatriques sont particulièrement concernés parce qu'il est difficile de maintenir l'immobilité chez les jeunes patients. [13]

II.4.2. Mouvements physiologiques involontaires

Les mouvements physiologiques involontaires sont des mouvements naturels qui se produisent dans le corps humain sans être contrôlés par le patient. Contrairement aux mouvements volontaires, ils persistent en dépit d'un parfait immobilisme du patient durant l'examen radiologique. Ces mouvements représentent un facteur de flou critique dans l'imagerie aux rayons X, à cause de la modification de la position des structures anatomiques durant l'exposition.

L'importance du flou généré dépend de plusieurs facteurs, notamment l'amplitude du mouvement, sa vitesse et la durée d'exposition. Les mouvements physiologiques principaux qui contribuent au flou sont les mouvements respiratoires, cardiaques et digestifs. [13]

a) Mouvement respiratoire

La respiration induit des mouvements cycliques des structures thoraciques et abdominales qui peuvent atteindre 20 à 30 mm d'amplitude et une fréquence respiratoire de 12 à 20 cycles/minute. Les organes les plus touchés sont les poumons, le diaphragme, le foie et la rate. D'une part, même un léger mouvement respiratoire d'une amplitude de quelques millimètres sur un temps d'exposition de 200 ms en radiographie thoracique peut générer un flou important. Cela peut masquer de petits nodules pulmonaires ou des infiltrats discrets.

b) Mouvement cardiaque

Le cœur subit un mouvement périodique d'amplitude variable, suivant la phase du cycle cardiaque, et de fréquence normale de 60 à 80 battements/minute. La vitesse de déplacement des parois cardiaques peut atteindre 50 à 150 mm/s lors de la phase de contraction des ventricules droit et gauche. En angiographie coronarienne et scanographie

cardiaque, ce mouvement est la cause principale de dégradation de l'image, pour laquelle des techniques de synchronisation électrocardiographique (ECG-gating) sont nécessaires pour obtenir une image nette.

c) Mouvements digestifs

Le tube digestif produit des ondes de péristaltisme, notamment dans l'intestin grêle et le côlon, qui causent des déplacements imprévisibles et irréguliers pouvant atteindre plusieurs centimètres. Ces mouvements peuvent être particulièrement gênants en imagerie abdomino-pelvienne (radiographie de l'abdomen sans préparation, scanner abdominal) et peuvent se présenter comme des lésions ou masquer d'autres lésions. Leur contrôle nécessite parfois l'administration de médicaments antispasmodiques.

d) Mouvements vasculaires

Les vaisseaux sanguins ont aussi des mouvements physiologiques qui sont liés à la circulation du sang et aux pulsations artérielles. Le mécanisme de contraction cardiaque entraîne une onde de pression qui se propage dans le sang lors de l'éjection, causant une dilatation des vaisseaux sanguins à chaque pulsation. Ce phénomène est particulièrement marqué dans :

- l'aorte ;
- les artères carotides ;
- les artères pulmonaires ;
- les artères coronaires.

Ces pulsations peuvent entraîner une légère déformation des parois vasculaires, favorisant la dégradation de l'image, particulièrement en angiographie à haute résolution. Dans certains cas, les pulsations artérielles peuvent générer des artefacts susceptibles d'être confondus avec des anomalies anatomiques.

II.4.3. Autres mouvements physiologiques

D'autres phénomènes physiologiques peuvent également contribuer au flou de mouvement. [13]

a) Mouvements musculaires involontaires

Même au repos, certains muscles présentent une activité tonique permanente permettant le maintien de la posture. Cette activité peut engendrer de légers déplacements des segments anatomiques étudiés.

b) Tremblements physiologiques

Le corps humain présente naturellement de faibles oscillations appelées tremblements physiologiques. Bien qu'ils soient fréquemment imperceptibles, ils peuvent être détectés dans des conditions d'examen à très haute résolution.

c) Mouvements oculaires

Le flou dû aux mouvements des globes oculaires est une source majeure de flou dans les explorations orbitaires et maxillo-faciales.

II.4.4. Mouvements du système d'acquisition

Le flou de mouvement peut également être causé par les mouvements du système d'acquisition. Lors de l'acquisition d'un scanner hélicoïdal ou axial (CT), le mouvement de la table pendant l'acquisition peut générer des artefacts si le déplacement de la table n'est pas parfaitement contrôlé. En angiographie de soustraction numérique (DSA), les vibrations mécaniques du bras en C peuvent laisser un flou résiduel. En mammographie, la compression de la palette et/ou les vibrations de la table peuvent avoir un impact sur la qualité de l'image. Ces sources de flou sont généralement minimisées par la conception mécanique des équipements et leur maintenance régulière. [13]

II.5. Modélisation mathématique du flou de mouvement

Pour comprendre les mécanismes de dégradation des images radiologiques et pour élaborer des techniques efficaces de correction, il est essentiel de modéliser mathématiquement le flou de mouvement. Le flou de mouvement apparaît lors de la

formation de l'image en imagerie par rayons X. Ce déplacement peut être lié au patient, à un organe interne ou à certains éléments du système d'imagerie. La conséquence directe est une perte de netteté et une diminution de la résolution spatiale de l'image obtenue.

Pour étudier ce phénomène, l'image radiologique est généralement vue comme le produit d'un système de formation d'image. Dans des conditions idéales, l'image enregistrée doit être une représentation fidèle de l'objet observé. Cependant, la présence d'un mouvement modifie cette représentation et introduit une dégradation qui peut être décrite mathématiquement.

II.5.1. Modèle de dégradation de l'image

Le modèle de convolution est le plus utilisé pour représenter le flou de mouvement. L'image observée est supposée être la convolution de l'image idéale avec une fonction représentant le mouvement, à laquelle s'ajoute le bruit :

$$g(x,y) = f(x,y) * h(x,y) + n(x,y)$$

où :

- g(x,y) est l'image observée ou dégradée ;
- f(x,y) est l'image idéale non floutée ;
- h(x,y) est la fonction d'étalement du point (Point Spread Function, PSF) décrivant l'effet du mouvement ;
- n(x,y) représente le bruit ;
- $*$ désigne l'opération de convolution.

Cette équation signifie que chaque point de l'objet ne sera pas enregistré comme un point unique sur le détecteur, mais comme une distribution spatiale, dont la forme dépend du mouvement effectué pendant l'exposition. [12]

II.5.2. Fonction d'étalement du point (PSF)

L'étalement du point, ou Point Spread Function (PSF), est un outil essentiel pour décrire le flou. Elle décrit la réponse du système lorsqu'un point théoriquement infinitésimal est imagé.

Dans un système parfait, un point de l'objet devrait apparaître comme un point sur l'image. En présence de mouvement, ce point est étalé sur une certaine distance, ce qui entraîne une perte de netteté.

La forme de la PSF dépend :

- de la nature du mouvement ;
- de sa direction ;
- de sa vitesse ;
- du temps d'exposition.

La connaissance de la PSF est indispensable pour les techniques de restauration d'images basées sur la déconvolution. [12]

II.5.3. Cas d'un mouvement rectiligne uniforme

Le flou de mouvement rectiligne uniforme correspond au cas observé lorsqu'un objet se déplace à vitesse constante selon une direction donnée pendant toute la durée de l'exposition. Ce modèle est fréquemment utilisé pour décrire les effets du mouvement en imagerie médicale et en traitement d'images.

Dans ce cas, la fonction d'étalement du point (PSF) est représentée par une fonction uniforme répartie sur la trajectoire du mouvement. Pour un déplacement de longueur L orienté suivant un angle θ, la PSF est définie par :

$$h(x,y) = \begin{cases} \frac{1}{L}, & \text{si } (x,y) \text{ appartient au segment de longueur } L \\ 0, & \text{ailleurs} \end{cases}$$

Cette fonction traduit le fait que la quantité d'énergie d'un point de l'image est répartie uniformément le long de la trajectoire lors du déplacement.

La transformée de Fourier de la PSF dans le domaine fréquentiel s'écrit :

$$H(u,v) = \operatorname{sinc}\left[\pi L(u\cos\theta + v\sin\theta)\right] e^{-j\pi L(u\cos\theta + v\sin\theta)}$$

avec :

$$\operatorname{sinc}(x) = \frac{\sin(x)}{x}$$

où :

- L représente la longueur du déplacement ;
- θ est l'angle du mouvement ;
- u et v sont les coordonnées fréquentielles ;
- j désigne l'unité imaginaire.

Il se trouve que la réponse de ce flou de mouvement est régie par une fonction sinc, comme l'indique la formule ci-dessus. Cette dernière présente des annulations pour certaines fréquences, dites « zéros fréquentiels » :

$$u\cos\theta + v\sin\theta = \frac{k}{L}$$

où k est un entier non nul.

À ces fréquences, l'information de l'image est totalement supprimée. Cette perte est irréversible et rend les opérations de restauration par déconvolution beaucoup plus difficiles. Le nombre de fréquences affectées est proportionnel à la longueur du déplacement L ; plus la longueur est grande, plus la dégradation de la qualité de l'image et de sa résolution spatiale est importante. [12]

II.5.4. Représentation fréquentielle du flou

L'étude du flou de mouvement peut également être effectuée dans le domaine fréquentiel à l'aide de la transformée de Fourier. Dans ce domaine, l'opération de convolution observée dans le modèle spatial se transforme en une simple multiplication, ce qui facilite l'analyse mathématique du phénomène. Le modèle de dégradation de l'image s'écrit alors :

$$G(u,v) = F(u,v) \cdot H(u,v) + N(u,v)$$

où :

- G(u,v) est la transformée de Fourier de l'image dégradée ;
- F(u,v) correspond à la transformée de Fourier de l'image originale ;
- H(u,v) est la fonction de transfert optique (Optical Transfer Function, OTF) du flou de mouvement ;
- N(u,v) représente la composante fréquentielle du bruit.

Cette représentation permet de mieux comprendre l'influence du flou sur les différentes fréquences spatiales de l'image. En particulier, le flou de mouvement agit comme un filtre qui atténue les hautes fréquences, responsables des détails fins et des contours. Par conséquent, l'image obtenue apparaît moins nette et présente une diminution de sa résolution spatiale.

La fonction de transfert H(u,v) joue un rôle essentiel dans les méthodes de restauration d'images par déconvolution. En théorie, elle permet de corriger les effets du flou et de reconstruire l'image originale. Cependant, lorsque certaines fréquences présentent des valeurs très faibles de H(u,v), le bruit est amplifié lors de la restauration, ce qui limite la qualité de l'image reconstruite et empêche une récupération complète de l'information perdue. [12]

II.6. Effets du flou de mouvement sur la qualité de l'image

II.6.1. Diminution de la résolution spatiale

Le flou de mouvement diminue la résolution spatiale du système d'imagerie, soit sa capacité à discerner des structures anatomiques très voisines. Lorsqu'un mouvement survient pendant l'exposition, les détails fins de l'image sont étalés sur plusieurs pixels, ce qui entraîne une perte de netteté et une diminution de la qualité de l'image.

L'importance de cette dégradation dépend de l'amplitude du déplacement. Pour une longueur d, la résolution spatiale maximale est environ de 1/d paires de lignes par millimètre (pl/mm) pour un mouvement rectiligne uniforme. Cela signifie que plus le déplacement est important, plus la résolution diminue. Cette diminution de la résolution spatiale peut compromettre la détection de petites structures ou micro-lésions, telles que :

- les micro-nodules pulmonaires ;
- les microcalcifications mammaires ;
- les fractures fines ;
- les petites lésions osseuses.

Ainsi, même un faible mouvement pendant l'exposition peut affecter la qualité diagnostique de l'image et rendre plus difficile pour le radiologue la détection de certaines anomalies de petite taille. [10]

II.6.2. Réduction du contraste

Le flou de mouvement est responsable d'une perte de contraste des structures anatomiques, particulièrement pour les détails fins (hautes fréquences spatiales). La fonction de transfert de modulation (MTF) peut être utilisée pour décrire cette dégradation. S'il y a flou de mouvement, la MTF du système est diminuée ce qui affecte la restitution du contraste des détails anatomiques.

Cette perte de contraste affecte particulièrement les lésions présentant un faible contraste naturel par rapport aux tissus environnants, telles que les infiltrats pulmonaires

discrets, les lésions hépatiques hypodenses, et certaines masses des tissus mous. Par conséquent, le flou de mouvement peut rendre ces anomalies plus difficiles à détecter et réduire la qualité diagnostique de l'image. [10]

II.6.3. Risque d'erreurs diagnostiques et répétition des examens

Lorsque la qualité de l'image devient insuffisante, le radiologue peut éprouver des difficultés à interpréter correctement les résultats. Le flou de mouvement augmente ainsi le risque de :

- faux négatifs (lésion non détectée).
- faux positifs, lorsque l'interprétation d'un artefact est confondue avec une anomalie.
- d'erreurs de mesure.
- d'incertitudes diagnostiques.

Dans certains cas, l'image doit être acquise une seconde fois afin d'obtenir une qualité diagnostique acceptable. Cette répétition entraîne plusieurs conséquences :

- augmentation de la dose de rayonnement reçue par le patient.
- allongement du temps d'examen.
- augmentation de la charge de travail du personnel.
- coûts supplémentaires pour le service d'imagerie.

La réduction du flou de mouvement est donc un enjeu majeur, car elle permet de s'assurer de la fiabilité du diagnostic tout en respectant les principes d'optimisation de la radioprotection. [13]

II.7. Méthodes de réduction du flou de mouvement

La réduction du flou de mouvement constitue un enjeu majeur en imagerie à rayons X, car elle permet d'améliorer la qualité diagnostique des images tout en limitant la nécessité de répéter les examens. Les stratégies mises en œuvre peuvent agir soit au

moment de l'acquisition, soit lors du traitement des images. Elles visent principalement à diminuer les mouvements du patient, à réduire le temps d'exposition ou à compenser les mouvements physiologiques.

II.7.1. Réduction du temps d'exposition

La réduction du temps d'exposition est l'une des méthodes les plus simples et les plus efficaces pour diminuer le flou de mouvement. Plus la durée d'acquisition est courte, moins les organes ou le patient ont le temps de se déplacer pendant l'examen. Le déplacement pendant l'exposition est donné par la relation :

$$d = v \times \tau$$

où :

- d est le déplacement de l'objet.
- v est sa vitesse.
- τ est le temps d'exposition.

Ainsi, une diminution du temps d'exposition permet de réduire directement le flou de mouvement. La radiographie peut être réalisée avec des temps d'exposition très courts, grâce à des générateurs modernes, et ainsi obtenir des images plus nettes.

Cependant, pour conserver une qualité d'image suffisante, il est souvent nécessaire d'augmenter le courant du tube (mA), ce qui peut accroître la température du tube à rayons X. [12]

II.7.2. Immobilisation du patient

L'immobilisation du patient permet de réduire les mouvements volontaires susceptibles de dégrader l'image. Elle se base sur une communication avec le patient et sur la mise en place de dispositifs adaptés comme :

- les coussins de positionnement.
- les sangles de maintien.

- les supports de tête.
- les systèmes d'immobilisation pédiatriques.

Cette méthode est particulièrement importante chez les enfants, les patients âgés ou les personnes souffrant de douleurs. [13]

II.7.3. Contrôle respiratoire

Le contrôle respiratoire permet de réduire le flou de mouvement causé par la respiration. Il consiste à demander au patient de retenir sa respiration pendant quelques secondes lors de l'acquisition de l'image. En utilisant cette technique, les mouvements des poumons et du diaphragme sont limités, ce qui améliore la netteté des images.

