

الجمهورية الجزائرية الديمقراطية الشعبية

**REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE**

وزارة التعليم العالي والبحث العلمي

**Ministère de l'Enseignement Supérieur et de la Recherche Scientifique**

جامعة أبي بكر بلقايد - تلمسان -

Université Aboubakr Belkaïd – Tlemcen –

Faculté de TECHNOLOGIE



**THESE**

Présentée pour l'obtention du **grade de DOCTORAT 3<sup>ème</sup> Cycle**

**En** : Génie biomédical

**Spécialité** : Imagerie médicale

**Par** : BENYELLES Asma

**Sujet**

**Etude et optimisation des facteurs influençant la qualité  
d'image en médecine nucléaire**

Soutenue publiquement, le 14/03/2026, devant le jury composé de :

Mr.Kerai Salim	Professeur	Univ. Tlemcen	Président
Mme.Korti Amel	Professeur	Univ. Tlemcen	Directrice de thèse
Mr.Djebbari Abdelghani	Professeur	Univ. Tlemcen	Examineur
Mr.Kameche Mohamed	Directeur de recherche	CDS. Oran	Examineur

## Remerciements

Je tiens à exprimer ma profonde gratitude, en tout premier lieu, à « **Allah** », le Tout-Puissant et Miséricordieux, qui, par Sa grâce, m'a accordé la force, la patience et la volonté nécessaires à l'achèvement de ce travail.

En signe de profonde gratitude, j'exprime mes plus sincères remerciements à ma directrice de thèse, **Mme. Korti Amel**, son encadrement éclairé et son investissement ont été des piliers durant toute la période de réalisation de cette thèse. Je lui suis particulièrement redevable de m'avoir encouragé à cultiver l'autonomie et la persévérance, et pour le temps qu'elle a si généreusement consacré à l'achèvement de ce travail.

J'adresse également mes respectueux remerciements aux membres du Jury de thèse : **Mr. Kerai Salim**, **Mr. Djebbari Abdelghani** et **Mr. Kameche Mohamed** que je remercie sincèrement d'avoir accepté d'examiner et de juger ce travail, et j'espère vivement qu'il saura répondre à leurs attentes.

Je remercie également l'ensemble du corps professoral, des enseignants-chercheurs et des doctorants du **Laboratoire de recherche de Génie Biomédical** pour leur accueil et leur soutien académique.

Je remercie également mes amis les plus proches et toute personne qui a contribué, de près ou de loin, à la réalisation de cette thèse par son encouragement ou son aide.

Enfin et surtout, j'adresse ma plus profonde et inconditionnelle gratitude à mes chers parents, mon mari et à l'ensemble de ma famille, pour leur soutien indéfectible, leur amour et leur patience, sans lesquels l'aboutissement de ce travail n'aurait pas été possible.

## *Dédicaces*

*Après des années d'efforts et au terme d'un parcours universitaire jalonné de défis et d'apprentissages, le jour est venu de présenter le fruit de cette persévérance.*

*C'est avec une profonde fierté que je dédie cette thèse en tout premier lieu à mes très chers parents pour l'amour inconditionnel et l'éducation exemplaire qu'ils m'ont donnée, et le soutien continu qui a été la source même de ma réussite ; aucun mot ne saurait exprimer la mesure de ma reconnaissance pour leur présence et les sacrifices consentis.*

*C'est avec une immense joie et une grande affection que je la dédie également à mon mari pour sa présence réconfortante, son soutien constant et la force morale qu'il m'a apportée tout au long de cette période de recherche, ainsi qu'à mon fils « Nizar » la prunelle de mes yeux, ma raison d'être et ma source de motivation. Je la dédie avec la même affection à ma sœur, mon frère, ma belle-sœur et ma belle-famille ainsi que mes adorables neveux et nièces, pour leur amour et leur présence.*

*Et en hommage, je dédie ce travail à la mémoire de ma sœur décédée. Son souvenir, à jamais gravé dans mon cœur, fut une source de courage et d'inspiration.*

# Résumé

La médecine nucléaire est une spécialité d'imagerie qui permet d'étudier le fonctionnement des organes à l'aide de faibles doses de radiotraceurs. Les deux modalités principales utilisées sont la Tomographie par Émission de Positrons (TEP) et la Tomographie par Émission Monophotonique (TEMP). Bien que ces techniques réduisent l'exposition du patient aux rayonnements, l'utilisation de faibles activités de radiotraceurs génère intrinsèquement un bruit élevé et une dégradation de qualité d'image, rendant difficile la détection des structures pathologiques fines et compromettant la précision diagnostique. Pour surmonter ce défi, cette thèse s'appuie sur une synergie entre la simulation physique et l'intelligence artificielle (IA). Dans un premier temps, le logiciel de simulation GEANT4 a été utilisé pour modéliser les interactions des rayonnements avec les détecteurs, dont le but d'optimiser la résolution en énergie. Parallèlement, l'apprentissage profond a été déployé pour améliorer la qualité d'image : un Réseau Antagoniste Génératif (GAN) a été spécifiquement conçu pour réduire efficacement le bruit au niveau du sinogramme avant la reconstruction de l'image, tandis qu'un Réseau à Attention par Canal Résiduel (RCAN) a été appliqué pour améliorer considérablement la résolution spatiale des images reconstruites. Les résultats obtenus, qui surpassent les performances des méthodes existantes rapportées dans la littérature, démontrent que cette approche combinée permet de produire des images TEP et TEMP de qualité supérieure, tant en termes de netteté que de fidélité quantitative. Ces avancées facilitent l'interprétation clinique et contribuent à un diagnostic plus précis, fiable et reproductible.

**Mots clés :** Médecine nucléaire, Tomographie par Emission de positrons (TEP), Tomographie par Emission Monophonique (TEMP), Apprentissage profond, Réseau Antagoniste Génératif (GAN), Simulation, Qualité d'image.

# Abstract

Nuclear medicine is an imaging specialty that allows the study of organ function using low doses of radiotracers. The two main modalities used are Positron Emission Tomography (PET) and Single-Photon Emission Computed Tomography (SPECT). Although these techniques reduce patient exposure to radiation, the use of low radiotracer activities inherently generates high noise and image quality degradation, making the detection of fine pathological structures challenging and compromising diagnostic accuracy. To overcome this challenge, this thesis leverages a synergy between physical simulation and Artificial Intelligence (AI). Initially, the GEANT4 simulation software was employed to model the interactions of radiation with the detectors, with the aim of optimizing energy resolution. Concurrently, deep learning was deployed to enhance image quality: a Generative Adversarial Network (GAN) was specifically designed for efficient noise reduction at the sinogram level prior to image reconstruction, while a Residual Channel Attention Network (RCAN) was applied to significantly improve the spatial resolution of the reconstructed images. The results obtained, which surpass the performance of existing methods reported in the literature, demonstrate that this combined approach produces superior quality PET and SPECT images, both in terms of sharpness and quantitative fidelity. These advancements facilitate clinical interpretation and contribute to a more precise, reliable, and reproducible diagnosis.

**Keywords:** Nuclear Medicine, Positron Emission Tomography (PET), Single-Photon Emission Computed Tomography (SPECT), Deep Learning, Generative Adversarial Network (GAN), Simulation, Image Quality.

## ملخص

يُعتبر الطب النووي تخصصًا تصويريًا يتيح دراسة الوظائف الحيوية للأعضاء باستخدام جرعات منخفضة من المقننات المشعة، وأهم طريقتين رئيسيتين مستخدمتين في هذا المجال هما التصوير المقطعي بالانبعاث البوزيتروني والتصوير المقطعي الحاسوبي بالانبعاث الفوتوني الأحادي؛ وعلى الرغم من أن هاتين التقنيتين تساهمان في تقليل تعرض المريض للإشعاع، فإن استخدام جرعات منخفضة من المقننات المشعة يولد بطبيعته مستويات عالية من الضوضاء وتدهورًا في جودة الصورة، مما يجعل الكشف عن الهياكل المرضية الدقيقة صعبًا ويهدد دقة التشخيص. للتغلب على هذا التحدي، تعتمد هذه الأطروحة على مبدأ التآزر بين المحاكاة الفيزيائية والذكاء الاصطناعي، حيث تم في المرحلة الأولى استخدام برنامج لنمذجة تفاعلات الإشعاعات مع الكواشف، بهدف تحسين التمييز الطاقوي. بالتوازي مع ذلك، جرى GEANT4 المحاكاة وتوظيف تقنية التعلم العميق لتحسين جودة الصورة: حيث تم تصميم شبكة توليدية خصامية (وهي نوع من الشبكات قبل عملية إعادة بناء الصورة، بينما طبقت شبكة العصبونية) خصيصًا لتقليل الضوضاء بفعالية على مستوى مخطط الجيب انتباه قنوية متبقية لتحسين كبير في التمييز المكاني للصور المُعاد بناؤها. تُظهر النتائج التي تم التوصل إليها، والتي تتفوق ذات جودة فائقة، سواء من حيث على أداء الأساليب الحالية المذكورة في المراجع، أن هذا النهج المشترك يتيح إنتاج صور الوضوح أو الدقة الكمية، مما يُسهل عملية التفسير السريري ويسهم في تشخيص أكثر دقة، وموثوقية، وقابلية للاستنساخ

### الكلمات المفتاحية :

الطب النووي، التصوير المقطعي بالانبعاث البوزيتروني، التصوير المقطعي الحاسوبي بالانبعاث الفوتوني الأحادي، التعلم العميق، شبكة توليدية خصامية، المحاكاة، جودة الصورة

# Table des Matières

Résumé.....	I
Abstract.....	II
ملخص.....	III
Table de matière.....	IV
Liste des figures.....	IX
Liste des tableaux.....	XII
Liste des acronymes.....	XIII
Introduction générale.....	1

## Chapitre I : Principe de l'imagerie en médecine nucléaire

1. Introduction.....	7
2. Fondements Physiques de l'Imagerie en Médecine Nucléaire .....	8
2.1. Radioactivité .....	8
2.1.1. Principes et Propriétés .....	8
2.1.2. Demi-vie (Période Radioactive) .....	8
2.1.3. Décroissance radioactive .....	8
2.1.4. Activité et Unités .....	9
2.2. Types d'Émissions Radioactives Utilisées en Imagerie .....	9
2.2.1. Emission Gamma ( $\gamma$ ) .....	9
2.2.2. Emission de positrons (Désintégration $\beta^+$ ).....	10
2.3. Interaction des Rayonnements avec la Matière Biologique.....	11
2.3.1. Effet photoélectrique .....	11
2.3.2. Diffusion Compton .....	12
2.3.3. Création de Paires.....	12
2.4. Radiopharmaceutique.....	13
3. Gamma caméra .....	14
3.1. Architecture et Composants de la Gamma-Caméra .....	15
3.1.1. Collimateur .....	15
3.1.1.1. Collimateur à trous d'épingle .....	15
3.1.1.2. Collimateur à réseau de trous parallèles .....	16
3.1.1.3. Collimateur divergent .....	16
3.1.1.4. Collimateur convergent.....	17

3.1.2. Cristal scintillateur .....	18
3.1.3. Guide lumière.....	18
3.1.4. Tube Photomultiplicateur (TPM) .....	19
4. Caméra TEP .....	19
4.1 Architecture et Composants de la caméra TEP .....	20
4.1.1 Cristaux scintillateurs .....	20
4.1.2 Photodétecteurs .....	20
4.1.3 Electronique de coïncidence .....	21
5. Imagerie Tomographique par Émission Monophotonique (TEMP) .....	21
5.1. Principe d'acquisition TEMP .....	21
5.2. Reconstruction d'images TEMP.....	22
6. La Tomographie par Émission de Positrons (TEP) .....	23
6.1 Principe de détection TEP.....	23
6.2. Reconstruction d'images en TEP .....	24
7. Facteurs affectant la qualité d'image en médecine nucléaire.....	24
7.1. Facteurs liés à l'équipement .....	24
7.1.1. Résolution spatiale .....	24
7.1.2. Résolution en énergie .....	25
7.2. Facteurs physiques et physiologiques liés au patient .....	26
7.2.1. Effet de Volume Partiel (EVP) .....	26
7.2.2. Mouvement du patient .....	26
7.3. Facteurs liés aux données brutes et aux algorithmes de reconstruction .....	26
7.3.1. Bruit de comptage .....	26
7.3.2. Types et paramètres des algorithmes de reconstruction .....	27
8. Conclusion.....	27

## **Chapitre II : Fondements théoriques et état de l'art**

1. Introduction.....	30
2. Fondement théorique .....	30
2.1 Bases de la simulation en médecine nucléaire.....	30
2.1.1. Principe Monte Carlo.....	31
2.2 Méthodes de reconstruction traditionnelles .....	32

2.2.1 Méthodes analytiques .....	3.2
A. Transformation de Radon.....	33
B. Rétroprojection filtrée .....	33
C. Avantages et inconvénients .....	34
2.2.2 Méthodes itératives .....	34
A. Principe et fonctionnement .....	34
B. Technique de Reconstruction Algébrique (ART) .....	35
C. Algorithme d'Espérance-Maximisation par Sous-Ensembles Ordonnés (OSEM).....	35
D. Avantages et inconvénients.....	35
2.3 Principe de l'apprentissage profond ou Deep Learning .....	36
2.3.1 Réseaux antagonistes génératifs (GAN) .....	37
A. Fonction de perte du générateur (G-Loss).....	38
B. Fonction de perte du discriminateur (D-Loss).....	38
C. Avantages et pertinence du modèle GAN .....	38
D. Rôle de l'apprentissage profond dans l'amélioration du sinogramme avant la reconstruction par les méthodes traditionnelles .....	39
2.3.2 Réseau Résiduel à Attention de Canal (RCAN).....	40
A. Architecture du RCAN.....	41
B. Rôle du RCAN dans l'optimisation de la résolution spatiale.....	42
3. Etat de l'art .....	42
3.1. Simulation en médecine nucléaire .....	42
3.2. Amélioration de la qualité de l'image en médecine nucléaire .....	44
3.3. Amélioration de la résolution spatiale en médecine nucléaire.....	45
4. Conclusion.....	48

### **Chapitre III : Cadre expérimental et méthodologique**

1. Introduction .....	50
2. Matériels et logiciels .....	50
2.1. Base de données .....	51
2.1.1. Base de données TEP .....	51
2.1.2. Base de données TEMP .....	52

2.2.1. Composants principaux .....	53
2.2.2. Stockage .....	53
2.3. Logiciels de programmation .....	54
2.3.1. GEANT4 .....	54
2.3.2. MATLAB (R2020a) .....	54
2.3.3. PYTHON (SPYDER 5.5.1).....	55
3. Méthodes proposées .....	56
3.1. Simulation de l'interaction des particules avec le détecteur .....	56
A. Configuration de la source et de la physique.....	57
B. Définition du détecteur et des matériaux.....	58
C. Mesure de l'énergie et du signal.....	59
D. Enregistrement et contrôle des données.....	59
3.2. Architecture de la méthode d'amélioration basée sur l'apprentissage profond .....	61
3.2.1 Préparation des données et paramètres .....	63
3.2.2 Modèle générateur .....	63
3.2.3 Modèle discriminateur .....	65
3.2.4. Optimisation .....	65
4. Transfert d'apprentissage .....	66
5. GAN basé sur RCAN pour l'amélioration de la résolution spatiale en imagerie nucléaire.....	67
5.1. Architecture du générateur (RCAN) .....	70
A. Blocs fondamentaux (RCAB et RG).....	70
B. Chemin de reconstruction.....	70
5.2. Architecture du discriminateur .....	71
6. Métriques d'évaluation .....	71
6.1. Rapport Signal/Bruit (PSNR).....	71
6.2. Racine carré de l'Erreur Quadratique Moyenne (RMSE).....	71
6.3. Indice de Similarité Structurale (SSIM).....	72
6.4. Similarité Apprise de Patches d'Image (LPIPS).....	72

6.5. Rapport Contraste sur Bruit (CNR).....	72
6.6. Largeur à Mi-Hauteur (FWHM).....	73
7. Conclusion .....	73

**Chapitre IV : Simulation des systèmes de détection et validation des méthodes de reconstruction**

1. Introduction.....	76
2. Simulation .....	76
2.1 Caméra TEP .....	77
2.1.1. Structure du détecteur.....	77
2.1.2. Modélisation du milieu.....	78
2.1.3. Modélisation de la source radioactive.....	78
2.2 Gamma caméra.....	81
3. Amélioration de la qualité d'image.....	83
3.1. Amélioration du sinogramme avec l'apprentissage profond.....	83
3. Reconstruction d'image.....	85
4. Transfert d'apprentissage .....	95
5. Amélioration de la résolution spatiale de l'image en médecine nucléaire.....	101
6. Conclusion.....	105
Conclusion générale.....	106
Références.....	109

## Liste des figures

<b>Figure I.1</b> : Domaines de prédominance des trois principaux mécanismes d'interaction des rayonnements gamma avec la matière en fonction du numéro atomique $Z$ et de l'énergie $E$ du photon.....	11
<b>Figure I.2</b> : Effet photoélectrique.....	12
<b>Figure I.3</b> : Diffusion Compton.....	12
<b>Figure I.4</b> : Création de paires.....	13
<b>Figure I.5</b> : Gamma caméra.....	14
<b>Figure I.6</b> : Composants de la tête de détection d'une gamma caméra.....	15
<b>Figure I.7</b> : Collimateur à trou d'épingle.....	16
<b>Figure I.8</b> : Collimateur à trous parallèles.....	16
<b>Figure I.9</b> : Collimateur divergent.....	17
<b>Figure I.10</b> : Collimateur convergent.....	18
<b>Figure I.11</b> : Tube photomultiplicateur.....	19
<b>Figure I.12</b> : Caméra TEP.....	20
<b>Figure I.13</b> : Processus de formation des sinogrammes.....	22
<b>Figure I.14</b> : Ligne de réponse.....	24
<b>Figure I.15</b> : Illustration schématique de l'influence de la résolution spatiale sur la localisation d'une source ponctuelle. De gauche à droite : faible, moyenne et haute résolution.....	25
<b>Figure II.1</b> : Illustration d'une projection et d'un sinogramme.....	33
<b>Figure II.2</b> : Positionnement du Deep Learning dans le domaine de l'Intelligence Artificielle.....	36
<b>Figure II.3</b> : Principe du réseau GAN.....	38
<b>Figure II.4</b> : Principe du réseau RCAN.....	41
<b>Figure III.1</b> : Logo du logiciel GEANT4.....	54
<b>Figure III.2</b> : Logo du logiciel MATLAB.....	55
<b>Figure III.3</b> : Logo du logiciel ANACONDA et son éditeur SPYDER.....	55
<b>Figure III.4</b> : Exemple de simulation de photons par un scintillateur modélisé à l'aide de GEANT4.....	56
<b>Figure III.5</b> : Architecture des classes de la simulation.....	57
<b>Figure III.6</b> : Architecture du Gan proposée.....	62
<b>Figure III.7</b> : Architecture du GAN basé sur RCAN proposée.....	68

<b>Figure III.8 :</b> Modèle détaillé du générateur RCAN et discriminateur GAN.....	69
<b>Figure IV.1 :</b> Prototype du détecteur TEP à base de scintillateur NaI simulé avec GEANT4.....	77
<b>Figure IV.2 :</b> Représentation du volume qui délimite le milieu (l'air).....	78
<b>Figure IV.3 :</b> Visualisation du Scintillateur en NaI (en bleu) et de photomultiplicateur (PMT) (en rose) dans le prototype de caméra TEP.....	79
<b>Figure IV.4 :</b> Simulation de 100 évènements.....	79
<b>Figure IV.5 :</b> Distribution 3D des dépôts d'énergie dans le scintillateur TEP.....	80
<b>Figure IV.6 :</b> Distribution du dépôt d'énergie pour les 100 évènements simulés.....	80
<b>Figure IV.7 :</b> Comparaison des différentes géométries de détecteurs de rayonnement (rectangulaire monoblocs, cylindriques et rectangulaire bidétecteurs) pour la simulation de (a) l'Iode131 et (b) du TCm99.....	81
<b>Figure IV.8 :</b> Évolution des fonctions de perte du générateur (a) G-Loss et du discriminateur (b) D-Loss au cours des époques d'entraînement.....	84
<b>Figure IV.9 :</b> Comparaison du sinogramme avant et après application du modèle GAN. (a) Sinogramme initial bruyant (b) Sinogramme amélioré par le GAN.....	85
<b>Figure IV.10 :</b> Images reconstruites à l'aide de l'algorithme hybride de reconstruction TEP intégrant la réduction de bruit par GAN. (a) Méthode GAN-FBP, (b) méthode GAN-ART, (c) méthode GAN-OSEM.....	86
<b>Figure IV.11 :</b> Comparaison d'images TEP reconstruites par OSEM, (a) sans traitement préliminaire par GAN et (b) après amélioration du sinogramme par le modèle GAN proposé.....	86
<b>Figure IV.12 :</b> Résultat quantitative des performances de reconstruction sur 12 000 images avec OSEM standard (a) Évolution du PSNR, (b) évolution du RMSE par rapport à l'image de référence.....	87
<b>Figure IV.13 :</b> Résultat quantitative des performances de reconstruction sur 12 000 images avec la méthode proposée (GAN-OSEM) (a) Évolution du PSNR et (b) évolution du RMSE par rapport à l'image de référence.....	88
<b>Figure IV.14 :</b> Images reconstruites par OSEM à partir de sinogrammes améliorés à l'aide de différents modèles : (a) SSSR, (b) FBSEM, (c) DeepPET, (d) modèle proposé.....	90
<b>Figure IV.15 :</b> Agrandissements mettant en évidence la qualité de reconstruction locale : (a) SSSR, (b) FBSEM, (c) DeepPET, (d) Modèle proposé.....	92

<b>Figure IV.16 :</b> Comparaison des performances moyennes des quatre méthodes — SSSR, FBSEM, DeepPET et modèle proposé — sur l’ensemble de la base de données test, selon trois métriques de qualité : (a) PSNR, (b) RMSE, (c) SSIM.....	93
<b>Figure IV.17 :</b> Résultats du transfert d’apprentissage appliqué à la base de données TEMP. (a) l’image originale, (b) l’image reconstruite en niveau de gris et (c) l’image reconstruite en couleurs.....	97
<b>Figure IV.18 :</b> Comparaison visuelle des sinogrammes TEMP (a) Avant et (b) Après Amélioration par Transfert d'Apprentissage.....	98
<b>Figure IV.19 :</b> Représentations des métriques d’évaluation sur l’ensemble des données TEMP.....	100
<b>Figure IV.20 :</b> Profil d'intensité de ligne horizontale des données LR originale et données améliorées HR.....	101
<b>Figure IV.21 :</b> Courbes de perte du (a) générateur et du (b) discriminateur du modèle proposé pour l’amélioration de la résolution spatiale en fonction du nombre d’époques.....	102
<b>Figure IV.22 :</b> Valeurs des différentes métriques enregistrés. (a) PSNR, (b) MSE, (c) SSIM, (d) CNR, (e) LPIPS, (f) FWHM.....	103

## Liste des tableaux

<b>Tableau I.1</b> : Radiopharmaceutiques utilisés en TEMP et en TEP.....	13
<b>Tableau III.1</b> : Composants principaux de la station de calculs.....	53
<b>Tableau III.2</b> : Performances des disques de la station de calculs.....	53
<b>Tableau III.3</b> : Description des couches composant le modèle générateur.....	64
<b>Tableau III.4</b> : Description des différentes couches du modèle du discriminateur.....	65
<b>Tableau III.5</b> : Description des composants de modèle GAN basé sur RCAN.....	69
<b>Tableau IV.1</b> : Analyse comparative de l'efficacité du dépôt d'énergie (Edep) dans les scintillateurs NaI en fonction de la géométrie et du radiotraceur.....	82
<b>Tableau IV.2</b> : Valeurs de PSNR, RMSE et SSIM des images reconstruites à partir des sinogrammes traités par les quatre modèles : SSSR, FBSEM, DeepPET et modèle proposé.....	89
<b>Tableau IV.3</b> : Valeurs de PSNR, RMSE et SSIM des 8 coupes.....	99
<b>Tableau IV.4</b> : Évaluation comparative entre l'image originale (basse résolution) et image (haute résolution) améliorée par GAN basé sur RCAN.....	102

## Liste des acronymes

**TEP** : Tomographie par Émission de Positrons.  
**TEMP** : Tomographique par Émission MonoPhotonique.  
**Bq** : Becquerel.  
**Ec** : Energie Cinétique.  
**Eliaison** : Energie de Liaison.  
**TPM** : Tubes Photomultiplicateurs.  
**NaI(Tl)** : Iodure de sodium dopé au Thallium.  
**Tc** : Technitium.  
**BGO** : Germanate de Bismuth.  
**LSO** : Orthosilicate de Lutétium.  
**LYSO** : Orthosilicate d'Yttrium et de Lutétium.  
**SiPM** : Photodétecteurs au Silicium.  
**IRM** : Imagerie par Résonance Magnétique.  
**LOR** : Ligne de Réponse.  
**SBP** : RétroProjection Simple.  
**FBP** : RétroProjection Filtrée.  
**ART** : Algebraic Reconstruction Technique.  
**SART** : Simultaneous Algebraic Reconstruction Technique.  
**OSEM** : Ordered Subsets Expectation Maximization.  
**PET** : Positron Emission Tomography.  
**SPECT** : Single-Photon Emission Computed Tomography.  
**EVP** : Effet de Volume Partiel.  
**SNR** : Rapport Signal/Bruit.  
**GEANT4** : GEometry ANd Tracking.  
**GATE** : GEANT4 Application for Tomographic Emission.  
**MCNP** : Monte Carlo N-Particle.  
**PENELOPE** : PENetration and Energy LOss of Positrons and Electrons.  
**SIMIND** : SIMulation of INDium.  
**DL** : Deep Learning.  
**ML** : Machine Learning.  
**IA** : Intelligence Artificielle.

**CNN** : Convolutional Neural Network.  
**RNN** : Recurrent Neural Network.  
**LSTM** : Long Short-Term Memory.  
**GAN** : Generative Adversarial Network.  
**RCAN** : Residual Channel Attention Network.  
**D-Loss** : Discriminator Loss.  
**G-Loss** : Generator Loss.  
**Lcont** : Content Loss.  
**RG** : Groupe Résiduel.  
**RCABs** : Blocs d'Attention par Canaux Résiduels.  
**CA** : Module d'Attention par Canaux.  
**SSL** : Self-Supervised Learning.  
**SSSR** : Single-Scan Super Resolution.  
**FBSEM** : Filtered Back-Projection with Statistical Estimation Model.  
**CNR** : Contrast-to-Noise Ratio.  
**NRMSE** : Normalized Root Mean Square Error.  
**SISR** : Super-Résolution d'Image Unique.  
**DNN** : Deep Neural Network.  
**CSAB** : Bloc d'Auto-Attention Convolutionnel.  
**EDSR** : Enhanced Deep Super Resolution.  
**VDSR** : Very Deep Super Resolution.  
**HR** : High Resolution.  
**BR** : Basse résolution.  
**SR** : Super Resolution.  
**HRRT** : High Resolution Research Tomograph.  
**DICOM** : Digital Imaging and Communications in Medicine.  
**IDA** : Image and Data Archive.  
**I** : Iode.  
**CPU** : Central Processing Unit.  
**RAM** : Random Access Memory.  
**GPU** : Graphics Processing Unit.  
**HDD** : Hard Disk Drive.  
**SSD** : Solid State Drive.

**CERN** : Conseil Européen pour la Recherche Nucléaire.

**IDE** : Integrated Development Environment.

**QE** : Quantum Efficiency.

**ReLU** : Rectified Linear Unit.

**PReLU** : Parametric Rectified Linear Unit.

**LBCE** : Binary Cross-Entropy Loss.

**ROIs** : Regions Of Interest.

# Introduction générale

## 1. Contexte générale

Depuis l'avènement de la première image par rayons X réalisée par Roentgen en 1895, l'imagerie médicale a inauguré une ère nouvelle dans le domaine des diagnostics médicaux en offrant la possibilité d'explorer l'anatomie interne du corps humain de manière non invasive. Cette avancée a ouvert la voie au développement de technologies innovantes permettant une visualisation améliorée en deux et trois dimensions de l'intérieur du corps humain. Les techniques d'imagerie les plus avancées actuelles englobent les rayons X, la TomoDensitoMétrie (TDM), la Tomographie par Emission de Positrons (TEP), la Tomographie par Emission MonoPhotonique (TEMP), les ultrasons et l'Imagerie par Résonance Magnétique (IRM). Chacune de ces modalités présente sa propre spécificité, cependant elles permettent toutes d'obtenir des images du corps humain avec une précision exceptionnelle, ce qui facilite l'établissement de diagnostics rapides et fiables et contribuent à accroître la précision de la détection des anomalies [1,2].

Des systèmes de diagnostic assisté par ordinateur ont été développés, efficaces pour détecter les maladies, facilitant ainsi leur détection précoce. De plus, divers auteurs ont exploré l'intégration des approches de traitement personnalisées et de la médecine de précision, permettant l'élaboration de plans de traitement adaptés aux caractéristiques et aux besoins individuels des patients [3].

## 2. Problématique

Les images en médecine nucléaire sont connues pour leur qualité intrinsèque souvent médiocre, due principalement à la faible dose de radiotracteur injectée pour des raisons de radioprotection, ce qui entraîne un fort bruit statistique. De plus, l'insuffisance de données ou le flou spatial peuvent rendre certaines petites régions d'intérêt indétectables. Ces limitations rendent fréquemment nécessaire un examen complémentaire afin d'aider le médecin à localiser précisément la pathologie et à poser un diagnostic fiable. Ce processus peut s'avérer long et retarder le début du traitement du patient. Ces facteurs combinés compliquent l'interprétation des images et peuvent, dans certains cas, conduire à un faux diagnostic.

## 3. Objectifs et motivations

Les images en médecine nucléaire jouent un rôle central dans le diagnostic et le suivi des pathologies, mais leur interprétation reste confrontée à des limitations intrinsèques liées à la

physique de l'acquisition. Le faible flux de comptage imposé par les contraintes de radioprotection entraîne un bruit élevé, une résolution spatiale limitée et des artefacts pouvant compromettre la visibilité des petites régions d'intérêt. Ces facteurs augmentent la difficulté d'analyse, même pour des praticiens expérimentés, et peuvent conduire à des diagnostics retardés ou erronés, avec des conséquences directes sur la prise en charge du patient [4,5].

Dans ce contexte, l'amélioration de la qualité des images reconstruites constitue un enjeu majeur, tant sur le plan technique que clinique. L'objectif de cette thèse est donc d'étudier et d'optimiser les différents facteurs affectant la qualité d'image en médecine nucléaire, notamment les artefacts, la résolution spatiale et le bruit lié aux conditions d'acquisition. Nous proposons pour cela une approche fondée sur l'apprentissage profond, appliquée en amont de la reconstruction, afin de restaurer les données en forme de sinogramme et d'enrichir l'information avant sa transformation en image.

Cette démarche vise à produire des images de meilleure qualité, plus fidèles anatomiquement et mieux adaptées à l'analyse visuelle comme quantitative. La validation de nos méthodes s'appuie ainsi sur une évaluation combinée, à la fois quantitative et qualitative, afin de permettre une comparaison rigoureuse avec les approches classiques et celles de l'état de l'art. L'objectif final est de contribuer à une interprétation plus fiable, rapide et précise des examens, en particulier dans les cas complexes où les signes de pathologie sont subtils ou peu contrastés.

#### **4. Contribution**

Les travaux présentés dans cette thèse s'appuient sur l'analyse critique des limites de l'état de l'art pour proposer plusieurs contributions originales dans le domaine de la reconstruction et de l'optimisation des images en médecine nucléaire. Ces apports se déploient selon trois axes complémentaires : la modélisation physique du système d'acquisition, l'amélioration des données par apprentissage profond, et l'évaluation rigoureuse des performances.