En radiographie et en tomodensitométrie thoraciques, l'examen est généralement réalisé lors d'une inspiration profonde suivie d'une courte apnée. Chez les patients qui ne peuvent pas retenir leur respiration, des systèmes de synchronisation respiratoire peuvent être utilisés pour acquérir les images au moment où les mouvements sont les plus faibles. [13]

II.7.4. Synchronisation cardiaque (ECG-gating)

La synchronisation cardiaque (ou ECG-gating) est une technique employée pour minimiser le flou dû aux battements du cœur. Elle consiste à synchroniser l'acquisition des images avec le signal électrocardiographique (ECG), afin d'obtenir les images pendant la phase du cycle cardiaque qui correspond aux mouvements les plus faibles, souvent la diastole. Cette méthode est particulièrement utilisée en tomodensitométrie cardiaque et en imagerie des artères coronaires. Elle permet d'améliorer la netteté des images et de réduire les artefacts liés au mouvement cardiaque.

Il existe deux modes principaux de synchronisation :

- la synchronisation prospective, où l'acquisition est déclenchée à un moment précis du cycle cardiaque.

- la synchronisation rétrospective, où les données sont acquises en continu puis sélectionnées après l'examen selon le signal ECG. [14]

II.7.5. Utilisation des détecteurs numériques rapides

Les détecteurs numériques modernes permettent de réduire le flou de mouvement grâce à leur vitesse d'acquisition élevée. Leur temps de réponse très court permet d'enregistrer les images plus rapidement, limitant ainsi les effets des mouvements du patient ou des organes.

En tomodensitométrie, les systèmes multi-barrettes (MDCT) permettent d'acquérir un grand volume de données en un temps réduit, ce qui améliore la qualité des images et diminue les artefacts de mouvement, notamment en imagerie cardiaque. Les technologies récentes, telles que les détecteurs à comptage de photons (Photon-Counting CT), offrent des performances encore plus élevées en termes de rapidité et de qualité d'image. Ainsi, l'utilisation de détecteurs rapides constitue une solution efficace pour limiter le flou de mouvement dès l'étape d'acquisition. [15]

II.7.6. Compensation numérique du mouvement

Les progrès du traitement d'images ont permis le développement d'algorithmes capables de corriger partiellement les effets du flou de mouvement après l'acquisition. Ces méthodes reposent notamment sur la déconvolution, le filtrage de Wiener, la déconvolution aveugle, et les technologies de l'intelligence artificielle. Ces approches permettent d'améliorer la netteté des images lorsque le flou ne peut être totalement évité lors de l'acquisition. [11]

II.8. Techniques de restauration et de correction du flou de mouvement

Lorsque le flou de mouvement n'a pas pu être évité lors de l'acquisition des images, il est possible d'améliorer la qualité des images par des techniques de restauration et de correction.

Ces méthodes sont appliquées a posteriori et visent à réduire l'effet du flou et à améliorer la netteté des structures anatomiques.

II.8.1. Déconvolution

La déconvolution est une méthode de restauration d'image pour atténuer le flou de mouvement en essayant de retrouver l'image originale à partir de l'image floutée. Elle repose sur le modèle de formation d'image où le flou est représenté par une fonction de transfert (PSF). Dans le domaine fréquentiel, elle consiste à estimer l'image originale par une opération de division entre le spectre de l'image observée et celui du flou :

$$F(u,v) \approx \frac{G(u,v)}{H(u,v)}$$

Cependant, cette méthode est sensible au bruit, surtout lorsque H(u,v) est proche de zéro. Dans ce cas, le bruit peut être fortement amplifié, ce qui limite la qualité de la restauration. Ainsi, la déconvolution permet d'améliorer la netteté des images, mais elle nécessite des techniques complémentaires pour être efficace en pratique. [11]

II.8.2. Filtre de Wiener

Le filtre de Wiener est une technique de restauration qui peut être appliquée pour atténuer le flou de mouvement, en prenant en compte le bruit contenu dans l'image. Contrairement à la déconvolution simple, il ne cherche pas uniquement à inverser le flou, mais à obtenir une estimation optimale de l'image originale en minimisant l'erreur entre l'image restaurée et l'image réelle. Ce filtre repose sur l'utilisation simultanée du modèle du flou et des caractéristiques statistiques du bruit et du signal. Dans le domaine fréquentiel, il s'exprime généralement sous la forme :

$$\hat{F}(u,v) = \frac{H^*(u,v)}{|H(u,v)|^2 + K} G(u,v)$$

où :

- $H*(u,v)$ est le conjugué de la fonction de transfert du flou ;
- $|H(u,v)|^2$ représente l'énergie du système ;

- K est un paramètre lié au rapport bruit/signal ;
- G(u,v) est l'image dégradée.

Le rôle principal du filtre de Wiener est de limiter l'amplification du bruit dans les fréquences pour lesquelles H(u,v) est faible. C'est pourquoi, il permet un compromis entre la correction du flou et la réduction du bruit. En pratique, ce filtre est largement utilisé en imagerie médicale car il offre une restauration plus stable et plus réaliste que la déconvolution simple, notamment dans les images fortement bruitées. [11]

II.8.3. Déconvolution aveugle

La déconvolution aveugle (Blind Deconvolution) est une méthode de restauration utilisée lorsque la fonction d'étalement du point (PSF) du flou est inconnue. Elle consiste à estimer simultanément l'image originale et la PSF à partir de l'image dégradée --- une sorte de problème d'optimisation à deux inconnues. Pour rendre ce problème solvable, des contraintes a priori sont généralement imposées, telles que la positivité, la régularité ou encore la limitation du support de la PSF. Les approches les plus avancées exploitent également des modèles statistiques des images naturelles (notamment la parcimonie des gradients) afin de stabiliser l'estimation. En imagerie à rayons X, cette technique est particulièrement utile lorsque le flou de mouvement est complexe (trajectoire de déplacement non linéaire), variable ou difficile à modéliser précisément. [11]

II.8.4. Méthodes basées sur l'intelligence artificielle

Les méthodes basées sur l'intelligence artificielle, en particulier l'apprentissage profond (deep learning), ont profondément amélioré la restauration des images radiologiques ces dernières années. Les réseaux de neurones convolutifs (CNN), entraînés sur de grandes bases de données d'images floues et nettes, sont capables d'apprendre directement la relation entre une image dégradée et son équivalent restauré, sans nécessiter la connaissance explicite de la PSF. Les architectures les plus couramment employées sont les réseaux U-Net, les réseaux résiduels (ResNet) et les réseaux antagonistes génératifs (GAN), qui ont montré de meilleures performances que les

méthodes classiques de déconvolution pour la correction du flou de mouvement en imagerie médicale. Ces approches seront détaillées dans le chapitre suivant. [17][18]

II.9. Applications cliniques du flou de mouvement et de sa correction

Le flou de mouvement constitue un problème fréquent en pratique clinique en imagerie à rayons X. Il influence directement la qualité des images obtenues et peut avoir un impact sur la précision du diagnostic. Les différentes techniques de réduction et de correction du flou sont donc largement utilisées dans plusieurs domaines de l'imagerie médicale.

II.9.1. Radiographie thoracique

La radiographie thoracique est l'examen radiologique le plus couramment réalisé et l'un des plus sensibles au flou de mouvement, en raison de la mobilité constante des structures du thorax. Les mouvements respiratoires, cardiaques ainsi que ceux des gros vaisseaux contribuent simultanément à la dégradation de l'image. En radiographie numérique standard, malgré des temps d'exposition très courts (de l'ordre de 10 à 20 ms), certaines zones restent particulièrement affectées, notamment les régions hilaires et les structures vasculaires péri-hilaires. Le flou de mouvement peut ainsi réduire la netteté des détails fins. Cette limitation est particulièrement critique pour la détection des nodules pulmonaires de petite taille (inférieurs à 5 mm), dont la visibilité peut être fortement altérée. Cela a des conséquences cliniques importantes, notamment dans le dépistage précoce du cancer bronchique. [13]

II.9.2. Mammographie

La mammographie est une technique d'imagerie qui exige une très haute qualité d'image, car elle vise la détection de lésions de très petite taille, notamment les microcalcifications (environ 0,1 à 0,5 mm) ainsi que des masses à faible contraste. Le flou de mouvement en mammographie est en grande partie causé par le mouvement involontaire de la patiente pendant l'exposition, bien que la compression du sein vise à

limiter ces déplacements. Même de très faibles mouvements peuvent dégrader significativement la netteté de l'image. Des études ont documenté une diminution de la détection des microcalcifications pour un flou > 0,25 mm. Cela peut avoir un impact direct sur le dépistage précoce des cancers du sein. Les systèmes de mammographie numérique modernes utilisent donc des temps d'exposition courts (environ 100 à 200 ms) ainsi qu'une compression optimale afin de limiter au maximum les effets du flou de mouvement. [13]

II.9.3. Angiographie

L'angiographie numérique (DSA) est très sensible au flou de mouvement car elle compare deux images prises à des instants différents. Si le patient ou les organes bougent entre ces deux acquisitions, cela crée des artefacts qui peuvent gêner l'analyse des vaisseaux. En imagerie couonarienne, le mouvement du cœur est la principale source de flou. Il peut déformer les images, rendant l'interprétation plus difficile. Des systèmes de correction et de recalage d'images sont utilisés pour réduire ces effets, mais ils ne peuvent pas toujours éliminer complètement les artefacts en cas de mouvements importants. Des temps de l'ordre de quelques millisecondes permettent une résolution temporelle cardiaque de 60-80 ms, suffisante pour les examens coronariens à fréquence cardiaque modérée. La reconstruction itérative intègre désormais des modèles de correction du mouvement pour améliorer la qualité des images en présence de mouvements résiduels. [14]

II.9.4. Tomodensitométrie (CT)

La tomodensitométrie est particulièrement sensible aux artefacts de mouvement, car l'acquisition des données se fait pendant la rotation du tube autour du patient. Tout mouvement du patient durant cette rotation peut entraîner des déformations de l'image. Ces mouvements peuvent produire différents artefacts tels que des stries, des images fantômes ou un flou des structures anatomiques. Les scanners modernes, notamment les systèmes à double source, permettent de réduire ces effets grâce à des temps d'acquisition très courts et une meilleure résolution temporelle. De plus, les techniques de

reconstruction avancées intègrent des corrections du mouvement afin d'améliorer la qualité des images en cas de déplacements résiduels. [15]

II.9.5. Imagerie pédiatrique

L'imagerie pédiatrique constitue l'un des contextes les plus difficiles en matière de flou de mouvement. Les enfants, en particulier les nourrissons, ont souvent des difficultés à rester immobiles pendant l'examen radiologique, ce qui augmente fortement le risque de flou. De plus, leurs fréquences cardiaque et respiratoire sont plus élevées que chez l'adulte, ce qui accentue encore les mouvements physiologiques pendant l'acquisition. Dans certains cas, une sédation peut être envisagée pour améliorer l'immobilité, mais elle comporte des risques et doit être utilisée avec prudence. La prise en charge repose donc sur une combinaison de stratégies : temps d'exposition très courts, détecteurs sensibles, dispositifs d'immobilisation adaptés à l'âge, ainsi que des techniques de traitement d'image permettant de réduire le flou après l'acquisition. [13]

II.10. Conclusion

Le flou de mouvement constitue une limitation importante en imagerie à rayons X, car il dégrade la qualité des images et peut influencer la fiabilité du diagnostic. Il résulte principalement des mouvements du patient, des mouvements physiologiques et, dans certains cas, du système d'acquisition lui-même.

Différentes approches permettent de réduire cet effet, allant des techniques d'acquisition (réduction du temps d'exposition, immobilisation, synchronisation respiratoire et cardiaque) aux méthodes de traitement d'image, telles que la déconvolution et les approches basées sur l'intelligence artificielle.

Ainsi, la maîtrise du flou de mouvement repose sur une combinaison de solutions physiques, techniques et algorithmiques, qui permettent d'améliorer la qualité des images tout en optimisant la dose et les performances diagnostiques.

CHAPITRE III :
TRAITEMENTS DES IMAGES MÉDICALES À L'AIDE DE L'INTELLIGENCE ARTIFICIELLE

III.1. Introduction

L'IA est une technologie qui a déjà joué un grand rôle dans l'univers de l'imagerie médicale, dans ses capacités d'analyse et de traitement des images. Elle permet d'améliorer la qualité des images médicales et d'assister le diagnostic à l'aide de techniques de Machine Learning et de Deep Learning, telles que les réseaux de neurones convolutifs (CNN) et le réseau U-Net.

Dans ce chapitre, les notions les plus importantes de l'IA en traitement d'images médicales seront présentées, ainsi que les architectures profondes les plus employées dans ce contexte.

III.2. Introduction à l'IA en imagerie médicale

III.2.1. Définition de l’intelligence artificielle

L'Intelligence Artificielle (IA) est une branche de l'informatique qui cherche à créer des systèmes capables d'accomplir des tâches qui sont normalement accomplies par l'intelligence humaine, comme l'apprentissage, la reconnaissance de formes, la prise de décision, l'analyse de données, etc. Le concept d'IA a été formalisé par John McCarthy en 1956, à la conférence de Dartmouth, qui est considérée comme le début officiel de la discipline.

L'avènement d'une puissance de calcul importante et de vastes volumes de données a conduit à un avancement significatif des capacités de l'IA, particulièrement à travers l'utilisation des techniques de Machine Learning et de Deep Learning. Ces techniques rendent les systèmes informatiques aptes à apprendre de manière autonome à partir des données, sans être explicitement programmés pour chaque tâche.

La science et l'industrie de l'IA sont aujourd'hui appliquées à divers domaines tels que la médecine, l'imagerie médicale, l'analyse automatique d'images, l'aide au diagnostic, etc. [16]

III.2.2. Rôle de l'IA en médecine

L'IA joue un rôle de plus en plus crucial dans la santé, grâce à sa capacité de traiter rapidement et efficacement de vastes volumes de données cliniques et d'imageries médicales. Elle a de nombreuses applications, comme l'aide au diagnostic, la prédiction des maladies, l'analyse d'images radiologiques, la médecine personnalisée et l'assistance aux traitements thérapeutiques.

En milieu hospitalier, les systèmes basés sur l'IA peuvent automatiser des tâches répétitives et améliorer l'efficacité des soins. Par exemple, dans le domaine de la radiologie, les algorithmes d'apprentissage profond peuvent identifier automatiquement certaines anomalies telles que les tumeurs, les fractures ou les lésions pulmonaires avec une grande précision.

L'IA peut également aider à minimiser les erreurs médicales, à optimiser le temps d'interprétation des examens et à affiner la qualité de la prise en charge médicale d'un patient.[17]

III.2.3. Rôle de l'IA dans l'imagerie médicale contemporaine

L'IA a radicalement changé le paysage de l'imagerie médicale contemporaine. Aujourd'hui, les algorithmes d'apprentissage profond aident à améliorer la qualité des images, à identifier automatiquement les anomalies et à faciliter l'interprétation du tableau clinique.

Les réseaux de neurones convolutifs (CNN) sont très performants pour l'analyse d'images médicales, comme par exemple les radiographies, les images IRM, les scanners, etc. Ils permettent d'extraire automatiquement des caractéristiques importantes à partir des images et d'améliorer les performances diagnostiques.

L'IA est également utilisée pour la segmentation des organes, la reconstruction d'images, la réduction du bruit et des artefacts ainsi que l'optimisation des acquisitions à faible dose en radiologie. Ces progrès augmentent la précision du diagnostic tout en minimisant la dose de rayonnements ionisants subie par le patient. [17]

III.3. Apprentissage automatique et Deep Learning

III.3.1. Notions d'apprentissage automatique (Machine Learning)

L'intelligence artificielle comprend une branche essentielle appelée apprentissage automatique, ou Machine Learning. Il permet aux systèmes informatiques d'apprendre automatiquement à partir des données et d'améliorer leurs performances sans programmation explicite. Cette approche se base sur des algorithmes qui peuvent traiter l'information disponible et identifier des modèles, ou réaliser des prédictions, des classifications, etc.