##### **Modélisation physique et simulation du système d'imagerie**

- Une simulation détaillée de composants clés de la gamma caméra et de la caméra TEP a été réalisée à l'aide d'un logiciel basé sur les lois fondamentales de la physique, permettant d'étudier finement leur réponse impulsionnelle et d'identifier des pistes d'optimisation pour améliorer la résolution en énergie.
- Une étude approfondie des interactions entre un scintillateur de type NaI(Tl) et des particules de masses et d'énergies différentes a été menée, offrant une meilleure

compréhension du comportement du détecteur selon le radiotracteur utilisé (notamment  $^{99m}\text{Tc}$  et  $^{123}\text{I}$ ).

### **Amélioration des données et reconstruction avancée**

- Nous avons proposé une stratégie d'amélioration des sinogrammes basée sur les Réseaux Antagonistes Génératifs (GAN), appliquée en amont de la reconstruction, afin de restaurer l'information perdue et de réduire le bruit sans altérer les structures pertinentes.
- Le modèle GAN basé sur RCAN, intégrant un générateur de type Residual Channel Attention Network (RCAN), a été développé et appliqué pour améliorer significativement la résolution spatiale des images reconstruites, tout en préservant les détails fins et en contrôlant la texture du bruit.
- Afin de surmonter la difficulté liée à la disponibilité limitée des données cliniques, une approche par transfert d'apprentissage a été mise en œuvre : un modèle pré-entraîné sur un jeu de données a été adapté efficacement à une petite base de données, permettant un gain substantiel en temps d'entraînement et une performance élevée en reconstruction.

### **Évaluation comparative et validation**

- Une comparaison systématique a été menée entre les méthodes classiques de reconstruction (FBP, ART et OSEM) et celles intégrant l'apprentissage profond, mettant en évidence les avantages de notre approche en termes de qualité visuelle et de stabilité.
- L'évaluation quantitative de notre modèle repose sur un ensemble complet de métriques reconnues : PSNR, RMSE, SSIM, CNR, LPIPS, ainsi que la mesure de la FWHM comme indicateur direct de la résolution spatiale.

En combinant ces différents apports, cette thèse propose une démarche globale et innovante, alliant rigueur physique, avancées algorithmiques et adaptation aux contraintes cliniques réelles. Les résultats obtenus dépassent ceux de l'état de l'art, notamment en imagerie TEP et TEMP, tant sur le plan de la qualité d'image que sur celui de la robustesse aux faibles statistiques.

## **5. Plan de thèse**

Cette thèse de doctorat est divisée en quatre chapitres :

## **Chapitre 1 : Principe de l'imagerie en médecine nucléaire**

Une introduction au domaine de la médecine nucléaire et à l'imagerie tomographique est présentée dans ce chapitre décrivant ainsi le processus détaillé de la formation de l'image à partir de donnée brute.

Ce chapitre est consacré à la présentation des fondements physiques de l'imagerie en médecine nucléaire ainsi que les types d'émission radioactives et d'interactions des rayonnements avec la matière. Une partie de ce chapitre est dédié à l'architecture de la gamma caméra, la caméra TEP et la présentation de leurs différents composants, ainsi que la description des deux principaux types de l'imagerie tomographique : la Tomographique par Emission MonoPhotonique (TEMP) et la Tomographique par Emission de Positrons (TEP). Et enfin, les paramètres et facteurs qui influent sur la qualité des images en médecine nucléaire.

## **Chapitre 2 : Fondements théoriques et état de l'art**

Plusieurs méthodes de reconstruction existent et sont divisées en deux catégories, les méthodes analytiques qui s'appuient sur des transformées mathématique telles que la transformée de Fourier ou de Radon et l'autre catégorie, les méthodes itératives, se basent sur un processus répétitif où une estimation initiale de l'image est progressivement affinée, ce chapitre présente en détails ces méthodes de reconstruction classiques ainsi que les méthodes d'apprentissage profond et de simulation adoptée dans l'étude et l'amélioration de la résolution spatiale, la résolution en énergie et la qualité de l'image.

Ce chapitre comprendra également une revue de littérature concernant la simulation et l'amélioration de la qualité d'image en médecine nucléaire.

## **Chapitre 3 : Cadre expérimental et méthodologique**

Ce chapitre présente le cadre expérimental et méthodologique mis en œuvre dans cette thèse. Il détaille les outils, les données et les approches utilisées pour mener à bien les différentes étapes de notre travail, depuis la simulation du système d'acquisition jusqu'à la reconstruction et l'évaluation des images. Nous commençons par décrire la structure du code de simulation utilisé, incluant la configuration du modèle, la définition des classes principales, ainsi que les mécanismes d'enregistrement et de contrôle des données. Cette simulation permet de modéliser fidèlement le fonctionnement d'une gamma caméra et d'un dispositif TEP, en prenant en compte les interactions physiques dans le scintillateur. Ensuite, nous présentons les bases de données employées, en précisant leurs caractéristiques et leur rôle dans l'entraînement et l'évaluation des modèles. Nous présentons par la suite les méthodes de

reconstruction mises en œuvre, avec un focus sur les approches hybrides intégrant l'intelligence artificielle dans des pipelines classiques. Pour chacune, une description détaillée des algorithmes, des architectures neuronales et des étapes de traitement est fournie, afin de clarifier leur fonctionnement et leur contribution respective à l'amélioration de la qualité d'image.

Ce travail a été réalisé à l'aide d'une station de calculs soigneusement choisie pour favoriser le temps de reconstruction d'images et la rapidité du calcul de nos programmes utilisés.

#### **Chapitre 4 : Simulation des systèmes de détection et validation des méthodes de reconstruction**

Ce chapitre présente et analyse les résultats obtenus dans cette thèse, tant sur le plan qualitatif que quantitatif. Il est structuré autour de trois axes principaux correspondant aux contributions méthodologiques développées :

- (1) Les performances de la simulation du système d'acquisition, notamment en termes de modélisation de la réponse et de résolution en énergie ;
- (2) L'évaluation de l'amélioration de la qualité des images médicales, incluant la réduction du bruit, le contraste et la netteté visuelle ;
- (3) Les gains en résolution spatiale atteints grâce aux approches hybrides basées sur l'apprentissage profond, notamment le modèle GAN basé sur RCAN.

Pour chaque axe, les résultats sont confrontés aux méthodes classiques et à l'état de l'art, permettant une discussion approfondie sur les avantages, les limites et l'impact clinique potentiel des solutions proposées.

Cette thèse se terminera par une conclusion générale et des perspectives dans le domaine d'étude et d'amélioration de la qualité d'image en médecine nucléaire.

# **Chapitre I : Principe de l'imagerie en médecine nucléaire**

## 1. Introduction

L'imagerie fonctionnelle a révolutionné le diagnostic médical en offrant des informations fondamentales sur le fonctionnement des organes et des tissus du corps humain, elle complète l'imagerie anatomique comme la tomodensitométrie ou l'imagerie par résonance magnétique qui visualise la partie structurelle du corps humain. L'imagerie fonctionnelle apporte un plus dans la détection précoce des maladies notamment les maladies cardiaques, cancers et maladies neurologiques dégénératives qui se manifestent par des changements fonctionnels précédant les altérations structurelles, elle permet également de faire la caractérisation et la différenciation des lésions en déterminant la nature d'une anomalie détectée par l'imagerie anatomique. L'imagerie fonctionnelle peut ainsi évaluer l'étendue des maladies et faire l'évaluation de la réponse au traitement et de la viabilité tissulaire, la planification thérapeutique et la compréhension des mécanismes physiopathologiques [6-8].

Cette modalité d'imagerie médicale se distingue par l'utilisation de radiopharmaceutiques, des substances injectables dans le corps humain dont le but est d'explorer un processus biologique spécifique. La fixation du radiopharmaceutique dans l'organe ciblé permet d'émettre des rayonnements détectables par des équipements spécialisés tels que la gamma caméra et la caméra TEP, ces signaux seront transformés en images qui représente la distribution des radiopharmaceutiques dans l'organe ciblé afin de déterminer son activité ou sa fonction, offrant ainsi des informations complémentaires indispensables aux autres modalités d'imagerie [9-11].

Le but de ce chapitre est de décrire les fondements physiques et technologiques de l'imagerie en médecine nucléaire. Nous commencerons par examiner les principes communs régissant l'utilisation des radiopharmaceutiques et leurs détectations. Nous aborderons ensuite, en détails, l'architecture et le fonctionnement des équipements clés : d'abord la gamma-caméra, puis la caméra TEP. Une fois ces technologies établies, nous présenterons leurs applications cliniques : l'imagerie Tomographique par Émission MonoPhotonique (TEMP), qui offre une vision tridimensionnelle, puis la Tomographie par Émission de Positrons (TEP), une technique ponctuelle qui a largement dépassé les limites fonctionnelles de la précision de l'image grâce à ses principes de détection de coïncidence. Enfin, nous présenterons l'ensemble des facteurs qui influent sur la qualité de l'image en médecine nucléaire qui peuvent être liés à l'équipement comme la résolution spatiale et la résolution en énergie, aux patients comme l'effet de volume partiel et les mouvements lors de l'acquisition, et finalement aux données brutes et aux algorithmes de reconstruction d'images tels que le bruit du comptage et les différents types et paramètres d'algorithmes de reconstruction en médecine nucléaire.

## 2. Fondements physiques de l'imagerie en médecine nucléaire

Afin de saisir le fonctionnement des différentes modalités d'imagerie en médecine nucléaire, il est important de comprendre les principes physiques fondamentaux qui permettent la visualisation des processus biologiques, depuis l'acquisition du signal jusqu'à l'obtention de l'image finale.

Dans cette partie, nous étudions les lois nucléaires régissant la désintégration des isotopes et les interactions des rayonnements avec la matière, dans le but de comprendre les phénomènes permettant de cartographier l'activité radioactive au sein du corps humain. Nous présentons les principes de la radioactivité, les types d'émissions utilisés en imagerie médicale, ainsi que les mécanismes d'interaction de ces rayonnements avec les tissus biologiques et les détecteurs.

### 2.1. Radioactivité

La radioactivité est un phénomène physique naturel correspondant à l'émission spontanée de rayonnements par des noyaux atomiques instables, qui se transforment en noyaux plus stables au cours d'un processus appelé désintégration. Ce phénomène trouve des applications dans de nombreux domaines scientifiques et technologiques, notamment en médecine, en énergie nucléaire, en industrie, en archéologie et en recherche fondamentale [12,13].

#### 2.1.1. Principes et propriétés

Au moment de la désintégration, le noyau parent, instable, se transforme en un noyau fils de stabilité accrue, cette transformation cause un changement dans le nombre de protons et de neutrons, l'excès d'énergie du noyau parent est libéré sous forme de rayonnements ionisants.

La radioactivité est caractérisée par une demi-vie et relative à la décroissance radioactive.

#### 2.1.2. Demi-vie (Période radioactive)

La durée au bout de laquelle la moitié des noyaux radioactifs seront désintégrés est appelée une demi-vie [14], c'est une caractéristique constante et propre à chaque isotope qui ne peut pas être modifié par aucun moyen physique, chimique ou biologique [15].

#### 2.1.3. Décroissance radioactive

La décroissance radioactive est un processus exponentiel qui dépend de la demi-vie, cela signifie que la vitesse à laquelle les noyaux se désintègrent est proportionnelle au nombre de noyaux radioactifs présents à un instant donné, elle est exprimée par la formule suivante [16] :

$$N(t) = N_0 e^{-\lambda t} \quad (I.1)$$

Où :

- $N(t)$  est le nombre de noyaux radioactifs restant au temps  $t$ .
- $N_0$  est le nombre initial de noyaux radioactifs.
- $\lambda$  est la constante de désintégration (liée à la demi-vie).

La demi-vie est directement liée à la constante de désintégration par la relation :  $T_{1/2} = \frac{\ln(2)}{\lambda} \approx \frac{0.693}{\lambda}$ .

#### 2.1.4. Activité et unité

L'activité est directement proportionnelle au nombre de noyaux radioactifs présents et à la constante de désintégration ( $\lambda$ ) de l'isotope (qui est inversement liée à la demi-vie). L'activité représente la quantité de la radioactivité présente dans une substance. Mathématiquement, elle est exprimée par la relation :

$$A = \lambda \cdot N \quad (I.2)$$

Où  $N$  est le nombre de noyaux radioactifs.

L'unité de l'activité radioactive d'une substance est le Becquerel (Bq) [17], une Becquerel est définie comme une désintégration par seconde.

L'activité en médecine nucléaire est cruciale pour la détermination de la quantité du radiopharmaceutique à administrer au patient afin d'obtenir des images de bonne qualité tout en respectant les limites de dose de rayonnement.

## 2.2. Types d'émissions radioactives utilisées en imagerie

La pertinence clinique de l'imagerie en médecine nucléaire dépend d'une manière directe du choix de type des rayonnements émis par le nucléide pour déterminer la méthode de détection utilisée, son énergie pour garantir la bonne pénétration à travers les tissus du corps humain pour assurer une bonne acquisition par les détecteurs et enfin sa demi-vie en faisant un compromis entre une durée suffisamment longue pour correspondre à la durée de l'acquisition de l'image, mais aussi suffisamment courte pour être rapidement éliminer du corps humain après la fin de l'examen.

Les deux types d'émissions fondamentales dans l'imagerie sont l'émission gamma et l'émission de positrons.

### 2.2.1. Emission gamma ( $\gamma$ )

L'émission gamma ( $\gamma$ ) est un processus de désintégration radioactive au cours duquel un noyau atomique, après une transformation  $\alpha$  ou  $\beta$ , se trouve dans un état énergétique excité. Pour atteindre un état fondamental plus stable, il libère un quantum d'énergie sous forme de

photon gamma (un rayonnement électromagnétique de très haute fréquence et de courte longueur d'onde). Contrairement aux particules  $\alpha$  ou  $\beta$ , l'émission  $\gamma$  n'entraîne ni changement de numéro atomique ni de masse nucléaire ; elle correspond uniquement à une désexcitation du noyau.

Ce type de rayonnement est exploité en imagerie médicale, notamment en TEMP. Dans cette technique, un radiotracer émettant des photons gamma est administré au patient. Ces derniers traversent les tissus biologiques avec une atténuation relativement faible, en raison de leur grande capacité de pénétration, et sont détectés par une gamma caméra. La reconstruction spatiale de la distribution de ces photons permet de former une image reflétant l'activité métabolique ou fonctionnelle des organes ciblés [18].

Les photons gamma sont caractérisés par une énergie discrète et spécifique à chaque isotope radioactif, ce qui facilite leur identification et leur collimation, assurant ainsi une bonne spécificité en imagerie.

### **2.2.2. Emission de positrons (Désintégration $\beta^+$ )**

La désintégration  $\beta^+$ , ou émission de positrons, se produit dans les noyaux instables présentant un excès de protons par rapport au nombre optimal assurant la stabilité nucléaire. Afin de rétablir un équilibre entre protons et neutrons, un proton du noyau se transforme en neutron. Cette transformation s'accompagne de la libération d'énergie cinétique partagée entre les particules émises.

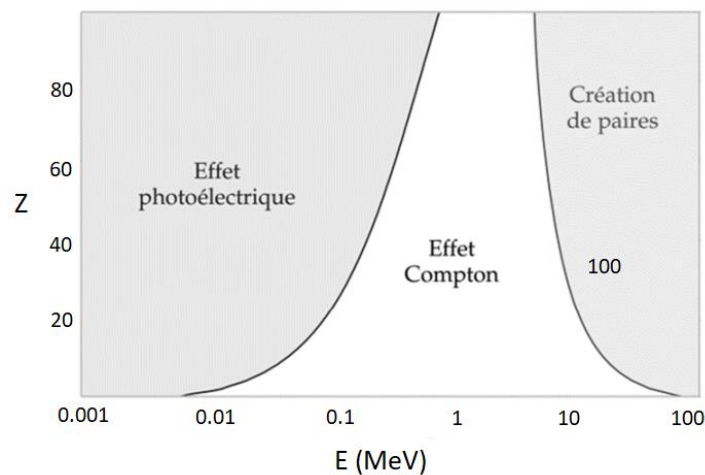
Le positron émis interagit rapidement avec la matière environnante : après avoir perdu une partie de son énergie par ionisation et excitation des atomes, il finit par rencontrer un électron. L'interaction entre ces deux particules (de masses égales mais de charges opposées) donne lieu à un phénomène appelé annihilation, au cours duquel leurs masses sont converties en énergie selon la relation d'Einstein  $E=mc^2$ . Ce processus génère deux photons gamma d'énergie 511 keV chacun, émis en sens opposés (environ  $180^\circ$ ), afin de conserver à la fois l'énergie et la quantité de mouvement.

Ce mécanisme fondamental constitue la base physique de la TEP. En effet, la détection coïncidente des deux photons gamma permet de localiser précisément la ligne d'origine de l'annihilation, ce qui rend possible la reconstruction tridimensionnelle de la distribution du radiotracer dans le corps.

### 2.3. Interaction des rayonnements avec la matière biologique

Lorsqu'un photon gamma traverse la matière biologique, il peut interagir avec les atomes selon trois principaux processus physiques : l'effet photoélectrique, la diffusion Compton et la création des paires.

La figure I.1 illustre les trois principaux mécanismes d'interaction des rayonnements gamma avec la matière en fonction du numéro atomique  $Z$  du milieu traversé et de l'énergie  $E$  du photon incident. Ces interactions sont décrites en détail dans la partie suivante [19].



**Figure I.1** : Domaines de prédominance des trois principaux mécanismes d'interaction des rayonnements gamma avec la matière en fonction du numéro atomique  $Z$  et de l'énergie  $E$  du photon.

#### 2.3.1. Effet photoélectrique


L'effet photoélectrique est une interaction fondamentale au cours de laquelle un photon incident est entièrement absorbé par un atome du milieu. Lors de cette interaction, le photon disparaît et transfère l'intégralité de son énergie à un électron situé dans l'une des couches internes de l'atome [20].

Si l'énergie ainsi transférée est supérieure à l'énergie de liaison de cet électron à son orbitale atomique, l'électron est alors éjecté de l'atome. Cet électron éjecté, appelé photoélectron, possède une énergie cinétique ( $E_c$ ) qui est égale à la différence entre l'énergie ( $E_\gamma$ ) du photon incident et l'énergie de liaison ( $E_{liaison}$ ) de l'électron à son orbitale :

$$E_c = E_\gamma - E_{liaison} \quad (I.3)$$

Ce phénomène est crucial en imagerie nucléaire, car c'est l'interaction principale recherchée dans les détecteurs (cristaux scintillateurs) pour la conversion de l'énergie des photons en un signal mesurable, garantissant ainsi une mesure précise de l'énergie du photon.

La figure I.2 résume le principe de l'effet photoélectrique [21].




**Figure I.2 :** Effet photoélectrique.

### 2.3.2. Diffusion Compton

Contrairement à l'effet photoélectrique où la totalité de l'énergie du photon est absorbée, la diffusion Compton implique un transfert partiel de l'énergie. Le photon incident cède une partie de son énergie à un électron des couches périphériques, c'est un processus de collision entre photon et électron.

Avec cette énergie reçue, l'électron est rejeté de son atome en devenant un électron Compton ce qui cause une déviation (diffusion) de la trajectoire du photon par un angle qui varie de 0 degrés (pas de perte d'énergie) à 180 degrés (perte maximale de l'énergie).

La figure I.3 résume le principe du phénomène de la diffusion Compton.



**Figure I.3 :** Diffusion Compton.

### 2.3.3. Création de paires

La création de paires se produit lorsqu'un photon de très haute énergie (un rayon gamma) s'approche du champ électrique puissant émanant d'un noyau atomique. Dans ce cas, l'énergie

du photon se transforme en masse, entraînant la création d'une paire électron-positron. Le positron créé se comporte comme tout autre positron émis par désintégration bêta plus. Il parcourt une courte distance, perd son énergie cinétique, puis s'annihile avec un électron du milieu, produisant deux photons gamma de 511 keV émis à 180° l'un de l'autre.

La figure I.4 illustre schématiquement ce processus.




Figure I.4 : Création de paires.

## 2.4. Radiopharmaceutiques

Les radiopharmaceutiques sont des substances pharmaceutiques qui contiennent des radionucléides, administré au patient afin de visualiser un processus biologique pour le diagnostic ou le traitement de plusieurs maladies [22].

Le radionucléide est la partie radioactive du radiopharmaceutique, celle qui permet d'émettre les rayonnements captés par l'appareil d'imagerie. Le choix du radionucléide dépend de l'objectif de l'examen (diagnostic ou thérapie) [23].

Le tableau I.1 présente les caractéristiques des principaux radiopharmaceutiques utilisés en diagnostic médical.

Tableau I.1 : Radiopharmaceutiques utilisés en TEMP et en TEP.

Type	Radionucléide	Demi-vie	Radiation	Application
Emission gamma	Gallium-67	3.26j	$\gamma$	Imagerie TEMP
	Technetium-99m	6h	$\gamma$	Imagerie TEMP
	Indium-111	2.80 j	$\gamma$	Imagerie TEMP
	Iodine-123	13.22h	$\gamma$	Imagerie TEMP
Emission de positron	Carbon-11	20.36m	$\beta^+$	Imagerie TEP
	Nitrogen-13	9.97m	$\beta^+$	Imagerie TEP
	Oxygen-15	2.13m	$\beta^+$	Imagerie TEP
	Fluorine-18	109.77m	$\beta^+$	Imagerie TEP
	Copper-61	3.34h	$\beta^+$	Imagerie TEP
	Copper-64	12.70h	$\beta^+$	Imagerie TEP
	Gallium-66	9.49m	$\beta^+$	Imagerie TEP

	Gallium-68	67.71m	$\beta +$	Imagerie TEP
	Rubidium-82	1.26m	$\beta +$	Imagerie TEP
	Zirconium-89	78.41h	$\beta +$	Imagerie TEP
	Iodine-124	4.17j	$\beta +$	Imagerie TEP

La gamma caméra, utilisée en TEMP, et le système TEP, destiné à la tomographie par émission de positrons, reposent sur des principes de détection fondamentalement différents, ce qui se traduit par des architectures et des composants spécifiques à chaque modalité. Ces différences s'expliquent principalement par la nature des rayonnements détectés et par la méthode de localisation spatiale des événements radiologiques.

### 3. Gamma caméra


La gamma caméra, ou la caméra d'Anger (du nom de son inventeur, Hal Anger, en 1957), est un dispositif d'imagerie nucléaire utilisé en TEMP pour visualiser la distribution spatiale d'un radiopharmaceutique émetteur gamma dans le corps du patient. En détectant les photons gamma émis, elle permet de reconstruire des images fonctionnelles de l'activité biologique. La figure I.5 représente une gamma caméra avec ses deux têtes mise face à face de forme plate et rectangulaire.



**Figure I.5 :** Gamma caméra.

La caméra gamma, ainsi que les scanners TEP, constitue un palier des technologies d'imagerie en médecine nucléaire [24-26], elle se compose principalement d'un collimateur (de type trou d'épingle, à trous parallèles, divergent ou convergent), d'un milieu de conversion (scintillateur ou semi-conducteur), de Tubes Photomultiplicateurs (TPM) ou de réseaux de détecteurs semi-conducteurs, et d'un mécanisme de lecture. Ces composants sont décrits en détails dans la section suivante.

La figure I.6 illustre l'architecture de la tête de détection de la gamma caméra.



**Figure I.6 :** Composants de la tête de détection d'une gamma caméra.

### 3.1. Architecture et composants de la gamma caméra

La gamma caméra se compose de trois éléments principaux, le collimateur, le composant le plus important pour la détection des photons, le cristal scintillateur qui a pour rôle la conversion des photons gamma en photons lumineux, et le tube photomultiplicateur.


#### 3.1.1. Collimateur

Le collimateur est le premier élément que rencontre les photons gamma émis par le corps humain, il agit comme un filtre optique dans sa sélection des photons, il garde les photons perpendiculairement reçus et élimine ceux qui sont obliques ou diffuse. Il est composé généralement de plomb ou de tungstène (matériaux lourds). Il existe plusieurs types de collimateurs, des collimateurs à trous d'épingle, des collimateurs à réseau de trous parallèles et des collimateurs convergents ou divergents.

##### 3.1.1.1. Collimateur à trou d'épingle

Le collimateur à trou d'épingle est un type de collimateurs conçu pour les applications qui nécessitent une très haute résolution spatiale. Il ne possède qu'un seul petit trou par lequel passent les photons gamma émis par le corps du patient. La taille de cette petite ouverture varie entre 0.5mm et quelques millimètres, permettant ainsi de visualiser de petit organes ou zones d'intérêt avec une très haute résolution mais une sensibilité réduite ce qui nécessite un temps d'acquisition plus longs [27,28].


La figure I.7 illustre l'architecture d'un collimateur à trou d'épingle.



**Figure I.7 :** Collimateur à trou d'épingle.

### 3.1.1.2. Collimateur à réseau de trous parallèles

C'est le type de collimateurs le plus répandu dans les gammacaméras, il se compose d'une plaque métallique de plomb ou de tungstène orientée perpendiculairement à la surface du cristal détecteur, percé d'une série de nombreux canaux parallèles de petite taille. Une illustration de ce type de collimateur est donnée à la figure I.8.



**Figure I.8 :** Collimateur à trous parallèles.


Ces collimateurs offrent une résolution spatiale (capacité à distinguer les détails fins) et une sensibilité (nombre de photons détectés) relativement uniforme [29].

### 3.1.1.3. Collimateur divergent

Les collimateurs divergents ont été conçus pour permettre à la gammacaméra d'imager un champ de détection plus large que la surface du cristal détecteur, c'est un type de collimateur

moins fréquemment utilisé, en raison de ses limitations en termes de résolution spatiale et de sensibilité.

Comme illustré à la figure I.9, les canaux du collimateur sont orientés de manière divergente par rapport au plan du détecteur. Cette géométrie fait que les photons provenant d'un objet de grande taille sont dirigés vers le cristal selon un angle convergent, produisant une image réduite par rapport aux dimensions réelles de l'objet.



**Figure I.9 :** Collimateur divergent.

Ce principe permet effectivement d'acquérir des images d'organes dont l'étendue dépasse celle du détecteur. Toutefois, cette possibilité s'accompagne de deux inconvénients majeurs :


- Une dégradation de la résolution spatiale : due à l'élargissement apparent des canaux avec la distance, ce qui réduit la précision de localisation des événements.
- Une faible sensibilité : plus le champ de vue est élargi, plus la fraction de photons pouvant traverser les canaux diminue, car l'angle d'acceptation devient plus restrictif.

Ainsi, bien que les collimateurs divergents offrent un gain en champ de vue, leur utilisation est limitée par un compromis défavorable entre résolution, sensibilité et distorsion géométrique [30,31].

#### **3.1.1.4. Collimateur convergent**

Les collimateurs convergents ont été conçus pour permettre à la gamma-caméra d'agrandir (ou de magnifier) l'image d'une région d'intérêt sur le cristal détecteur. C'est également un type de collimateur moins fréquemment utilisé en routine que le collimateur parallèle, mais il trouve des applications spécifiques.

Les photons émis par le patient passent par des canaux convergents qui se dirigent vers un point focal situé devant le collimateur, comme illustré à la figure I.10.



**Figure I.10 :** Collimateur convergent.

Ce processus permet de grossir la taille de l'image projetée sur le détecteur par rapport à la taille réelle de l'objet imagé. Ce type de collimateur est ainsi utilisé pour acquérir des images d'organes de taille moyenne ou de régions d'intérêt spécifiques avec une résolution spatiale améliorée due à cette magnification. Cependant, cela s'opère au détriment d'un champ de vision plus restreint par rapport aux collimateurs parallèles, et la sensibilité peut varier en fonction de la distance de l'objet par rapport au point focal du collimateur [32,33].

### 3.1.2. Cristal scintillateur

Le cristal scintillateur joue un rôle central dans la détection des rayons gamma en médecine nucléaire : il convertit les photons gamma de haute énergie en signaux lumineux (photons visibles ou proches du visible) par un processus appelé scintillation. Pour assurer une efficacité de détection optimale, ce matériau doit présenter une forte probabilité d'interaction avec les photons incidents, condition remplie lorsqu'il combine une densité élevée et un numéro atomique ( $Z$ ) élevé. Ces propriétés favorisent les interactions telles que l'effet photoélectrique et la diffusion Compton, augmentant ainsi la probabilité d'absorption des photons gamma.

L'iodure de sodium dopé au thallium [ $\text{NaI}(\text{Tl})$ ] est le scintillateur le plus largement utilisé en TEMP. Grâce à la densité du matériau ( $3,67 \text{ g/cm}^3$ ) et au numéro atomique élevé de l'iode ( $Z = 53$ ), il présente une excellente efficacité d'absorption pour les photons gamma dont l'énergie se situe entre 70 et 200 keV. La majorité de ces photons sont arrêtés sur une épaisseur de quelques centimètres, ce qui permet d'optimiser la conception des détecteurs tout en garantissant une réponse rapide et linéaire [34,35].

### 3.1.3. Guide lumière


Le guide lumière, placé entre le cristal scintillateur et les photomultiplicateurs, est généralement constitué d'une plaque de verre ou d'un matériau transparent similaire. Il assure l'adaptation de l'indice de réfraction entre le cristal et la photocathode des tubes photomultiplicateurs, ce qui optimise le transfert de la lumière produite lors de la scintillation.

Par ailleurs, il maintient une distance mécanique nécessaire entre le cristal et les tubes, assurant une bonne étanchéité du vide interne des photomultiplicateurs tout en protégeant le cristal contre les chocs thermiques ou mécaniques [36,37].

### 3.1.4. Tube photomultiplicateur (TPM)

Le photomultiplicateur est un instrument qui convertit les photons de lumière, générés par un cristal scintillant, en signaux électriques. Ce tube à vide fonctionne avec trois composants principaux : une photocathode (négative), des dynodes (sous haute tension progressive), et une anode (positive).

Son fonctionnement repose sur les étapes suivantes : des photons incidents percutent la photocathode, où ils génèrent l'émission d'électrons par effet photoélectrique. Ces électrons primaires sont ensuite attirés par un champ électrique et accélérés vers la première dynode, où commence le processus d'amplification en cascade. À chaque dynode, de nouveaux électrons sont libérés, créant une avalanche électronique. Ce phénomène est répété jusqu'à ce que le signal, fortement amplifié, soit collecté par l'anode. L'amplitude du signal final, également appelé gain, est directement liée au nombre de dynodes et à la tension appliquée. Plus l'énergie des photons lumineux est grande, plus l'amplitude du signal électrique sera élevée. La figure I.11 illustre les composants d'un tube photomultiplicateur [38].



**Figure I.11** : Tube photomultiplicateur.

La gamma caméra est l'appareil de base pour l'imagerie en médecine nucléaire. Elle permet de réaliser les examens de type TEMP, qui fournissent des images en 3D. Quant à la TEP, plus récente et plus précise que la TEMP, offrant une meilleure résolution et sensibilité pour visualiser l'activité des organes.

## 4. Caméra TEP

La caméra TEP possède une architecture et des composants spécifiquement conçus pour détecter les paires de photons d'annihilation émis lors de la désintégration  $\beta^+$ . Elle se

compose généralement d'un anneau de détection entourant le patient, comme illustré sur la Figure I.12 [39].



**Figure I.12 :** Caméra TEP.

#### **4.1 Architecture et composants de la caméra TEP**

Le bloc de détection, qui est le cœur de la caméra TEP, est composé de trois éléments disposés en série :

##### **4.1.1 Cristaux scintillateurs**

Le cristal scintillateur constitue la première interface rencontrée par les rayons gamma dans le bloc de détection TEP. Son rôle principal est d'arrêter efficacement les photons de 511 keV issus de l'annihilation positron-électron et de convertir leur énergie en un signal lumineux (appelé scintillation) proportionnel à l'énergie absorbée. Pour maximiser l'efficacité de détection, ces cristaux sont fabriqués à partir de matériaux présentant une haute densité, un numéro atomique effectif élevé et un temps de décroissance radiative court, permettant ainsi une bonne résolution temporelle et énergétique. Parmi les matériaux les plus utilisés figurent le BGO (Germanate de Bismuth), le LSO (Orthosilicate de Lutétium), très performant, et le LYSO (Orthosilicate d'Yttrium et de Lutétium), largement répandu en imagerie clinique moderne. Ces cristaux sont généralement découpés en petits éléments discrets ou en blocs segmentés, afin d'améliorer la résolution spatiale du système et de localiser précisément l'interaction photon-matière au sein du détecteur.

##### **4.1.2 Photodétecteurs**

Placés à l'arrière des cristaux, les photodétecteurs ont pour rôle de convertir la lumière émise lors de la scintillation en un signal électrique exploitable par l'électronique

d'acquisition. Deux types principaux sont utilisés en imagerie TEP : les tubes photomultiplicateurs (PMT) classiques, et les photodétecteurs au silicium (SiPM, Silicon Photomultiplier), de plus en plus employés dans les systèmes modernes.

Les SiPM présentent plusieurs avantages significatifs : ils sont compacts, insensibles aux champs magnétiques externes (ce qui permet leur utilisation en imagerie hybride TEP/IRM), et offrent une excellente résolution temporelle, essentielle pour réduire les événements aléatoires grâce à une fenêtre de coïncidence étroite.

#### 4.1.3 Electronique de coïncidence

C'est un composant qui permet d'enregistrer les événements (lumière convertie en signal électrique) de tous les détecteurs, il est caractérisé par :

**Une ligne de réponse (LOR) :** qui définit la trajectoire possible de la paire de photons.

**Un temps de vol:** la mesure de la légère différence de temps d'arrivée entre les deux photons pour localiser le point d'annihilation plus précisément sur la LOR, améliorant ainsi le rapport signal sur bruit et la qualité de l'image [40].

### 5. Imagerie Tomographique par Émission Monophotonique (TEMP)

L'imagerie tomographique par émission monophotonique (TEMP ou SPECT, de l'anglais *Single Photon Emission Computed Tomography*) est une technique d'imagerie en médecine nucléaire qui explore le métabolisme des tissus et des organes et produit des images tridimensionnelles. Le processus du fonctionnement de la TEMP commence par l'injection du radiotracer, qui va émettre des photons détectables par le gamma caméra, et se termine par la reconstruction des données brutes en une image 3D révélant ainsi l'activité fonctionnelle.

Les système TEMP sont équipés généralement d'une, deux ou trois têtes gamma caméra ce qui permet de réduire le temps d'acquisition et d'augmenter la sensibilité du système.


L'imagerie TEMP offre deux avantages majeurs. D'abord, elle permet la reconstruction d'images en 3D, ce qui fournit une vue beaucoup plus détaillée de la distribution du radiotracer et aide à localiser précisément une pathologie. Ensuite, cette visualisation en trois dimensions améliore le contraste en éliminant la superposition des structures anatomiques, ce qui rend la détection des lésions beaucoup plus facile pour le clinicien.

#### 5.1. Principe d'acquisition TEMP

Le principe d'acquisition dans la TEMP repose sur la rotation de la gamma caméra. Après injection du radiotracer dans le corps du patient, les photons gamma émis seront détectés par une ou plusieurs gamma caméra qui tournent autour du patient, ce qui permet d'acquérir une

série de projection 2D sous différents angles. Chaque projection correspond à une vue de la distribution du traceur dans l'organisme depuis un angle spécifique.

L'ensemble de ces projections collectées est appelé données brutes, qui vont par la suite former des sinogrammes.



**Figure I.13 :** Processus de formation des sinogrammes.

La formation des sinogrammes est une étape essentielle dans la reconstruction d'images car il représente graphiquement la position du détecteur en fonction de l'angle de rotation [41].

## 5.2. Reconstruction d'images TEMP

Après l'acquisition des données brutes par le gamma caméra, l'étape de reconstruction joue un rôle fondamental dans la formation de l'image fonctionnelle. Deux grandes familles de méthodes sont utilisées en imagerie TEMP : les méthodes analytiques et les méthodes itératives.

Les méthodes analytiques telles que la rétroprojections simple et filtrée (SBP et FBP) sont connues par leur rapidité de reconstruction mais nécessite un nombre de projection important.

Le principe de ces méthodes est basé sur le calcul d'une estimation discrète de la transformée inverse de Radon, dont la formulation mathématique est donnée par [42]:

$$f(x) = \frac{1}{2d} \sum_k^d b\theta_k * h(t) |_{t=x\cos\theta_k+y\sin\theta_k} \quad (I.4)$$

La méthode de la rétroprojection filtrée (FBP) évalue la valeur du pixel  $f(x)$  en additionnant les résultats traités des projections pour chacun des angles  $k$ , une opération appelée sommation  $k$  (la rétroprojection), puis normalise le résultat par un facteur  $1/2d$  associé au nombre total d'angles  $d$ . Le filtrage est l'étape essentielle : chaque projection brute (sinogramme)  $b\theta_k$ , obtenue sous l'angle  $\theta_k$ , est convoluée avec la Fonction de Filtre de Rampe  $h(t)$  afin d'éliminer le flou radial inhérent au processus. Cela donne ainsi la projection filtrée  $b\theta_k * h(t)$ . Ce résultat filtré est par la suite cartographié sur le pixel  $(x, y)$  grâce à la relation géométrique  $t = x \cos \theta_k + y \sin \theta_k$ .

Contrairement aux méthodes analytiques, les méthodes itératives reposent sur un processus progressif d'ajustement entre les projections mesurées et un modèle direct de formation de l'image. Elles utilisent des algorithmes tels que l'ART (la Technique de Reconstruction Algébrique de l'anglais *Algebraic Reconstruction Technique*), le SART (Technique de Reconstruction Algébrique Simultanée de l'anglais *Simultaneous Algebraic Reconstruction Technique*) ou l'OSEM (Algorithme de maximisation de l'espérance par sous-ensembles ordonnés de l'anglais *Ordered Subsets Expectation Maximization*). Ces approches permettent de mieux gérer le bruit, d'intégrer des modèles physiques (atténuation, diffusion, réponse du détecteur) et de réduire les artéfacts, même avec un nombre limité de projections [43].

Le principe des méthodes de reconstruction des images est détaillé dans le deuxième chapitre.

## 6. La Tomographie par Émission de Positrons (TEP)

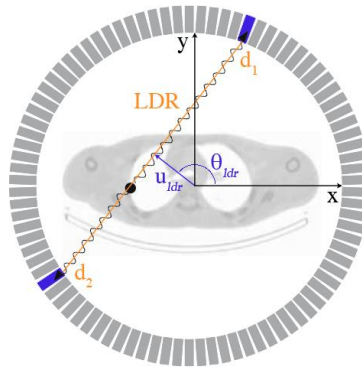
L'imagerie tomographique par émission de positrons (TEP ou PET, de l'anglais *Positron Emission Tomography*) est une technique d'imagerie diagnostique de la médecine nucléaire. Elle permet de visualiser en image 3D le processus biologique ou métabolique du corps humain en utilisant des radiotraceurs émetteurs de positrons. Cette modalité est particulièrement précieuse en cardiologie, neurologie et en oncologie afin d'évaluer l'activité métabolique des tissus.

### 6.1. Principe de détection en TEP

Le principe de l'imagerie TEP est basé sur la désintégration bêta plus avec libération d'un positron [44]. Cela commence par l'injection du radiotraceur émetteur de positrons, le noyau radioactif de ce traceur se désintègre dans le corps du patient et libère un positron. Ce dernier va rencontrer un électron après avoir parcouru une très courte distance de 1mm généralement, cette rencontre est appelée l'annihilation.

La masse de ces deux particules va être transformée en énergie en libérant deux photons gamma de 511KeV chacun et de direction complètement opposée l'un de l'autre. Ce qui fait qu'on ne peut parler de détection en coïncidence TEP que lorsque deux photons gamma frappent deux détecteurs opposés simultanément ou dans une fenêtre de temps extrêmement courte (en nanosecondes) [45].

La figure I.14 montre la ligne de réponse qui constitue une ligne imaginaire reliant entre les deux détecteurs ayant reçus les deux photons gamma simultanément et enregistrée une coïncidence, et en captant des milliers de ces événements en coïncidences on peut reconstruire la distribution du radiotraceur dans le corps du patient [46].



**Figure I.14 :** Ligne de réponse.

La détection en coïncidence offre une sensibilité et une résolution spatiale bien supérieures à la SPECT, car il n'y a pas de perte de photons due à la collimation physique.

## 6.2. Reconstruction d'images en TEP

Les données brutes en TEP sont des sinogrammes qui représentent l'ensemble des lignes de réponses (LOR) des événements de coïncidences détectés, contrairement à la TEMP qui sont des projections 2D simple [47].

La reconstruction en TEP utilise ces milliers de ligne de réponses afin de déterminer où se trouve le radiotracer à l'intérieur du corps humain, à l'aide de méthodes de reconstruction analytiques ou itératives. Une image reconstruite de l'organe cible est obtenue à la fin de la reconstruction.

Plusieurs facteurs influencent la qualité d'image en médecine nucléaire, notamment en TEMP et en TEP, et peuvent conduire à une dégradation de la qualité des images reconstruites. Ces facteurs constituent des sources majeures d'artéfacts et de perte de contraste. Leur prise en compte adéquate dans le processus de reconstruction représente la problématique centrale de ce travail.

## 7. Facteurs affectant la qualité d'image en médecine nucléaire

La qualité d'image en imagerie nucléaire (TEMP, TEP) dépend de facteurs liés à l'équipement, au patient, aux données brutes et aux algorithmes de reconstruction d'image.

### 7.1. Facteurs liés à l'équipement

Ces facteurs déterminent la qualité intrinsèque de l'image comme la résolution spatiale et la résolution en énergie.


#### 7.1.1. Résolution spatiale

La résolution spatiale fait référence à la capacité d'une modalité d'imagerie à différencier deux structures adjacentes comme étant distinctes l'une de l'autre. D'autres termes connexes incluent la définition ou la visibilité des détails.

La résolution spatiale est exprimée en paires de lignes par mm.

L'absence de résolution spatiale dans une image peut être appelée flou. Lorsqu'ils sont optimisés, les systèmes de film à écran ont une excellente résolution spatiale, tandis que les détecteurs électroniques sont limités par la taille des pixels. Le mouvement du patient pendant la capture d'image réduira également la résolution spatiale.

Les yeux humains ont la capacité de différencier une résolution spatiale de 5 paires de lignes par mm à une distance de vision de 25 cm [48].



**Figure I.15 :** Illustration schématique de l'influence de la résolution spatiale sur la localisation d'une source ponctuelle. De gauche à droite : faible, moyenne et haute résolution.

La figure I.15 démontre l'impact de la résolution spatiale sur la détermination de l'emplacement d'une source ponctuelle. Sur la gauche, la faible résolution se manifeste par une grille peu détaillée dans laquelle la source rouge n'est identifiée que dans une unique cellule, ce qui rend sa localisation très approximative. Au centre, en raison d'une résolution intermédiaire, la grille est plus précise et l'influence de la source sur plusieurs cellules adjacentes permet une meilleure localisation tout en gardant un léger flou. Sur la droite, la résolution élevée est synonyme d'une grille extrêmement dense, facilitant un positionnement très précis de la source ponctuelle grâce à une distinction spatiale supérieure des intensités. Par conséquent, une résolution spatiale accrue permet de localiser la source de manière plus précise.

### 7.1.2. Résolution en énergie

Elle mesure la capacité du détecteur à absorber l'énergie du photon détecté. Une bonne résolution en énergie aide à distinguer les photons primaires (qui portent l'information de localisation correcte) des photons diffusés (Compton), qui perdent de l'énergie lors de leur interaction avec les tissus, ce qui compromet leur localisation exacte et altère la précision de la position d'émission reconstruite.

## 7.2. Facteurs physiques et physiologiques liés au patient

Ces facteurs introduisent des erreurs dans les données acquises comme l'effet de volume partiel ou les mouvements du patient.

### 7.2.1. Effet de volume partiel (EVP)

C'est une perte d'activité apparente dans les petites structures en raison de la résolution spatiale du système.

Si la taille de la structure d'intérêt (par exemple, une petite tumeur) est comparable ou inférieure à la résolution spatiale du système, l'activité est sous-estimée. L'EVP est une source importante de limitation de la précision de quantification en TEMP et TEP.

### 7.2.2. Mouvement du patient

Le mouvement du patient lors de l'acquisition en imagerie nucléaire est une cause importante de dégradation, il se comporte comme un flou cinétique qui dégrade artificiellement la résolution spatiale. En effet, tout mouvement involontaire (respiration, tremblements) déplace la position réelle de l'organe ou de la lésion entre les différentes projections ou lignes de réponse (LOR) acquises, ce qui étale l'activité radioactive sur une zone plus large que sa taille réelle lors de la reconstruction tomographique. Ce flou, non seulement rend difficile la délimitation exacte des structures (diminuant la précision diagnostique), mais biaise aussi la quantification de l'activité (exacerbant l'effet de volume partiel en sous-estimant la concentration d'activité réelle dans la cible), rendant l'interprétation des images moins fiable.

## 7.3 Facteurs liés aux données brutes et aux algorithmes de reconstruction

La transformation mathématique des projections (données brutes) en images 3D finales est essentielle, car l'algorithme détermine directement le compromis entre résolution spatiale et contenu en bruit.

### 7.3.1 Bruit de comptage

La résolution effective en imagerie nucléaire est fondamentalement limitée par la nature aléatoire de l'émission des photons gamma, ce qui induit une fluctuation statistique connue sous le nom de bruit de comptage. Le nombre total d'événements détectés, déterminé par l'activité injectée et la durée d'acquisition, conditionne directement le rapport signal/bruit (SNR). Un faible nombre de comptes se traduit par une image bruitée, avec une mauvaise précision dans la détection et la quantification des structures d'intérêt. En outre, en TEP, une activité élevée, bien qu'elle améliore le SNR, augmente également le taux de coïncidences aléatoires (ou fortuites) : deux photons issus d'annihilations distinctes peuvent être enregistrés

comme un événement unique, conduisant à une fausse localisation le long d'une ligne de réponse. Ces événements parasites dégradent non seulement le contraste, mais altèrent aussi la linéarité de la quantification, compromettant ainsi la fidélité de l'image reconstruite.

### 7.3.2. Types et paramètres des algorithmes de reconstruction

La qualité de l'image finale en imagerie nucléaire dépend fortement du choix de l'algorithme de reconstruction et de ses paramètres. Deux grandes familles d'approches sont utilisées : les méthodes analytiques et les méthodes itératives.

Les méthodes analytiques, telles que la rétroprojection filtrée (FBP), offrent un traitement rapide et sont encore largement utilisées dans les systèmes cliniques pour leur simplicité.

Toutefois, elles produisent des images souvent plus bruitées et sujettes aux artefacts, notamment dans les zones à faible activité ou à fort contraste, où la résolution spatiale et la quantification sont compromises.

En revanche, les méthodes itératives, comme l'OSEM (Ordered Subsets Expectation Maximization) ou l'ART (Algebraic Reconstruction Technique), permettent une meilleure modélisation du processus physique de formation de l'image. Elles intègrent naturellement des corrections pour l'atténuation, la diffusion et la réponse du système, ce qui améliore significativement la précision de la reconstruction et la fidélité quantitative. Cependant, ces méthodes sont plus coûteuses en temps de calcul et nécessitent un ajustement fin des paramètres par l'opérateur.

Ce dernier doit opérer un compromis stratégique : Augmenter le nombre d'itérations améliore la convergence vers une solution plus précise, mais accroît également le bruit d'échantillonnage.

Appliquer des filtres de lissage post-reconstruction réduit visuellement le bruit et facilite l'interprétation clinique, mais au prix d'une perte de résolution spatiale et d'une altération des contours fins, affectant ainsi la précision des mesures quantitatives.

Ainsi, le choix de l'algorithme et la calibration de ses paramètres constituent un élément clé du compromis entre résolution, bruit et temps de calcul, directement lié à la fiabilité diagnostique et à la validité des analyses quantitatives.

## 8. Conclusion

Ce chapitre a permis de présenter les fondements physiques et technologiques de l'imagerie en médecine nucléaire, en décrivant les principes de la radioactivité, les interactions des rayonnements avec la matière, ainsi que les architectures des systèmes TEMP et TEP. Ces éléments constituent le socle nécessaire à la compréhension des défis liés à la

qualité des images reconstruites, notamment en termes de résolution, de bruit et de quantification.

L'étude de ces limitations naturelles motive l'importance des algorithmes de reconstruction, dont les approches et l'évolution font l'objet du chapitre suivant.

# **Chapitre II :**

## **Fondements théoriques et état de l'art**

## 1. Introduction

L'amélioration de la qualité des images médicales en médecine nucléaire est contrainte par plusieurs facteurs qui dépendent du processus de formation de l'image, depuis la simulation de l'équipement et ses composants, ensuite la formation du sinogramme jusqu'à la reconstruction de l'image finale. Ces facteurs peuvent être liés aux différents composants de l'imageur, comme le détecteur (par sa forme et ses matériaux), ou au patient (par les mouvements indésirables comme la respiration) ; mais surtout, la qualité de l'image finale dépend fortement de son électronique de traitement et des algorithmes logiciels utilisés pour l'imagerie. Ces derniers éléments constituent le cerveau du système, transformant les signaux bruts en une image significative.

Ce chapitre a pour objectif de présenter l'état de l'art sur l'approche méthodologique adoptée pour la simulation et la reconstruction, en mettant l'accent sur l'intégration de l'apprentissage profond dans l'amélioration, le raffinement et la préservation des détails pertinents de l'image finale, afin qu'elle soit aisément interprétable par le clinicien. Il débutera par introduire les bases de la simulation en médecine nucléaire ensuite une revue des méthodes de reconstruction les plus couramment employées en imagerie médicale ainsi que les métriques d'évaluation utilisés, avant de présenter l'état de l'art sur la simulation, l'amélioration de la qualité de l'image et de la résolution spatiale en médecine nucléaire.

## 2. Fondements théoriques

L'étude des rayonnements en médecine nucléaire repose sur des phénomènes stochastiques complexes, impliquant les lois de désintégration radioactive et les multiples interactions des particules avec la matière biologique et les détecteurs. Pour valider les modèles théoriques et optimiser la conception des systèmes d'imagerie, il est essentiel de disposer d'outils capables de modéliser ces processus physiques de manière probabiliste et rigoureuse.

### 2.1. Bases de la simulation en médecine nucléaire

La simulation en médecine nucléaire est réalisée grâce à des logiciels basés sur le principe Monte Carlo tels que GEANT4 (GEometry ANd Tracking), GATE (GEANT4 Application for Tomographic Emission), MCNP (Monte Carlo N-Particle), PENELOPE (PENetration and Energy LOSS of Positrons and Electrons) et SIMIND (SIMulation of INDium). Ces logiciels représentent une boîte à outils créée pour la simulation des détecteurs en physique des hautes énergies, ils permettent aussi une modélisation précise des sources de radiation et des dispositifs de détection, avec une configuration facile et une

interface conviviale, tout en offrant une grande précision dans la simulation des processus physiques [49].

### **2.1.1. Principe Monte Carlo**

La méthode de Monte Carlo dans la simulation en médecine nucléaire est une technique numérique qui se base sur un échantillonnage statistique aléatoire pour reproduire le déplacement et l'interaction des particules telles que les photons, les électrons et les positrons, lorsqu'elles pénètrent dans la matière.

Cette méthode essentielle permet d'anticiper le comportement physique et l'accumulation d'énergie dans des systèmes complexes, tels que les détecteurs en physique des particules de haute énergie ou, pour la médecine nucléaire, les organes et les appareils TEP/TEMP [50].

### **2.1.2. Etapes fondamentales de la simulation**

Il existe quatre étapes fondamentales (construction, physique, génération et contrôle) qui forment le squelette de tout programme de simulation en médecine nucléaire.

- **Définition des matériaux et de la géométrie**

Cette étape correspond à la construction d'un environnement physique et définir les substances pour les tissus pour et le détecteur. Il s'agit de la représentation qui permet à chaque particule de connaître sa position et ses interactions possibles.

- **Définition des processus physiques**

Cette étape permet de dicter les lois de la nature au simulateur pour déterminer la probabilité et le type d'interaction subie par la particule.

- **Génération des événements primaires**

Cette étape permet la configuration de la source de rayonnement (particule, énergie, direction et point d'émission) pour initier la simulation selon les paramètres définis.

- **Contrôle de l'événement et collecte de données**

Cette dernière étape permet le suivi des particules, gestion des processus pendant l'événement et extraction des informations utile (énergie déposée, position et temps).

C'est le pont entre la simulation physique et l'obtention de données exploitables (spectres, images) via le post-traitement.

### **2.1.3. Rôle de la simulation en médecine nucléaire**

Les logiciels de simulation en médecine nucléaire représentent une étape fondamentale dans la conception, la modalisation et l'étude des équipements TEP et TEMP, leur rôle consiste à :

- Reproduire numériquement avec une grande précision l'intégralité du processus d'imagerie et d'interaction de la radiation avec la matière.
- Modéliser les phénomènes qui sont à la base de l'imagerie et de la dosimétrie.
- Tester différentes configurations de scanners (taille des cristaux, géométrie du détecteur, matériaux de blindage).
- Optimiser la performance avant même la construction du prototype.
- Calculer les métriques de performance clés sans mesure expérimentale coûteuse.
- Générer des données très réalistes.
- Aider à développer des algorithmes pour corriger les artéfacts dans les images TEP et TEMP.
- Tracer l'énergie déposée par les particules (électrons et photons) à l'intérieur des tissus.
- Planifier les traitements de radiothérapie interne (radiothérapie métabolique) et évaluer les risques pour le patient.

En résumé, la simulation constitue l'élément essentiel de la modélisation en médecine nucléaire, offrant les fondements physiques précis indispensables à la recherche, à l'innovation des dispositifs et à l'optimisation des thérapies [51-53].

## **2.2. Méthodes de reconstruction traditionnelles**

Les méthodes de reconstruction conventionnelles en imagerie représentent les algorithmes historiques et fondamentaux qui transforment les données de projection brutes en une image de coupe. Ces méthodes se divisent en deux catégories principales : les approches analytiques et les approches itératives, chacune de ces approches présente des avantages et des inconvénients spécifiques, et leur sélection est conditionnée par l'objectif clinique de l'étude.

Les méthodes analytiques sont significativement plus rapides et plus aisées à mettre en œuvre. En revanche, bien que les méthodes itératives soient plus complexes et plus exigeantes en temps de calcul, elles fournissent généralement des résultats d'une qualité supérieure [54].

### **2.2.1. Méthodes analytiques**


Une méthode analytique repose sur une inversion mathématique exacte de la projection (Transformation de Radon). Ces méthodes donnent la solution de reconstruction en une seule

étape, contrairement aux méthodes itératives qui nécessitent plusieurs boucles de calcul pour améliorer l'image.

### A. Transformation de Radon

La Transformation de Radon établit la relation entre l'objet bidimensionnel et ses projections, garantissant ainsi qu'un objet bidimensionnel est reconstruit.

La figure II.1 présente une illustration d'une projection et d'un sinogramme. Le sinogramme, illustré à droite, est construit en empilant les projections successives, de sorte que chaque ligne horizontale du sinogramme corresponde à une projection complète acquise à un angle de rotation spécifique,  $\theta$ .



**Figure II.1 :** Illustration d'une projection et d'un sinogramme.

Afin d'obtenir l'image tomographique bidimensionnelle (la coupe) à partir du sinogramme, différentes méthodes sont utilisées. Parmi les méthodes analytiques les plus couramment employées, on cite notamment la rétroprojection filtrée.

### B. Rétroprojection filtrée

La Rétroprojection Filtrée (FBP - *Filtered Back Projection*) est une technique analytique fondamentale et simple en termes de calcul pour la reconstruction d'images tomographiques.

Le processus implique souvent l'utilisation d'un filtre de rampe et d'un fenêtrage pour l'atténuation du bruit. Ceci permet de corriger l'effet de flou inhérent à la rétroprojection en filtrant les données de projection (sinogramme) dans le domaine fréquentiel. L'image reconstruite est ensuite produite en rétroprojetant ces projections filtrées sur la grille d'image [55].

L'équation de la rétroprojection filtrée (FBP) permet de reconstruire la valeur d'image  $f(x,y)$  en chaque point à partir des données de projection  $p(\theta,r)$ .

$$f(x, y) = \int_0^\pi [P(\theta, r) * h(r)]_{r=x\cos(\theta)+y\sin(\theta)} d\theta \quad (\text{II.1})$$

Ceci implique de filtrer chaque projection à l'aide d'un noyau  $h(r)$ , puis de sommer (ou d'intégrer) ces contributions filtrées provenant de tous les angles ( $\theta$ ). Le terme  $r=x\cos\theta+y\sin\theta$  gère le mapping géométrique nécessaire pour rétroprojeter correctement les données filtrées sur la grille d'image [56,57].

La Rétroprojection Filtrée est largement utilisée pour sa rapidité de calcul et sa robustesse. Cependant, comme toute méthode de reconstruction, elle présente des limites inhérentes.

### C. Avantages et inconvénients

Les méthodes analytiques sont puissantes par leur efficacité de calcul, leur atout majeur est leur rapidité et leur faible coût en ressources, permettant la reconstruction d'images en temps réel sur les scanners. Elles sont directes et ne nécessitent pas de gestion des paramètres de convergence, ce qui garantit une simplicité d'utilisation.

Mais cette simplicité mathématique entraîne des inconvénients qui dégradent l'image, en particulier dans les situations actuelles de faible dose. Le filtrage nécessaire à la correction du flou entraîne une amplification du bruit haute fréquence des données et l'image est très bruitée si la dose d'acquisition est faible. De plus, la FBP ne modélise pas la physique d'acquisition complexe (atténuation, diffusion) et les statistiques du bruit et nécessite des étapes de correction externes. Enfin, elles sont sensibles à des artefacts typiques, et ont un compromis fixe entre résolution et bruit : toute tentative de réduire le bruit se fait au détriment de la netteté des détails fins [58,59].

En conclusion, les méthodes analytiques sont les fondations de la reconstruction rapide, mais leurs faiblesses face au bruit et à la modélisation sont les raisons principales pour lesquelles on se tourne vers les méthodes itératives et l'apprentissage profond.

#### 2.2.2 Méthodes itératives

Les méthodes itératives sont des algorithmes qui reconstruisent une image tomographique par un processus d'amélioration et d'optimisation itératif. Au lieu d'utiliser une équation mathématique directe pour inverser la projection, ces méthodes commencent par une estimation de l'image, puis la corrigent itérativement jusqu'à ce que l'image corresponde le mieux aux données de projection brutes mesurées.

##### A. Principe et fonctionnement

Le processus itératif se déroule généralement selon un cycle en 3 étapes qui se répète :

- **Estimation Initiale** : L'algorithme démarre avec une image initiale.

- **Projection** : L'image estimée est projetée pour simuler les projections qui auraient été mesurées si cette image était l'objet réel.
- **Correction** : L'erreur entre les projections simulées et les projections réelles mesurées est calculée. Cette erreur est ensuite utilisée pour ajuster l'image estimée initiale. Ce processus se répète pour un nombre d'itérations fixé, ou jusqu'à ce que l'erreur entre les projections simulées et réelles soit inférieure à un seuil.

La Technique de Reconstruction Algébrique (ART - *Algebraic Reconstruction Technique*) est l'une des premières méthodes itératives de reconstruction d'images.

### B. Technique de reconstruction algébrique (ART)

Partant d'une estimation d'image préliminaire, l'ART ajuste de manière itérative les valeurs des pixels le long des lignes de projection afin de minimiser la différence entre les données observées et les projections calculées à partir de l'image courantes [60].

$$p_i = \sum_{j=1}^N w_{ij} f_j \quad \text{for } i = 1, \dots, M \quad (\text{II.2})$$

Dans le système linéaire utilisé par l'ART pour la reconstruction,  $p_i$  représente la  $i$ -ième mesure de projection,  $f_j$  désigne la valeur du  $j$ -ième pixel, et  $w_{ij}$  est un poids qui signifie la contribution du  $j$ -ième pixel à la  $i$ -ième mesure. Ce poids est généralement défini par la taille de l'intersection entre le rayon de projection  $i$  et le pixel  $j$ .

### C. Algorithme d'espérance-maximisation par sous-ensembles ordonnés (OSEM)

La technique OSEM (*Ordered Subset Expectation Maximization*) a été introduite en 1994 [61]. C'est un algorithme de reconstruction itérative couramment utilisé en médecine nucléaire pour améliorer la vitesse de convergence sans compromettre la qualité de l'image.

L'équation de mise à jour pour la valeur du pixel  $f_j$  à l'itération  $k+1$  peut être généralement exprimée comme suit :

$$f_j^{(k+1)} = \left[ \frac{f_j^k}{\sum_{i \in S_m} a_{ij}} \right] \cdot \sum_{i \in S_m} a_{ij} \left[ \frac{g_i}{\sum_i a_{ij} f_j^k} \right] \quad (\text{II.3})$$

Cette équation montre comment l'estimation actuelle  $f_j(k)$  est ajustée en fonction du rapport entre les projections mesurées  $g_i$  et les projections estimées, pondéré par la matrice du système  $a_{ij}$  pour le sous-ensemble actuel  $S_m$ .

### D. Avantages et inconvénients


L'ART est l'une des méthodes itératives les plus simples, qui consiste à ajuster successivement les pixels pour résoudre un système d'équations linéaires. Son atout majeur est sa flexibilité structurelle, ce qui la rend idéale pour les géométries d'acquisition non standard, comme les données de vue clairsemée ou d'angle limité. Mais son principal défaut

est sa lenteur inhérente, car elle traite généralement les projections une par une, ce qui est très consommateur de temps pour les grands volumes de données. De plus, elle dépend du paramètre de relaxation qui contrôle la vitesse de correction et sa convergence est difficile à maîtriser lorsque les données mesurées sont bruitées et rendent le système d'équations formellement inconsistant.

L'OSEM est la méthode itérative prépondérante en imagerie d'émission (TEP et TEMP). Son atout majeur est sa vitesse de convergence largement améliorée. Il le fait en découpant l'ensemble des données en sous-ensembles, autorisant ainsi plusieurs mises à jour de l'image par itération, ce qui le rend compatible avec la clinique. Statistique, l'OSEM est idéal pour traiter le bruit des détections de photons, avec un bon compromis entre réduction du bruit et résolution de l'image. Son principal défaut est qu'il faut bien choisir le nombre d'itérations et de sous-ensembles, sinon l'image peut être bruitée ou sur-converger (le bruit commence à s'accumuler de façon structurée et artificielle dans l'image finale).

### 2.3 Principe de l'apprentissage profond (Deep Learning)

L'apprentissage profond, appelé aussi le *Deep Learning* (DL) en anglais, est défini comme une sous-catégorie de l'apprentissage automatique (ou *Machine Learning* ML) en Intelligence Artificielle (IA) qui permet aux ordinateurs de construire des concepts complexes à partir de concepts plus simples en utilisant des réseaux qui apprennent de manière non supervisée à partir de données, améliorant les performances à travers des couches d'algorithmes complexes.



**Figure II.2 :** Positionnement du Deep Learning dans le domaine de l'Intelligence Artificielle.

L'apprentissage profond propose une diversité d'architectures, notamment les réseaux de neurones convolutionnels (CNN) pour l'analyse d'images [62], les réseaux récurrents (RNN) et les LSTM pour le traitement des séquences [63], les autoencodeurs pour la réduction de

dimension ou la reconstruction de données [64], les réseaux de neurones convolutionnels en U (U-Net) [65], largement employés pour la segmentation d'images médicales, et les réseaux antagonistes génératifs (GAN) pour la génération d'images réalistes [66] ainsi que le Réseau Résiduel à Attention de Canal (RCAN) [67], conçu pour améliorer la qualité et la netteté des images en mettant l'accent sur les caractéristiques les plus pertinentes dans chaque canal.

### 2.3.1 Réseaux antagonistes génératifs (GAN)

Les réseaux antagonistes génératifs (GAN) constituent une classe d'algorithmes d'intelligence artificielle conçus pour apprendre la distribution sous-jacente des données. Ils peuvent potentiellement conduire à la réduction du bruit, à la complétion des informations manquantes et à l'amélioration de la résolution des échantillons générés [68].