En médecine, le Machine Learning est appliqué pour automatiser certaines tâches comme la détection d'anomalies, l'analyse des examens médicaux, etc., apportant ainsi une aide précieuse aux diagnostics. [16]

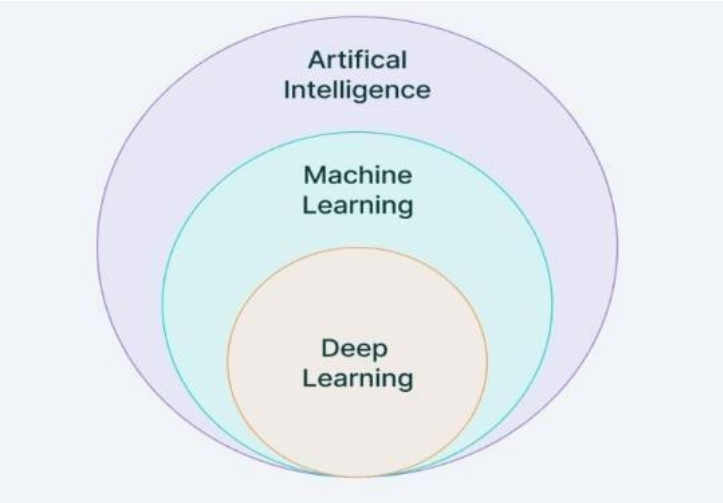


Figure III.1 : Relation hiérarchique entre l'intelligence artificielle (IA), le Machine Learning (ML) et le Deep Learning (DL)

III.3.2. Apprentissage supervisé et non supervisé

L'apprentissage supervisé repose sur des ensembles de données étiquetées (données annotées) avec des résultats connus a priori. Le modèle est alors entraîné à corréler les données d'entrée avec les sorties correctes. Cette méthode est fréquemment employée pour la classification et la segmentation des images médicales.

En revanche, l'apprentissage non supervisé fonctionne avec des données non étiquetées. Son objectif principal est de découvrir automatiquement des structures, des regroupements ou des motifs cachés dans les données. Cette technique est très utile pour l'analyse de motifs complexes et la reconnaissance de formes. [16]

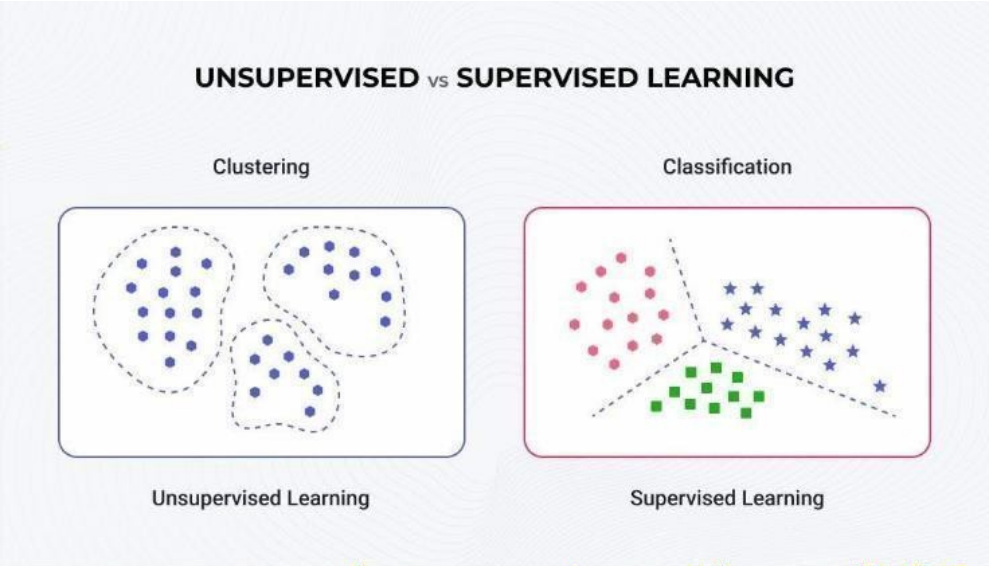


Figure III.2 : Comparaison entre l'apprentissage supervisé (classification) et le clustering (apprentissage non supervisé)

III.3.3. Introduction au Deep Learning

Le Deep Learning, ou apprentissage profond, est une sous-catégorie du Machine Learning de niveau supérieur. Il est basé sur des réseaux de neurones artificiels qui contiennent plusieurs couches successives pour extraire des caractéristiques de plus en plus complexes à partir d'une suite de données.

Le Deep Learning a révolutionné le domaine de l'imagerie médicale en offrant des performances très élevées dans les tâches de segmentation, de classification et de reconstruction d'images. [16]

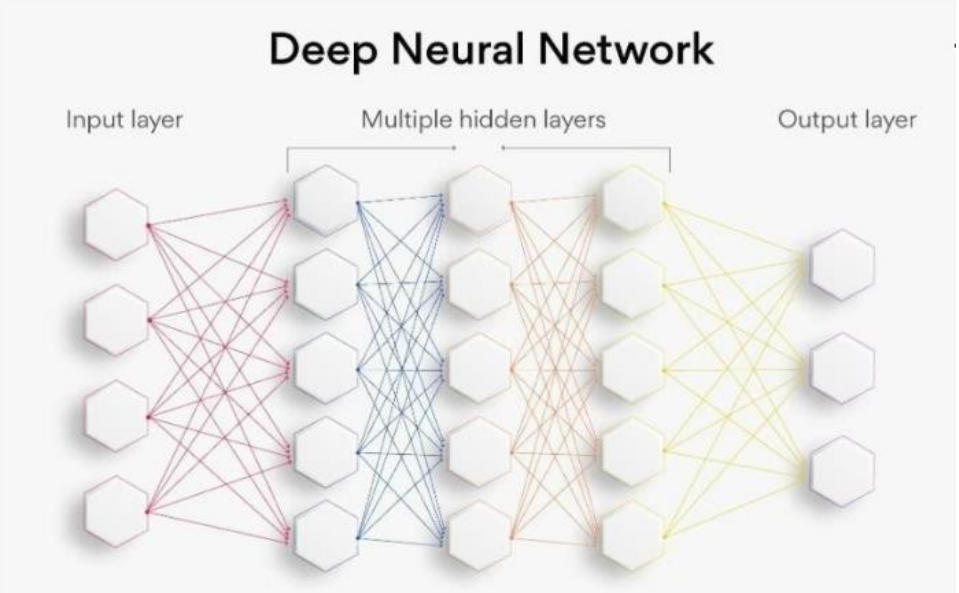


Figure III.3 : Architecture simplifiée d'un réseau de neurones profond

III.3.3.4. Importance des réseaux de neurones dans l'analyse d'images

Les réseaux de neurones artificiels sont d'une importance capitale pour l'analyse des images médicales. Ils sont capables de s'auto-entraîner et d'apprendre les propriétés visuelles des structures, ce qui leur permet d'identifier précisément diverses structures anatomiques ainsi que certaines anomalies.

En particulier, les réseaux de neurones convolutifs (CNN) sont particulièrement bien adaptés aux images car ils peuvent extraire automatiquement des caractéristiques pertinentes comme les formes, les textures et les contours. La rapidité et la précision des analyses médicales s'en trouvent grandement améliorées par leur usage. [17]

III.4. Intelligence artificielle pour le filtrage et la restauration d'images

III.4.1. Réduction du bruit (Denoising)

Le débruitage (denoising) désigne l'élimination du bruit dans les images, tel que le bruit quantique rencontré dans les acquisitions d'images à faible dose de rayonnement. Les modèles d'apprentissage profond, en particulier les réseaux de neurones convolutifs

(CNN) et U-Net, ont été entraînés pour distinguer le signal utile du bruit afin de produire des images plus nettes sans altérer les détails anatomiques importantes.

En radiologie à faible dose, l'IA a pour avantage de pouvoir maintenir une qualité diagnostique acceptable tout en diminuant la dose de rayonnements ionisants que le patient reçoit. [28]

III.4.2. Correction du flou (Deblurring)

Il s'agit de la correction du flou de mouvement (deblurring), qui constitue le but principal de ce travail. L'objectif est de restaurer une image claire à partir d'une image dégradée par le déplacement du patient lors de l'acquisition. Contrairement aux filtres de déconvolution traditionnels, le modèle d'apprentissage profond apprend directement à partir des données, sans nécessiter la connaissance explicite de la fonction d'étalement du point (Point Spread Function, PSF).

Les architectures de type U-Net, dotées de blocs résiduels, se sont avérées très performantes dans cette application. Elles permettent la reconstruction des détails fins et la conservation des structures anatomiques indispensables pour le diagnostic. [21]

III.4.3. Super-résolution

La super-résolution est un processus qui permet de créer une image de haute résolution à partir d'une ou de plusieurs images de basse résolution. En imagerie médicale, elle peut être utilisée pour améliorer la résolution spatiale des images sans augmenter la dose de rayonnement ni le temps d'acquisition. [16]

III.4.4. Amélioration de la qualité d'image (Image Enhancement)

L'amélioration de la qualité d'image regroupe l'ensemble des techniques permettant d'augmenter le contraste, la netteté et la visibilité des structures anatomiques dans les images médicales. Ces paramètres peuvent être optimisés automatiquement grâce à des modèles de Deep Learning en s'adaptant aux caractéristiques de chaque image. [17]

III.5. Réseaux de neurones convolutifs et architecture U-Net

III.5.1. Notions essentielles des réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) font partie des modèles d'apprentissage profond développés pour traiter des données visuelles. Ils se basent sur une opération appelée convolution qui extrait automatiquement des caractéristiques pertinentes des images, telles que les contours, les textures et les formes.

L'architecture des CNN comprend généralement plusieurs couches de convolution, suivies de fonctions d'activation et de couches de sous-échantillonnage (pooling), permettant de réduire la dimension des données tout en conservant les informations spatiales essentielles. [16]

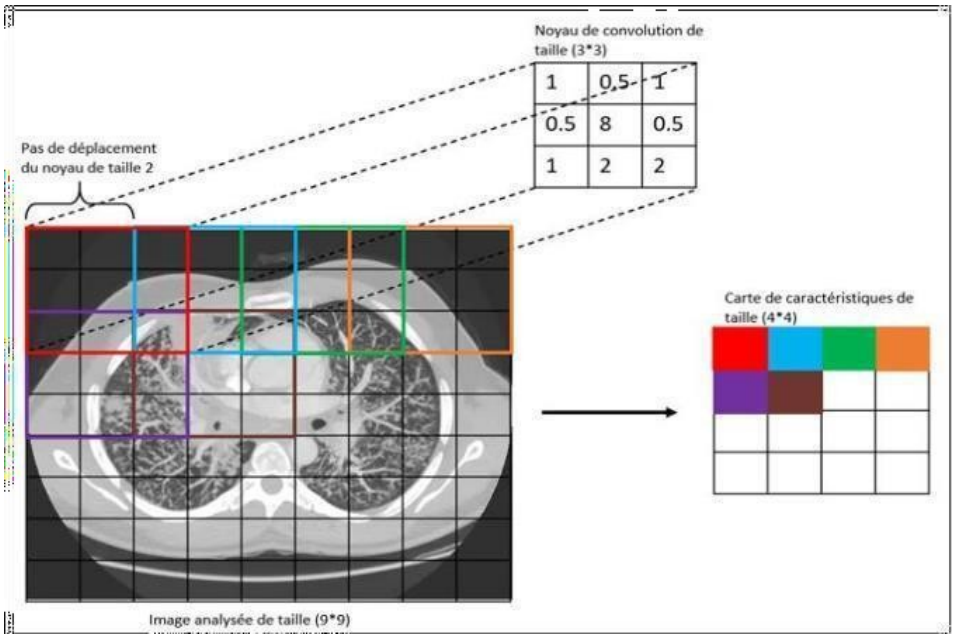


Figure III.4 : Illustration du processus de convolution dans un réseau CNN appliqué à une image médicale

III.5.2. Limites des CNN dans les tâches d'analyse d'images médicales

Bien que très performants, les CNN présentent certaines limites dans le contexte de l'imagerie médicale. En effet, bien que le pooling soit utile pour réduire la

complexité, des informations spatiales fines sont perdues, ce qui peut diminuer la précision des tâches de segmentation.

De plus, les CNN standards requièrent souvent de très grandes quantités de données étiquetées, ce qui est une contrainte majeure dans le secteur médical où les données annotées sont rares et coûteuses à acquérir. [17]

III.5.3. Architecture U-Net : principe général et structure encodeur-décodeur

L'architecture U-Net est un type de réseau neuronal profond spécialement développé pour la segmentation d'images biomédicales. Elle repose sur une structure symétrique en forme de "U" composée de deux parties principales : l'encodeur et le décodeur.

L'encodeur réduit progressivement la résolution de l'image sur plusieurs étapes pour extraire les caractéristiques à différents niveaux d'abstraction, tandis que le décodeur reconstruit une carte de segmentation détaillée en augmentant progressivement la résolution spatiale. [18]

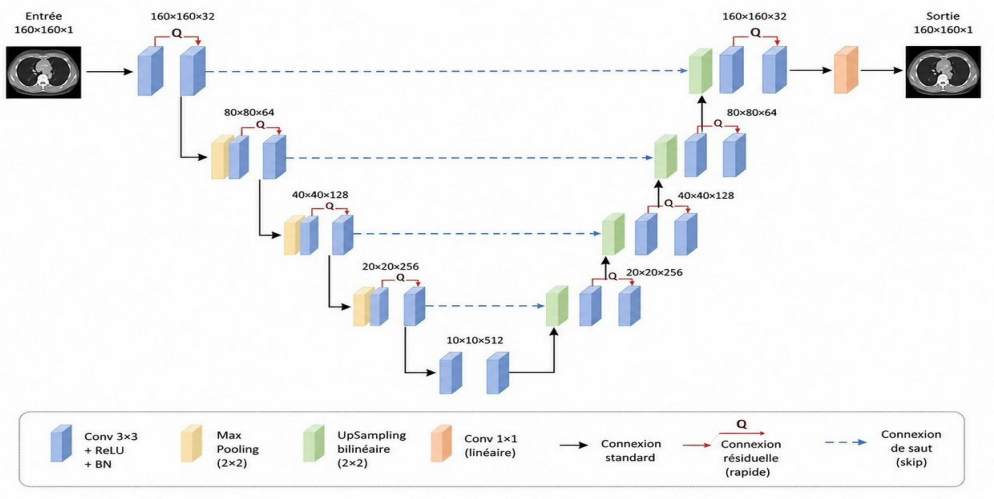


Figure III.5 : Architecture du modèle Residual U-Net 2D proposé

III.5.4. Skip connections et préservation des détails

Les skip connections (connexions de saut) sont des connexions directes reliant les couches de l'encodeur aux couches correspondantes du décodeur. Elles servent à transmettre des informations de haute résolution spatiale qui ont été perdues lors de la phase de compression.