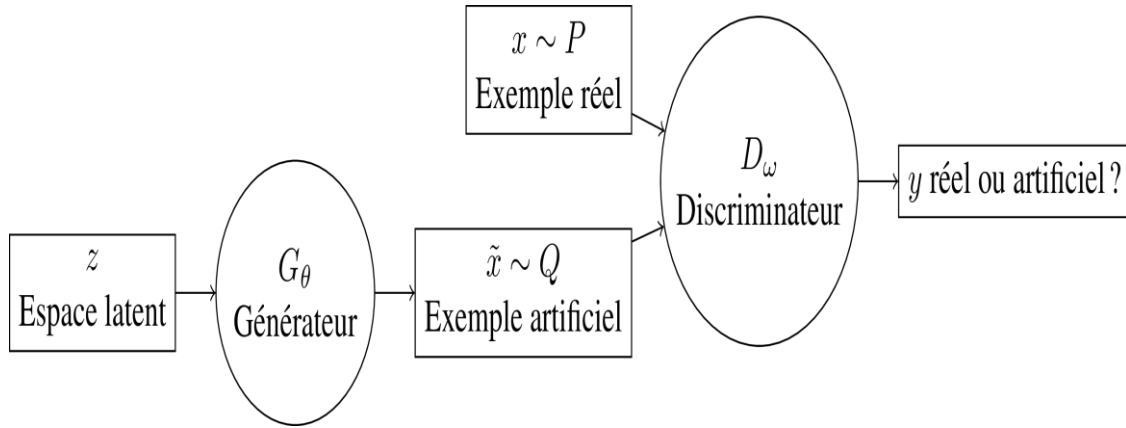
Les GAN comprennent typiquement deux réseaux neuronaux convolutifs adverses : un générateur et un discriminateur. Alors que le discriminateur est un classifieur binaire conçu pour différencier les échantillons synthétiques des données réelles, le générateur est entraîné à apprendre la distribution sous-jacente des données réelles pour créer des échantillons synthétiques [69].

La représentation mathématique de ce processus antagoniste est définie par la fonction objectif suivante :

$$\text{Min}_G \text{Max}_D f(D, G) = \text{Ex}[\log(D(x))] + \text{Ez}[\log(1 - D(G(z)))] \quad (\text{II.4})$$

Dans ce contexte,  $\text{Ex}$  désigne l'espérance sur l'ensemble des sinogrammes réels ;  $D(x)$  représente l'estimation de probabilité par le discriminateur que l'entrée  $x$  soit réelle ;  $G(z)$  représente la sortie du générateur pour le bruit  $z$  ;  $D(G(z))$  représente l'estimation de probabilité par le discriminateur quant à l'authenticité des sinogrammes générés ; et  $\text{Ez}$  indique l'espérance sur l'ensemble de l'espace d'entrée aléatoire du générateur.

Afin d'évaluer la performance antagoniste, plus spécifiquement la capacité du générateur à tromper le discriminateur et la capacité du discriminateur à distinguer les sinogrammes réels des sinogrammes générés, les fonctions de perte du générateur (G-Loss) et de perte du discriminateur (D-Loss) ont été utilisées [70].



**Figure II.3 :** Principe du réseau GAN.

### A. Fonction de perte du générateur (G-Loss)

La fonction de perte du générateur (G-Loss) est utilisée pour guider l'entraînement du générateur en évaluant la réaction du discriminateur aux données générées [71].

La fonction G-Loss est exprimée comme suit :

$$L_G = E_{z \sim P_Z(z)} [\log D(G(z))] \quad (\text{II.5})$$

Le générateur cherche à maximiser  $D(G(z))$ , ce qui signifie qu'il veut que le discriminateur croie que ses échantillons générés sont réels. Pour atteindre cet objectif de maximisation, l'optimiseur du générateur effectue une opération de minimisation. Il minimise en effet le négatif de cette expression, ce qui est la procédure standard pour les optimiseurs.

### B. Fonction de perte du discriminateur (D-Loss)

La perte du discriminateur (D-Loss) quantifie les erreurs de ce dernier durant la classification des données. Elle sert de fonction objective pour son entraînement, visant à minimiser ces erreurs et à maximiser la probabilité de classer correctement les données réelles et synthétiques.

La fonction D-Loss est exprimée comme suit :

$$L_D = E_{x \sim P_{data}(x)} [\log D(x)] - E_{z \sim P_Z(z)} [\log (1 - D(G(z)))] \quad (\text{II.6})$$

Où  $x$  est un échantillon de données réelles et  $z$  est un bruit aléatoire. Le générateur  $G$  crée des fausses données  $G(z)$  à partir de  $z$ . Le discriminateur  $D$  produit la probabilité  $D(x)$  que  $x$  soit réel et  $D(G(z))$  que l'échantillon généré soit réel.

### C. Avantages et pertinence du modèle GAN

Le principal avantage des GANs par rapport aux autres architectures d'apprentissage classiques est leur capacité à produire des données de haute qualité et réalistes grâce à leur apprentissage par opposition.

- **Création de données hyperréalistes**

L'avantage majeur est la fidélité des données produites, le discriminateur incite sans cesse le générateur à produire des échantillons (sinogrammes) indistinguables des données réelles. Avec leur perte adversaire, les GAN évitent le flou et génèrent des détails nets et photoréalistes.

- **Saisie de la distribution complexe des données**

Le mécanisme antagoniste permet au générateur d'apprendre implicitement la distribution des données. Les GAN n'ont pas besoin de définir une fonction de vraisemblance explicite. Ils apprennent directement des données la structure des relations complexes et peuvent ainsi produire des variations qui respectent mieux les règles internes (style, texture, cohérence spatiale) de l'ensemble de données initial.

- **Applications particulières en imagerie**

En reconstruction tomographique ou en amélioration d'images, les GAN apportent des bénéfices essentiels, ils sont excellents pour éliminer le bruit tout en conservant ou en restaurant les textures fines et les détails structurels.

- **Super-résolution et complétion d'information**

Ils peuvent être entraînés pour deviner l'information manquante et améliorer la résolution des images finales, remplissant les trous que les méthodes itératives classiques ont du mal à combler sans créer d'artefacts d'étirement.

#### **D. Rôle de l'apprentissage profond dans l'amélioration du sinogramme avant la reconstruction par les méthodes traditionnelles**

Le rôle de l'apprentissage profond, et notamment des GAN est de convertir un sinogramme de basse qualité (bruité, incomplet, faible dose) en un sinogramme de haute qualité avant la reconstruction finale par une méthode classique (ART, FBP, OSEM). Cette action stratégique est d'autant plus efficace qu'elle se situe dans l'espace de Radon où les artefacts et les données manquantes ont des structures plus régulières et prévisibles que dans l'image reconstruite.

L'amélioration du sinogramme par apprentissage profond corrige les défauts d'acquisition à la source des artefacts, comme le bruit de Poisson des acquisitions à faible dose ou les incohérences d'un échantillonnage clairsemé, apparaissent structurés dans le sinogramme. Il a été démontré qu'un réseau neuronal peut apprendre à débruiter ou à interpoler des lignes de projection manquantes mieux qu'un filtre classique appliqué à l'image finale, car il travaille sur des données non encore rétroprojetées. En offrant un sinogramme amélioré et quasi-parfait au processus de reconstruction, on diminue considérablement le nombre d'itérations pour

obtenir une image de qualité et on accélère la chaîne de traitement globale. Cette approche permet une intégration transparente, en employant l'apprentissage profond comme un module de prétraitement puissant pour des algorithmes de reconstruction éprouvés et cliniquement validés [72-74].

Le GAN joue un double rôle crucial pour assurer la qualité du sinogramme amélioré :

- **Générateur** : Le générateur (G) est formé pour apprendre la cartographie, son but n'est pas seulement de réduire le bruit, mais de reconstruire l'information structurelle cohérente qui aurait existé dans des conditions d'acquisition idéales. Il apprend les causes du bruit et de la dégradation pour les remplacer par des informations fidèles.
- **Discriminateur** : Le discriminateur (D) est ce qui donne aux GAN leur force de réalisme. Formé à différencier les sinogrammes réels des sinogrammes synthétiques, il incite le générateur à produire des sorties qui préservent les caractéristiques statistiques et les textures fines des données cliniques réelles. Le résultat est un sinogramme corrigé qui est non seulement mathématiquement correct, mais aussi visuellement réaliste, ce qui est essentiel pour produire des images reconstruites claires et diagnosticables.

L'utilisation de l'apprentissage profond pour améliorer le sinogramme se traduit par des avantages cliniques concrets :

- **Sécurité du patient par la diminution de dose** : En rendant les acquisitions à faible dose acceptables en diagnostic, cette approche permet une réduction significative de l'exposition au rayonnement pour le patient, un aspect essentiel en TEP/TDM.
- **Amélioration de la qualité** : En corrigeant les données brutes avant la reconstruction, le modèle améliore la précision des contours et des mesures de densité, ce qui améliore la quantification et la fiabilité du diagnostic.
- **Amélioration du flux de travail** : L'acquisition rapide de sinogrammes de qualité diminue le temps de post-traitement et de reconstruction itérative, permettant aux radiologues et aux médecins nucléaristes d'obtenir plus rapidement les images finales pour l'interprétation.

### 2.3.2 Réseau Résiduel à Attention de Canal (RCAN)

Le RCAN (*Residual Channel Attention Network*) est une architecture de réseau neuronal convolutif profond principalement conçue pour la super-résolution d'images uniques. Son

innovation principale réside dans l'intégration efficace de réseaux résiduels très profonds avec des mécanismes d'attention par canaux.

Le RCAN résout le problème de dégradation des réseaux ultra-profonds grâce aux connexions résiduelles, tout en exploitant l'attention par canaux pour rééquilibrer les cartes de caractéristiques de manière adaptative. Cela permet d'accentuer les caractéristiques plus informatives et de supprimer celles qui sont moins utiles. Le RCAN peut ainsi apprendre des caractéristiques plus discriminantes et atteindre des performances de super-résolution de pointe avec une grande efficacité [75].

### A. Architecture du RCAN

Les composantes principales de l'architecture du RCAN sont :

- **Groupes Résiduels (RGs)**

Le RCAN empile plusieurs groupes résiduels, chacun se compose de plusieurs blocs d'attention par canaux résiduels et d'une longue connexion sautée.

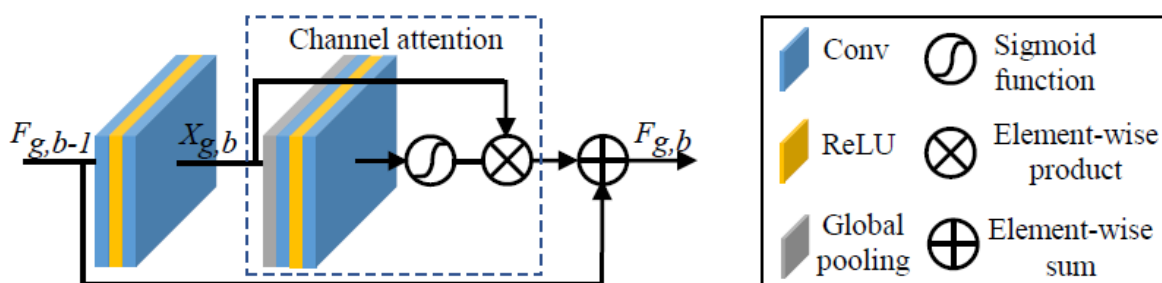
- **Blocs d'attention par canaux résiduels (RCABs)**

Ce sont les blocs de construction au sein des RGs. Un RCAB combine une connexion résiduelle avec un module d'attention par canaux (CA).

- **Module d'attention par canaux (CA)**

Ce module recalibre de manière adaptative les réponses des caractéristiques par canal. Il implique généralement une pondération moyenne globale qui compresse les informations spatiales en un descripteur de canal. Deux couches entièrement connectées qui apprennent les dépendances par canal. Et une multiplication par canal qui ajuste les caractéristiques d'entrée en fonction des poids appris [76].

La figure II.4 représente le principe d'un réseau RCAN.



**Figure II.4 :** Principe du réseau RCAN.

Ce schéma démontre le concept essentiel d'une attention par canal, élément central des structures modernes de réseaux neuronaux comme le RCAN, mis en œuvre dans la vision informatique. Le bloc reçoit des caractéristiques d'entrée  $X_{g,b}$  et utilise un processus en trois

phases pour optimiser leur pertinence : il commence par appliquer une mise en commun globale et une activation sigmoïde pour déterminer un vecteur de poids qui symbolise l'importance de chaque canal, ensuite, il associe ce vecteur de poids aux caractéristiques d'entrée par multiplication afin de les rééchelonner (amplifiant les canaux informatifs tout en atténuant le bruit), et finalement, il incorpore ce résultat dans une structure résiduelle en le combinant (somme élément par élément) à une autre caractéristique  $F_{g,b-1}$  pour générer la sortie  $F_{g,b}$ . Ce processus favorise l'apprentissage des caractéristiques par le réseau, lui permettant ainsi de se focaliser dynamiquement sur les éléments les plus significatifs des données.

### **B. Rôle du RCAN dans l'optimisation de la résolution spatiale**

Le choix du modèle RCAN pour la super-résolution s'explique par la volonté d'obtenir un compromis entre la fidélité de reconstruction et le réalisme visuel (haute qualité perceptive). RCAN est un modèle qui vise à préserver la fidélité de l'image grâce à deux contributions principales :

- **Meilleure qualité perceptive**

Il permet d'inciter le modèle à produire des résultats visuellement plus réalistes, même si cela peut entraîner un léger compromis sur la fidélité pixel par pixel pure.

- **Restauration des détails**

C'est un élément clé pour une amélioration spatiale réaliste et pour imiter la complexité structurelle des images haute résolution. Finalement, le RCAN est choisi car il tire parti de la précision structurelle et la capacité à produire un réalisme visuel supérieur, ce qui se traduit par une résolution spatiale améliorée, à la fois techniquement solide et visuellement agréable.

## **3. Etat de l'art**

L'étude des interactions des détecteurs avec les particules émises et l'amélioration de la qualité d'image et de la résolution spatiale en médecine nucléaire font objet de nombreux sujets de recherche. Dans cette partie nous présentons un ensemble de ces travaux existants qui visent à trouver une solution à la problématique fondamentale de la reconstruction d'image en médecine nucléaire.

Ces travaux sont divisés en trois directions distinctes : simulation en médecine nucléaire, amélioration de la qualité de l'image et amélioration de la résolution spatiale.

### **3.1. Simulation en médecine nucléaire**

G. Santin et al [77] ont introduit GATE (Geant4 Application for Tomographic Emission), une plateforme de simulation destinée à la TEP et la TEMP, qui enrichit le robuste moteur de

simulation GEANT4 avec des caractéristiques dédiées à la médecine nucléaire. Le principal avantage de GATE réside dans sa compétence à représenter la progression temporelle des acquisitions réelles, ce qui lui confère la possibilité de simuler des systèmes en mouvement tels que la désintégration des sources radioactives et le déplacement des détecteurs.

Amirreza Hashemi et al. [78] ont mis au point une application innovante basée sur GEANT4 pour la simulation Monte Carlo de scanners d'imagerie nucléaire complexes, dans le but de surmonter les difficultés de modélisation géométrique et les coûts de calcul élevés des outils existants. Leur approche repose sur la création de géométries de détecteurs complexes et la simulation des photons optiques. Les résultats de leurs tests sur un cristal simple ont montré une accélération remarquable, rendant la simulation de grands volumes d'événements jusqu'à 300 fois plus rapide, validant ainsi cette méthode haute performance pour la conception de systèmes d'imagerie nucléaire sophistiqués futurs.

M. Cañadas et al [79] ont effectué une validation exhaustive du scanner TEP Raytest ClearPET pour petit animal. Le modèle de simulation du ClearPET qu'ils ont élaboré comprend des éléments essentiels comme les cristaux scintillateurs à deux couches, le mouvement du portique, ainsi que la radioactivité intrinsèque des cristaux. Les résultats ont démontré une bonne concordance globale entre sensibilité et résolution en énergie.

F. Poignant et al. [80] ont détaillé le processus de création et de validation d'une plateforme de simulation Monte Carlo en utilisant GEANT4. L'objectif étant d'améliorer la production de radio-isotopes tout en réduisant les coûts et la contamination. Ce résultat a été confronté et comparé aux rendements théoriques et expérimentaux trouvés dans la littérature ainsi qu'aux données provenant de la base de données nucléaire TENDL. Cette étude confirme l'outil en tant qu'instrument efficace pour anticiper l'activité des isotopes et la contamination antérieure à l'expérimentation.

Robert Freudenberg et Jorg Kotzerke [81] ont réalisé des simulations afin d'évaluer les doses cellulaires absorbées par les radio-isotopes en se servant du logiciel GEANT4 pour un modèle de cellule unique. Leurs conclusions étaient en bonne concordance avec les chiffres (doses absorbées par unité d'activité) trouvés dans la littérature.

L'application du kit d'outils GEANT4 pour la simulation des photons optiques dans les caméras TEMP a été présentée par S. Lo Meo et al [82], mettant en avant la capacité singulière de GEANT4 à reproduire le déplacement de la lumière dans divers milieux. L'objectif était d'examiner la propagation de la lumière à l'intérieur d'un détecteur (cristal scintillant, tube photomultiplicateur et couplage en verre). En imitant un flux concentré de

photons de 140 keV qui frappe le cristal à divers points. Les conclusions ont servi à déterminer les résolutions spatiale et énergétique de la caméra. Cette recherche confirme que GEANT4 est approprié pour représenter avec exactitude le comportement optique des appareils de détection en médecine nucléaire.

### 3.2 Amélioration de la qualité de l'image en médecine nucléaire

Diverses études ont exploré l'intégration de l'IA dans l'imagerie nucléaire, notamment la méthode proposée par Vashistha et al. [83], l'étude de Kishore Krishnagiri Manoj Doss et al. [84], et le travail d'Alexandre Bousse et al. [85]. Ces travaux se concentrent sur l'amélioration des sinogrammes en utilisant l'apprentissage profond.

Spécifiquement, parmi les travaux existants, Reader et al. [86] ont mis au point une méthode d'apprentissage auto-supervisé (SSSR) pour améliorer la reconstruction d'images. Leur méthode repose sur l'utilisation d'un réseau profond entraîné sur un seul sinogramme avec du bruit simulé, et met en œuvre des techniques d'auto augmentation pour améliorer les performances de généralisation du modèle, visant finalement à améliorer la qualité des images en médecine nucléaire, en particulier lorsque les données sont rares.

La méthode DeepPETmodified de Rufo et al. [87] utilise l'apprentissage profond pour améliorer la reconstruction d'images. Leur méthode implique l'organisation des données, l'application d'augmentations telles que la rotation et le zoom, et l'utilisation de sinogrammes comme entrée pour un réseau neuronal. Le modèle est entraîné avec des données augmentées. Ensuite, le modèle entraîné est testé par rapport aux méthodes traditionnelles, dans le but d'améliorer la qualité de l'image, de réduire le bruit et d'améliorer les détails en combinant l'apprentissage profond avec les techniques conventionnelles de l'imagerie nucléaire.

La méthodologie de Mahranian et al. [88] repose sur l'algorithme FBSEM pour la reconstruction bayésienne de la TEP, en l'améliorant avec un CNN pour apprendre la fonction de régularisation avec un processus d'apprentissage potentiellement structuré par un cadre RNN. Le réseau est entraîné avec des données TEP en utilisant l'apprentissage supervisé afin de minimiser l'erreur de reconstruction. L'efficacité de la méthode pour améliorer la qualité de l'image TEP et réduire les artefacts est évaluée par rapport aux techniques traditionnelles en utilisant le contraste-sur-bruit (CNR) et l'erreur quadratique moyenne normalisée (NRMSE).

Xiang Hong et al [89] ont introduit une méthode de super-résolution d'image unique (SISR) via un réseau neuronal convolutif résiduel (CNN), conçue pour améliorer la qualité d'image des systèmes TEP. En appliquant ce réseau directement aux sinogrammes, les chercheurs ont démontré que cette approche logicielle permet d'atteindre une résolution

comparable et une meilleure gestion du bruit qu'avec les cristaux coûteux de petite taille. L'étude valide ainsi le potentiel d'une solution d'apprentissage profond pour la conception de systèmes TEP haute performance à coût réduit.

Qiupeng Feng et al [90] ont mené une recherche qui présente un nouveau modèle de reconstruction en TEP basé sur l'apprentissage profond, capable de fonctionner à partir de sinogrammes à très faible dose. En combinant deux réseaux neuronaux pour le processus de débruitage du sinogramme suivi de la reconstruction de l'image, cette approche permet d'obtenir des images TEP de qualité satisfaisante. Cette méthode représente une avancée significative pour minimiser l'exposition des patients.

Jianan Cui et al [91] propose une étude qui présente un cadre de reconstruction paramétrique itérative pour la TEP qui évite le besoin de vastes ensembles de données d'entraînement. Cette approche utilise le réseau neuronal profond (DNN) et en se focalisant exclusivement sur l'image TEP spécifique au patient. Ce modèle se révèle plus performant que les méthodes traditionnelles de débruitage en ce qui concerne la quantification clinique.

Afin de minimiser les dangers associés à l'exposition aux radiations lors de la TEP, il est essentiel de parvenir à générer des images de qualité diagnostique optimale en utilisant des doses de radiotraceurs extrêmement faibles, tout en préservant l'exactitude du diagnostic clinique. Afin de remédier à cette problématique complexe et peu efficace avec les approches traditionnelles, Junshen Xu et al [92] suggèrent l'adoption d'une méthode d'apprentissage profond fondée sur un réseau résiduel de type encodeur-décodeur intégrant des connexions résiduelles par concaténation. Cette méthode, améliorée par l'exploration de diverses fonctions de coût et l'adoption d'une stratégie d'entrée multi-couches pour renforcer la résistance au bruit, a prouvé sa supériorité par rapport à la référence actuelle. L'analyse des données cliniques à très faible dose démontre que la méthode est apte à générer des images de qualité similaire à celles obtenues avec la dose standard.

### **3.3. Amélioration de la résolution spatiale en médecine nucléaire**

En plus des méthodes de reconstruction basées uniquement sur l'apprentissage profond, des approches hybrides combinant l'intelligence artificielle avec des méthodologies traditionnelles ont émergé comme des alternatives potentielles. Ces approches hybrides intègrent les avantages des algorithmes conventionnels, tels que la résilience de la reconstruction itérative, avec la capacité d'apprentissage des réseaux neuronaux, ce qui se traduit par une fidélité d'image améliorée, une réduction de bruit supérieure et des exigences de traitement diminuées. Les méthodes hybrides améliorent la qualité des images en intégrant des modèles

d'apprentissage profond dans des cadres de reconstruction conventionnels, offrant ainsi un compromis pratique qui préserve l'interprétabilité et la fiabilité des techniques classiques [93].

De nombreuses études ont été menées dans ce domaine ; nous faisons référence à la recherche de Dong Yun Lee et al [94], qui présentent un modèle de super-résolution basé sur CNN utilisant un ensemble de données pour améliorer la résolution de l'image. Au cœur de ce système se trouve un bloc d'auto-attention convolutionnel (CSAB), qui combine l'attention de canal et l'attention spatiale (mettant en évidence les caractéristiques spatiales haute fréquence via une convolution à un seul canal). L'attention intégrée optimise l'extraction des caractéristiques, ce qui permet d'obtenir des images de super-résolution de haute qualité.

Lim B et al propose L'EDSR [95], une méthode basée sur l'apprentissage profond pour la génération d'images haute résolution qui utilise un réseau neuronal profond et robuste. Néanmoins, l'EDSR améliore davantage la structure des blocs résiduels et utilise un champ réceptif plus large pour générer des images haute résolution plus précises et naturelles. Cela permet l'extraction de plus de détails à haute fréquence. La complexité accrue de la structure EDSR peut entraîner de nombreux paramètres, des besoins élevés en ressources.

Kim J et al propose le VDSR [96], une architecture de réseau neuronal profond pour générer des images haute résolution en apprenant les résidus entre les images basse et haute résolution. Cela permet d'extraire des détails haute fréquence à partir d'images d'entrée de basse résolution afin de générer des images haute résolution. L'utilisation d'un réseau profond dans VDSR accroît le risque de surapprentissage et nécessite souvent une grande quantité de données d'entraînement. De plus, les processus d'entraînement et d'inférence de VDSR peuvent être intensifs en termes de calcul et prendre beaucoup de temps.

Une méthode de super-résolution auto-supervisée (SSSR) pour la TEP a été mise au point par Tzu-An Song et al [97], s'appuyant sur des GANs bifaces. Cette technique présente un atout majeur : elle ne requiert pas de couples d'images d'apprentissage cliniques (basse résolution BR / haute résolution HR). Le modèle exploite l'image TEP BR et HR du patient, incorporant des attributs déduits d'un CNN déjà entraîné sur des simulations. Cette méthode offre un moyen significatif d'améliorer la qualité de l'image TEP (résolution et bruit) pour la neuro-imagerie, en surmontant le défi de la pénurie des données annotées.

Guangtong Yang et al [98] ont suggéré une approche d'apprentissage quasi-supervisé pour surmonter la contrainte majeure de la TEP (résolution faible), sans besoin des paires d'images haute et basse résolution (HR/BR) requises par les techniques supervisées. Ce mode d'apprentissage faiblement supervisé innovant surmonte le défi de la pénurie de données

cliniques en identifiant et en associant les patches d'images HR les plus comparables issus d'autres patients pour attribuer des étiquettes aux patches BR du patient présent. En utilisant cette ressemblance comme donnée préalable, les auteurs ont apporté des modifications à un réseau CycleGAN pour la super-résolution (SR) de la TEP. Leurs données expérimentales et numériques prouvent que cette méthode novatrice dépasse l'état de la technique en rehaussant la qualité des images TEP.

Yoshimura A. et al [99] ont tenté de vérifier si l'approche de super-résolution (SR) basée sur l'apprentissage profond peut préserver la qualité des images TEP tout en réduisant le temps d'acquisition de moitié, ce qui pourrait minimiser la quantité du traceur et l'exposition aux radiations. Les auteurs ont mis en parallèle les images obtenues formé grâce à une validation croisée sur 108 patients. En termes quantitatifs, les images SR-PET ont obtenu d'excellents indices de similarité structurelle (SSIM=0,931). Subjectivement, les images SR-PET ont montré une qualité significativement améliorée par rapport aux images 50% TEP et étaient très proches des images 100% TEP. La recherche conclut que l'utilisation de la SR par apprentissage profond constitue une technique efficace pour diviser par deux le temps d'acquisition (ou la dose administrée), tout en maintenant la qualité de l'image pour le diagnostic.

Sijin Ren et al [100] ont proposé une méthode de super-résolution (SR) destinée à l'imagerie TEP, dans le but de remédier à sa résolution intrinsèque limitée et aux problèmes de quantification associés. Ils utilisent une méthode basée sur un réseau d'apprentissage profond formé à partir d'images TEP de haute résolution (HR) issues du scanner HRRT, ainsi que leurs homologues simulés en basse résolution (BR). Suite à l'entraînement, le modèle, enrichi par des méthodes d'amélioration de données, a prouvé son efficacité : il a grandement optimisé la résolution et la qualité générale des images BR.

Kennedy et al [101] ont présenté une technique de super-résolution (SR) destinée à rehausser la résolution spatiale des appareils TEP cliniques, sans nécessiter d'altération matérielle ni d'intensification de l'exposition aux radiations du patient. La technique SR, validée sur un modèle fantôme, a permis de résoudre des structures de 3 mm en axial, offrant ainsi un contraste amélioré dans les images coronales et 3D. Cette nouvelle stratégie a été conçue et approuvée dans le but d'optimiser la résolution des images TEP en utilisant les potentialités de décalage des appareils cliniques déjà existants.

Mingdong Liu et al [102] ont entrepris de relever le défi d'amélioration continue de la résolution en TEP. Pour réaliser cela, les auteurs ont utilisé un modèle de GAN pour effectuer

la super résolution de l'image TEP. Ils utilisent des méthodes d'optimisation sophistiquées, pour assurer la stabilité de l'entraînement du GAN. Les tests expérimentaux ont validé l'efficacité de cette approche, montrant une ressemblance structurale de l'image finale supérieure à 60% par rapport à l'image référentielle en haute définition.

Tandis que Limin Ma et al [103] ont suggéré une approche basée sur un réseau antagoniste génératif multi-tâches afin de résoudre les deux enjeux majeurs du nombre restreint de photons et de la résolution limitée des images TEP, indispensables pour le diagnostic et l'investigation en médecine nucléaire. Grâce à l'apprentissage supervisé, leur technique combine la réduction du bruit et l'amélioration de la résolution des images TEP de faible qualité. Des essais réalisés avec des données cliniques ont prouvé que leur méthode offre des performances quantitatives et qualitatives supérieures aux techniques de pointe actuelles pour optimiser la qualité d'image en tomographie par émission de positons.

#### **4. Conclusion**

Dans ce chapitre nous avons présenté l'ensemble de méthode de simulation, de reconstruction et d'apprentissage profond que nous avons adopté pour l'amélioration de la qualité d'image en médecine nucléaire.

Ce chapitre a été une introduction vers le prochain chapitre qui va présenter en détails l'architecture de notre modèle proposé ainsi que les différentes étapes que nous avons suivies afin d'arriver aux résultats obtenus et d'ajouter un plus dans le domaine de la reconstruction d'image et l'intelligence artificielle.

# **Chapitre III :**

## **Cadre expérimental et méthodologique**

## 1. Introduction

L'intelligence artificielle a démontré sa force en tant qu'outil puissant dans divers secteurs, révolutionnant la recherche en matière d'apprentissage automatique. Toutefois, l'insuffisance permanente de base de données d'entraînement en médecine nucléaire demeure un défi persistant qui nuit à la performance et à la flexibilité des modèles d'apprentissage profond.

Afin de résoudre ce problème de disponibilité et d'insuffisance de base de données une technique innovatrice d'apprentissage profond a été employée dans cette thèse, c'est une méthode d'apprentissage automatique qui permet d'exploiter et de réutiliser un modèle pré-entraîné sur une tâche source (souvent basée sur une grande base de données primaire), afin de bénéficier des connaissances et des caractéristiques qu'il a déjà apprises.

Ce chapitre a pour but la présentation des méthodes proposées dans cette thèse en commençant par la structure du code de simulation utilisé par le logiciel de simulation, sa configuration, la définition et le rôle de chaque classe ainsi que l'enregistrement du modèle et contrôle de données. Cette partie a été bénéfique pour l'étude et la comparaison des interactions de multiples particules avec le détecteur. Ensuite nous abordons la partie d'amélioration de la qualité de l'image avec un réseau GAN très performant appliqué sur les sinogrammes avant la reconstruction de l'image finale. Le modèle entraîné sera ensuite enregistré et appliqué sur notre base de données TEMP à l'aide de la technique du transfert d'apprentissage permettant ainsi un résultat impeccable sur une base de données réduite.

L'amélioration de la résolution spatiale est étudiée grâce à un algorithme GAN basé sur RCAN, en gardant le même modèle GAN mais en modifiant son cœur qui est le générateur en un générateur basé sur RCAN grâce à ses mécanismes d'attention de canal, il priorise et utilise intelligemment les informations structurelles.

Les différents blocs de ce modèle seront présentés et décrits dans cette partie afin de mieux comprendre son fonctionnement dans l'amélioration de la résolution spatiale.

## 2. Matériels et logiciels

Notre travail repose sur la méthodologie du transfert d'apprentissage. Cette approche nous a permis d'exploiter un modèle pré-entraîné sur une vaste base de données primaire (TEP), un processus qui a initialement nécessité une station de calculs très performante pour extraire des caractéristiques génériques et robustes, et l'appliquer sur une deuxième base de données (TEMP).

## 2.1. Base de données

La base de données utilisée dans cette étude comprend des images médicales au format DICOM, obtenues à partir du site web *Image and Data Archive* (IDA) [104].

Les images ont été préparées en les convertissant en sinogrammes via la transformée de Radon. Le traitement des données à ce niveau fondamental permet au réseau GAN d'apprendre à atténuer le bruit et les artefacts inhérents au processus d'acquisition. Cela conduit à une préservation plus efficace des détails structurels et à une image finale plus nette, par rapport à d'autres méthodes d'amélioration où certaines informations pourraient déjà être perdues ou effacées.

La base de données se compose d'images cérébraux avec une résolution de  $128 \times 128$  et inclut des exemples présentant des niveaux de complexité et des conditions de bruit variés. La base de données est partitionnée en trois sous-ensembles : 70% alloués à l'entraînement, 15% à la validation et 15% au test. Cette base de données est essentielle au développement et à la validation des méthodes proposées pour l'amélioration des sinogrammes et la reconstruction d'images.

La base de données utilisée pour cette étude est un ensemble d'images TEP et TEMP provenant de cohortes de recherche clinique et institutionnelle. Cette section détaille la composition et les caractéristiques cliniques et techniques des données utilisées.

### 2.1.1. Base de données TEP

Les sujets sont identifiés par un identifiant unique, et leurs données sont collectées de manière longitudinale. Les principales caractéristiques de la base de données TEP sont présentés par les points suivants :

- **Taille de la base de données** : L'ensemble de données initial se compose de 36 853 jeux d'images.
- **Modalité d'imagerie** : Tomographie par Émission de Positons (TEP).
- **Sexe** : Les données incluent les deux sexes (masculin et féminin).
- **Type de données** : Données dédiées à la recherche sur le cerveau et les maladies neurodégénératives.
- **Âge** : Les âges des sujets varient de 51 ans à 77 ans.
- **Equipements** : Les données proviennent de différents équipements, principalement Siemens, Philips, et GE Medical Systems. La diversité des machines est un avantage,

car cela rend le modèle d'amélioration moins dépendant du bruit spécifique d'un seul scanner.

- **Radio-isotope principal** : L'isotope utilisé pour la TEP est le Fluor-18 (F-18).
- **Épaisseur de coupe** : L'épaisseur des coupes varie, notamment entre 2.0 mm et 3.3 mm.
- **Durée d'acquisition** : Les acquisitions impliquent des durées d'acquisition de 16 seconds jusqu'à 4 minutes.

Les images TEP sont caractérisées par une diversité de machines et de protocoles, ce qui garantit la robustesse du modèle d'apprentissage profond face à la variabilité clinique.

### 2.1.2. Base de données TEMP

Les sujets sont identifiés par un identifiant unique, et leurs données sont collectées de manière longitudinale. Les principales caractéristiques de la base de données TEMP sont présentées par les points suivants :

- **Taille de la base de données** : L'ensemble de données initial se compose de 500 jeux d'images.
- **Modalité d'imagerie** : Tomographie par Émission MonoPhotonique (TEMP).
- **Sexe** : Les données incluent les deux sexes (masculin et féminin).
- **Type de données** : Données dédiées à la recherche sur le cerveau et les maladies neurodégénératives.
- **Durée d'acquisition** : Les acquisitions impliquent des durées d'acquisition de 30 à 45 minutes.
- **Âge** : Les âges des sujets varient de 67 ans à 71 ans.
- **Équipement** : Utilisation d'une gamme de caméras gamma Siemens.
- **Radio-isotope principal** : l'Ioflupane marqué à l'Iode-123 (123I-Ioflupane), souvent commercialisé sous le nom de marque DaTscan.

## 2.2. Station de calculs

La station de calculs utilisée dans ce travail est une configuration de pointe et extrêmement puissante, conçue pour les tâches les plus exigeantes comme le calcul intensif et l'apprentissage profond. Elle est équipée des éléments matériels suivants :

### 2.2.1. Composants principaux

Le tableau III.1 présente une description détaillée sur les composants principaux de la station de calculs utilisée dans ce travail de thèse.

**Tableau III.1** : Composants principaux de la station de calculs.

Composant	Détails
<b>Processeur (CPU)</b>	Intel Core i9-13900K (13 <sup>e</sup> génération, Raptor Lake). Un CPU extrêmement performant avec 8 cœurs P (Performance) et 16 cœurs E (Efficacité), pour un total de 24 cœurs physiques et 32 threads. Il dispose d'un grand cache L3 de 36 Mo.
<b>Carte mère</b>	MSI MAG Z790 TOMAHAWK MAX WIFI (MS-7 <sup>E</sup> 07), utilisant le chipset Intel Z790. Une carte mère moderne supportant le DDR5 et idéale pour le surcadencage.
<b>Mémoire vive (RAM)</b>	128 Go de type DDR5 (4 barrettes de 32 Go chacune) parfaite pour les charges de travail exigeantes qui nécessitent d'énormes jeux de données (comme la simulation ou l'apprentissage profond).
<b>Carte graphique (GPU)</b>	NVIDIA GeForce RTX 4090. C'est la carte graphique la plus performante de la gamme NVIDIA Ada Lovelace. Elle est équipée de 23,69 Go de mémoire GDDR6X avec un bus de 384 bits. Cette GPU est indispensable pour les tâches de calcul (CUDA/OpenCL).

### 2.2.2. Stockage

La configuration utilise une combinaison de disques pour optimiser la capacité et la vitesse, elle dispose d'au moins 2 To de stockage ultra-rapide pour des performances optimales. Le tableau III.2 décrit les performances de la station de calculs.

**Tableau III.2** : Performances des disques de la station de calculs.

Disque	Type/Modèle	Capacité	Rôle
<b>Disque 0 &amp; 1</b>	HDD(SATA)	/	Stockage de masse, sauvegardes.
<b>Disque 2</b>	SSD NVMe M.2 (Dahua C900)	512 Go	Applications, jeux, ou fichiers de travail rapide.
<b>Disque 3</b>	SSD NVMe M.2 (WD Black Gen4)	1 To	Disque système principal (système d'exploitation et applications critiques).
<b>Disque 4</b>	SSD NVMe M.2 (Dahua C900)	512 Go	Stockage secondaire rapide.

L'association du i9-13900K avec 128 Go de RAM DDR5 et une RTX 4090 en fait une machine capable de gérer absolument n'importe quelle charge de travail professionnelle avec une aisance remarquable. Le système de stockage est également très bien optimisé avec une utilisation intensive des SSD NVMe. Ce qui a facilité l'entraînement de notre modèle.

### 2.3. Logiciels de programmation

Durant la réalisation de ce travail, nous avons utilisé plusieurs logiciels de programmation et de simulation tels que GEANT4, MATLAB et PYTHON. L'utilité et la performance de chaque logiciel est décrite dans cette partie.

#### 2.3.1. GEANT4

GEANT4 (GEometry ANd Tracking (version 4)) est un logiciel qui utilise la méthode de simulation Monte Carlo et est renommé à l'échelle mondiale pour sa capacité à modéliser le trajet des particules à travers la matière. Élaboré grâce à une collaboration internationale avec Organisation Européenne pour la Recherche Nucléaire (CERN), cet instrument est indispensable dans le domaine de la physique nucléaire et des hautes énergies. Le CERN, où se trouve l'accélérateur LHC, a conduit à la création de GEANT4 pour modéliser avec précision le comportement des particules et la réaction des détecteurs. Ce qui a facilité la modélisation numérique des interactions entre les particules ionisantes et la matière.

Dans le cadre de cette recherche, on a employé la version GEANT4.11.0. Cette version majeure introduit des améliorations notables en termes de précision des modèles physiques et d'efficacité de calcul, assurant l'emploi des méthodes de simulation les plus actuelles [105].



**Figure III.1** : Logo du logiciel GEANT4.

#### 2.3.2. MATLAB (R2020a)

MATLAB (Matrix Laboratory) R2020a est un environnement de programmation et de calcul numérique de MathWorks. Dans cette thèse, son utilisation a été essentielle pour la mise au point et la comparaison rigoureuse des algorithmes de reconstruction d'images classiques, à savoir les méthodes analytiques et les méthodes itératives.

Matlab a été l'environnement de référence pour implémenter ces algorithmes avec des fonctions optimisées et ainsi comparer directement et quantitativement leurs performances

(vitesse de calcul, précision, bruit) avec les méthodes d'apprentissage profond mises en place. Son puissant environnement d'analyse de données et de visualisation a été utilisé pour le traitement des sinogrammes, l'exécution des boucles itératives, la manipulation des matrices de projection et, enfin, la production des métriques de qualité d'image pour la validation des résultats [106].



**Figure III.2 :** Logo du logiciel MATLAB.

### 2.3.3. PYTHON (SPYDER 5.5.1)

Le langage de programmation PYTHON a été utilisé pour le prétraitement des données complexes et le développement d'algorithmes spécialisés, notamment pour la gestion des fichiers d'entrée/sortie et l'application de traitements statistiques avancés. L'efficacité de Python repose sur l'utilisation des bibliothèques clés du calcul scientifique : NumPy pour la manipulation performante des tableaux et opérations numériques ; SciPy pour les fonctions scientifiques avancées (optimisation, intégration) ; et Matplotlib pour la visualisation graphique personnalisée des résultats.

L'ensemble du développement Python a été effectué au sein de SPYDER (version 5.5.1), un Environnement de Développement Intégré (IDE) spécifiquement conçu pour la science des données. SPYDER a fourni un environnement optimisé avec un éditeur multifenêtre, une console interactive et un explorateur de variables, facilitant grandement le développement, l'exécution et le débogage des scripts utilisés pour les analyses [107,108].



**Figure III.3 :** Logo du logiciel ANACONDA et son éditeur SPYDER.

### 3. Méthodes proposées


Dans le cadre de cette étude, plusieurs approches sont utilisées et combinées pour améliorer la résolution spatiale en imagerie nucléaire, depuis la modélisation physique des processus d'acquisition jusqu'à l'application de techniques avancées d'apprentissage profond. La méthodologie se décompose en trois grandes parties.

Tout d'abord, une simulation de l'interaction des particules avec le détecteur est réalisée. Cette étape permet de reproduire fidèlement les phénomènes physiques fondamentaux impliqués dans la détection des rayonnements. Ensuite, une architecture de méthode d'amélioration basée sur l'apprentissage profond est conçue spécifiquement pour traiter les caractéristiques uniques des images en imagerie nucléaire, telles que le faible rapport signal-sur-bruit et la résolution limitée. Cette architecture exploite des mécanismes de traitement hiérarchique pour restaurer les détails fins tout en préservant la cohérence structurelle. Enfin, afin d'optimiser les performances avec un entraînement plus efficace et moins coûteux, une stratégie de transfert d'apprentissage est mise en œuvre, et un modèle innovant de GAN basé sur RCAN, qui intègre les avantages du réseau générateur attentionnel (RCAN) et du GAN proposé pour maximiser la qualité de la super-résolution, en particulier dans les régions anatomiques critiques.

#### 3.1. Simulation de l'interaction des particules avec le détecteur

A l'aide du logiciel de simulation GEANT4, nous avons réalisé une simulation Monte Carlo de la réponse du détecteur (scintillateur) face à un rayonnement ionisant (photon gamma), ce qui constitue une étape fondamentale dans la conception de tout système d'imagerie nucléaire (TEP ou TEMP) ou de détection de rayonnement.

La figure III.4 représente une simulation de paires de photons dans un scintillateur à l'aide du logiciel GEANT4.



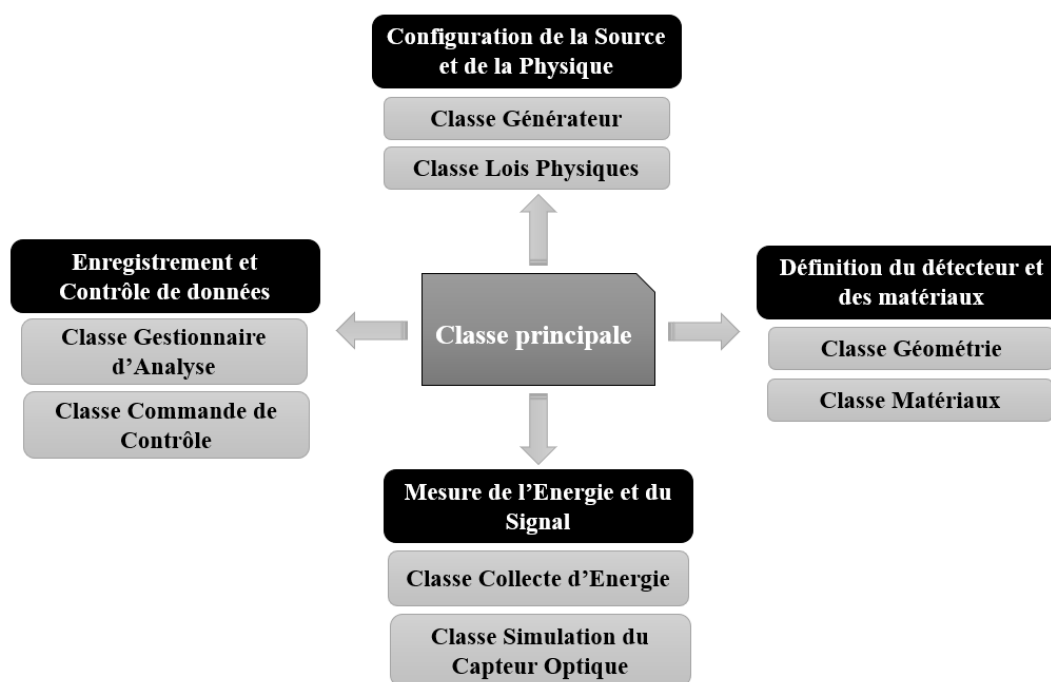
**Figure III.4 :** Exemple de simulation de photons par un scintillateur modélisé à l'aide de GEANT4.

Il s'agit d'une analyse de faisabilité et d'optimisation du système de détection. En explorant différentes géométries et matériaux par simulation, il est possible d'identifier la configuration offrant le meilleur compromis entre résolution énergétique et efficacité de détection, avant de procéder à la fabrication physique du détecteur, généralement coûteuse et exigeante en ressources.

Le code simule la détection de rayons gamma de haute énergie émis par différents isotopes, en provenance d'une source radioactive située à quelques centimètres de distance.

Le but est de modéliser le fonctionnement complet d'un détecteur complexe à scintillation afin d'analyser ses performances en termes de spectre d'énergie, de résolution spatiale et de résolution temporelle.

La figure III.5 représente le schéma récapitulatif des différentes classes du code de simulation utilisé par GEANT4.



**Figure III.5 :** Architecture des classes de la simulation.

### A. Configuration de la source et de la physique

La simulation réaliste du processus de détection en imagerie nucléaire repose sur une modélisation rigoureuse de la source radioactive et des phénomènes physiques fondamentaux régissant l'interaction des particules avec la matière. Deux composantes clés permettent de structurer cette étape : d'une part, la génération contrôlée des particules émises par la source, et d'autre part, l'implémentation des lois physiques nécessaires à la propagation et à l'interaction des rayonnements dans le détecteur. Les sections suivantes détaillent

respectivement la conception de la classe générateur, responsable de l'émission des isotopes et de leur positionnement spatial, et celle de la classe lois physiques, qui gère les processus de désintégration, les interactions photon-matière et la réponse scintillante du détecteur.

### **Classe générateur**

Cette classe contient un code qui configure un pistolet à particules afin d'émettre des ions spécifiques, tels que l'iode-131 ou le technétium-99m, couramment utilisés en imagerie nucléaire. La source est positionnée à 20 cm sur l'axe Z, simulant ainsi une géométrie proche, représentative de conditions expérimentales réalistes.

Ces ions sont traités comme des particules primaires, dont la désintégration spontanée est automatiquement gérée par les lois de la physique intégrées au système.

### **Classe lois physiques**

Cette classe regroupe plusieurs fonctions essentielles à la modélisation physique réaliste du processus de détection. Elle inclut une fonction permettant d'initialiser les lois de la physique nécessaires à la simulation complète, ainsi qu'une autre dédiée à la simulation de la désintégration radioactive de l'ion émetteur. Une troisième fonction gère les interactions des photons gamma et des électrons secondaires avec le matériau du détecteur, en prenant en compte les effets Compton et photoélectrique, responsables du dépôt d'énergie. Enfin, une dernière fonction simule la détection proprement dite : elle modélise la production de lumière par scintillation suite au dépôt d'énergie, puis la propagation de cette lumière à travers le cristal (incluant réflexion et réfraction) jusqu'au capteur photosensible.

## **B. Définition du détecteur et des matériaux**

### **Classe géométrie**

Cette classe définit la structure physique du monde simulé. Elle crée les volumes nécessaires, notamment celui du scintillateur en iodure de sodium (NaI), qui représente le détecteur actif, ainsi qu'un volume atmosphérique stratifié présentant un gradient de densité sur une distance de 20 cm, simulant les conditions de propagation entre la source et le détecteur.

La classe fournit également une fonction qui retourne le volume logique du cristal NaI, désigné pour l'accumulation de l'énergie déposée par les photons gamma.

### **Classe matériaux**

Cette classe permet de définir précisément les propriétés physiques et optiques des matériaux intervenant dans la simulation. Elle inclut la caractérisation du cristal scintillateur NaI (masse volumique, composition chimique et indice de réfraction), ainsi que les propriétés

de l'atmosphère (gradient de densité et absorption partielle). Elle gère également les interfaces entre les milieux pour assurer une modélisation réaliste de la propagation de la lumière (réflexion, réfraction, absorption). Ces données sont essentielles pour garantir la fidélité physique de la simulation

### **C. Mesure de l'énergie et du signal**

La précision de la détection en imagerie nucléaire dépend non seulement de la modélisation physique des interactions, mais aussi de la fidélité avec laquelle l'énergie déposée est mesurée et convertie en signal électrique exploitable. Cette section décrit les classes responsables de la collecte de l'énergie déposée dans le cristal scintillateur ainsi que de la simulation de la réponse du capteur optique (PMT). Ensemble, elles permettent de reconstruire le spectre d'énergie et de modéliser le bruit électronique associé à la détection.

#### **Classes de collecte d'énergie**

Cette classe est appelée à chaque étape de propagation des particules dans le détecteur. Elle filtre les dépôts d'énergie et vérifie si l'interaction a lieu dans le volume actif du cristal. Lorsqu'une interaction est détectée, l'énergie déposée par la particule est récupérée et accumulée pour l'événement en cours. Ce processus est répété pour toutes les interactions contributives au sein du même événement. Une fonction dédiée transmet ces contributions élémentaires, qui sont sommées pour former le signal total associé à un photon incident. La valeur finale est enregistrée et utilisée ultérieurement pour construire le spectre d'énergie du détecteur.

#### **Classe de simulation du capteur optique**

Cette classe simule le comportement du photomultiplicateur (PMT) en tenant compte de ses caractéristiques réalistes et permet de modéliser fidèlement le rendement quantique et les fluctuations statistiques inhérentes à la conversion lumière-signal électrique, éléments cruciaux pour évaluer la résolution énergétique globale du système.

### **D. Enregistrement et contrôle des données**

Une simulation Monte Carlo réaliste génère d'importantes quantités de données qui doivent être enregistrées, organisées et analysées efficacement. Cette section décrit les outils mis en place pour gérer le stockage des résultats physiques pertinents (photons, détections, énergie) dans un format standardisé, ainsi que les mécanismes de contrôle permettant d'automatiser les études paramétriques et de visualiser les processus simulés. L'ensemble assure la traçabilité, la reproductibilité et l'efficacité du traitement des données

#### **Classe gestionnaire d'analyse**

Cette classe configure l'enregistrement des données de simulation au format ROOT, un format standard développé par le CERN (Organisation européenne pour la recherche nucléaire) et largement adopté en physique des particules, imagerie médicale et autres domaines scientifiques pour le stockage, l'analyse et la visualisation de grands volumes de données.

Elle crée trois tables principales, chacune dédiée à un type spécifique d'information :

- **Données 0 (Photons)** : Enregistre propriétés individuelles de chaque photon incident, telles que sa position d'émission, son temps de vol, sa direction et sa longueur d'onde. Ces données sont essentielles pour les analyses temporelles et spectrales fines.
- **Données 1 (Détections)** : Stocke les coordonnées spatiales du détecteur ayant réagi, ainsi que le temps de détection. Ces informations constituent la base des algorithmes de reconstruction d'image.
- **Données 2 (Comptage)** : Enregistre l'énergie totale déposée (fEdep) par événement dans le cristal actif. Ces données permettent de construire le spectre gamma et d'évaluer la résolution énergétique du système.

### Commandes de contrôle

Ces commandes permettent de piloter la simulation de manière flexible et automatisée, en particulier pour les études paramétriques visant à optimiser la géométrie ou les matériaux du détecteur. Le script peut être exécuté plusieurs fois en faisant varier un paramètre spécifique (épaisseur du cristal, type de matériau et distance source-détecteur), afin d'en évaluer l'impact sur les performances globales.

Parmi les fonctionnalités clés :

- Une commande active la multi-exécution, exploitant jusqu'à 8 cœurs du processeur pour accélérer significativement le temps de calcul.
- Des commandes de visualisation interactive permettent d'afficher la géométrie du système, les trajectoires des particules et les points d'interaction, ce qui est crucial pour valider la configuration de la simulation et diagnostiquer d'éventuels comportements anormaux.

L'ensemble de ces outils renforce la robustesse, la reproductibilité et l'efficacité de la chaîne de simulation. Une fois la simulation terminée, les données collectées sont utilisées pour

former l'image, qui peut présenter des artefacts ou du bruit enregistré lors des interactions ou au moment de l'acquisition.

Pour cette raison nous proposons dans la partie suivante, une méthode d'amélioration de la qualité d'image basée sur l'intelligence artificielle, appliquée avant la reconstruction de l'image médicale par la méthode OSEM choisie, après étude et comparaison avec les autres méthodes les plus utilisées en médecine nucléaire (FBP et ART), pour son efficacité computationnelle et sa rapidité, en particulier pour la reconstruction tomographique.

### **3.2. Architecture de la méthode d'amélioration basée sur l'apprentissage profond**

La méthodologie s'articule autour d'un pipeline d'amélioration des données de projection basé sur un GAN grâce à sa capacité à apprendre des distributions de données complexes, ce qui est crucial pour générer des détails fins et réduire les artefacts, dont l'objectif est d'améliorer les sinogrammes avant la reconstruction.

Cette section présente le développement et l'application du modèle GAN proposé pour l'amélioration et la reconstruction des images TEP. Une représentation schématique de la méthode proposée est montrée dans la Figure III.6. La méthode implique plusieurs étapes clés : la préparation des données et la transformation initiale du sinogramme, l'amélioration du sinogramme basée sur le GAN, la reconstruction de l'image OSEM et l'évaluation. Le jeu de données d'entraînement, représentant 70 % de la base de données totale, a d'abord été converti en sinogrammes en utilisant la transformée de Radon. Une architecture GAN, reposant sur une structure convolutionnelle profonde, a été appliquée à ces sinogrammes pour les améliorer. Cette architecture comprend un générateur et un discriminateur. Le réseau discriminateur traite les sinogrammes pour différencier les données réelles des données générées, en produisant un score de probabilité via une fonction d'activation Sigmoidale dans sa dernière couche.

Le processus d'entraînement pour les deux réseaux implique l'optimisation de leurs paramètres en utilisant l'algorithme Adam, une méthode adaptative largement utilisée, connue pour son efficacité et sa robustesse. L'entraînement a été effectué pendant 100 époques, permettant aux réseaux d'apprendre et de converger sur l'ensemble des données plusieurs fois. Le générateur est composé de six couches convolutionnelles bidimensionnelles avec une taille de noyau fixe et un rembourrage pour maintenir les dimensions spatiales de l'entrée tout au long du réseau. L'entrée du générateur est un tenseur de dimension  $(N, 1, H, W)$ , cette dimension est modifiée par la première couche convolutionnelle (conv1), suivie d'une normalisation d'instance et d'une fonction d'activation Parametric Rectified Linear Unit

(PReLU), qui offre une meilleure flexibilité par rapport à la ReLU standard. Les autres couches suivent un schéma similaire jusqu'à la connexion résiduelle, où la sortie de la dernière convolution est ajoutée à l'entrée originale du générateur. Cette connexion résiduelle facilite l'entraînement et peut améliorer la qualité des sinogrammes générés en préservant les informations de bas niveau. Au niveau du discriminateur, les sinogrammes générés sont comparés aux sinogrammes réels. Le processus d'entraînement adversaire est guidé par la minimisation des fonctions de perte D-Loss et G-Loss.

Après avoir terminé la phase d'entraînement, la performance du modèle GAN entraîné a ensuite été testée sur un ensemble de données distinct. Les images de test ont d'abord été converties en sinogrammes, puis affinées à l'aide du GAN pour améliorer la qualité et réduire le bruit.

La deuxième étape essentielle est la reconstruction de l'image. Les sinogrammes améliorés sont ensuite reconstruits en utilisant OSEM, qui a été mis en œuvre avec 5 itérations, en utilisant 4 sous-ensembles par itération, où chaque étape de sous-ensemble implique une estimation et une mise à jour multiplicative de l'image, suivie d'un masquage final.

Le choix de la méthode OSEM fait suite à une comparaison des trois méthodes de reconstruction (FBP, ART et OSEM) et à une évaluation des résultats ayant démontré que la méthode OSEM est la plus adaptée et efficace pour notre base de données.

La performance de l'approche proposée combinant l'amélioration du sinogramme par apprentissage profond et la reconstruction OSEM est évaluée en utilisant les métriques du Rapport Signal sur Bruit (PSNR), de la Racine de l'Erreur Quadratique Moyenne (RMSE) et de la Mesure de Similarité Structurale (SSIM).

La figure III.6 illustre l'architecture du modèle GAN proposé.

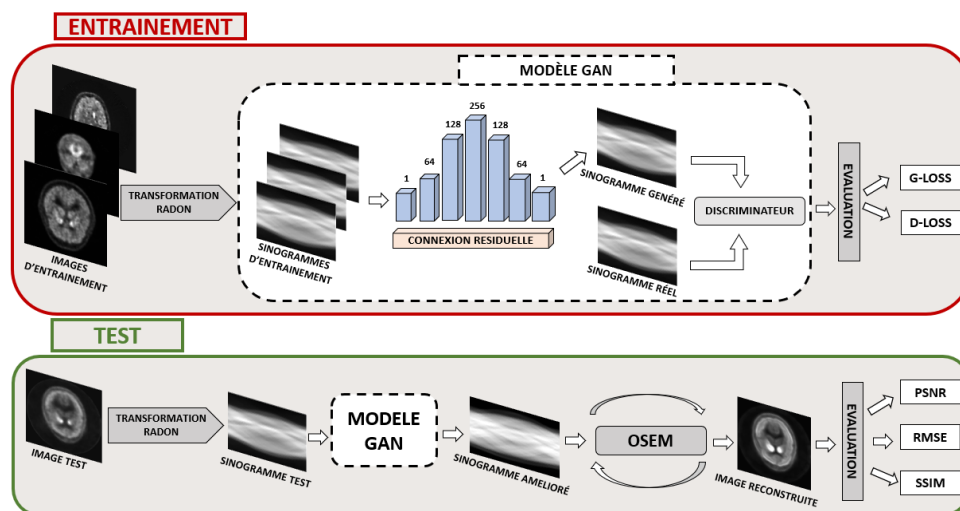


Figure III.6 : Architecture du modèle GAN proposée.

Le modèle utilise une approche séquentielle hybride combinant des outils d'imagerie médicale classique avec l'apprentissage profond.

### 3.2.1 Préparation des données et paramètres

Cette section détaille toutes les étapes nécessaires de l'architecture proposée :

**Type de données :** Une classe est dédiée pour charger des images dans le format médical DCM (DICOM).

**Prétraitement :** Les images sont converties en niveaux de gris redimensionnées uniformément à  $128 \times 128$  pixels. Elles sont ensuite normalisées entre 0 et 1.

**Génération du sinogramme :** Le sinogramme, qui sert de vérité terrain pour l'entraînement, est calculé par la transformée de Radon.

**Format de tenseur :** Le sinogramme est converti en tenseur *PyTorch* et formaté avec une dimension de canal unique ( $\text{BatchSize} \times 1 \times 128 \times 182$ ). Le sinogramme brut est alimenté au générateur. Le rôle du générateur est de créer un sinogramme amélioré qui est plus proche du sinogramme d'entrée initial.

**Reconstruction itérative (OSEM) :** L'implémentation choisie applique explicitement un nombre déterminé d'itérations (5 itérations) pour optimiser la qualité et le raffinement de l'image reconstruite.

**Évaluation finale :** L'image reconstruite est comparée à l'image initiale en utilisant les métriques PSNR, RMSE et SSIM.

### 3.2.2 Modèle générateur

Le générateur possède une architecture optimisée par une fonction de résidu (ou correction) entre le sinogramme d'entrée et le sinogramme idéal.

#### Couches et fonctions d'activation principales

Le modèle générateur repose sur une architecture en profondeur conçue pour restaurer les détails fins du sinogramme. Les composantes principales sont les suivantes :

- **Convolution :** Toutes les couches utilisent un noyau  $3 \times 3$ , préservant ainsi la dimension spatiale du sinogramme tout au long du réseau.
- **Normalisation :** Utilisée après chaque convolution pour stabiliser et accélérer l'entraînement, particulièrement important dans les réseaux profonds.
- **Activation *PReLU* :** Elle est employée car elle permet au modèle d'apprendre de petits coefficients pour la partie négative, améliorant la performance par rapport au *ReLU* standard dans les problèmes de reconstruction.

Le modèle est constitué d'une séquence de couches convolutives, dont les caractéristiques sont détaillées dans le tableau III.3.

**Tableau III.3** : Description des couches composant le modèle générateur.

Couche	Entrée → sortie (Canaux)	Noyau/ Padding	Normalisation/ Activation	Détails Opérationnel
<b>C1</b>	1 → 64	3 x 3 / Padding1	BatchNorm2d+ PReLU	Extraction des caractéristiques de bas niveau.
<b>C2</b>	64 → 128	3 x 3 / Padding1	BatchNorm2d+ PReLU	Augmentation de la dimension pour les caractéristiques intermédiaires.
<b>C3</b>	128 → 256	3 x 3 / Padding1	BatchNorm2d+ PReLU	Dimension maximale des caractéristiques.
<b>C4</b>	256 → 128	3 x 3 / Padding1	BatchNorm2d+ PReLU	Diminution des caractéristiques.
<b>C5</b>	128 → 64	3 x 3 / Padding1	BatchNorm2d+ PReLU	Retour à une dimension plus réduite.
<b>C6 (Finale)</b>	64 → 1	3 x 3 / Padding1	-	Projection finale vers le canal unique de sortie.
<b>Connexion résiduelle</b>	G(Input)	Ajout	-	La sortie permet au réseau d'apprendre la correction nécessaire en accélérant l'apprentissage.

### 3.2.3 Modèle discriminateur

Le discriminateur agit comme un inspecteur, évaluant si un sinogramme donné est une entrée réelle ou une sortie générée du générateur.

#### Fonctionnement et rôle du discriminateur

- **Fonction d'activation** : Le Leaky ReLU est utilisé pour éviter le phénomène de « neurones morts », fréquent avec le ReLU standard. Cette propriété est cruciale pour assurer la stabilité de l'apprentissage dans les GANs.
- **Pooling adaptatif** : Une couche de pooling adaptatif réduit les dimensions spatiales à une taille fixe, indépendamment des dimensions d'entrée. Cela permet au discriminateur de traiter des sinogrammes de tailles variables tout en maintenant une architecture de classification uniforme.
- **Classification finale** : La dernière couche produit un score scalaire passé à travers une fonction sigmoïde, fournissant une probabilité d'authenticité comprise entre 0 (image reconstruite) et 1 (image réelle).

Le modèle utilise un réseau de classification décrits dans le tableau III.4.