Grâce à ce mécanisme, le modèle conserve davantage de détails géométriques et spatiaux, améliorant de manière significative la précision des contours et la délimitation des structures segmentées. [18]

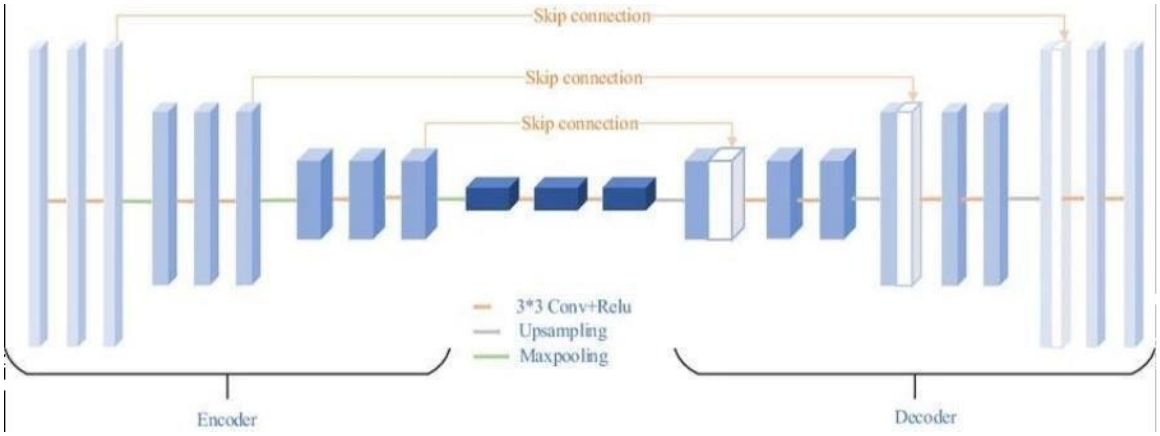


Figure III.6 : Structure du réseau U-Net : encodeur, décodeur et connexions de saut (skip connections)

III.5.5. Applications du modèle U-Net en segmentation et restauration d'images médicales

Le modèle U-Net a été largement utilisé dans une grande variété d'applications d'imagerie médicale, en particulier pour la segmentation d'organes, de tumeurs et de lésions pathologiques.

Il est également employé dans la restauration d'images médicales, notamment pour la réduction du bruit, l'amélioration du contraste et la reconstruction d'images dégradées. La précision qu'il permet d'obtenir, même en disposant de peu de données annotées, en fait une architecture de référence dans ce domaine. [18]

III.6. Réseaux résiduels et architecture Residual U-Net

III.6.1. Réseaux résiduels (ResNet)

He et al. (2016) ont proposé une nouvelle approche pour surmonter le problème de disparition du gradient dans les réseaux très profonds, appelée réseaux résiduels (ResNet). Dans un réseau de neurones comportant un grand nombre de couches, le gradient calculé lors de la rétropropagation tend à diminuer de manière exponentielle au fil des couches, ce qui peut rendre l'apprentissage très difficile, voire impossible pour les couches les plus profondes. [19]

L'idée clé de ResNet est l'introduction de "connexions résiduelles" (shortcuts), permettant à chaque bloc du réseau de n'apprendre que la différence (le résidu) entre son entrée et sa sortie souhaitée :

$$y = F(x) + x$$

où :

- x :représente l'entrée du bloc résiduel ;
- $F(x)$est la transformation apprise par les couches convolutives ;
- y :représente la sortie du bloc résiduel.

III.6.2. Blocs résiduels (Residual Blocks)

L'unité de base d'un réseau résiduel est appelée bloc résiduel. Il est généralement composé de deux ou trois couches de convolution, d'une normalisation par lots (Batch Normalization), de fonctions d'activation ReLU et d'une connexion résiduelle qui contourne ces couches.

Dans notre modèle, des blocs résiduels ont été intégrés dans chaque étage de l'architecture U-Net, ce qui améliore la capacité du modèle à apprendre des transformations complexes tout en évitant le problème de disparition du gradient. [19]

III.6.3. U-Net avec blocs résiduels (Residual U-Net)

Le modèle utilisé dans ce travail est une variante de l'architecture U-Net enrichie de blocs résiduels, connue sous le nom de Residual U-Net. Cette combinaison permet de tirer parti des forces de ces deux architectures : la structure encodeur-décodeur avec skip connections de U-Net pour la reconstruction d'images, et les connexions résiduelles de ResNet pour faciliter l'apprentissage profond. [20]

Dans cette architecture, les blocs encodeurs et décodeurs de chaque étage sont remplacés par un bloc résiduel, ce qui permet au modèle de :

- Mieux préserver les informations de haute fréquence essentielles à la reconstruction des détails anatomiques fins.
- Minimiser le risque de perte de gradient lors de l'entraînement sur des ensembles de données médicales limités.
- Améliorer l'efficacité de la restauration des images floues, notamment en augmentant les indices de PSNR et de SSIM.

III.7. Fonctions de perte pour la restauration d'images

III.7.1. Fonctions de perte classiques

Les fonctions de perte L1 et L2 sont les plus couramment utilisées dans les tâches de restauration d'images. [22]

La perte L2 (Mean Squared Error, MSE) correspond à la moyenne des carrés des différences pixel à pixel entre l'image reconstruite et l'image de référence :

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(y_i' - y_i)^2$$

où :

- N : représente le nombre total de pixels de l'image .

- y_i : valeur du pixel i dans l'image de référence .
- y_i' : valeur du même pixel i dans l'image restaurée (ou reconstuite) .
- $(y_i' - y_i)$: erreur ou différence entre la valeur du pixel restauré et celle de référence .
- $(y_i' - y_i)^2$: carré de l'erreur, qui élimine les signes négatifs et attribue une importance accrue aux erreurs de grande amplitude.

La perte L1 (Mean Absolute Error, MAE) mesure quant à elle la moyenne des valeurs absolues des différences :

$$MAE = \frac{1}{N} \times \sum_{i=1}^{N} |y_i' - y_i|$$

La perte L2 a tendance à prroduire des images légèrement floues car elle pénalise fortement les grands écarts, tandis que la perte L1 est plus robuste aux valeurs aberrantes et tend à mieux préserver les détails fins.

III.7.2. Edge Loss (perte sur les contours)

La Edge Loss est une fonction de perte spécialement conçue pour préserver les contours et les structures anatomiques fines dans les images médicales restaurées. Elle repose sur le calcul des gradients de l'image à l'aide d'opérateurs de détection de contours tels que l'opérateur de Sobel ou le Laplacien.

L'opérateur de Sobel calcule une approximation du gradient de l'image dans les directions horizontale et verticale à l'aide de deux noyaux de convolution 3×3:

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} \qquad G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ +1 & +2 & +1 \end{bmatrix}$$

La magnitude du gradient en chaque pixel est ensuite obtenue par :

$$G = \sqrt{G_x^2 + G_y^2}$$

La Edge Loss est alors définie comme l'erreur (généralement L1 ou L2) entre les cartes de gradients de l'image restaurée et de l'image de référence :

$$\mathcal{L}_{edge} = | \nabla I_restaurée - \nabla I_référence |$$

où :

- ∇I : représente la carte des gradients (magnitude de Sobel) de l'image I.

En forçant le modèle à reproduire fidèlement les gradients de l'image de référence, la Edge Loss améliore la netteté des contours anatomiques dans l'image restaurée. Dans le contexte de la correction du flou de mouvement, cette fonction est particulièrement importante car le flou affecte principalement les contours et les structures de haute fréquence. [22]

III.7.3. Frequency Loss (perte en domaine fréquentiel)

La Frequency Loss opère dans le domaine fréquentiel, en comparant les transformées de Fourier de l'image reconstruite et de l'image de référence. Elle vise à préserver les informations de haute fréquence qui correspondent aux détails fins et aux textures de l'image.

Le flou de mouvement atténue principalement les composantes haute fréquence du spectre de l'image, entraînant une perte des détails fins. La Frequency Loss contraint le modèle à récupérer ces composantes haute fréquence, améliorant ainsi la netteté globale et la résolution effective de l'image restaurée. [23]

III.7.4. Fonction de perte combinée

En pratique, les modèles de restauration d'images combinent plusieurs fonctions de perte afin d'optimiser simultanément différents aspects de la qualité de l'image. La fonction de perte combinée peut s'écrire sous la forme :

$$\mathcal{L}_{tot} = \mathcal{L}_{pixel} + \lambda_1 \times \mathcal{L}_{edge} + \lambda_2 \times \mathcal{L}_{frequency}$$

où λ_1 et λ_2 sont des hyperparamètres contrôlant l'importance relative de chaque composante de la perte.

Cette formulation permet au modèle de produire des images qui sont à la fois fidèles à l'image de référence au niveau des pixels (L_pixel), nettes au niveau des contours (L_edge) et riches en détails de haute fréquence (L_frequency). [22]

III.8. Métriques d'évaluation des performances

L'évaluation objective des performances d'un modèle de restauration d'images nécessite l'utilisation de métriques quantitatives permettant de mesurer la qualité des images reconstruites

par rapport aux images de référence. Les deux métriques les plus utilisées dans ce domaine sont le PSNR et le SSIM.

III.8.1. PSNR (Peak Signal-to-Noise Ratio)

Le PSNR (rapport signal/bruit de crête) est une métrique classique utilisée pour mesurer la qualité d'une image reconstruite par rapport à une image de référence. Il est défini à partir de l'erreur quadratique moyenne (MSE) :

$$PSNR = 10 \times \log_{10}\left(\frac{MAX^2}{MSE}\right)$$

où MAX représente la valeur maximale possible d'un pixel (255 pour une image 8 bits) et MSE représente l'erreur quadratique moyenne entre l'image reconstruite et l'image de référence.

Le PSNR est exprimé en décibels (dB). Plus la valeur du PSNR est élevée, meilleure est la qualité de l'image reconstruite. Une valeur supérieure à 30 dB est généralement considérée comme acceptable en imagerie médicale. Cette métrique sera utilisée dans le chapitre IV pour évaluer les performances du modèle Residual U-Net développé dans ce travail. [24]

III.8.2. SSIM (Structural Similarity Index)

Le SSIM (indice de similarité structurelle) est une métrique perceptuelle qui mesure la similarité entre deux images en tenant compte de la luminance, du contraste et de la structure. Contrairement au PSNR qui mesure uniquement les différences pixel à pixel, le SSIM évalue la similarité de manière plus proche de la perception visuelle humaine.

Le SSIM prend des valeurs comprises entre 0 et 1. Lorsqu'il est égal à 1, les deux images sont identiques. Plus la valeur du SSIM est proche de 1, plus l'image reconstruite est similaire à l'image de référence en termes de structures et de contours. En imagerie médicale, le SSIM est particulièrement pertinent car il reflète la préservation des structures anatomiques importantes pour le diagnostic.

Les résultats des métriques PSNR et SSIM obtenus avec le modèle développé seront présentés et analysés dans le chapitre IV. [24]

III.8.3. RMSE (Root Mean Squared Error)

Le RMSE (racine de l'erreur quadratique moyenne) est une métrique simple et directe qui quantifie l'écart moyen entre les valeurs des pixels de l'image reconstruite et de l'image de référence. Il est défini comme la racine carrée de la MSE :

$$RMSE = \sqrt{\frac{1}{N} \times \sum_{i=1}^{N} \left(I_{restaurée}(i) - I_{référence}(i)\right)^2}$$

où :

- N : représente le nombre total de pixels ;
- $I_{restaurée}(i)$: la valeur du pixel i dans l'image restaurée ;
- $I_{référence}(i)$: la valeur du pixel i dans l'image de référence.

Contrairement au PSNR, le RMSE est exprimé dans la même unité que les valeurs des pixels (par exemple, sur une échelle de 0 à 255 ou de 0 à 1 selon la normalisation utilisée). Plus la valeur du RMSE est faible, plus l'image reconstruite est proche de l'image de référence. Cette métrique offre une interprétation directe et

intuitive de l'erreur de reconstruction, complémentaire aux mesures perceptuelles comme le SSIM. [24]

III.9. Optimiseur (AdamW)

L'entraînement du modèle Residual U-Net utilise l'optimiseur AdamW (Adaptive Moment Estimation with Weight Decay), une variante améliorée d'Adam très répandue en Deep Learning.

Son principal avantage est de séparer la régularisation par décroissance des poids (weight decay) de la mise à jour adaptative du gradient, contrairement à Adam classique. Cela améliore la généralisation du modèle et réduit le risque de surapprentissage (overfitting), ce qui le rend particulièrement adapté à l'entraînement du Residual U-Net sur des données d'imagerie médicale. [25]

III.10. Autres architectures profondes utilisées en imagerie médicale

En complément du Residual U-Net, d'autres architectures de Deep Learning sont largement utilisées dans le domaine de l'imagerie médicale pour des tâches de restauration, de classification et de segmentation. Parmi les plus importantes figurent les réseaux antagonistes génératifs (GAN) et les Vision Transformers (ViT).

III.10.1. GAN (Generative Adversarial Networks) et amélioration d'images

Les GAN sont des modèles composés de deux réseaux en compétition : un générateur et un discriminateur. Le générateur produit des images synthétiques tandis que le discriminateur tente de distinguer les images réelles des images générées par le générateur. Ce jeu de compétition pousse le générateur à produire des images de plus en plus réalistes.

En imagerie médicale, les GAN sont utilisés pour améliorer la qualité des images, notamment la réduction du bruit, la super-résolution et la reconstruction

d'images à faible dose de rayons X. Ils sont également utilisés pour générer des données synthétiques afin d'augmenter les bases de données médicales limitées, ce qui constitue un atout majeur dans ce domaine. [26]

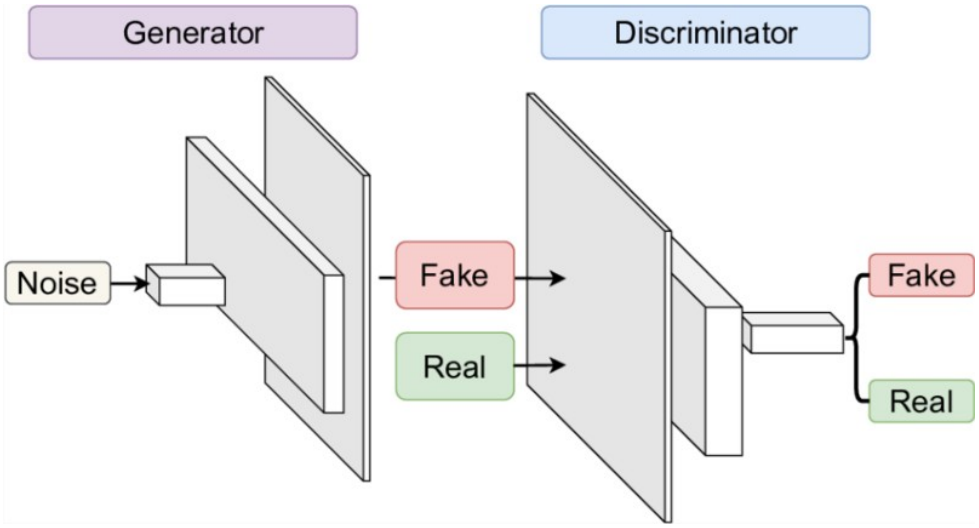


Figure III.7 : Générateur et discriminateur du réseau GAN

III.10.2. Vision Transformers (ViT) : notions générales

Les Vision Transformers (ViT) exploitent le mécanisme d'attention et divisent l'image en de nombreuses petites parties appelées patches. Ces patches sont traités comme une séquence.

Contrairement aux CNN, qui sont limités aux relations locales définies par la taille du noyau de convolution, les ViT peuvent modéliser les relations globales à l'échelle de l'image.

En imagerie médicale, les ViT sont employés pour la classification et la segmentation d'images complexes. Cependant, leurs performances dépendent fortement de la disponibilité de grandes bases de données d'entraînement, ce qui constitue une limitation importante dans le contexte médical. [27]

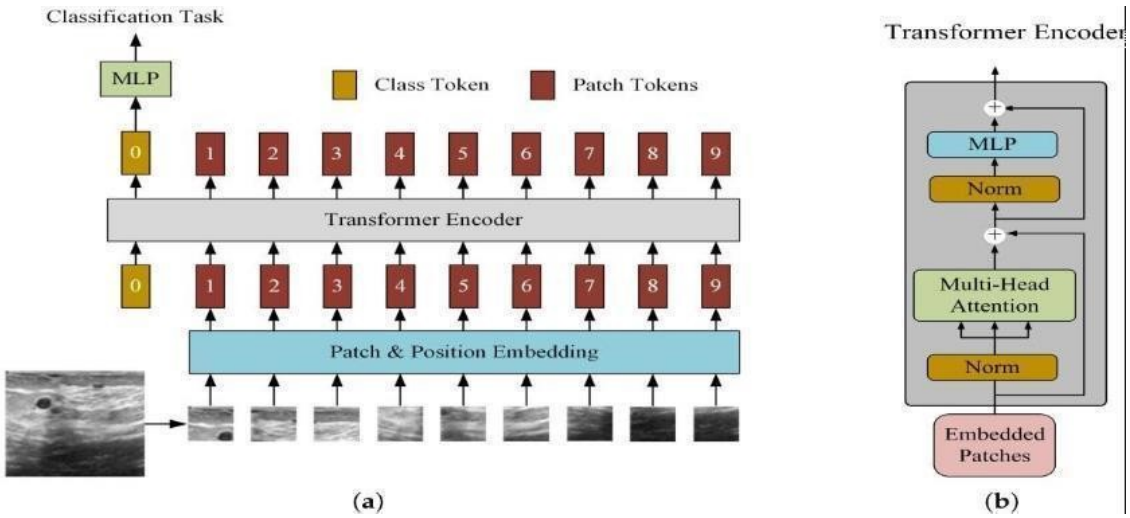


Figure III.8 : Schéma de l'architecture d'un Vision Transformer (ViT)

III.10.3. Comparaison générale des architectures

Chaque architecture possède ses propres forces et limitations, s'adaptant spécifiquement à certaines tâches. Le tableau suivant présente une comparaison globale entre les architectures les plus utilisées en imagerie médicale :

Architecture	Principe de fonctionnement	Points forts	Applications en imagerie médicale
Residual U-Net	Encodeur-décodeur avec skip connections et blocs résiduels	Reconstruction précise, préservation des détails fins, stable en entraînement	Correction du flou de mouvement, débruitage, segmentation
ResNet	Connexions résiduelles pour éviter la disparition du gradient	Efficace pour l'extraction de caractéristiques locales, stable en profondeur	Classification, détection des anomalies (tumeurs, fractures)
GAN	Compétition entre	Génération d'images	Super-résolution,

	un générateur et un discriminateur	réalistes, excellent pour l'amélioration d'images et la création de données synthétiques	réduction du bruit, génération de données synthétiques
Vision Transformers (ViT)	Découpage en patches + mécanisme d'attention pour modéliser les relations globales	Capture des relations contextuelles et sémantiques globales dans l'image	Classification avancée, segmentation de structures complexes

Tableau III.1 : Comparaison générale des architectures d'intelligence artificielle utilisées en imagerie médicale

- Le modèle Residual U-Net a été sélectionné pour sa capacité à reconstruire précisément les images grâce à la contribution de U-Net, tout en bénéficiant des connexions résiduelles qui permettent de mieux filtrer les contours flous et d'en préserver les détails anatomiques importants. [17][18][19] [26][27]

III.11. Importance de l'IA pour l'amélioration des images médicales

III.11.1. Amélioration de la qualité des images médicales

L'IA permet d'améliorer la qualité des images en reconstruisant les détails perdus et en augmentant le contraste entre les différentes structures anatomiques. Cela facilite l'interprétation médicale et améliore la précision diagnostique. En imagerie dynamique à rayons X, l'IA permet de corriger le flou de mouvement en temps quasi-réel, offrant ainsi aux cliniciens des images exploitables même dans des conditions d'acquisition difficiles. [17]

III.11.2. Réduction du bruit et des artefacts

Les algorithmes d'apprentissage profond permettent de réduire efficacement le bruit dans les images médicales, notamment celui causé par les faibles doses de rayonnement ou les limitations des capteurs. Ils permettent également de corriger les artefacts de mouvement, qui constituent l'un des principaux défis de l'imagerie dynamique à rayons X.

Cette double capacité — réduction du bruit et correction du flou — fait des approches basées sur l'IA des outils particulièrement adaptés à l'imagerie thoracique et cardiovasculaire, où ces deux types d'artéfacts sont fréquents. [17][28]

III.11.3. Contribution à l'aide au diagnostic médical

L'IA permet la détection automatique de pathologies telles que les tumeurs, les fractures et les infections à partir d'images médicales. Elle agit comme un outil d'aide au diagnostic, améliorant la précision et réduisant le temps d'analyse. En améliorant la qualité des images par la correction du flou de mouvement, les méthodes d'IA contribuent indirectement à réduire les erreurs diagnostiques liées à la dégradation de la qualité des images. [17]

III.12. Conclusion

Ce chapitre a permis de mettre en lumière l’intérêt de l’IA dans l’imagerie médicale et les architectures de Deep Learning les plus utilisées pour l’analyse et l’amélioration d’une image.

Chapitre IV :
Implémentation et évaluation des performances du modèle

IV.1. Introduction

L'imagerie tomodensitométrique pulmonaire joue un rôle essentiel dans le diagnostic et le suivi de nombreuses pathologies thoraciques, notamment les cancers pulmonaires, les infections respiratoires et les maladies interstitielles. Cependant, la qualité des images acquises peut être fortement dégradée par différents artefacts, parmi lesquels le flou de mouvement constitue l'un des plus fréquents et des plus problématiques.

Dans les examens thoraciques, le flou de mouvement est principalement causé par les mouvements respiratoires du patient ainsi que par les mouvements cardiaques involontaires durant l'acquisition. Ces mouvements entraînent une perte de netteté des structures anatomiques, une diminution du contraste local et une altération des contours des lésions pulmonaires. En conséquence, la détection et la caractérisation précises des anomalies peuvent devenir plus difficiles pour le radiologue.

Face à cette problématique, de nombreuses méthodes de restauration d'images ont été développées. Les approches récentes basées sur l'apprentissage profond ont démontré des performances remarquables grâce à leur capacité à apprendre directement la relation entre les images dégradées et les images de référence.

Dans ce chapitre, nous présentons l'implémentation d'un modèle Residual U-Net dédié à la correction du flou de mouvement dans les images CT pulmonaires. Après une description détaillée du jeu de données utilisé et du protocole expérimental adopté, les différentes étapes du pipeline d'apprentissage sont présentées. Enfin, une évaluation quantitative et qualitative des performances du modèle est réalisée à l'aide de plusieurs métriques de référence telles que le PSNR, le SSIM et le RMSE afin d'évaluer sa capacité à restaurer les structures pulmonaires altérées par le flou de mouvement.

IV.2. protocole expérimental

Afin d'évaluer les performances du modèle proposé pour la réduction du flou de mouvement dans les images thoraciques, un protocole expérimental a été mis en place

en deux étapes principales. Dans un premier temps, un flou de mouvement artificiel a été généré à partir des images thoraciques originales afin de reproduire les dégradations pouvant survenir lors de l'acquisition des images, notamment à cause des mouvements respiratoires des poumons. Cette étape a permis de constituer une base de données comprenant à la fois des images de référence et leurs versions floutées. Dans un second temps, le modèle U-Net a été entraîné en utilisant les couples d'images originales et dégradées. Après la phase d'apprentissage, le modèle a été appliqué aux images floutées afin de restaurer leur qualité, réduire les artefacts liés au mouvement et récupérer les détails anatomiques altérés par le flou. Les performances obtenues ont ensuite été évaluées à l'aide de différentes métriques quantitatives et d'une analyse visuelle des résultats.

IV.2.1. Description du jeu de données

Le jeu de données utilisé dans cette étude est issu de la base publique LIDC-IDRI (Lung Image Database Consortium and Image Database Resource Initiative), l'une des bases de données les plus utilisées dans la recherche en imagerie thoracique assistée par intelligence artificielle.

Cette base de données, disponible via The Cancer Imaging Archive (TCIA), contient plus de 1000 examens tomodensitométriques pulmonaires provenant de patients présentant ou non des nodules pulmonaires. Les images sont fournies au format DICOM et accompagnées d'annotations réalisées indépendamment par plusieurs radiologues experts, ce qui en fait une référence pour le développement et la validation des algorithmes d'analyse d'images médicales.

Le dataset complet contient environ 244 527 coupes tomographiques. Afin de limiter le coût computationnel tout en conservant une diversité anatomique suffisante, un sous-ensemble représentatif composé d'environ 10 000 images issues de 56 patients a été sélectionné pour cette étude.

Les images utilisées couvrent différentes régions pulmonaires et présentent une grande variabilité anatomique, notamment au niveau des bronches, des vaisseaux pulmonaires, du médiastin et des nodules pulmonaires. Cette diversité permet au modèle

d’apprendre à restaurer efficacement les structures affectées par le flou de mouvement dans différentes situations cliniques.

IV.2.2. phase de génération du flou de mouvement (motion blur)

Afin d'entraîner le modèle de restauration dans des conditions représentatives de l'imagerie thoracique réelle, un flou de mouvement artificiel a été appliqué aux images pulmonaires du dataset LIDC-IDRI. Cette étape est essentielle car la base de données originale contient principalement des images de bonne qualité et ne présente pas systématiquement des artefacts de mouvement suffisamment marqués pour l'apprentissage supervisé.

Pour reproduire ce phénomène, un noyau de convolution simulant une trajectoire de mouvement a été généré. Contrairement à un flou linéaire classique, un mouvement courbe a été choisi afin de mieux représenter la complexité des déplacements respiratoires observés au niveau des poumons. Le noyau utilisé possède une taille de 14×14 pixels et contient une trajectoire elliptique partielle couvrant un angle d'environ 120°. Après sa construction, le noyau est normalisé afin de conserver l'énergie globale de l'image lors de l'opération de convolution.

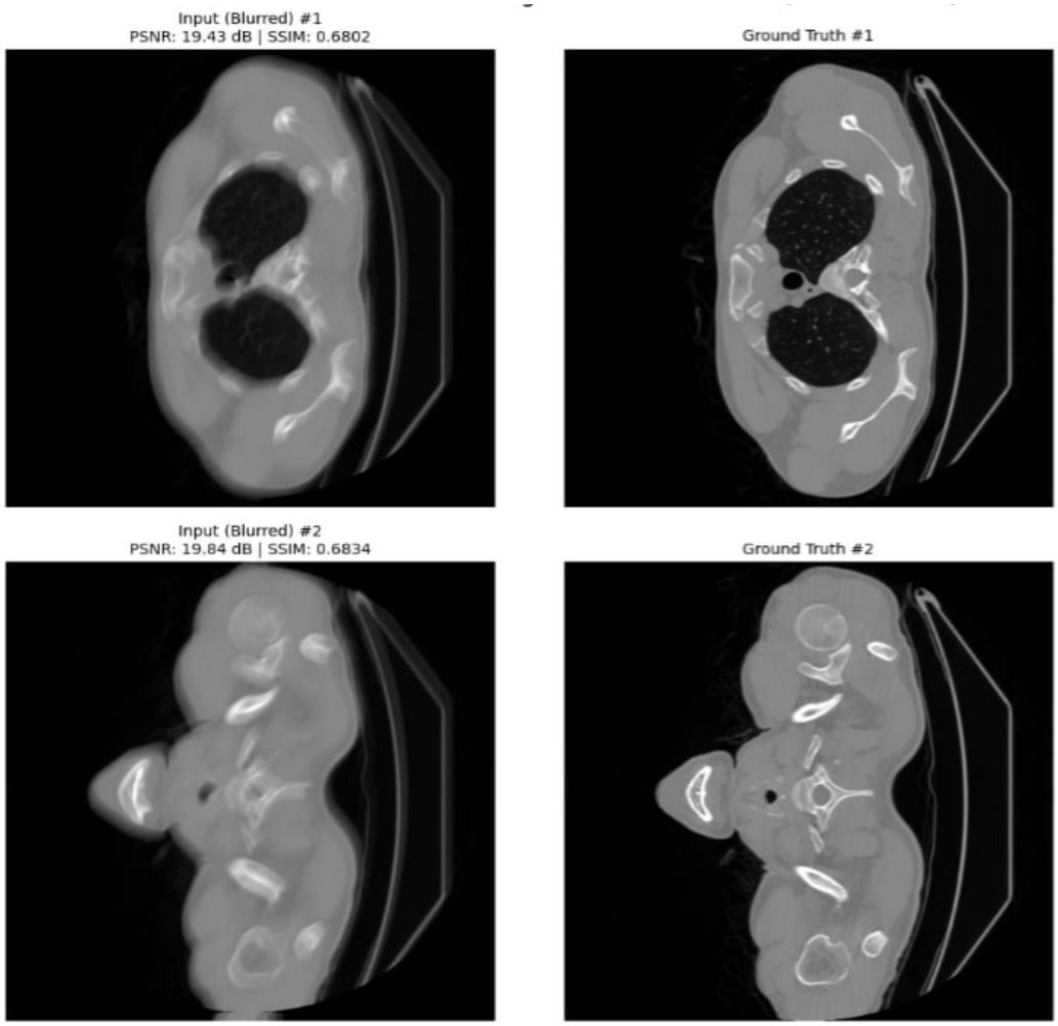
Le flou est ensuite appliqué à chaque image CT par convolution bidimensionnelle. Cette opération permet de diffuser l'information spatiale des pixels voisins et de reproduire la perte de résolution caractéristique du flou de mouvement. Les images obtenues constituent les données d'entrée du réseau neuronal tandis que les images originales servent de vérité terrain (groundtruth).

Cette approche permet de créer un ensemble cohérent de paires image floue/image de référence nécessaire à l'apprentissage supervisé du modèle Residual U-Net. Elle offre également un cadre expérimental contrôlé permettant d'évaluer quantitativement la capacité du réseau à restaurer les détails anatomiques altérés par le mouvement.

IV.2.2.1. Illustration de la dégradation des images par flou de mouvement

Dans cette section, nous présentons quelques exemples d’images utilisées afin d’illustrer l’effet du flou de mouvement sur la qualité des images tomodensitométriques.

Ces images permettent de comparer visuellement l'image originale avec sa version dégradée, et de mettre en évidence les principales altérations introduites par le flou, notamment la perte de netteté et de détails.