**Tableau III.4** : Description des différentes couches du modèle du discriminateur.

Couche	Entrée → sortie (Canaux)	Opération	Normalisation / Activation
<b>D1</b>	1 → 32	Conv 3 x 3	LeakyReLU(0.2)+ Dropout(0.3)
<b>D2</b>	32 → 64	Conv 3 x 3	BatchNorm2d + LeakyReLU(0.2) +Dropout(0.3)
<b>Pooling</b>	64 → 64	AdaptiveAvgPool2d(4 x 4)	-
<b>Classification</b>	1024 → 1	Flatten + Linear	Sigmoid

Le discriminateur est entraîné 5 fois pour chaque entraînement du générateur, une pratique standard des GAN pour garantir que le discriminateur maintient un niveau de compétence suffisant pour fournir des gradients significatifs au générateur.

### 3.2.4. Optimisation

- **Optimiseurs** : Les deux modèles utilisent l'algorithme *Adam* avec un taux d'apprentissage initial de  $10^{-4}$ .

- **Planification du taux d'apprentissage** : Les deux optimiseurs sont gérés pour réduire le taux d'apprentissage de 50% toutes les 10 époques, favorisant une convergence plus stable à mesure que les modèles se rapprochent de l'optimum.
- **Stabilité** : Une fonction est utilisée pour écrêter les gradients à une norme maximale de 1.0, évitant l'instabilité et l'explosion de gradients souvent rencontrées lors de l'entraînement des GAN.

#### 4. Transfert d'apprentissage

L'apprentissage profond s'est imposé comme un outil puissant dans de nombreux domaines de l'analyse d'image, révolutionnant les approches en vision par ordinateur et en imagerie médicale. Toutefois, son application en TEMP reste limitée par la disponibilité restreinte de données d'entraînement de haute qualité, ce qui nuit à la convergence et à la généralisation des modèles. Pour pallier ce manque de données, nous avons recours au transfert d'apprentissage (Transfer Learning), une technique consistant à exploiter les connaissances acquises sur un domaine source (généralement riche en données, comme la TEP ou l'imagerie anatomique) pour améliorer l'apprentissage dans un domaine cible à faible volume de données.

Cette approche permet d'initialiser notre modèle avec des poids pré-entraînés, accélérant ainsi la convergence et améliorant significativement ses performances en reconstruction d'image TEMP [109].

Le transfert d'apprentissage est une méthode qui consiste à réutiliser un modèle pré-entraîné sur un domaine source (généralement riche en données) afin de l'adapter à un nouveau problème similaire. Son objectif principal est d'exploiter les connaissances acquises lors de l'apprentissage initial (telles que la détection de contours, textures ou motifs hiérarchiques) pour accélérer l'entraînement et améliorer les performances dans un domaine cible où les données sont limitées.

Cette approche est particulièrement pertinente dans le contexte du TEMP, où l'acquisition de grands jeux de données est coûteuse et difficile. Elle permet ainsi de contourner les contraintes liées au coût computationnel élevé et à la complexité de l'entraînement de modèles profonds, tout en assurant une bonne convergence même avec peu d'exemples d'entraînement [110].

L'idée de transfert d'apprentissage est intégrée dans l'apprentissage profond en transmettant les savoirs acquis à partir d'autres données ou modèles. En raison de leur remarquable aptitude à extraire des caractéristiques et à réaliser le transfert de domaine, les techniques

d'apprentissage profond par transfert ont suscité un intérêt croissant dans le diagnostic des pannes de roulements ces dernières années [111].

Cette technique nous a permis de développer et d'entraîner notre modèle sur une large base de données TEP afin d'extraire les différentes caractéristiques et informations nécessaires à la reconstruction, pour l'appliquer ensuite à la base de données TEMP contenant peu de données.

Afin d'améliorer la résolution spatiale des images reconstruite et obtenir des images de super-résolution, nous avons proposé une autre architecture du GAN avec un générateur sous forme de RCAN. Cette méthode est détaillée dans la partie suivante.

### **5. GAN basé sur RCAN pour l'amélioration de la résolution spatiale en imagerie nucléaire**

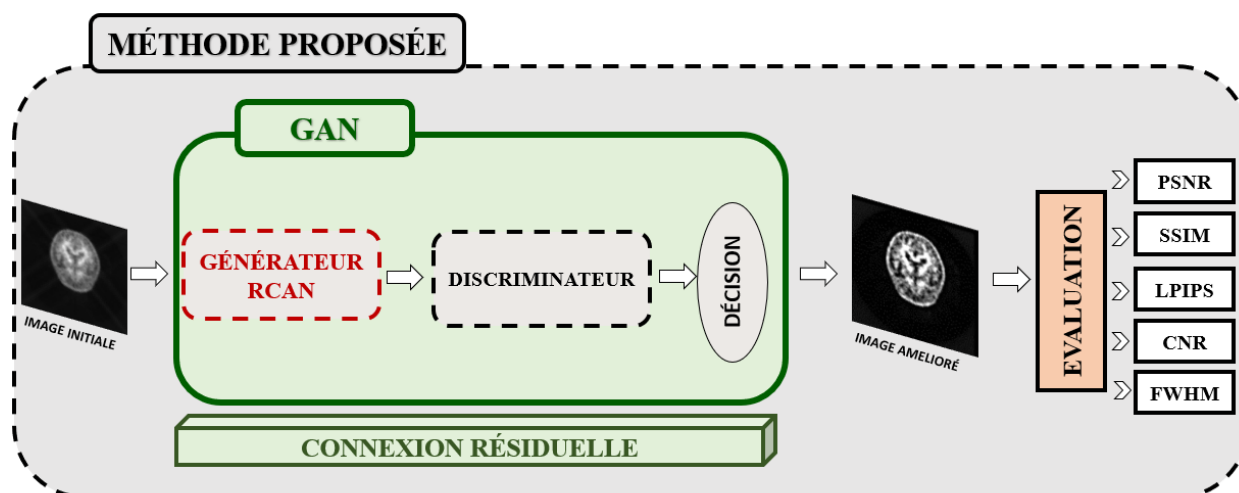
La méthode proposée se concentre sur la super-résolution spatiale des images TEP/TEMP en employant un cadre innovant de GAN avec un Réseau Résiduel avec Mécanisme d'Attention sur les Canaux (RCAN) comme générateur principal, grâce à la guidance morphologique multimodale pour une fidélité structurelle améliorée.

L'innovation réside dans l'intégration spécifique et optimisée des capacités de récupération des détails de RCAN et des pertes adversaires et perceptuelles renforçant le réalisme d'un GAN. En introduisant ces données dans le générateur RCAN du modèle, grâce à ses mécanismes d'attention de canal, priorise et utilise intelligemment cette information structurelle.

Ce processus permet une meilleure délimitation des bords, des formes et des structures dans les images TEP/TEMP super-résolues, en abordant leur faible résolution spatiale inhérente et en produisant des sorties qui ne sont pas seulement améliorées métriquement, mais aussi perceptuellement et structurellement plus fidèles, ce qui est crucial pour le diagnostic médical.

La performance de cette méthode sera rigoureusement évaluée et quantifiée à travers diverses métriques, y compris le PSNR et la SSIM pour la qualité générale de l'image, le CNR pour la détectabilité des caractéristiques à faible contraste, la FWHM pour la résolution spatiale et la netteté, et la LPIPS pour évaluer le réalisme perceptuel.

La méthode proposée est illustrée dans le schéma de la figure III.7.



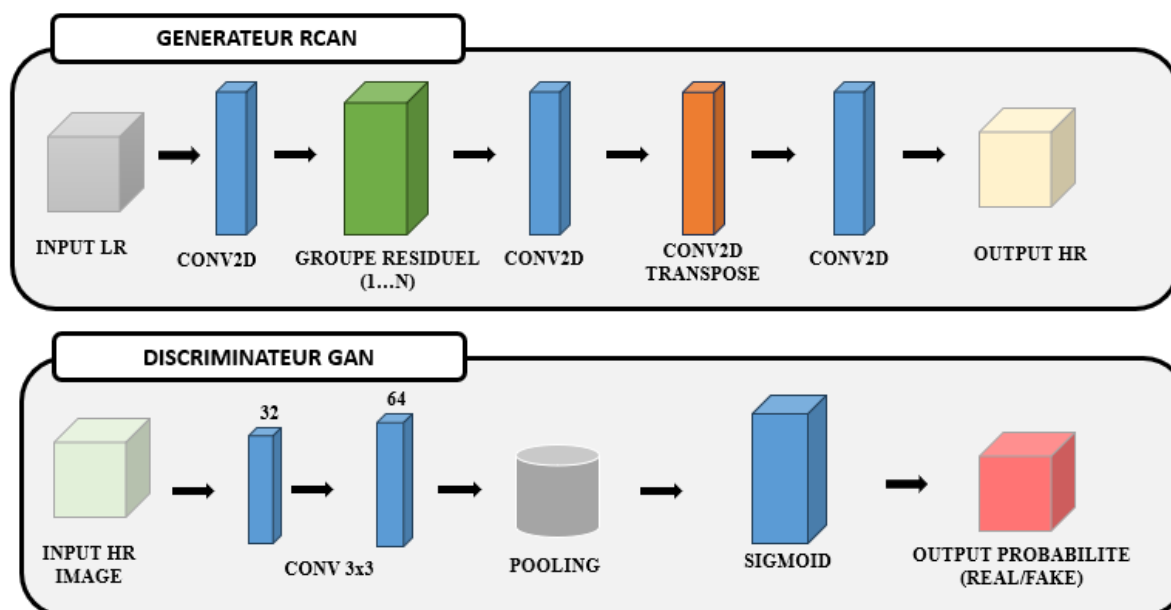
**Figure III.7 :** Architecture du GAN basé sur RCAN proposée.

Ce modèle utilise une architecture d'apprentissage profond basée sur le GAN pour améliorer la résolution spatiale des images DICOM, répondant à un besoin crucial en imagerie médicale. Au cœur du système se trouve un générateur, un réseau inspiré de RCAN conçu pour apprendre la cartographie complexe des images d'entrée à basse résolution (BR) vers leurs homologues à haute résolution (HR), en utilisant des groupes résiduels, des mécanismes d'attention de canal et des convolutions de suréchantillonnage pour affiner progressivement les détails de l'image.

Complétant cela, un discriminateur, structuré comme un réseau de convolution, agit comme un adversaire critique, apprenant à distinguer entre les images authentiquement haute résolution et celles générées synthétiquement.

Le processus d'entraînement est adversaire, avec le générateur s'efforçant de produire des images HR de plus en plus réalistes pour tromper le discriminateur, tandis que le discriminateur affine simultanément sa capacité à identifier les faux ; cet équilibre dynamique, équilibré par des pertes adversaires et de reconstruction pousse le générateur à générer des sorties super-résolues perceptuellement supérieures et quantitativement précises. Les fonctions utilitaires gèrent méticuleusement le chargement des données DICOM, la génération de HR réalistes, et l'évaluation par des métriques telles que PSNR, SSIM, LPIPS, CNR et FWHM, pour une évaluation approfondie des performances du modèle.

La figure III.8 représente un diagramme détaillé du générateur et du discriminateur.



**Figure III.8 :** Modèle détaillé du générateur RCAN et discriminateur GAN.

Le code met en œuvre un réseau antagoniste génératif (GAN) pour améliorer la résolution spatiale d'images médicales. Le générateur est inspiré du RCAN, une architecture qui utilise des mécanismes d'attention par canal pour mieux exploiter les caractéristiques importantes. L'objectif principal est d'entraîner le générateur à transformer une image basse résolution (BR) bruitée en une image haute résolution (HR) réaliste et quantitativement précise. Ce processus simule une amélioration effective de la résolution spatiale, tout en maîtrisant le bruit de comptage inhérent à l'imagerie TEP et TEMP.

Le tableau III.5 présente le rôle de chaque composant du modèle GAN basé sur RCAN.

**Tableau III.5 :** Description du rôle de chaque composant du modèle GAN basé sur RCAN.

Composant	Rôle	Métriques cibles
<b>Générateur (RCAN)</b>	Apprendre la fonction de cartographie BR $\rightarrow$ HR.	PSNR, SSIM, FWHM (amélioration de la résolution).
<b>Discriminateur</b>	Distinction entre les images HR réelles et celles générées.	Réalisme de la texture et des détails fins.

En imagerie nucléaire, l'évaluation de la performance du modèle de Super-Résolution dépasse les métriques informatiques traditionnelles telles que le PSNR et le SSIM, pour s'appuyer sur la validation médicale. Cette étape assure l'amélioration visuelle de la précision quantitative ou du contraste. L'évaluation de l'amélioration de la résolution spatiale s'appuie

sur le calcul de la largeur à mi-hauteur (FWHM) d'un profil d'intensité. Une FWHM plus faible indique un pic plus étroit, traduisant une meilleure capacité du modèle à réduire le flou spatial et à restituer les détails fins.

Parallèlement, le rapport contraste-sur-bruit (CNR) est calculé afin d'évaluer la capacité du modèle à améliorer le contraste des lésions par rapport au bruit de fond. Un CNR accru est essentiel, car il reflète une meilleure détectabilité des structures faibles, critique en diagnostic clinique.

Enfin, la valeur moyenne des pixels dans des régions d'intérêt (ROIs) est analysée pour valider la fidélité quantitative de la reconstruction. Cette mesure garantit que le modèle ne modifie pas artificiellement la concentration d'activité radioactive, information cruciale pour des applications telles que la dosimétrie et le diagnostic quantitatif en TEP.

La performance du modèle repose sur une conception soigneusement équilibrée entre le générateur, chargé de restaurer les détails fins tout en préservant la fidélité quantitative, et le discriminateur, responsable de l'évaluation perceptuelle des images reconstruites. Pour atteindre cet équilibre, une architecture GAN spécifique a été implémentée, où chaque composante joue un rôle distinct mais complémentaire. Les sections suivantes détaillent respectivement l'architecture du générateur basée sur RCAN et son flux de données, puis celle du discriminateur et la logique d'apprentissage antagoniste qui régit leur interaction

### 5.1. Architecture du générateur (RCAN)

Le générateur est conçu pour extraire des caractéristiques profondes et effectuer la reconstruction à haute résolution.

#### A. Blocs fondamentaux

**RCAB (*Bloc d'Attention Résiduel de Canal*)** : L'unité de base. Il se compose de deux couches de convolution et d'une connexion résiduelle. Il intègre le mécanisme d'attention par canal (CA), qui permet au réseau de supprimer les informations redondantes.

**RG (*Groupe Résiduel*)** : Empile plusieurs RCAB et utilise une connexion résiduelle longue pour contourner l'ensemble du groupe, facilitant l'apprentissage.

#### B. Chemin de reconstruction

**Extraction initiale** : Utilise une convolution  $3 \times 3$  pour l'extraction des caractéristiques primitives.

**Apprentissage profond** : Passage à travers la séquence de RG pour modéliser les caractéristiques HR.

**Fusion globale (GFF) :** Une connexion résiduelle globale fusionne le résultat des RG avec les caractéristiques initiales (après la première convolution). Cela garantit que les informations de bas niveau ne sont pas perdues.

**Suréchantillonnage :** C'est l'étape clé qui augmente la résolution spatiale.

**Sortie :** Une convolution 3x3 avec activation linéaire pour produire l'image SR finale à 1 canal.

## 5.2. Architecture du discriminateur

Le GAN utilise une stratégie de perte hybride pour garantir le réalisme de l'image SR. Le modèle suit une structure de classification à base de couches de convolution pour un sous-échantillonnage progressif.

Il utilise l'activation *LeakyReLU* et la *BatchNormalization* pour améliorer la stabilité de l'entraînement.

La sortie finale produit une probabilité que l'image HR d'entrée soit réelle ou fausse.

## 6. Métriques d'évaluation

Plusieurs métriques d'évaluation ont été employés dans ce travail de thèse afin d'évaluer quantitativement les méthodes proposées, parmi ces métriques nous avons : le rapport signal/bruit (PSNR), la racine carrée de l'erreur quadratique moyenne (RMSE), l'indice de similarité structurelle (SSIM), la similarité apprise de patches d'image (LPIPS), le rapport contraste sur bruit (CNR) et la largeur à mi-hauteur (FWHM).

### 6.1. Rapport Signal/Bruit (PSNR)

Le PSNR (*Peak Signal-to-Noise Ratio*) est une métrique largement utilisée pour évaluer la qualité de la reconstruction d'image. Il est appliqué dans cette étude pour mesurer la performance de la méthode proposée en examinant les écarts, pixel par pixel, entre l'image originale et l'image reconstruite. Le PSNR est mesuré en décibels (dB) et est noté comme suit [112] :

$$PSNR = 10 \cdot \log_{10} \left( \frac{MAX_I^2}{MSE} \right) \quad (III.1)$$

Où  $MAX_I$  représente la valeur maximale possible du pixel dans l'image [113].

### 6.2. Racine carrée de l'Erreur Quadratique Moyenne (RMSE)

Le RMSE (*Root Mean Square Error*, RMSE) est une mesure statistique standard utilisée pour évaluer la performance d'un modèle. Elle est calculée comme la racine carrée de la moyenne des différences au carré entre les pixels correspondants des images originale et reconstruite. L'équation du RMSE est la suivante :

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (I_1 - I_2)^2} \quad (\text{III.2})$$

Où  $n$  est le nombre de pixels, et  $I_1$  et  $I_2$  sont les valeurs de pixels correspondantes à l'image originale et l'image reconstruite respectivement [114].

### 6.3. Indice de Similarité Structurale (SSIM)

En tant que mesure basée sur la perception, le SSIM considère la dégradation d'une image comme un changement dans la perception de l'information structurale.

Le SSIM évalue la ressemblance entre l'image originale et l'image reconstruite [115], il est calculé comme suit :

$$SSIM(X, Y) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (\text{III.3})$$

Où  $l(x, y)$  permet la comparaison de luminance,  $c(x, y)$  la comparaison de contraste,  $s(x, y)$  la comparaison de structure et  $\alpha, \beta, \gamma$  représentent les poids attribués à chaque composante [116].

### 6.4. Similarité Apprise de Patches d'Image (LPIPS)

L'indice de similarité LPIPS est une métrique de similarité d'image qui correspond mieux à la perception visuelle humaine que les méthodes plus anciennes comme le PSNR ou le SSIM.

Son principe fondamental est que si ces caractéristiques extraites sont similaires, les humains percevront également les images comme étant similaires. La métrique quantifie cette similarité en calculant une distance euclidienne pondérée entre les caractéristiques normalisées, comme représenté dans l'équation III.4 :

$$d(x, y) = \sum_l \frac{1}{H_l W_l} \sum_{h, w} \|w_l (\phi_l(x)_{h, w} - w_l \phi_l(y)_{h, w})\|^2 \quad (\text{III.4})$$

Où  $X$  et  $Y$  sont les deux images comparées ;  $\phi_l$  représente l'activation issue de la couche  $l$  d'un réseau pré-entraîné ;  $w_l$  sont les poids appris pour chaque couche  $l$ , qui ajustent l'importance des caractéristiques de cette couche ; et  $H_l$  et  $W_l$  sont les dimensions spatiales de la carte de caractéristiques à la couche  $l$  [117].

### 6.5. Rapport Contraste sur Bruit (CNR)

Le CNR est une métrique quantitative utilisée pour évaluer la qualité d'une image en mesurant la capacité à distinguer différentes régions d'intérêt (ROIs) ou tissus par rapport au bruit de fond.

Un CNR élevé indique une meilleure qualité d'image, car il implique une distinction plus nette entre les structures anatomiques ou les pathologies comparées par rapport au bruit inhérent à l'image. Il est crucial pour la détectabilité des lésions ou des tissus à faible contraste. La formulation la plus courante du CNR est :

$$CNR = \frac{|S_A - S_B|}{\delta_{bruit}} \quad (III.5)$$

Où :

$S_A$  : Représente l'intensité moyenne du signal de la Région d'Intérêt A.

$S_B$  : Représente l'intensité moyenne du signal de la Région B de fond.

$|S_A - S_B|$  : la différence absolue entre les intensités moyennes des deux régions.

$\Sigma_{bruit}$  : Représente l'écart-type du bruit, mesuré dans une zone homogène de l'image [118].

### 6.6. Largeur à Mi-Hauteur (FWHM)

La FWHM est une mesure courante utilisée pour déterminer la largeur d'un pic ou d'une fonction, fréquemment employée en imagerie médicale pour quantifier la résolution spatiale. Essentiellement, la FWHM indique la largeur d'une fonction d'étalement du point où l'intensité du signal a chuté de moitié par rapport à sa valeur de crête. Une FWHM plus petite signifie une image plus nette et une meilleure résolution spatiale. Cela indique que le système d'imagerie peut différencier plus efficacement les objets qui sont proches les uns des autres [119].

La FWHM pour une distribution gaussienne est liée à son écart-type ( $\sigma$ ) par la relation suivante :

$$FWHM = 2\sqrt{2\ln(2)} \cdot \sigma \approx 2.355 \cdot \sigma \quad (III.6)$$

Pour un pic général, la FWHM est déterminée en trouvant les deux points ( $x_1$  et  $x_2$ ) situés de chaque côté du pic où la valeur de la fonction est égale à la moitié de son maximum ( $f(x_1) = f(x_2) = 0.5 \cdot f_{max}$ ).

$$FWHM = |x_2 - x_1| \quad (III.7)$$

### 7. Conclusion

Dans ce chapitre nous avons présenté l'ensemble des méthodes et matériels utilisés dans ce travail, en commençant par une description de nos bases de données, ensuite la station de calculs et les logiciels de programmation utilisés, après cela nous avons détaillés les méthodes proposées dans la simulation en médecine nucléaire, dans l'amélioration de la qualité et de la résolution spatiale de l'image, tout en présentant les métriques d'évaluation utilisés.

L'application de transfert d'apprentissage renforce l'architecture performante et l'adaptabilité de notre modèle aux différents caractéristiques spécifiques des modalités similaires, ce qui rend notre méthodologie utilisée dans ce travail de thèse un système puissant à l'aide aux diagnostics et à la prédiction et la modélisation des équipements en imagerie nucléaire.

Les résultats de simulation avec GEANT4, d'amélioration de la qualité d'image ainsi que le résultat du transfert d'apprentissage, seront présentés et discutés dans le chapitre suivant.

**Chapitre IV :**  
**Simulation des systèmes de détection et**  
**validation des méthodes de reconstruction**

## 1. Introduction

Le but de l'étude et l'optimisation des facteurs qui influent sur la qualité d'image en médecine nucléaire concerne principalement les experts de santé dans la facilité de l'interprétation de l'image finale et la détection des pathologies si existantes.

Dans ce chapitre, nous présentons les résultats de l'étude de la résolution en énergie obtenue lors de la simulation des systèmes TEP et TEMP à l'aide du code Monte Carlo GEANT4. Ces simulations permettent de modéliser fidèlement les interactions des photons gamma avec le détecteur, produisant ainsi des signaux bruts représentatifs de l'acquisition réelle. Après traitement par des algorithmes de reconstruction, ces données conduisent à une image de la distribution du radiotracer, reproduisant le fonctionnement d'une gamma caméra ou d'un scanner TEP en conditions cliniques.

Ces simulations réalisées sous GEANT4 permettent une compréhension fine des performances physiques des systèmes TEP et TEMP. Toutefois, dans la pratique clinique, la qualité des images est également conditionnée par les algorithmes de reconstruction et le niveau de bruit des données acquises. C'est pourquoi, dans une seconde approche, nous proposons une chaîne de traitement basée sur l'apprentissage profond, appliquée cette fois à des sinogrammes issus d'une base de données, afin d'améliorer la qualité des images reconstruites.

Le sinogramme extrait d'une base de données, est tout d'abord amélioré à l'aide d'un GAN, dans le but de réduire le bruit et les artefacts avant la reconstruction. Cette approche, que nous désignons par GAN-OSEM, vise à produire un sinogramme de meilleure qualité, servant ensuite de base à une reconstruction itérative par OSEM. L'image obtenue est alors soumise à une seconde étape d'amélioration, basée sur un modèle GAN dont l'architecture du générateur s'inspire du RCAN. Ce dernier permet de restaurer les détails fins et d'améliorer significativement la résolution spatiale. Ainsi, notre chaîne de traitement combine deux modèles de GAN spécialisés : le premier agit pour améliorer les données d'entrée, le second intervient pour affiner la qualité visuelle et diagnostique du résultat final.

## 2. Simulation

La simulation des caméras TEP et gamma repose sur les lois fondamentales de la physique nucléaire, notamment les lois de désintégration radioactive impliquées dans l'émission de photons gamma et de positons. Cette première étape modélise le comportement de la source radioactive, y compris la géométrie de l'émission et le taux de désintégration.

Ensuite, les interactions entre les rayonnements émis et la matière sont simulées selon les lois de l'interaction photon-matière (effet Compton, effet photoélectrique). Ces processus permettent de suivre fidèlement le trajet des photons depuis leur émission jusqu'à leur arrivée au détecteur.

Enfin, les phénomènes liés à la détection sont pris en compte : lorsque le photon interagit avec le cristal scintillateur, la simulation modélise la production de lumière (scintillation), ainsi que sa propagation à travers le milieu (réflexion, réfraction, absorption) jusqu'au photodétecteur (PMT ou SiPM).

L'ensemble de ces étapes constitue une chaîne complète de simulation réaliste, reproduisant le fonctionnement d'un système d'imagerie nucléaire.


## 2.1 Caméra TEP

L'étude de la caméra TEP s'articule autour de trois volets essentiels : la conception du détecteur, la modélisation du milieu traversé par les rayonnements, et la caractérisation de la source radioactive, afin de comprendre et optimiser la formation de l'image en tomographie par émission de positons

### 2.1.1. Structure du détecteur

Afin d'étudier l'interaction des photons avec la matière au niveau de la caméra TEP, nous avons simulé un prototype d'une caméra TEP contenant un scintillateur de type NaI(Tl) (Iodure de Sodium dopé au Thallium) en supposant que la source radioactive est émise du centre de ce cylindre. La géométrie du détecteur se compose de plusieurs blocs de scintillation disposés en rangée autour du centre, chaque bloc est séparé par des matériaux absorbants. Le diamètre interne du cylindre est de 40cm (rayon de 20cm), ce qui représente l'espace dédié à la source radioactive.

La figure IV.1 présente le prototype du détecteur TEP avec un scintillateur NaI simulé par GEANT4.

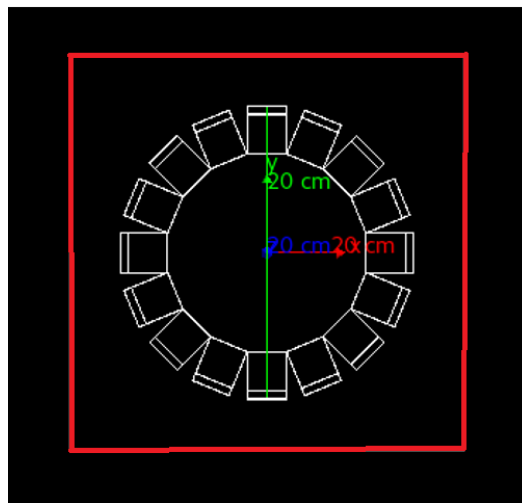


**Figure IV.1** : Prototype du détecteur TEP à base de scintillateur NaI simulé avec GEANT4.

Cette conception facilite la localisation précise du point d'interaction (x, y) sur le détecteur, ce qui est crucial pour la reconstruction de l'image en tomographie par émission de positons (TEP).

### 2.1.2. Modélisation du milieu

Afin d'obtenir des résultats réalistes, nous avons simulés la source radioactive dans un volume qui englobe la source et le détecteur, ce volume est défini avec une faible densité ( $1.29 \text{ kg/m}^3$ ) pour représenter l'air afin de modéliser réellement le transport des photons au moment de l'interaction, comme le montre la figure IV.2.

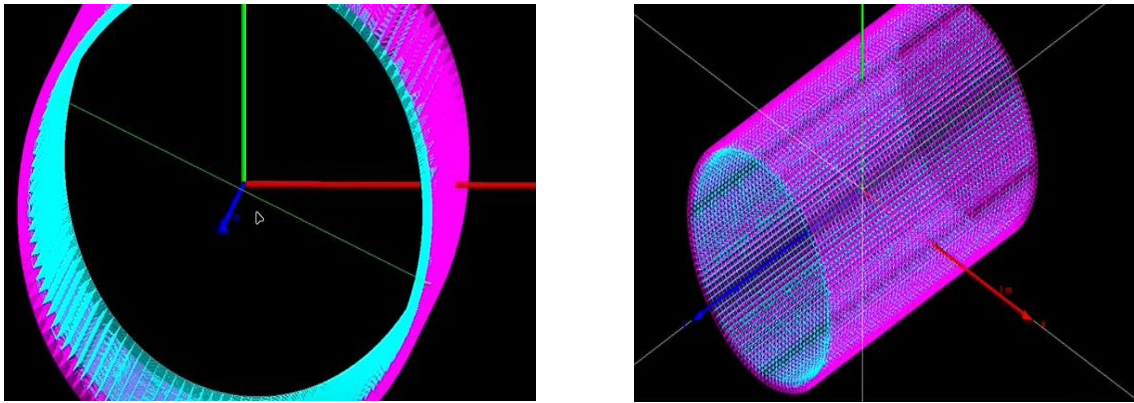


**Figure IV.2 :** Représentation du volume qui délimite le milieu (l'air).

### 2.1.3. Modélisation de la source radioactive


La simulation commence par la désintégration du  $^{18}\text{F}$  qui donne naissance à deux photons gamma de deux directions opposées et ayant chacun une énergie de 511KeV. A ce niveau GEANT4 génère un nombre d'évènements entrés par l'utilisateur afin de représenter les paires de photons émis dos-à-dos, chacun suivant sa trajectoire dans l'air.

Afin d'étudier le dépôt d'énergie des photons gammas au niveau du détecteur, une deuxième simulation à été réalisée. La figure IV.3 représente une caméra TEP équipée d'un scintillateur en NaI(Tl) (en bleu), qui constitue le milieu dans lequel les photons gamma interagissent et déposent leur énergie. Un photomultiplicateur (PMT), représenté en rose, est placé à l'arrière du cristal scintillateur. Cette simulation consiste en l'émission d'un seul évènement générant deux photons gamma d'énergie 511 keV, se propageant en sens opposés, conformément aux lois de la désintégration radioactive en médecine nucléaire [120].



**Figure IV.3 :** Visualisation du scintillateur en NaI (en bleu) et de photomultiplicateur (PMT) (en rose) dans le prototype de caméra TEP.

Pour mieux étudier le dépôt d'énergie et l'effet des interactions particule-matière, nous avons simulé 100 événements émis depuis le centre de la source radioactive, comme le montre la figure IV.4.

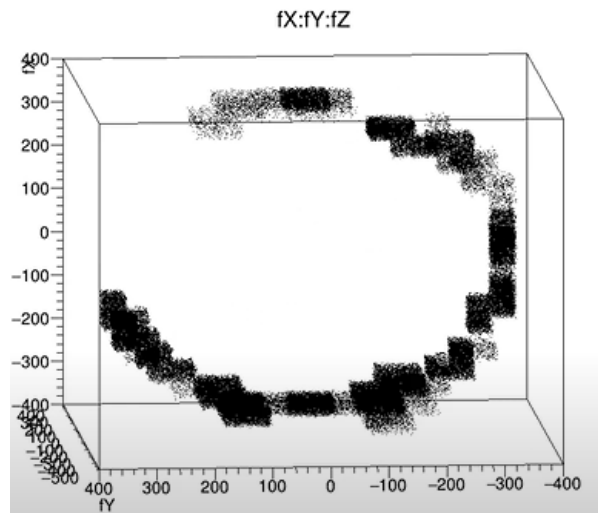


**Figure IV.4 :** Simulation de 100 événements.

Cette quantité de photons est suffisante pour illustrer la géométrie et le principe physique, tout en simplifiant l'étude de la réponse intrinsèque du détecteur.

On peut remarquer sur la figure IV.4 à droite l'effet de la diffusion des photons, à l'origine d'un bruit de fond qui dégrade le contraste et la quantification de l'image. Ce phénomène peut entraîner un dépôt d'énergie partiel et nuire à la résolution énergétique.

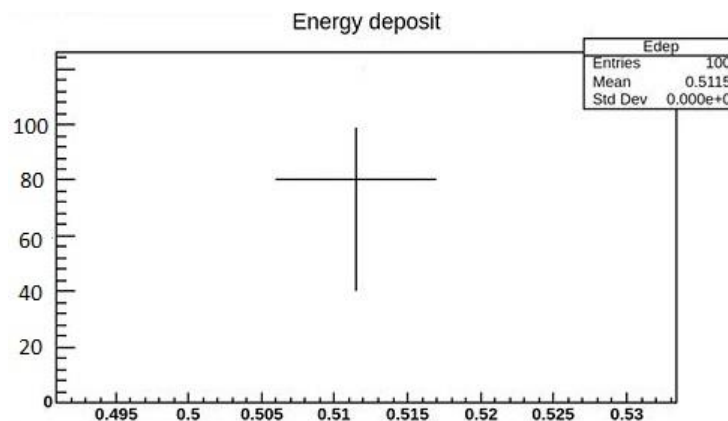
L'enregistrement de ces événements constitue une étape cruciale de la simulation, permettant de déterminer la position d'impact des photons sur le détecteur. La figure IV.5 est une représentation graphique du nuage de points correspondant aux positions des photons détectés.



**Figure IV.5 :** Distribution 3D des dépôts d'énergie dans le scintillateur TEP.

Au moment des interactions, le photon transfère une partie ou la totalité de son énergie au milieu, créant des électrons. GEANT4 suit ces électrons et enregistre l'énergie déposée (l'énergie perdue par les particules) à chaque petit pas de leur trajectoire.

La figure IV.6 représente la valeur moyenne de l'énergie déposée est de 0.5115 MeV, très proche de l'énergie du photon d'annihilation qui est 511 KeV. Les événements de diffusion de photons ont été filtrés dans le cadre de cette simulation, ce qui montre que, parmi les 100 événements simulés, seuls ceux correspondant à une absorption totale ont été retenus. Cette sélection a été effectuée afin d'analyser précisément le comportement du détecteur en conditions idéales, dans le cadre de notre étude.



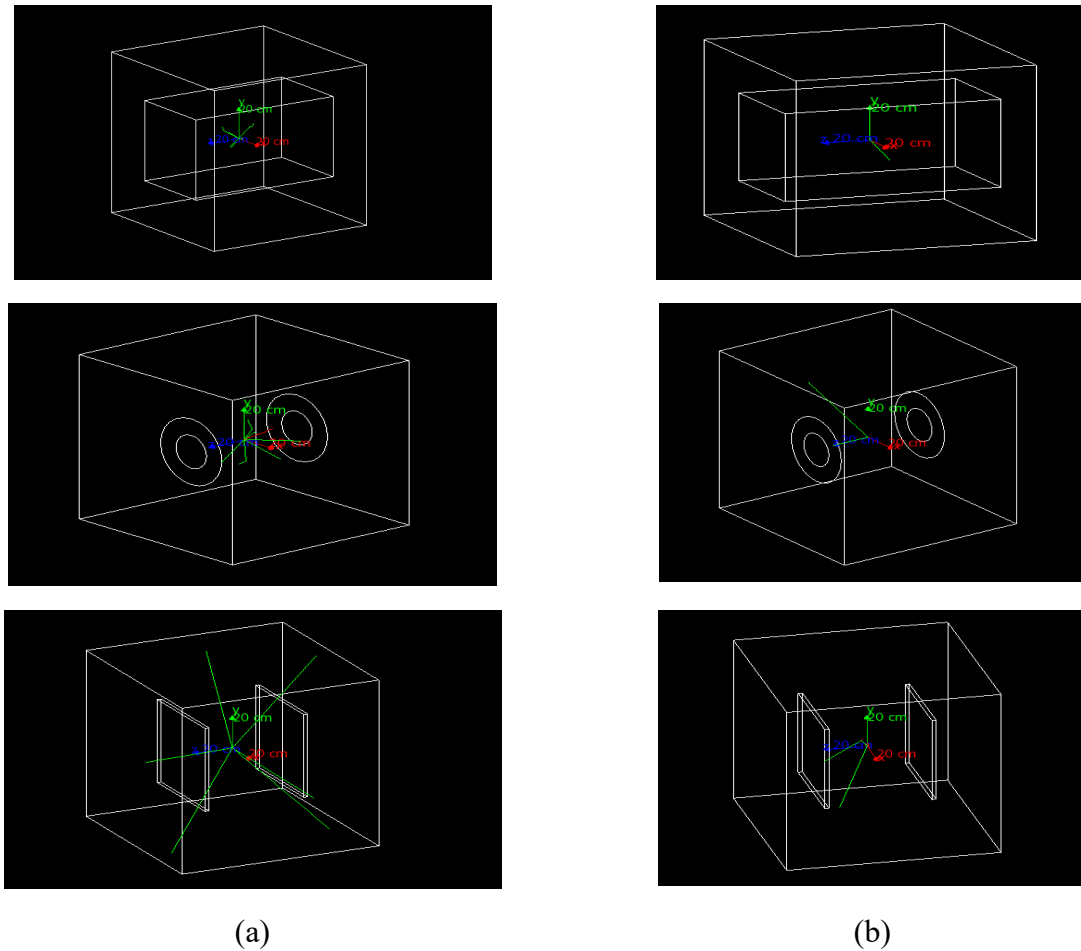
**Figure IV.6 :** Distribution du dépôt d'énergie pour les 100 événements simulés.

Dans cette simulation idéalisée où les fluctuations statistiques sont négligées, l'écart-type du dépôt d'énergie est négligeable, conduisant à une résolution énergétique apparente proche de zéro. En condition réelle, le NaI(Tl) présente toutefois une résolution de 6 à 10 % à 511 keV. Le filtrage strict des événements de diffusion et du bruit électronique permet ici de se concentrer uniquement sur les absorptions totales, justifiant cette amélioration artificielle.

## 2.2 Gamma Caméra

La simulation du prototype gamma caméra sous GEANT4 s'est appuyée sur la comparaison de différents radiotraceurs et géométrie de cristaux scintillateurs, dans le but de modéliser la réponse du détecteur aux rayonnements ionisants.

La figure IV.7 illustre cette Comparaison entre différentes géométries de détecteurs de rayonnement (monoblocs, cylindriques et bidétecteurs) pour deux radionucléides : l'iode-131 (figure IV.7a) et le technétium-99m (figure IV.7b).



**Figure IV.7 :** Comparaison des différentes géométries de détecteurs de rayonnement (rectangulaire monoblocs, cylindriques et rectangulaire bidétecteurs) pour la simulation de (a) l'Iode131 et (b) du TCm99.

Ces différentes configurations géométriques ont été quantifiées afin d'évaluer leur impact sur le dépôt d'énergie. Le tableau IV.1 présente les résultats des paramètres obtenus pour six simulations réalisées avec un cristal scintillateur en NaI(Tl). Chaque ligne illustre l'effet de la géométrie du détecteur et du choix du radiotraceur sur l'étendue du dépôt d'énergie simulé (Edep).

**Tableau IV.1** : Analyse comparative de l'efficacité du dépôt d'énergie (Edep) dans les scintillateurs NaI en fonction de la géométrie et du radiotraceur.

<b>Forme</b>	<b>Particule simulée</b>	<b>Energie nominale (MeV)</b>	<b>Plage Edep (MeV)</b>	<b>Energie moyenne (MeV)</b>	<b>Performance</b>
<b>Rectangulaire (Monobloc)</b> <b>0.25m*0.25m*0.45m</b>	Iode131	0.364	[0.297, 0.364]	0.330	Moyenne très proche de l'énergie nominale (Bonne absorption).
<b>Rectangulaire (Monobloc)</b> <b>0.25m*0.25m*0.45m</b>	TCm99	0.140	[0.133, 0.200]	0.166	Moyenne supérieure à l'énergie nominale (bruit).
<b>Cylindrique</b> <b>10cm, 20cm, 30cm</b>	Iode131	0.364	[0.213, 0.347]	0.280	Moyenne inférieure à l'énergie nominale (Perte de l'énergie).
<b>Cylindrique</b> <b>10cm, 20cm, 30cm</b>	TCm99	0.140	[0.070, 0.14]	0.105	Moyenne légèrement inférieure à l'énergie nominale (bon comportement).
<b>Rectangulaire (Bidéteur)</b> <b>0.25m*0.25m*0.01m</b>	Iode131	0.364	[0.222, 0.666]	0.444	Moyenne nettement supérieure à l'énergie nominale (bruit).

<b>Rectangulaire (Bidétecteur)</b>	TCm99	0.140	[0.14, 0.120]	0.130	Moyenne très proche de l'énergie nominale (très bonne absorption).
<b>0.25m*0.25m*0.01m</b>					

Ces résultats montrent qu'il n'existe pas de géométrie unique optimale pour toutes les énergies. Le monobloc rectangulaire s'avère être le meilleur compromis pour les hautes énergies, car il maximise l'absorption totale grâce à son grand volume actif. En revanche, la configuration à deux rectangles minces est plus adaptée aux basses énergies, car elle offre une meilleure résolution énergétique en limitant les effets de diffusion Compton dans le cristal, tout en assurant une absorption totale efficace du technétium-99m [121].

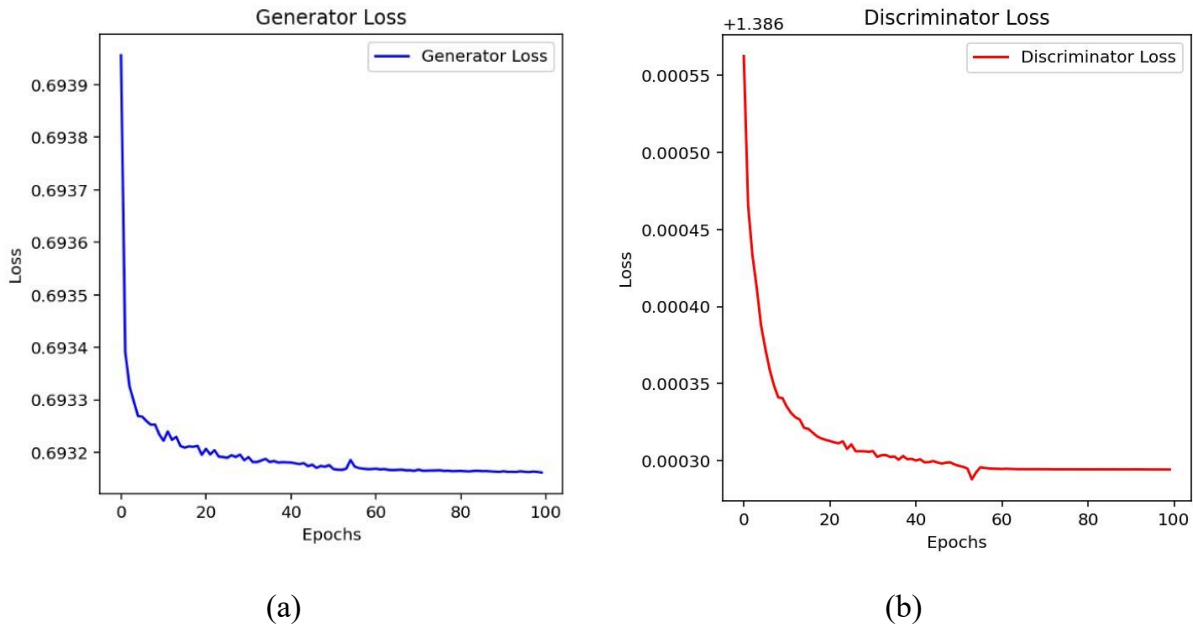
À partir des photons gamma détectés, des signaux électroniques sont générés et enregistrés. Ces données brutes sont ensuite traitées pour former un sinogramme, qui est reconstruit, à l'aide de méthodes de reconstruction tomographique adaptées, en une image représentant la distribution du traceur radioactif dans le volume exploré.

### 3. Amélioration de la qualité d'image

L'amélioration de la qualité d'image en imagerie TEP repose en grande partie sur une optimisation des données brutes en amont de la reconstruction. Une approche prometteuse consiste à intervenir directement au niveau du sinogramme, avant toute reconstruction tomographique. Dans ce cadre, nous avons développé et appliqué une méthode fondée sur l'apprentissage profond, mettant en œuvre des réseaux antagonistes génératifs (GAN), afin d'améliorer la qualité des sinogrammes. L'objectif principal est de réduire le bruit statistique tout en préservant les structures fines et la fidélité quantitative des données, dans le but d'obtenir une image finale caractérisée par une meilleure résolution spatiale et un contraste accru.

#### 3.1. Amélioration du sinogramme avec l'apprentissage profond

Afin d'évaluer la stabilité de l'apprentissage et la convergence de l'architecture GAN proposée, nous avons analysé l'évolution des fonctions de perte du générateur (G-Loss) et du discriminateur (D-Loss) au cours des époques d'entraînement. La figure IV.8a présente la courbe de G-Loss, tandis que la figure IV.8b illustre celle de D-Loss.



**Figure IV.8 :** Évolution des fonctions de perte du générateur (a) G-Loss et du discriminateur (b) D-Loss au cours des époques d'entraînement.

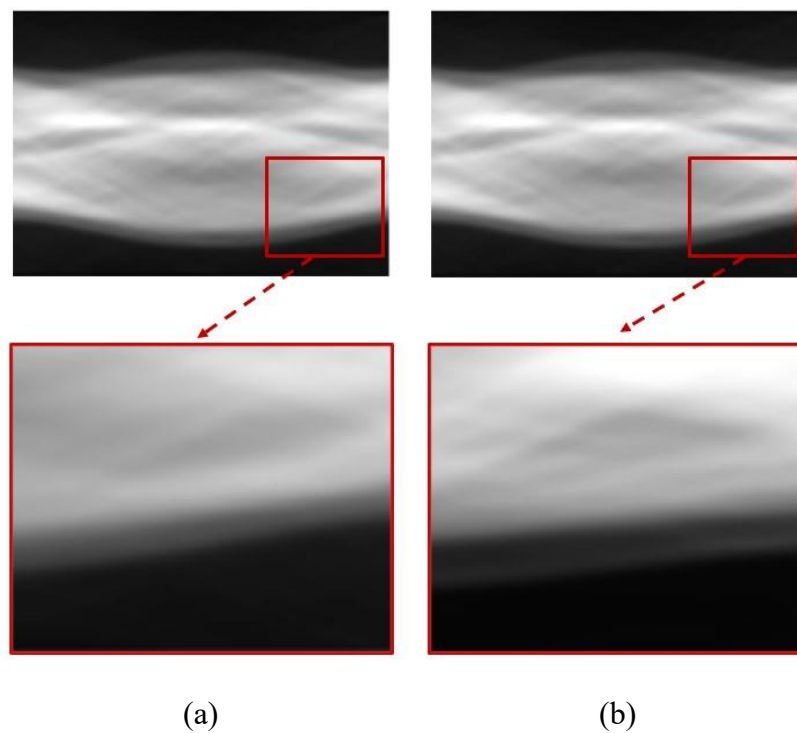
La perte du générateur diminue fortement au début de l'entraînement (entre les époques 10 et 20), puis baisse progressivement avant de se stabiliser, ce qui indique une amélioration rapide de sa capacité à générer des sinogrammes réalistes. En parallèle, la perte du discriminateur diminue également dans les premières époques, puis atteint un plateau, reflétant son apprentissage efficace pour distinguer les sinogrammes réels de ceux générés. L'évolution conjointe de ces deux courbes, avec une stabilisation commune sans dominance excessive de l'un des réseaux, démontre que le modèle converge vers un équilibre souhaitable, caractéristique d'un entraînement stable.

Une fois entraîné, le modèle GAN a été appliqué à quatre sinogrammes tests afin d'évaluer son impact à la fois sur les données en sinogramme et sur les images reconstruites ultérieurement.

Pour la première évaluation, une seule image a été sélectionnée afin de comparer son sinogramme avant et après amélioration par le modèle GAN. La Figure IV.9 présente les résultats de cette comparaison.

La zone rouge agrandie dans la Figure IV.9 permet une comparaison détaillée entre le sinogramme initial (figure IV.9a) et le sinogramme amélioré par le modèle GAN (figure IV.9b), facilitant l'analyse fine des structures et des artefacts. Le sinogramme original présente un bruit important, se manifestant par des fluctuations aléatoires et des lignes artificielles qui perturbent la structure sous-jacente. En revanche, le sinogramme traité par le


GAN révèle une nette amélioration de la netteté des structures sinusoïdales, témoignant d'une suppression efficace du bruit tout en préservant les motifs physiques significatifs.




**Figure IV.9 :** Comparaison du sinogramme avant et après application du modèle GAN. (a) Sinogramme initial bruyant (b) Sinogramme amélioré par le GAN.

### 3.2. Reconstruction d'image

Afin de déterminer la méthode de reconstruction la plus adaptée aux sinogrammes améliorés par le GAN, nous avons évalué trois approches largement utilisées en médecine nucléaire : la rétroprojection filtrée (FBP), la Technique de Reconstruction Algébrique (ART) et la Méthode de Maximisation de l'Espérance Ordonnée (OSEM). La figure IV.10 représente les images reconstruites obtenues avec chacune de ces méthodes [122, 123].





**Figure IV.10 :** Images reconstruites à l'aide de l'algorithme hybride de reconstruction TEP intégrant la réduction de bruit par GAN. (a) Méthode GAN-FBP, (b) méthode GAN-ART, (c) méthode GAN-OSEM.

Après avoir identifié l'algorithme OSEM comme la méthode de reconstruction offrant les meilleures performances sur notre base de données, nous avons procédé à une comparaison qualitative entre deux approches : d'une part, une coupe reconstruite par OSEM à partir du sinogramme brut, et d'autre part, la même coupe reconstruite par OSEM après amélioration du sinogramme via notre modèle GAN proposé. Cette comparaison est illustrée dans la figure IV.11

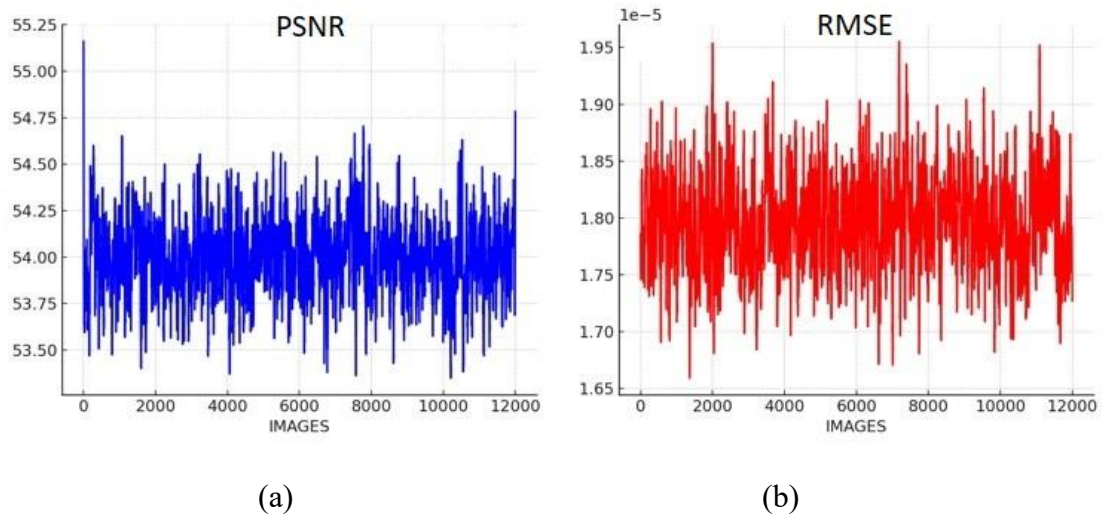


**Figure IV.11 :** Comparaison d'images TEP reconstruites par OSEM, (a) sans traitement préliminaire par GAN et (b) après amélioration du sinogramme par le modèle GAN proposé.


Il est clair que l'image reconstituée par OSEM à partir du sinogramme d'origine présente une qualité d'image inférieure par rapport à celle obtenue après amélioration du sinogramme par le modèle GAN proposé. Une forte présence de bruit statistique est observable dans les régions tissulaires homogènes lorsque le GAN n'est pas utilisé, avec une texture granuleuse typique des acquisitions TEP à faible comptage. En revanche, l'image issue du sinogramme

traité par GAN montre une réduction significative du bruit, un aspect visuel plus lisse et une meilleure homogénéité dans les tissus uniformes [124].

Par ailleurs, une amélioration de la définition des structures fines est perceptible, suggérant un gain en qualité spatiale. Toutefois, une évaluation quantitative complémentaire (PSNR, RMSE) est nécessaire pour confirmer la préservation fidèle des détails anatomiques et éviter toute surestimation liée à un lissage excessif. La figure IV.12 et IV.13 présente une comparaison quantitative des images reconstruites en termes de PSNR (en bleu) et de RMSE (en rouge), évalués par rapport à l'image de référence. La figure IV.12 : Images reconstruites par OSEM à partir du sinogramme brut. La figure IV.13 : Images reconstruites par OSEM après amélioration du sinogramme via le modèle GAN proposé. On observe une augmentation du PSNR et une réduction du RMSE dans le cas (b), indiquant une meilleure qualité de reconstruction.



**Figure IV.12 :** Résultat quantitative des performances de reconstruction sur 12 000 images avec OSEM standard (a) Évolution du PSNR, (b) évolution du RMSE par rapport à l'image de référence.



**Figure IV.13 :** Résultat quantitative des performances de reconstruction sur 12 000 images avec la méthode proposée (GAN-OSEM) (a) Évolution du PSNR et (b) évolution du RMSE par rapport à l'image de référence.

Afin de valider les performances de notre approche, nous avons comparé notre modèle à plusieurs méthodes de pointe récemment proposées dans la littérature.

Tout d'abord, avec le modèle DeepPET proposée par Häggström et al. [87], une approche de reconstruction directe d'images basée sur une architecture encodeur-décodeur. L'encodeur utilise initialement des noyaux de convolution de grande taille (Con 7x7 et 5x5), permettant un champ réceptif plus étendu et une meilleure intégration du contexte spatial dans l'espace du sinogramme. Une architecture plus profonde est employée afin de capturer les structures complexes et de compenser le manque d'information anatomique explicite inhérent au sinogramme d'entrée.

Nous avons également comparé notre modèle avec SSSR [86], une méthode d'amélioration de la reconstruction d'images TEP basée sur l'apprentissage auto-supervisé. Cette approche repose sur un réseau profond entraîné à partir d'un seul sinogramme auquel du bruit est ajouté de manière simulée, permettant ainsi une auto-supervision sans nécessité d'image de référence. Pour améliorer la généralisation du modèle, des techniques d'augmentation stochastique sont appliquées au sinogramme durant l'entraînement, telles que des rotations, des translations ou des perturbations aléatoires.

Enfin, nous avons comparé notre approche au modèle FBSEM [88], qui intègre un processus d'apprentissage structuré autour d'un réseau neuronal récurrent (RNN). Ce dernier est conçu pour modéliser la dynamique itérative de la reconstruction tout en exploitant les dépendances temporelles entre les itérations d'optimisation. Le réseau a été entraîné sur un

jeu de données TEP simulées, afin de restaurer les images à partir de sinogrammes bruités. Quatre sinogrammes tests ont été améliorés respectivement à l'aide de notre approche basée sur le GAN, ainsi qu'à l'aide de trois méthodes de référence : SSSR, FBSEM et DeepPET.


Les images finales ont été reconstruites par l'algorithme OSEM à partir des sinogrammes traités. Les résultats comparatifs sont présentés dans les Figures IV.14 et IV.15 : la première montre les images reconstruites dans leur globalité, tandis que la seconde offre des agrandissements de régions d'intérêt afin de mettre en évidence les différences de qualité de reconstruction au niveau local.

Les résultats démontrent que la qualité d'image obtenue avec le modèle proposé est supérieure, tant sur le plan qualitatif que quantitatif. L'architecture basée sur le GAN offre un meilleur rapport signal-bruit tout en diminuant efficacement le bruit et le flou dans les images PET reconstruites par rapport à d'autres techniques. Comme on le constate dans les zones agrandies, les détails fins et les structures cliniquement significatives sont mieux préservés, ce qui améliore la clarté et l'interprétabilité des images de PET.


Le tableau IV.2 présente les valeurs du PSNR, RMSE et SSIM des images reconstruites à partir des sinogrammes traités par les quatre modèles : SSSR, FBSEM, DeepPET et modèle proposé.


**Tableau IV.2 :** Valeurs de PSNR, RMSE et SSIM des images reconstruites à partir des sinogrammes traités par les quatre modèles : SSSR, FBSEM, DeepPET et modèle proposé.


		SSSR	FBSEM	DeepPET	Modèle proposé
<b>Coupe 1</b>	<b>PSNR</b>	39.5	37.22	40.5	41.65
	<b>RMSE</b>	0.0106	0.0137	0.0094	0.0083
	<b>SSIM</b>	0.8993	0.7613	0.8900	0.9013
<b>Coupe 2</b>	<b>PSNR</b>	39.38	37.5	40.35	41.58
	<b>RMSE</b>	0.0107	0.0133	0.0096	0.0084
	<b>SSIM</b>	0.8976	0.7734	0.9056	0.8996
<b>Coupe 3</b>	<b>PSNR</b>	39.33	37.45	40.21	41.63
	<b>RMSE</b>	0.0108	0.0134	0.0098	0.0083
	<b>SSIM</b>	0.8555	0.7600	0.8100	0.9005
<b>Coupe 4</b>	<b>PSNR</b>	40.44	37.98	40.36	41.64
	<b>RMSE</b>	0.0096	0.0126	0.0096	0.0083
	<b>SSIM</b>	0.8650	0.7709	0.8239	0.9003



**Figure IV.14 :** Images reconstruites par OSEM à partir de sinogrammes améliorés à l'aide de différents modèles : (a) SSSR, (b) FBSEM, (c) DeepPET, (d) modèle proposé.



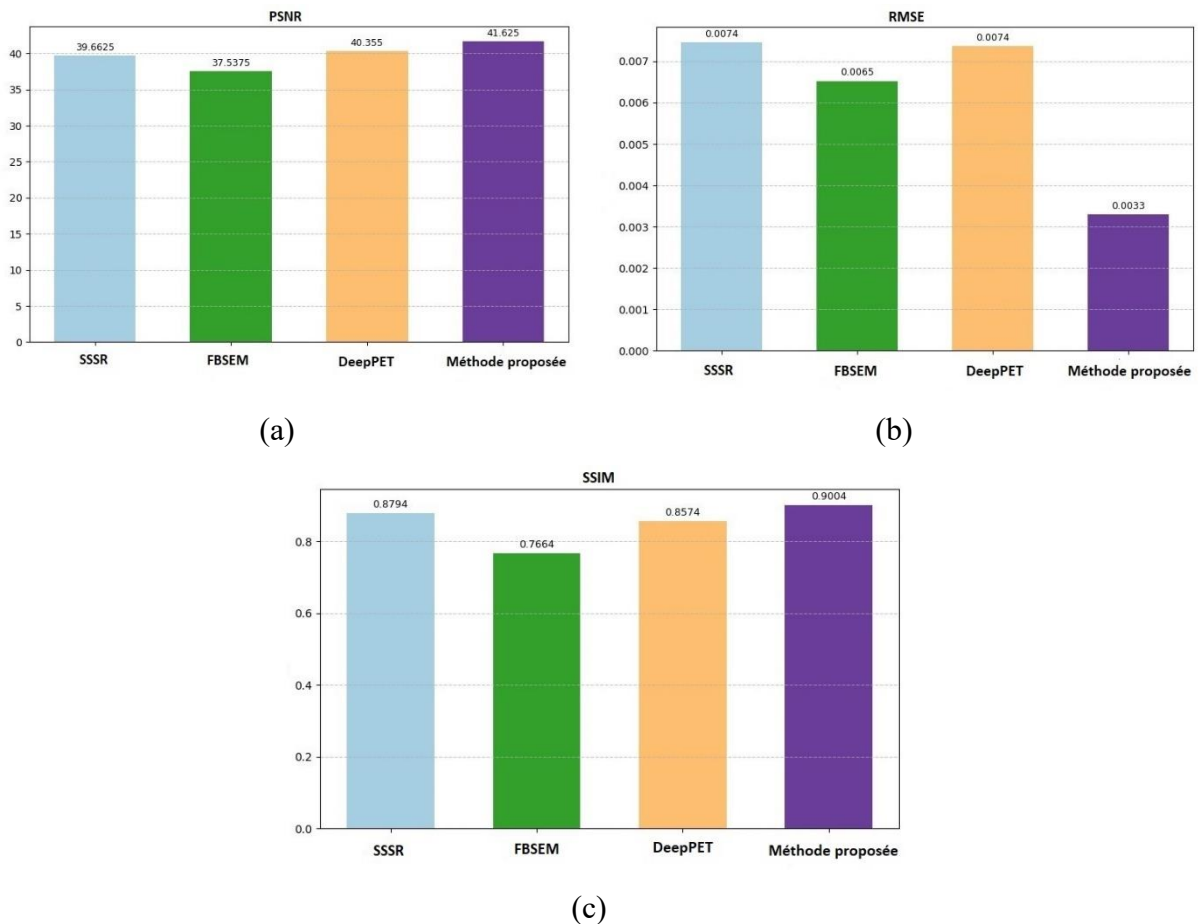




**Figure IV.15 :** Agrandissements mettant en évidence la qualité de reconstruction locale : (a) SSSR, (b) FBSEM, (c) DeepPET, (d) Modèle proposé.

L'évaluation de notre méthodologie basée sur un réseau génératif antagoniste (GAN) a montré des performances prometteuses, tant sur le plan qualitatif que quantitatif. La Figure IV.15, présentant des agrandissements de régions d'intérêt, met en évidence l'amélioration de la qualité des images reconstruites avec notre approche : une réduction marquée du bruit et du flou, une meilleure préservation des contours et une restitution plus fidèle des détails anatomiques, permettant ainsi une discrimination plus claire des structures d'intérêt. En termes de métriques quantitatives, le PSNR atteint jusqu'à 45 dB pour certaines séries, indiquant une forte similarité avec les références de haute qualité. Ces résultats suggèrent une bonne convergence du modèle GAN, confirmée par la difficulté croissante du discriminateur à distinguer les sinogrammes réels de ceux synthétisés, signe d'un générateur efficace. Des tests menés sur une large base de données, incluant diverses morphologies, niveaux de contraste et intensités de bruit, ont produit des résultats cohérents, démontrant la robustesse et la généralisation de notre méthode dans différents scénarios d'imagerie TEP. Le choix de l'algorithme OSEM pour la reconstruction finale s'est avéré pertinent, notamment grâce à sa compatibilité avec les sinogrammes améliorés par apprentissage profond et aux performances quantitatives élevées obtenues dans ce cadre combiné. Le Tableau IV.2 fournit les métriques quantitatives correspondantes, confirmant la supériorité de notre approche en termes de résolution spatiale et de gestion du bruit [125, 126].

La figure IV.16 compare les performances moyennes des quatre méthodes : SSSR, FBSEM, DeepPET et modèle proposé selon les métriques PSNR, RMSE et SSIM, évaluées sur l'ensemble de la base de données test.



**Figure IV.16 :** Comparaison des performances moyennes des quatre méthodes (SSSR, FBSEM, DeepPET et modèle proposé) sur l'ensemble de la base de données test, selon trois métriques de qualité : (a) PSNR, (b) RMSE, (c) SSIM.

Les valeurs moyennes du PSNR, RMSE et SSIM de notre modèle proposé démontrent l'efficacité qualitative et quantitative par rapport aux autres modèles.