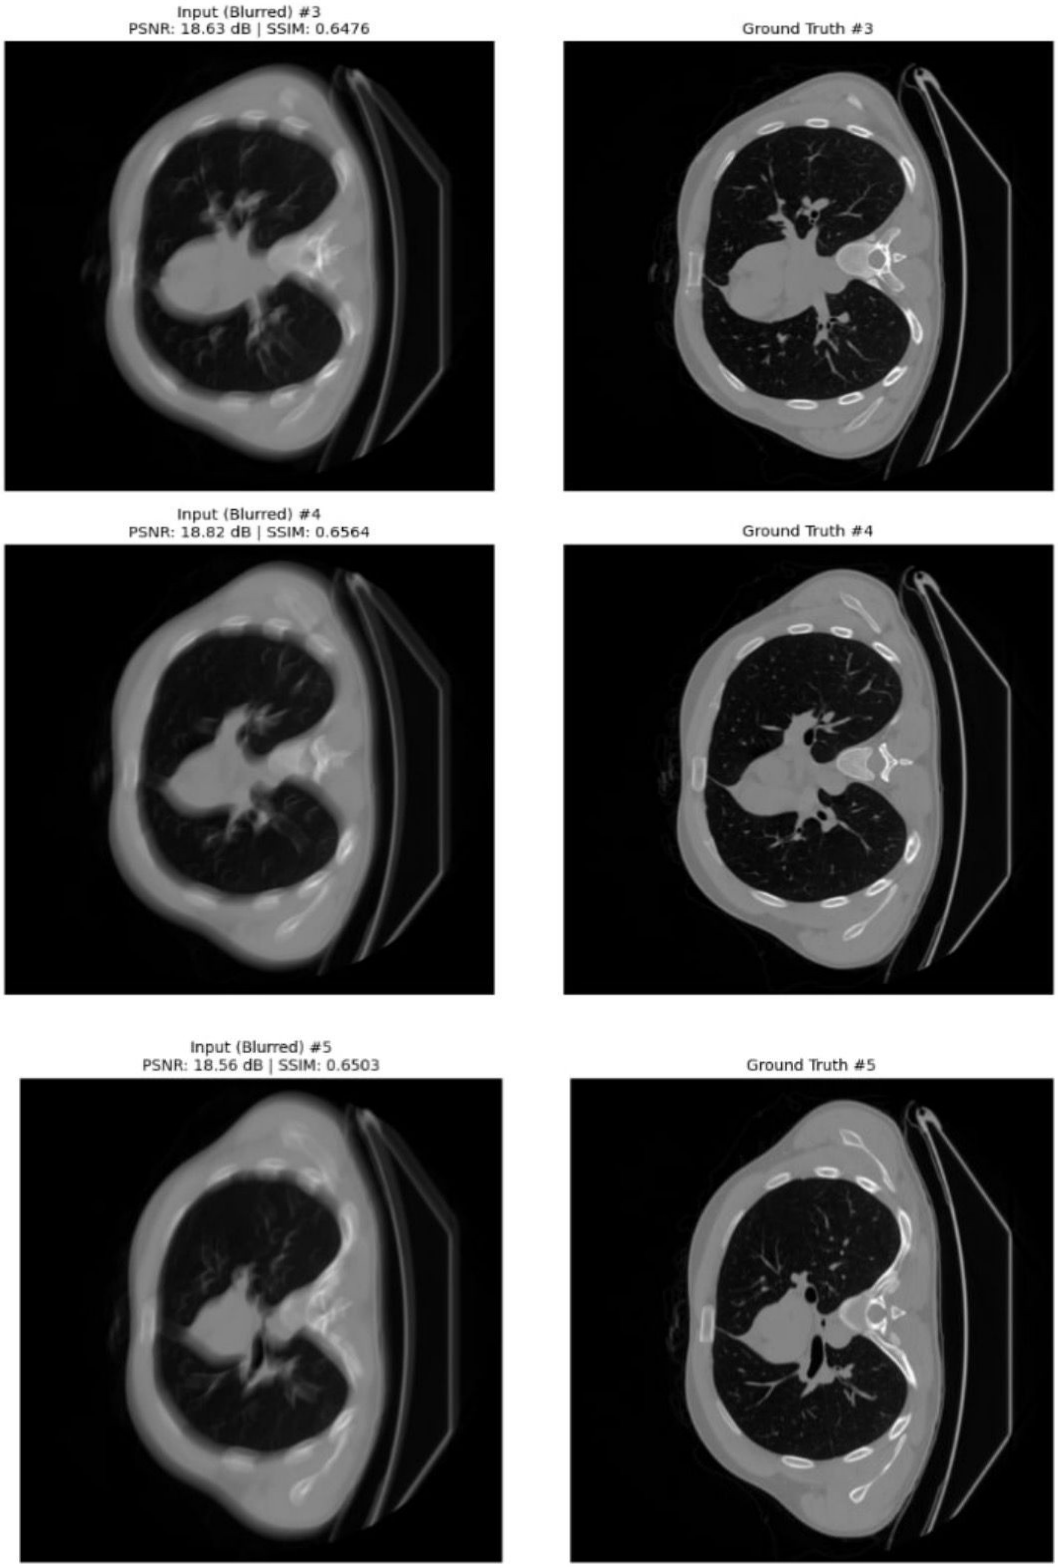


Figure IV.1 : Quelque Images avec flou de mouvement (motion blur)

L'observation visuelle de la Figure IV.1 montre que l'application du flou de mouvement entraîne une diminution visible de la netteté des structures pulmonaires. Les contours des vaisseaux sanguins et des bronches deviennent plus flous et moins bien définis, ce qui rend certaines structures difficiles à distinguer.

On remarque également une perte des détails fins présents dans l'image originale, en particulier au niveau des petites structures. Cette perte d'information est due à l'effet de lissage introduit par le flou, qui réduit la précision des contours et atténue les variations d'intensité.

Ce type de dégradation est représentatif des conditions réelles d'acquisition en imagerie médicale, notamment à cause des mouvements respiratoires du patient. Il constitue donc un cas réaliste pour tester les méthodes de restauration d'image.

Enfin, cette dégradation se traduit aussi par une baisse des indicateurs de qualité comme le PSNR et le SSIM, ce qui confirme la perte d'information entre l'image floutée et l'image originale.

IV.2.3. Préparation des données

IV.2.3.1. Constitution des paires d'images originales et floutées

À l'issue de l'étape de génération du flou de mouvement présentée dans la section précédente, deux ensembles d'images ont été obtenus : un ensemble d'images originales issues de la base de données LIDC-IDRI et un ensemble d'images dégradées par l'application du flou de mouvement simulé.

Les images originales constituent les images de référence (Ground Truth), tandis que les images floutées représentent les données d'entrée du modèle. Chaque image dégradée est associée à son image originale correspondante afin de former une paire d'apprentissage. Cette organisation permet au modèle de comparer les images restaurées aux images de référence durant la phase d'entraînement et d'apprendre progressivement à corriger les dégradations causées par le flou de mouvement.

Les paires ainsi constituées forment la base de données utilisée dans cette étude pour l'apprentissage et l'évaluation du modèle Residual U-Net. Cette approche

supervisée permet au réseau neuronal d'établir une correspondance entre les images dégradées et les images de référence afin de reconstruire les détails anatomiques perdus et d'améliorer la qualité visuelle des images pulmonaires.

IV.3. Entraînement du modèle et restauration des images pulmonaires

IV.3.1. Répartition des données d'entraînement et de validation

Afin d'évaluer objectivement les performances du modèle, les données ont été séparées en deux ensembles indépendants. L'ensemble d'entraînement comprend 39 patients représentant 7017 coupes tomographiques, tandis que l'ensemble de validation est constitué de 17 patients correspondant à 2709 coupes.

Cette séparation est réalisée au niveau des patients afin d'éviter qu'une même anatomie soit présente simultanément dans les deux ensembles. Une telle stratégie garantit une évaluation plus fiable de la capacité du modèle à généraliser ses performances sur des données non observées durant l'apprentissage.

Le découpage adopté permet également de maintenir un équilibre entre la quantité de données utilisée pour l'apprentissage et celle réservée à l'évaluation des performances.

IV.3.2. Prétraitement des images

Avant leur utilisation par le réseau neuronal, plusieurs opérations de prétraitement ont été appliquées aux données. Les fichiers DICOM ont d'abord été triés selon leur numéro d'instance afin de préserver l'ordre anatomique des coupes pulmonaires.

Les images ont ensuite été normalisées afin de limiter les variations d'intensité entre les acquisitions. Les valeurs CT ont été restreintes à l'intervalle [-1000 ; 1000] unités Hounsfield puis converties dans l'intervalle [0 ; 1], ce qui facilite la convergence du modèle durant l'apprentissage.

Pour optimiser l'utilisation de la mémoire GPU et augmenter le nombre d'échantillons disponibles, les images ont été subdivisées en patches de taille 256 × 256 pixels. Cette opération a permis de générer environ 21 051 patches destinés à l'entraînement du réseau.

IV.3.3. Environnement matériel et logiciel

Les expérimentations ont été réalisées sur une plateforme de calcul équipée d'un processeur graphique (GPU), permettant d'accélérer significativement les opérations d'apprentissage profond. L'utilisation du GPU réduit le temps d'entraînement tout en autorisant le traitement d'un grand nombre d'images.

IV.3.4. Paramétrage du modèle Residual U-Net

Le modèle utilisé est une architecture Residual U-Net bidimensionnelle adaptée à la restauration d'images médicales. Il reçoit en entrée des images pulmonaires en niveaux de gris et produit des images restaurées de mêmes dimensions.

L'architecture comporte plusieurs niveaux d'extraction de caractéristiques organisés selon une structure encodeur-décodeur. Les profondeurs de canaux utilisées sont respectivement 32, 64, 128, 256 et 512 filtres. Chaque bloc intègre deux unités résiduelles permettant d'améliorer la propagation de l'information à travers le réseau.

Un taux de dropout de 0,1 a été introduit afin de limiter le surapprentissage. Le modèle comprend environ 6,49 millions de paramètres entraînables, ce qui lui confère une capacité suffisante pour apprendre les relations complexes entre les images dégradées et les images de référence.

Cette configuration a été retenue afin d'obtenir un compromis entre précision de reconstruction, stabilité de l'apprentissage et coût computationnel.

Le développement du modèle a été effectué dans l'environnement Python à l'aide de bibliothèques spécialisées dans le traitement d'images médicales et l'apprentissage profond. Les opérations de chargement des données, de prétraitement, d'entraînement et d'évaluation ont été automatisées afin d'assurer une gestion efficace des différentes étapes expérimentales.

L'évolution des performances du modèle a été suivie tout au long de l'entraînement grâce à l'enregistrement des métriques et des fonctions de perte, permettant une analyse continue de la convergence du réseau.

IV.3.5. Fonction de perte hybride

La fonction de perte utilisée dans cette étude repose sur une combinaison de plusieurs critères complémentaires afin d'améliorer la qualité de restauration des images pulmonaires. Elle associe une perte basée sur l'erreur absolue moyenne (L1 Loss), une composante structurelle (SSIM Loss), une perte de contours (Edge Loss) et une perte fréquentielle (Frequency Loss).

Cette combinaison permet de préserver simultanément les intensités des pixels, les structures anatomiques, les contours ainsi que les détails fins affectés par le flou de mouvement. L'utilisation d'une fonction de perte hybride contribue ainsi à améliorer la fidélité et la qualité visuelle des images restaurées tout en favorisant une meilleure convergence du modèle durant l'apprentissage.

IV.3.6. Configuration de l'optimisation

a) Optimiseur AdamW

L'entraînement du modèle repose sur l'optimiseur AdamW, largement utilisé dans les applications d'apprentissage profond.

Ses principaux avantages sont :

- adaptation automatique du taux d'apprentissage ;
- convergence rapide ;
- meilleure généralisation grâce au mécanisme de régularisation Weight Decay.

b) Scheduler Warmup Cosine Annealing

Le taux d'apprentissage est contrôlé par une stratégie Warmup Cosine Annealing. Cette méthode comporte deux étapes :

Phase Warmup

- augmentation progressive du learning rate ;
- stabilisation des premières itérations.

Phase Cosine Annealing

- diminution progressive du learning rate ;
- amélioration de la convergence ;
- réduction des oscillations en fin d'entraînement.

Cette stratégie contribue à améliorer la stabilité globale de l'apprentissage.

IV.3.7. Stratégie d'entraînement progressive

Afin d'améliorer la stabilité de l'apprentissage et d'obtenir une convergence efficace, une stratégie d'entraînement progressive a été mise en œuvre. Cette approche consiste à modifier progressivement l'influence des différentes composantes de la fonction de perte au cours des époques.

a) Phase initiale (0 à 15 époques)

Durant cette première phase, l'apprentissage est principalement guidé par la perte L1.

Objectifs :

- stabiliser les premières étapes de l'apprentissage ;
- réduire les erreurs globales de reconstruction ;
- fournir une base solide pour les phases suivantes.

b) Phase d'enrichissement (15 à 40 époques)

Les composantes structurelles, fréquentielles et de contours sont progressivement introduites.

Cette phase permet :

- d'améliorer la cohérence anatomique ;

- de renforcer la préservation des contours ;
- de récupérer davantage de détails anatomiques.

c) Phase de focalisation (40 à 60 époques)

L'apprentissage est davantage orienté vers les informations structurelles et fréquentielles.

Les objectifs sont :

- l'amélioration des textures pulmonaires ;
- l'optimisation des structures anatomiques ;
- la récupération des détails fins dégradés par le flou.

d) Phase finale (au-delà de 60 époques)

La contribution de la perte L1 redevient prépondérante afin de stabiliser les performances du modèle et d'affiner les reconstructions obtenues.

IV.3.8. Gestion des points de sauvegarde (checkpoints)

Afin d'assurer la continuité des expérimentations, un système de sauvegarde automatique a été mis en place.

Les points de sauvegarde enregistrent :

- les paramètres du réseau neuronal ;
- les paramètres de l'optimiseur ;
- les paramètres du scheduler ;
- les métriques obtenues durant l'apprentissage.

Cette approche permet :

- la reprise de l'entraînement en cas d'interruption ;
- la conservation du meilleur modèle ;
- la reproductibilité des résultats expérimentaux.

IV.3.9. Procédure d'entraînement et de validation du modèle

a) Phase d'entraînement

Durant chaque époque d'apprentissage :

1. Les images floutées sont chargées sous forme de lots.
2. Le modèle Residual U-Net génère les images restaurées.
3. La fonction de perte hybride est calculée.
4. Les gradients sont rétropropagés à travers le réseau.
5. Les paramètres sont mis à jour à l'aide de l'optimiseur AdamW.

Cette procédure est répétée jusqu'à la convergence du modèle.

b) Phase de validation

À la fin de chaque époque, le modèle est évalué sur l'ensemble de validation.

Cette étape permet :

- d'évaluer les performances sur des données non vues ;
- de calculer les métriques PSNR, SSIM et RMSE ;
- de surveiller l'apparition éventuelle d'un surapprentissage.

c) Restauration des images pulmonaires

Après la phase d'apprentissage, le modèle entraîné est appliqué aux images pulmonaires dégradées par le flou de mouvement.

Les images restaurées obtenues présentent :

- une amélioration de la netteté ;
- une meilleure définition des structures bronchiques ;
- une meilleure visibilité des vaisseaux pulmonaires ;
- une récupération des détails anatomiques affectés par le flou.

Les performances finales du modèle sont ensuite analysées à travers une évaluation quantitative et qualitative présentée dans la section des résultats.

IV.4. Évaluation des performances

Afin d'évaluer quantitativement les performances du modèle, trois métriques complémentaires ont été utilisées : le PSNR, le SSIM et le RMSE.

IV.4.1. Peak Signal-to-Noise Ratio (PSNR)

Le PSNR mesure la qualité de reconstruction d'une image en comparant le signal utile au bruit résiduel introduit lors du traitement.

$$PSNR = 10 \log_{10} \left(\frac{MAX^2}{MSE} \right)$$

où :

- MAX représente la valeur maximale d'intensité du pixel ;
- MSE correspond à l'erreur quadratique moyenne.

Valeurs de référence :

Valeur PSNR	Interprétation
< 20 dB	Qualité faible
20 – 30 dB	Qualité acceptable
30 – 40 dB	Bonne qualité
> 40 dB	Excellente qualité

Tableau IV.1 : Valeurs de référence du PSNR et leur interprétation

Une valeur élevée du PSNR indique une meilleure fidélité de reconstruction.

IV.4.2. Structural Similarity Index Measure (SSIM)

Le SSIM évalue la similarité structurelle entre l'image restaurée et l'image de référence en prenant en compte la luminance, le contraste et la structure.

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$

Valeurs de référence :

Valeur SSIM	Interprétation
< 0,50	Faible similarité
0,50 – 0,80	Similarité moyenne
0,80 – 0,90	Bonne similarité
> 0,90	Excellente similarité

Tableau IV.2 : Valeurs de référence du SSIM et leur interprétation

Le SSIM varie entre 0 et 1. Plus sa valeur est proche de 1, plus les deux images sont similaires.

IV.4.3. Root Mean Square Error (RMSE)

Le RMSE mesure l'écart moyen entre les pixels de l'image restaurée et ceux de l'image de référence.

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(I_i - \hat{I}_i)^2}$$

où :

- Ii représente le pixel de référence ;
- Î i représente le pixel reconstruit ;
- N est le nombre total de pixels.

Valeurs de référence :

Valeur RMSE	Interprétation
> 0,10	Erreur importante
0,05 – 0,10	Erreur modérée
0,01 – 0,05	Faible erreur
< 0,01	Très faible erreur

Tableau IV.3 : Valeurs de référence du RMSE et leur interprétation

Contrairement au PSNR et au SSIM, une faible valeur du RMSE indique de meilleures performances.

IV.5. Résultats et discussion

IV.5.1. Résultats quantitatifs de la restauration

Les résultats quantitatifs obtenus après l'entraînement du modèle fournissent une indication objective de la qualité de reconstruction des images pulmonaires. Le Tableau IV.4 récapitule les valeurs des différentes métriques utilisées pour l'évaluation.

Échantillon	Avant		Après		
	PSNR (dB)	SSIM	PSNR (dB)	SSIM	RMSE
Échantillon 1	19.43	0.6802	32.89	0.9007	0.0227
Échantillon 2	19.84	0.6834	32.45	0.8653	0.0239
Échantillon 3	18.63	0.6476	31.67	0.8855	0.0261
Échantillon 4	18.82	0.6564	31.38	0.8816	0.0270
Échantillon 5	18.56	0.6503	31.63	0.8873	0.0262
Moyenne	19.06	0.6636	32.00	0.8841	0.0252

Tableau IV.4 : Valeurs de PSNR, SSIM et RMSE obtenues avant et après restauration des images test

IV.5.1.1. Discussion des résultats

Les résultats obtenus montrent une amélioration significative de la qualité des images pulmonaires après l'application du modèle Residual U-Net. Cette amélioration est observée pour l'ensemble des échantillons à travers les métriques PSNR, SSIM et RMSE.

La valeur moyenne du PSNR passe de 19,06 dB avant restauration à 32,00 dB après restauration, ce qui indique une nette réduction des dégradations causées par le flou de mouvement et une meilleure fidélité des images reconstruites.

De même, le SSIM augmente de 0,6636 à 0,8841, traduisant une excellente préservation des structures anatomiques pulmonaires. Cette amélioration montre que le modèle parvient à restaurer efficacement les détails importants tout en conservant l'organisation anatomique de l'image.

Par ailleurs, la faible valeur moyenne du RMSE (0,0252) confirme que les images restaurées sont très proches des images de référence. Les erreurs de reconstruction restent limitées, ce qui témoigne de la précision du modèle.

L'analyse des différents échantillons révèle des performances homogènes, avec des valeurs de PSNR supérieures à 31 dB et des valeurs de SSIM supérieures à 0,86 pour tous les cas étudiés. Ces résultats démontrent la robustesse du modèle face aux différentes dégradations introduites par le flou de mouvement.

Les performances obtenues peuvent être attribuées à l'architecture Residual U-Net ainsi qu'à l'utilisation d'une fonction de perte hybride, qui permettent conjointement de préserver les structures anatomiques, les contours et les détails fins des images pulmonaires.

Dans l'ensemble, ces résultats confirment l'efficacité de la méthode proposée pour la restauration des images pulmonaires affectées par le flou de mouvement et mettent en évidence son potentiel pour améliorer la qualité des examens d'imagerie médicale.

IV.5.2. Analyse de l'évolution de l'apprentissage

Le présent travail analyse l'évolution des performances du modèle au cours du processus d'apprentissage. Elle permet d'observer le comportement du modèle en fonction des itérations, notamment en termes d'amélioration de la qualité des images restaurées. Les courbes présentées ci-après illustrent l'évolution des indicateurs de performance, tels que le PSNR et le SSIM, et permettent d'évaluer la convergence et la stabilité du modèle.

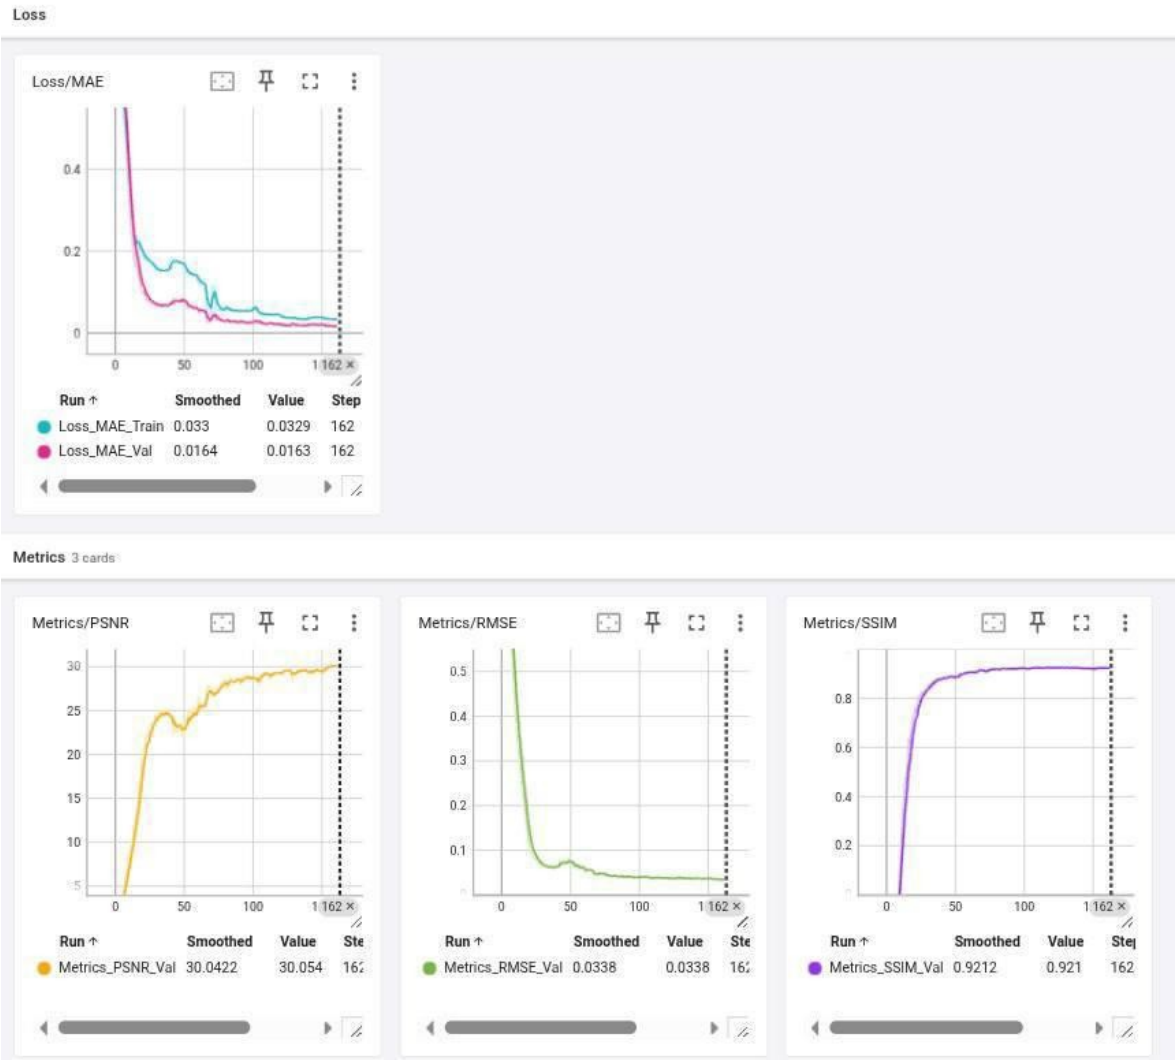


Figure IV.2 : illustre l'évolution des métriques de performance utilisées pour évaluer le modèle durant la phase d'entraînement. Ces résultats permettent d'analyser la qualité de la reconstruction ainsi que la capacité de généralisation du réseau

Les résultats d'entraînement montrent une amélioration progressive des performances du modèle au cours des époques. La diminution continue de la perte MAE, qui atteint une valeur finale d'environ 0,033 pour l'entraînement et 0,0163 pour la validation, indique une réduction significative des erreurs de reconstruction.

Parallèlement, le PSNR augmente progressivement jusqu'à environ 30,05 dB, traduisant une amélioration de la qualité des images restaurées et une meilleure fidélité par rapport aux images de référence.

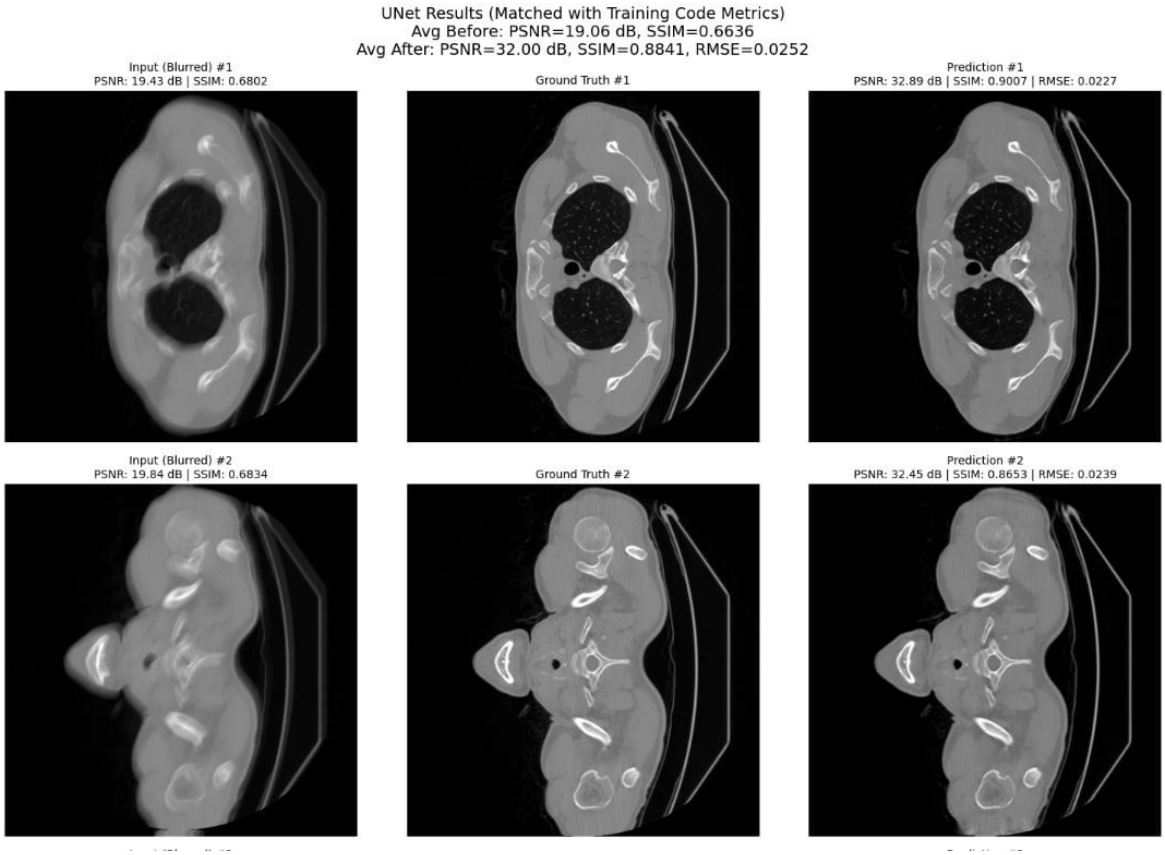
De même, la valeur du SSIM atteint environ 0,921, ce qui témoigne d'une bonne préservation des structures et des détails importants de l'image.

La diminution du RMSE jusqu'à une valeur proche de 0,0338 confirme également la précision des images reconstruites et leur proximité avec les images originales. En outre, la faible différence observée entre les courbes d'entraînement et de validation suggère une bonne capacité de généralisation du modèle et l'absence de surapprentissage notable.

Dans l'ensemble, ces résultats démontrent l'efficacité du modèle pour la restauration des images, avec une amélioration simultanée des métriques de qualité visuelle et une réduction des erreurs de reconstruction.

IV.5.3. Évaluation qualitative des images restaurées

La figure IV.3 illustre quelques exemples de restauration d'images obtenues avec le modèle proposé. Les images floues, les images de référence et les images restaurées sont présentées afin d'évaluer visuellement la qualité de la reconstruction.



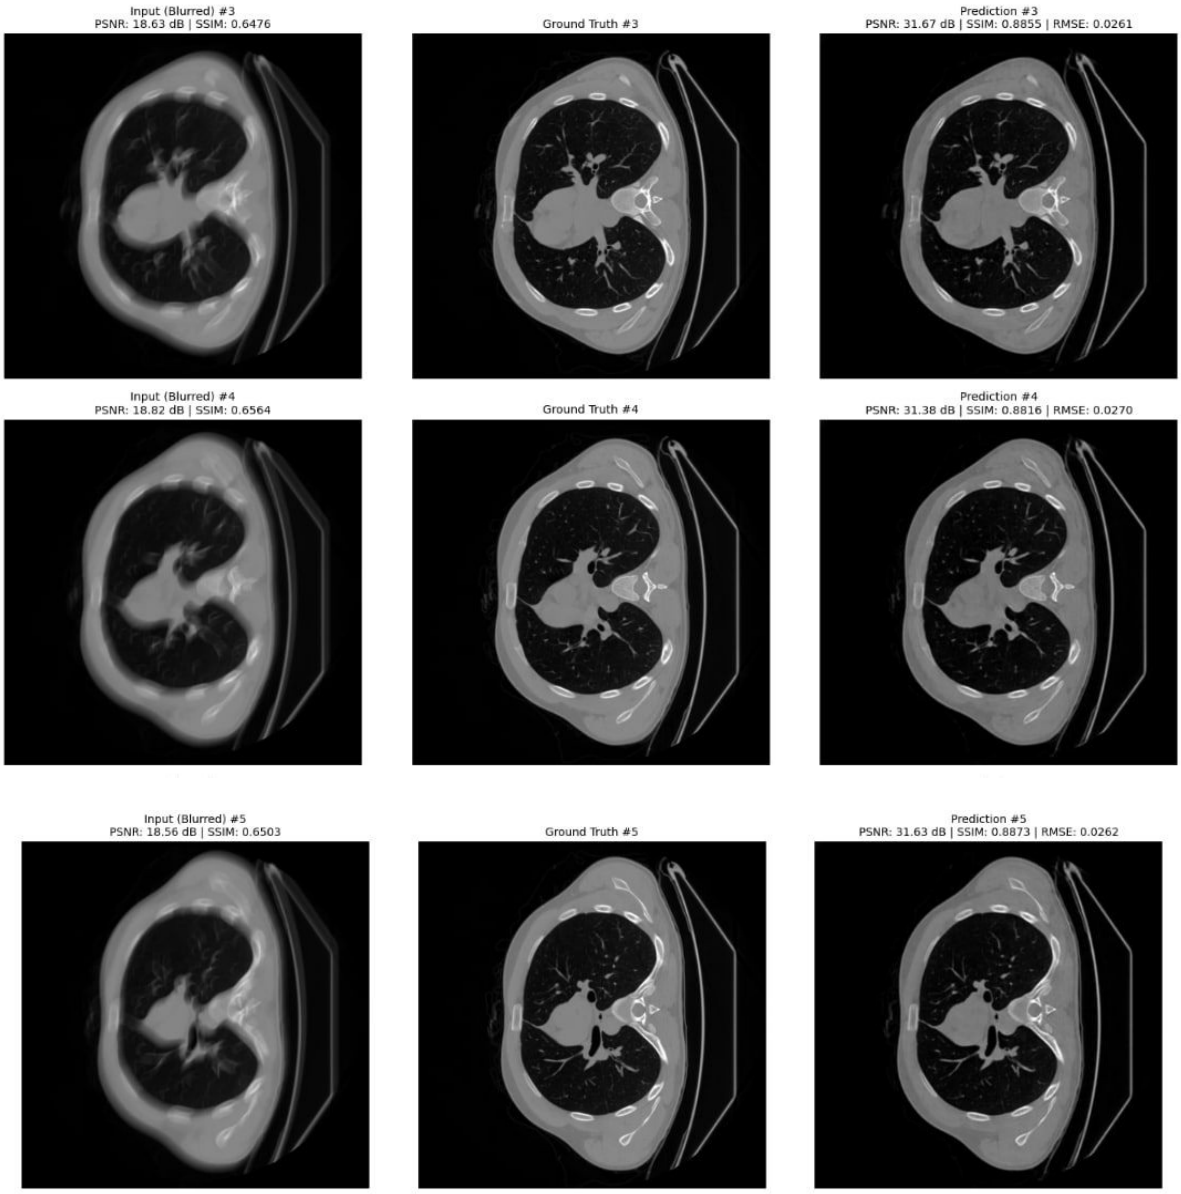


Figure IV.3 : présente cinq exemples d'images restaurées par le modèle proposé. Pour chaque échantillon, l'image floue en entrée est comparée à l'image de référence (Ground Truth) et à l'image reconstruite.

L'observation visuelle montre que le modèle réduit efficacement les effets du flou de mouvement présents dans les images d'entrée. Les images restaurées présentent une meilleure netteté ainsi qu'une meilleure visibilité des structures anatomiques par rapport aux images dégradées. Les contours des organes et les détails internes apparaissent plus précis et se rapprochent davantage des images de référence.

Les résultats quantitatifs confirment cette amélioration. Les valeurs du **PSNR** augmentent significativement après restauration, passant d'environ **19–20 dB** pour les images floues à plus de **37 dB** pour les images restaurées. De même, le **SSIM** passe d'environ **0,65–0,67** à plus de **0,92**, ce qui traduit une meilleure conservation des structures anatomiques. Par ailleurs, les faibles valeurs du **RMSE** (inférieures à 0,02) indiquent que les images reconstruites sont très proches des images de référence.

Dans l'ensemble, ces résultats démontrent la capacité du modèle à restaurer efficacement les images médicales affectées par le flou de mouvement, tout en préservant les détails anatomiques essentiels. Cette amélioration est particulièrement importante pour faciliter l'interprétation et l'analyse des examens d'imagerie médicale.

IV.5.4. Résultats d'entraînement :

Les résultats obtenus durant la phase d'entraînement permettent d'évaluer la convergence et la stabilité du modèle proposé. L'analyse des courbes et des métriques de validation montre une amélioration progressive des performances au cours des époques, avec une diminution de la perte et une augmentation des indicateurs de qualité d'image.

Le tableau ci-dessous résume les performances globales du modèle sur l'ensemble de validation ainsi que leur évolution par rapport aux images d'entrée initiales.

Métrique	Valeur validation	Évolution vs entrée
PSNR	30.05 dB	↑ +10.4 dB vs entrée
SSIM	0.921	↑ +0.29 vs entrée
RMSE	0.034	↓ amélioration significative
Loss MAE (val)	0.0163	Convergence stable

Tableau IV.5 : Résultats d'entraînement et de validation du modèle

Les résultats montrent une amélioration significative de la qualité des images reconstruites. Le **PSNR atteint 30.05 dB**, ce qui indique une réduction importante du bruit et une meilleure fidélité par rapport aux images de référence. De même, la valeur du **SSIM de 0.921** traduit une bonne préservation des structures et des détails importants.

La diminution du **RMSE jusqu'à 0.034** confirme la précision du modèle dans la reconstruction des images, tandis que la faible valeur de la **loss MAE de validation (0.0163)** montre que le modèle a atteint une convergence stable sans signe de surapprentissage notable.

Dans l'ensemble, ces résultats confirment que le modèle présente de bonnes capacités de généralisation et qu'il parvient à améliorer significativement la qualité des images dégradées par le flou de mouvement.

IV.6. Discussion des résultats

Les résultats obtenus confirment l'efficacité du modèle pour la restauration des images TDM dégradées par le flou de mouvement. Les métriques d'évaluation montrent une bonne qualité de reconstruction, avec un PSNR moyen de 32,00 dB sur l'ensemble de test, un SSIM de 0,8841 et un RMSE de 0,0252, ce qui traduit une forte similarité avec les images de référence.

L'évolution des courbes d'apprentissage met en évidence une amélioration progressive des performances, caractérisée par la baisse de la MAE et du RMSE, ainsi que l'augmentation du PSNR et du SSIM. La proximité entre les courbes d'entraînement et de validation indique une bonne capacité de généralisation et l'absence de surapprentissage notable.

Ces performances s'expliquent par l'architecture Residual U-Net, qui facilite la préservation des informations fines grâce aux connexions résiduelles et à la structure encodeur-décodeur. La fonction de perte hybride contribue également à équilibrer la minimisation de l'erreur et la conservation des structures.

Bien que les résultats obtenus en termes de PSNR, SSIM et RMSE soient satisfaisants, cette étude s'est concentrée principalement sur l'évaluation des performances du modèle proposé. Une comparaison détaillée avec des méthodes classiques telles que le filtre de Wiener, la déconvolution aveugle ou un U-Net standard n'a pas été réalisée dans le cadre de ce travail. Cette comparaison constitue une perspective intéressante pour des travaux futurs afin de confirmer davantage les performances du modèle.

Certaines limites subsistent néanmoins, notamment une sensibilité variable selon le niveau de dégradation, avec une perte légère de détails dans les cas de flou important.

Dans l'ensemble, ces résultats montrent que l'approche proposée est performante et adaptée à la restauration d'images médicales, avec un bon compromis entre précision numérique et qualité visuelle.

IV.7. Conclusion du chapitre

Ce chapitre a été consacré à l'évaluation expérimentale du modèle proposé pour la restauration des images tomodensitométriques pulmonaires dégradées par le flou de mouvement. L'approche adoptée repose sur une architecture de type **Residual U-Net**, entraînée dans un cadre supervisé et évaluée à l'aide de métriques quantitatives complémentaires, à savoir le PSNR, le SSIM, le RMSE et la MAE.

Les résultats obtenus mettent en évidence une convergence stable du modèle au cours de l'entraînement, caractérisée par une diminution progressive des erreurs et une amélioration continue des mesures de qualité d'image. Les valeurs élevées de PSNR et de SSIM, associées à de faibles valeurs de RMSE, attestent de la capacité du modèle à produire des reconstructions fidèles aux images de référence, tant sur le plan structurel que sur le plan radiométrique. L'analyse qualitative confirme également une amélioration significative de la netteté et de la visibilité des structures pulmonaires.

Ces résultats démontrent la pertinence de l'approche proposée pour la correction du flou de mouvement en imagerie pulmonaire, en assurant un compromis satisfaisant entre fidélité numérique et préservation des informations anatomiques.

CONCLUSION GÉNÉRALE

Ce travail a porté sur la conception et l'évaluation d'une méthode basée sur l'apprentissage profond pour la restauration des images tomodensitométriques pulmonaires affectées par le flou de mouvement. L'objectif principal consistait à améliorer la qualité des images afin de renforcer leur lisibilité et leur exploitation dans un contexte d'aide au diagnostic médical.

La méthodologie proposée s'appuie sur une architecture Residual U-Net, combinant les avantages des réseaux encodeur–décodeur et des connexions résiduelles, ainsi qu'une fonction de perte hybride permettant de concilier optimisation pixel-wise et préservation des structures. Cette configuration a permis une extraction efficace des caractéristiques pertinentes et une reconstruction cohérente des détails anatomiques.

Les résultats expérimentaux obtenus montrent des performances globalement satisfaisantes, avec des valeurs élevées de PSNR et de SSIM et une réduction significative de l'erreur RMSE. L'analyse qualitative des images restaurées confirme ces performances en mettant en évidence une amélioration notable de la netteté et de la qualité structurelle.

Cependant, malgré ces résultats encourageants, certaines limites doivent être soulignées. D'une part, les performances du modèle restent fortement dépendantes de la qualité et de la diversité des données d'entraînement, ce qui peut limiter sa capacité de généralisation à des données cliniques réelles plus variées. D'autre part, le modèle peut rencontrer des difficultés à restaurer des flous très complexes ou non uniformes, notamment dans des situations de mouvements importants ou irréguliers. Par ailleurs, l'utilisation de fonctions de perte principalement basées sur des critères pixel-wise peut conduire à une reconstruction parfois insuffisamment fidèle sur le plan perceptuel.

En définitive, les résultats obtenus valident l'efficacité de la méthode proposée pour la correction du flou de mouvement en imagerie pulmonaire. Des perspectives d'amélioration peuvent être envisagées, notamment l'enrichissement des bases de données, l'optimisation de l'architecture et l'intégration de fonctions de perte perceptuelles afin d'améliorer davantage la fidélité structurelle des reconstructions.

LISTE DES RÉFÉRENCES

[1] Prabhu, S., Naveen, D. K., Bangera, S., & Bhat, B. S. (2020). Production of XRAYS using X-RAY tube. Journal of Physics: Conference Series, 1712(1), 012036.

[2] Assif, S., Faiz, A., Ennawaoui, C., Ducourneau, J., & Hajjaji, A. (2023). Physics of X-ray production and its applications in medicine. Letters in High Energy Physics.

[3] ScienceDirect Topics. (n.d.). X-ray tube – an overview. https://www.sciencedirect.com/topics/medicine-and-dentistry/x-ray-tube

[4] Bushberg, J. T., Seibert, J. A., Leidholdt, E. M., & Boone, J. M. (2012). The essential physics of medical imaging (3rd ed.). Lippincott Williams & Wilkins.

[5] Tubiana, M., Dutreix, J., & Wambersie, A. (1986). Radiobiologie. Hermann.

[6] Hall, E. J., & Giaccia, A. J. (2012). Radiobiology for the radiologist (7th ed.). Lippincott Williams & Wilkins.

[7] Podgorsak, E. B. (2010). Radiation physics for medical physicists (2nd ed.). Springer.

[8] Seeram, E. (2019). Digital radiography: Physical principles and quality control (2nd ed.). Springer.

[9] Seeram, E. (2018). Digital mammography: A practical approach. Springer.

[10] Samei, E., Flynn, M. J., & Reimann, D. A. (1998). A method for measuring the presampled MTF of digital radiographic systems using an edge test device. Medical Physics, 25(1), 102–113.

[11] Gonzalez, R. C., & Woods, R. E. (2018). Digital image processing (4th ed.). Pearson Education.

[12] Carlton, R. R., & Adler, A. M. (2018). Principles of radiographic imaging: An art and a science (6th ed.). Cengage Learning.

[13] Hendee, W. R., & Ritenour, E. R. (2019). Medical imaging physics (5th ed.). Wiley-Liss.

[14] Ritchie, C. J., Godwin, J. D., Crawford, C. R., Stanford, W., Anno, H., & Kim, Y. (1992). Minimum scan speeds for suppression of motion artifacts in CT. Radiology, 185(1), 37–42.

[15] Willemink, M. J., Persson, M., Pourmorteza, A., Pelc, N. J., & Fleischmann, D. (2018). Photon-counting CT: Technical principles and clinical prospects. Radiology, 289(2), 293–312.

[16] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436–444.

[17] Litjens, G., Kooi, T., Bejnordi, B. E., et al. (2017). A survey on deep learning in medical image analysis. Medical Image Analysis, 42, 60–88.

[18] Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. MICCAI 2015, 234–241.

[19] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. IEEE CVPR, 770–778.

[20] Zhang, Z., Liu, Q., & Wang, Y. (2018). Road extraction by deep residual U-Net. IEEE Geoscience and Remote Sensing Letters, 15(5), 749–753.

[21] Nah, S., Hyun Kim, T., & Mu Lee, K. (2017). Deep multi-scale convolutional neural network for dynamic scene deblurring. IEEE CVPR, 3883–3891.

[22] Zhao, H., Gallo, O., Frosio, I., & Kautz, J. (2017). Loss functions for image restoration with neural networks. IEEE Transactions on Computational Imaging, 3(1), 47–57.

[23] Jiang, L., Dai, B., Wu, W., & Loy, C. C. (2021). Focal frequency loss for image reconstruction and synthesis. IEEE/CVF ICCV, 13919–13929.

[24] Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. IEEE Transactions on Image Processing, 13(4), 600–612.

[25] Loshchilov, I., & Hutter, F. (2019). Decoupled weight decay regularization. ICLR.

[26] Goodfellow, I., Pouget-Abadie, J., Mirza, M., et al. (2014). Generative adversarial nets. NeurIPS, 27, 2672–2680.

[27] Dosovitskiy, A., Beyer, L., Kolesnikov, A., et al. (2021). An image is worth 16x16 words: Transformers for image recognition at scale. ICLR.

[28] Chen, H., Zhang, Y., Kalra, M. K., et al. (2017). Low-dose CT with a residual encoder-decoder convolutional neural network. IEEE Transactions on Medical Imaging, 36(12), 2524–2535.

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche

Université 20 août 1955-Skikda

Faculté des Sciences

Département de Physique

جامعة 20 أوت 1955- سكيكدة

كلية العلوم

قسم الفيزياء

سكيكدة يوم: ..../ 0/2026

رقم:...../ق ف/2026

محضر تصحيح مذكرة الماستر

أنا الممضي أسفله الأستاذ(ة) المشرف(ة): .....د.كارسهيلة.....

أشهد بأن الطالب (ة): .....لموشي جيهان.....

تخصص: .....فيزياء طبية.....

قد قام(ت) بجميع التصحيحات المتعلقة بمذكرة الماستر

تحت عنوان: .....Traitement du flou de mouvement en imagerie à rayons X par des techniques robuste de filtrage basée sur l'intelligence artificielle.....

امضاء الأستاذ(ة) المشرف(ة)

رئيس القسم

رئيس قسم الفيزياء
الدكتور: بوقبسان مولود

Scanned with CamScanner

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي و البحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche

Université 20 août 1955-Skikda

Faculté des Sciences

Département de Physique

جامعة 20 أوت 1955- سكيكدة

كلية العلوم

قسم الفيزياء

سكيكدة يوم: ..../ 0/2026

رقم:...../ق ف/2026

محضر تصحيح مذكرة الماستر

أنا الممضي أسفله الأستاذ(ة) المشرف(ة): ..... دكتور سهيلة .....

أشهد بأن الطالب (ة): .... بومدين لبنى .....

تخصص: ..... علوم مادة طبية .....

قد قام(ت) بجميع التصحيحات المتعلقة بمذكرة الماستر

تحت عنوان: ..... Traitement du flou de mouvement en imagerie à rayons X par des techniques robustes de filtrage basées sur l'intelligence artificielle .....

امضاء الأستاذ(ة) المشرف(ة)

رئيس القسم

رئيس قسم الفيزياء

الدكتور: بوقجان مولود

Scanned with CamScanner