D'après la courbe du générateur présentée dans la figure IV.8.a, il est clair que la perte commence à une valeur relativement élevée, puis diminue avant de se stabiliser autour de 0.6932. Comme illustré dans la Figure IV.8.b, la courbe du discriminateur débute également à un niveau élevé, puis chute nettement avant de se stabiliser autour de 0.0003. Cette forte baisse et une très faible valeur stabilisée de la perte du discriminateur montrent que ce dernier est devenu extrêmement compétent pour différencier les sinogrammes générés de ceux réels. En revanche, la stabilisation de la perte du générateur autour de 0.6932, associée à une performance solide du discriminateur, indique que bien que le générateur ait appris à produire des sinogrammes, il n'a pas systématiquement réussi à tromper le discriminateur mieux qu'une éventualité aléatoire dans cette configuration d'entraînement.

En exploitant l'ensemble de données d'entraînement, le modèle GAN formé a assimilé les caractéristiques des sinogrammes de haute qualité. L'application du générateur de ce modèle sur les sinogrammes de test entraîne leur transformation en fonction de ces connaissances acquises. Cette transformation se caractérise par la réduction du bruit, l'éventuelle complétion des informations manquantes, l'amélioration de la résolution et du contraste, ainsi que la normalisation des données, produisant ainsi une amélioration visuelle de la qualité des sinogrammes test [127,128].

L'algorithme proposé montre des résultats très prometteurs, contribuant à son efficacité d'apprentissage et offrant un gain de temps significatif. Le GAN a considérablement diminué le bruit contenu dans les sinogrammes d'entrée, ce qui a permis de réduire à un nombre très limité d'itérations la reconstruction OSEM ultérieure. Ainsi, avec un nombre minimal d'époques pour l'entraînement et d'itérations pour la reconstruction, l'algorithme proposé fait preuve d'une efficacité et d'une robustesse notables.

D'après le tableau IV.2 et en se basant sur les quatre échantillons étudiés, la méthode suggérée montre une amélioration significative du PSNR d'environ 6.46% par rapport à SSSR, 10.89% par rapport à FBSEM, et 3.10% par rapport à DeepPET, en moyenne. Parallèlement, une diminution substantielle de l'Erreur Quadratique Moyenne (RMSE) est constatée, atteignant une moyenne de 55.68% par rapport au SSSR, 49.41% en comparaison avec le FBSEM et 55.21% face au DeepPET. En ce qui concerne la SSIM, les valeurs obtenues sont concurrentielles, indiquant une bonne préservation des détails structuraux des images reconstruites. Les améliorations chiffrables en PSNR et les diminutions de RMSE, associées à une préservation structurale compétitive, mettent en évidence l'efficacité de la méthode suggérée pour la tâche de reconstruction d'image.

En examinant notre travail par rapport à la méthodologie SSSR élaborée par Reader et al., nous décelons de nombreuses lacunes et contraintes. Bien que leur méthode permette d'utiliser des données limitées, elle repose actuellement sur des données de haute qualité ou des vérités de référence qui sont généralement difficiles à obtenir en imagerie médicale. De plus, les réseaux auto-supervisés nécessitent un étalonnage minutieux et peuvent ne pas s'adapter facilement à diverses sources de données. De plus, l'utilisation d'un algorithme sur des données limitées peut réduire la capacité de généralisation du réseau et accroître le risque de surapprentissage. En revanche, la base de données utilisée dans cette recherche contient un grand volume de points de données, ce qui permet à notre algorithme de se généraliser efficacement et de s'adapter aux caractéristiques particulières de chaque ensemble de données.

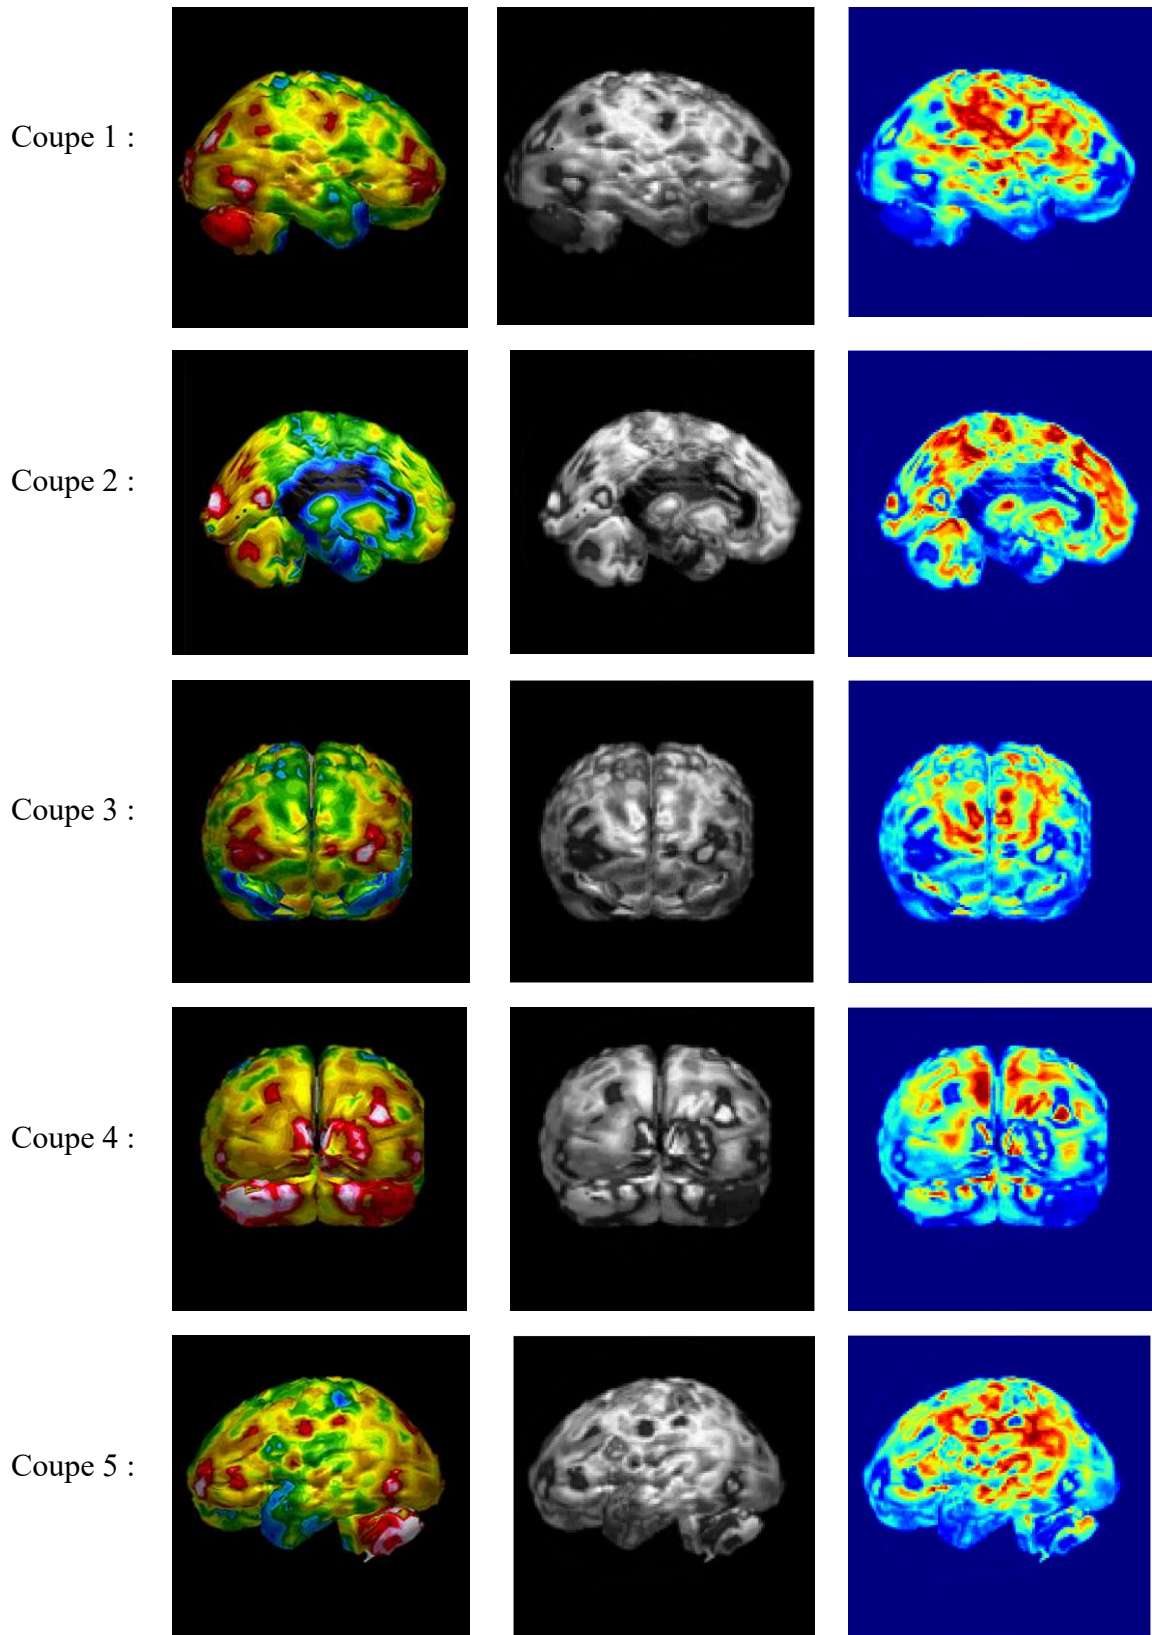
La méthode DeepPET a démontré son utilité ; cependant, elle présente également de nombreux inconvénients significatifs. Une préoccupation constante est le risque de surapprentissage potentiel, qui compromet sa fiabilité avec des données inédites. Elle présente particulièrement de mauvaises performances avec des images PET excessivement bruyantes ou chargées d'artefacts, surtout dans des situations où la qualité de l'image est déjà compromise. Par conséquent, la qualité de la reconstruction se dégrade. L'enjeu des ressources réside dans le coût computationnel lié à l'entraînement et au fonctionnement de ce modèle, en particulier lorsqu'il s'agit de gérer d'importants ensembles de données comme le nôtre. Cela le rend incompatible avec notre méthodologie proposée. De plus, l'exactitude de la reconstruction est négativement influencée par les imprécisions inhérentes au modèle FBSEM, et ce problème s'aggrave avec l'augmentation du bruit de l'image. Finalement, une quantité significative de temps doit être consacrée à l'optimisation des hyperparamètres, ce qui rend le processus de formation laborieux et complexe. Ceci entrave considérablement sa traduction en application clinique, en particulier dans des environnements où les ressources et le temps sont limités. Notre travail pourrait avoir un impact majeur, notamment dans le domaine de l'imagerie médicale. Le modèle que nous avons élaboré montre une amélioration des résultats dans la reconstruction d'images PET, facilitant ainsi aux professionnels de la santé de poser des diagnostics plus précis.

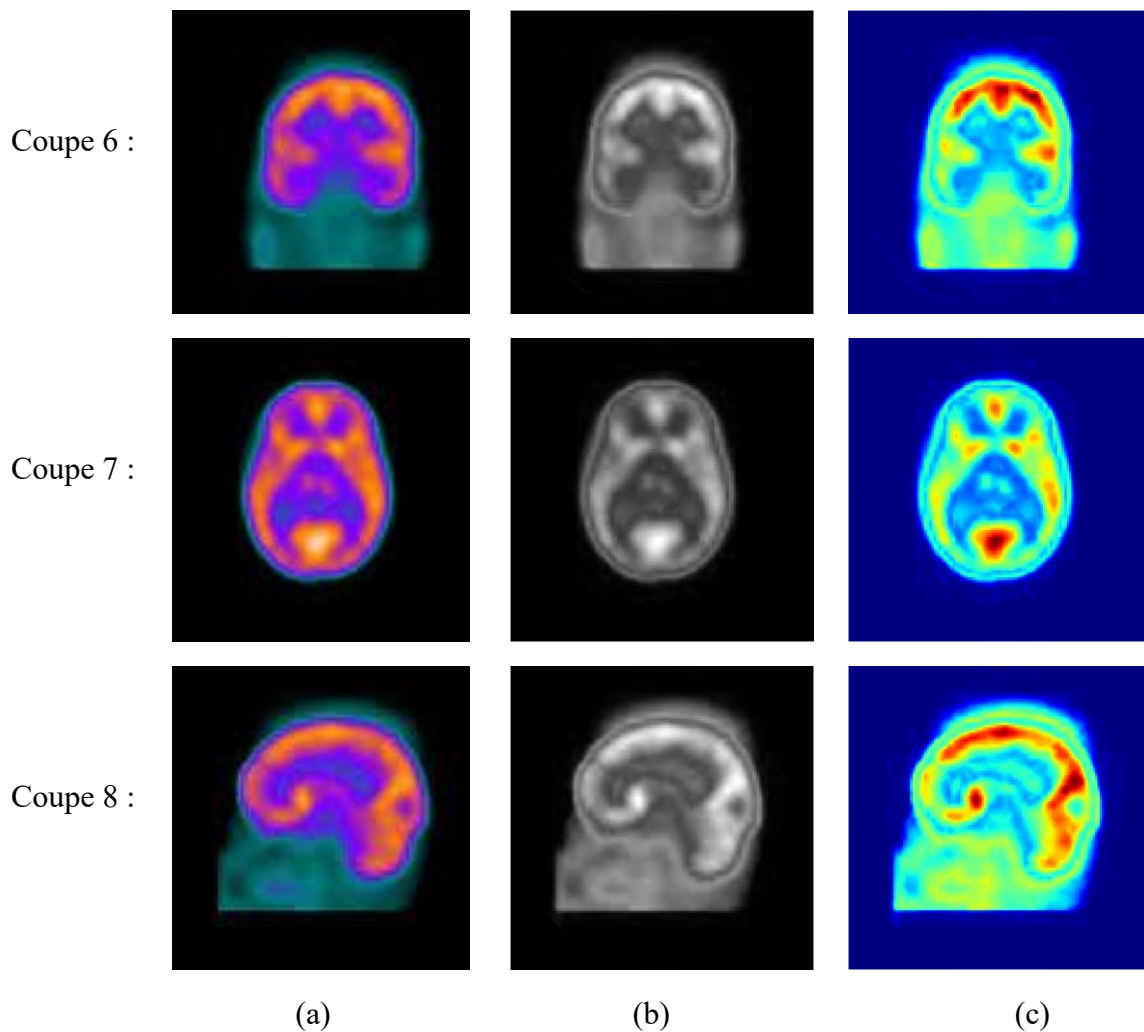
#### **4. Transfert d'apprentissage**

Après avoir validé les résultats quantitatifs et qualitatifs du modèle que nous avons élaboré pour l'amélioration du sinogramme et la reconstruction d'image sur une large base de données TEP, nous avons appliqué un transfert d'apprentissage grâce à notre modèle pré-entraîné, sur une deuxième base de données TEMP contenant moins de données et sur laquelle l'entraînement du modèle aurait été moins performant en terme de fiabilité et de robustesse, surtout dans l'extraction des caractéristiques, la correction des données manquantes et la réduction du bruit sur le sinogramme.

Dans cette partie, nous avons utilisé un modèle pré-entraîné sur une base de données TEP. Ce modèle, ayant appris les caractéristiques des images TEP, a réussi à les améliorer. Nous l'avons ensuite appliqué à un jeu de données de test comprenant huit coupes issues de notre base de données TEMP. Ce jeu de données représente la base de test pour l'évaluation de notre modèle.

La figure IV.17 illustre les résultats du transfert d'apprentissage obtenues avec notre modèle pré-entraîné. (a) l'image de référence, (b) la reconstruction en niveaux de gris, et (c) la même image visualisée en couleurs pour faciliter l'analyse des détails.






**Figure IV.17 :** Résultats du transfert d'apprentissage appliqué à la base de données TEMP. (a) l'image originale, (b) l'image reconstruite en niveau de gris et (c) l'image reconstruite en couleurs.

L'image reconstruite conserve fidèlement les structures anatomiques tout en bénéficiant d'une meilleure visualisation grâce au codage couleur.

La Figure IV.18 illustre de manière visuelle l'influence du transfert d'apprentissage sur la qualité des sinogrammes obtenus en TEMP. Le sinogramme de gauche, correspondant à l'état brut avant amélioration, présente une structure globale préservée, mais une faible définition des lignes et des intersections, témoignant d'un flou ou d'un bruit élevé. Les zones d'intensité élevée semblent assez floues et les transitions entre les diverses projections sont moins nettes. L'examen de la zone ciblée (encadrée en rouge) confirme cette observation : il révèle une perte significative de détails et un bruit granulaire marqué, pouvant masquer des structures fines ou compromettre la fidélité de la reconstruction finale.



**Figure IV.18 :** Comparaison visuelle des sinogrammes TEMP (a) avant et (b) après amélioration par transfert d'apprentissage.

À l'inverse, le sinogramme de droite, obtenu après traitement par un modèle adapté via transfert d'apprentissage, présente une nette amélioration en termes de qualité visuelle et de fidélité structurale. Les projections sont plus nettes, avec des lignes mieux définies et une restitution plus précise aux intersections, indiquant une réduction du bruit et une préservation accrue des détails fins. Un zoom sur la même zone d'intérêt confirme ces gains : les structures apparaissent plus claires, la texture est homogène, et les artefacts liés au flou ou à la granularité sont significativement atténués. Cette amélioration locale témoigne d'une diminution efficace du bruit et d'une résolution spatiale rehaussée, favorisant une reconstruction plus fidèle.

En résumé, cette comparaison visuelle démontre que le transfert d'apprentissage permet une amélioration significative de la qualité des sinogrammes TEMP, en termes de définition structurale et de rapport signal sur bruit. L'algorithme a facilité une différenciation plus précise des apports de chaque projection, essentiel pour réaliser des reconstructions tomographiques d'une résolution supérieure et plus fidèles à la réalité anatomique ou fonctionnelle. Ceci indique que le modèle a pu apprendre et mettre en œuvre des attributs pertinents pour réduire le bruit et optimiser les données brutes, même avec une base de

données TEMP de taille réduite, en se fondant sur les caractéristiques obtenues à partir de la plus grande base de données TEP. Donc le modèle a appris à résoudre le problème générique de l'amélioration de la qualité d'une image fonctionnelle de médecine nucléaire qui est statistiquement limitée et bruyante. Les caractéristiques de la TEP constituent une base d'apprentissage riche pour ce type de débruitage fonctionnel, ce qui a permis d'obtenir de bons résultats par généralisation sur les images TEMP.

Les résultats présentés dans le Tableau IV.3, obtenus à l'aide par le transfert d'apprentissage, illustrent les performances du cadre proposé en termes de reconstruction et d'amélioration appliqué sur le jeu de données. Ces performances sont évaluées quantitativement à l'aide des métriques PSNR, RMSE et SSIM.


**Tableau IV.3** : Valeurs de PSNR, RMSE et SSIM des 8 coupes.

	<b>PSNR</b>	<b>RMSE</b>	<b>SSIM</b>
<b>Coupe 1</b>	38.06	0.0125	0.9831
<b>Coupe 2</b>	35.97	0.0159	0.9770
<b>Coupe 3</b>	37.70	0.0130	0.9883
<b>Coupe 4</b>	37.42	0.0135	0.9864
<b>Coupe 5</b>	50.18	0.0031	0.9864
<b>Coupe 6</b>	51.39	0.0027	0.9969
<b>Coupe 7</b>	47.55	0.0042	0.9929
<b>Coupe 8</b>	37.46	0.0134	0.9827

Chaque coupe montre une fidélité d'image exceptionnelle, avec des valeurs moyennes de PSNR qui se placent principalement au-dessus de 37 dB, un niveau souvent jugé excellent pour la reconstruction d'images médicales. La faible valeur moyenne du RMSE, qui évalue l'erreur de reconstruction en termes d'intensité des pixels, est en accord avec le PSNR élevé, signalant des erreurs de reconstruction négligeables. En outre, l'indice SSIM, qui mesure la ressemblance structurelle entre l'image reconstruite et celle de référence, affiche toujours un score très haut (toutes les sections excèdent 0.977). Ces résultats démontrent que le modèle a magistralement retenu les informations structurelles et anatomiques cruciales au cours du processus de transfert d'apprentissage. De plus, on note une performance remarquable et constante sur les Coupes 5, 6 et 7 (PSNR > 47 dB, RMSE extrêmement bas, et SSIM avoisinant les 0.99), indiquant que le modèle a su idéalement généraliser les attributs

pertinents sur ces sections précises, confirmant ainsi l'utilité du transfert d'apprentissage pour la conservation des détails structuraux dans la base de données TEMP restreinte.

La figure IV.19 illustre les résultats des trois métriques d'évaluation sur l'ensemble de la base de données TEMP sur laquelle nous avons appliqué le transfert d'apprentissage.



**Figure IV.19 :** Représentations des métriques d'évaluation sur l'ensemble des données TEMP.


Ce graphique démontre la constance et la performance du modèle transféré sur le jeu de données TEMP, en montrant l'évolution de trois indicateurs majeurs (PSNR, RMSE, SSIM) selon le volume d'images traitées. La SSIM, indiquée par la ligne verte, montre une performance à la fois extrêmement stable et optimale, se rapprochant presque de 1 sur toute l'étendue des images (de 100 à 500). Cette saturation du SSIM signale que le modèle de transfert d'apprentissage a idéalement préservé l'information structurale des images TEMP. Le PSNR, illustré par la ligne bleue, affiche toujours un niveau élevé (environ 36 dB), attestant d'une qualité de reconstruction supérieure et d'une présence réduite du bruit à travers l'ensemble des données. On observe une légère amélioration de la performance à 300 images, moment où le PSNR atteint son niveau maximum. Parallèlement, la ligne rouge qui représente l'erreur de reconstruction, illustrée par la métrique RMSE, varie en sens inverse par rapport au PSNR, ce qui est conforme aux attentes. Une réduction drastique du RMSE (atteignant son niveau le plus bas autour de 0.0130) est observée lorsque le PSNR atteint son apogée (à 300 images), indiquant une erreur de reconstruction minimale à cette instance. Malgré une légère augmentation du RMSE à 400 images avant de se stabiliser, ses fluctuations demeurent dans une fourchette très étroite (entre 0.0134 et 0.0138), ce qui témoigne de la solidité du modèle et

de sa capacité à garantir une erreur moyenne basse sur l'ensemble des données TEMP, confirmant ainsi l'efficacité du transfert d'apprentissage.

### 5. Amélioration de la résolution spatiale de l'image en médecine nucléaire

Le modèle proposé pour l'amélioration de la résolution spatiale avec le GAN basé sur RCAN représente un processus d'entraînement adversaire, avec le générateur s'efforçant de produire des images de haute résolution de plus en plus réalistes pour tromper le discriminateur, tandis que le discriminateur affine simultanément sa capacité à les identifier ; cet équilibre pousse le générateur à générer des sorties super-résolues perceptuellement supérieures et quantitativement précises. Ce modèle a été appliqué sur les images reconstruite TEP et TEMP et évalué avec PSNR, SSIM, LPIPS, CNR et FWHM.

Ce modèle a donné lieu à des images de haute résolution. Nous avons tracé les profils d'intensité des pixels le long d'une ligne horizontale commune pour les deux ensembles de données : les images TEP/TEMP (courbe bleue) de basse résolution BR et les images améliorées par le GAN basé sur RCAN de haute résolution HR (courbe orange). La ligne pointillée rouge représente la ligne à mi-hauteur, déterminée en prenant la valeur d'intensité maximale du profil des images originales et en la divisant par deux. Cette ligne de référence permet de comparer visuellement la largeur et la forme des pics d'intensité entre les deux images, offrant ainsi un indicateur de la qualité de la reconstruction en termes de résolution spatiale. Figure IV.20 présente les courbes de profil d'intensité de ligne horizontale des données TEP/TEMP originales BR et les données HR améliorées par notre modèle.



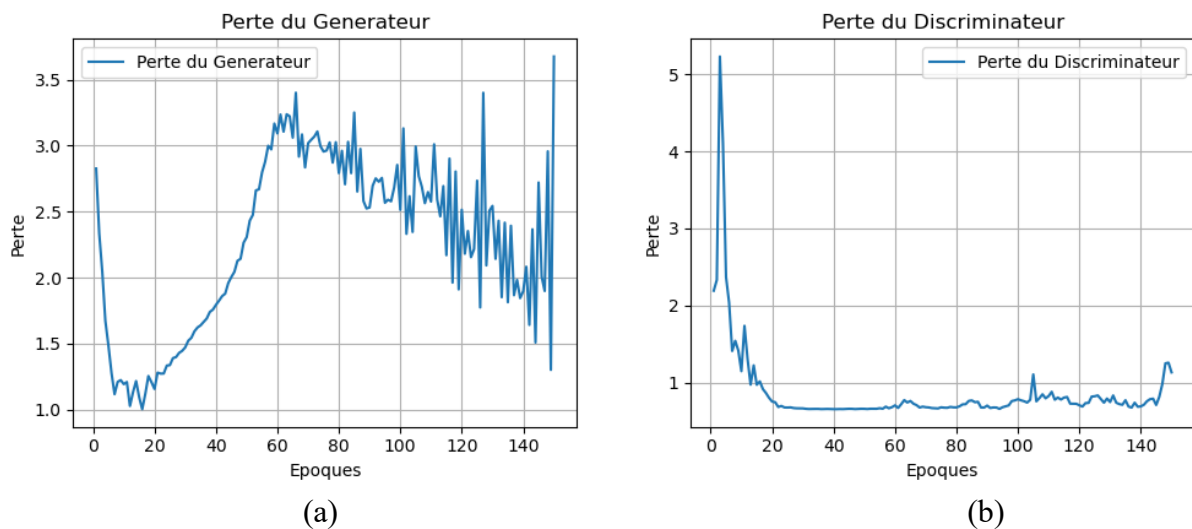
**Figure IV.20 :** Profil d'intensité de ligne horizontale des données BR originale et données améliorées HR.

Nous avons ensuite évalué une image de notre base de données avec une images de haute résolution améliorée grâce à notre modèle GAN basé sur RCAN en utilisant différentes métriques. Les résultats de l'évaluation sont affichés dans le Tableau IV.4.


**Tableau IV.4 :** Évaluation comparative entre l'image originale (basse résolution) et image (haute résolution) améliorée par GAN basé sur RCAN.

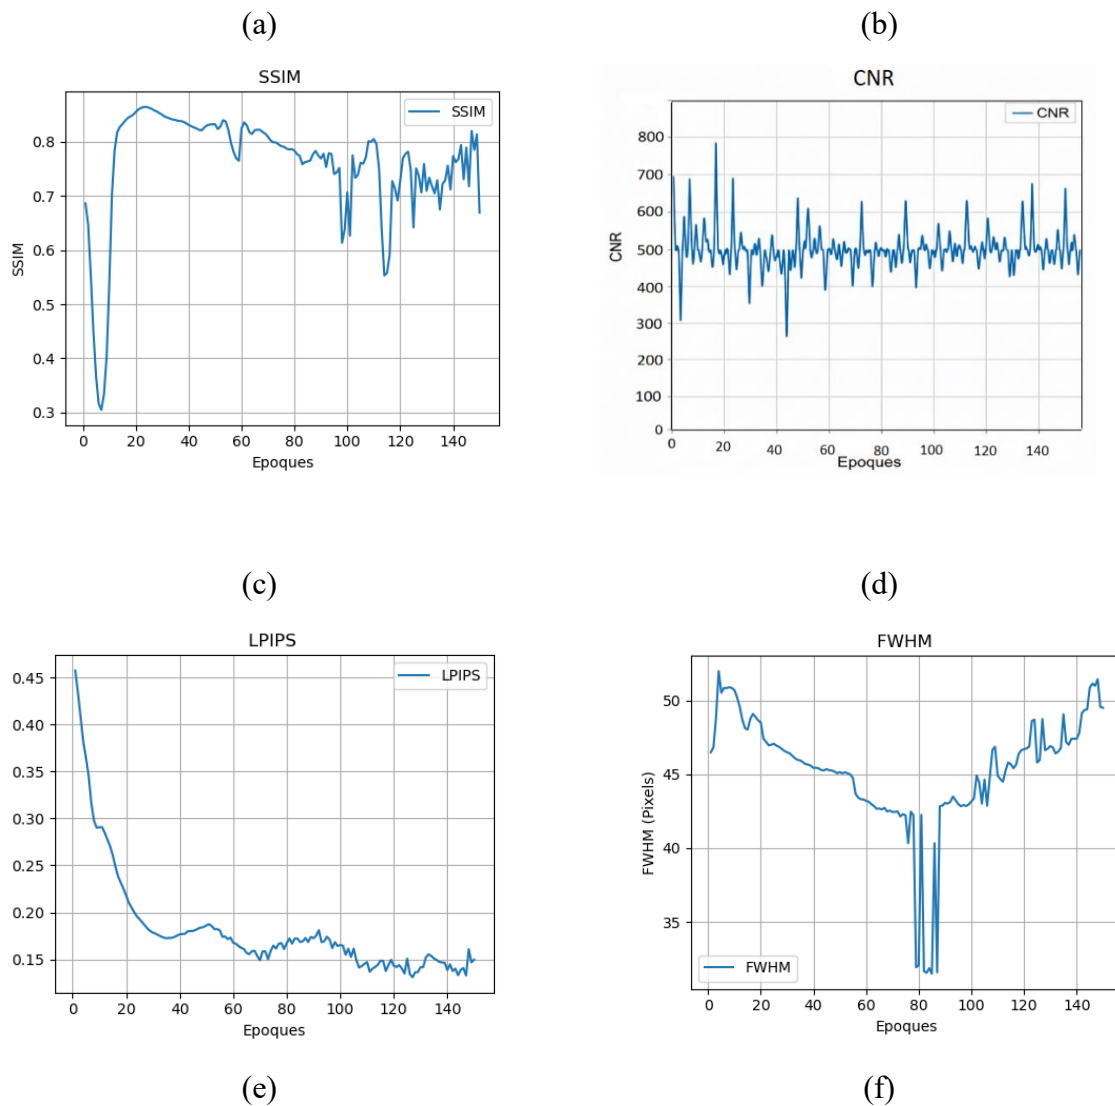
	PSNR	SSIM	LPIPS	CNR	MSE	FWHM
<b>Image BR</b>	29.34	0.77	0.2	601.3	0.0116	61.43
	30.7	0.8	0.25	652	0.0085	63.8
	30.01	0.81	0.29	639.76	0.0099	62.9
<b>Image HR</b>	30.25	0.87	0.19	791.3	0.0094	60.69
	31.03	0.9	0.15	644.09	0.0079	57.6
	30.44	0.88	0.21	737	0.0090	58.33

Les résultats obtenus par notre modèle proposé affirment la super résolution de l'image finale comme illustré dans les figures IV.21 et IV.22



**Figure IV.21 :** Courbes de perte du (a) générateur et du (b) discriminateur du modèle proposé pour l'amélioration de la résolution spatiale en fonction du nombre d'époques.





**Figure IV.22 :** Valeurs des différentes métriques enregistrés. (a) PSNR, (b) MSE, (c) SSIM, (d) CNR, (e) LPIPS, (f) FWHM.

Les valeurs enregistrées des métriques calculées témoignent du potentiel du modèle de réseau antagoniste génératif (GAN) basé sur RCAN à augmenter la résolution des images TEP et TEMP de notre base de données.

Le modèle GAN basé sur un générateur RCAN que nous proposons dans cette recherche constitue une avancée novatrice dans le domaine de l'amélioration de la résolution spatiale pour les images médicales TEP/TEMP. Ce modèle a la capacité de reproduire des images haute résolution avec une fidélité élevée aux détails et aux structures générales. D'après la Figure IV.20, la qualité du profil originale a été améliorée et l'analyse du profil démontre l'efficacité du modèle dans l'augmentation du contraste et l'amélioration de la netteté de l'image.

L'intensité maximale du profil HR s'élève à près de 0.60 (plus élevée que celle du BR) ce qui signifie que l'amplitude du signal a été augmentée donc il y a un gain de contraste ce qui rend l'image visuellement plus brillante et distincte.

La mesure de la largeur à mi-hauteur représente un indicateur clé de la netteté de la résolution, pour le BR le signal s'étale à environ 49 pixels tandis que le HR à environ 43 pixels. Cette réduction démontre une amélioration de la netteté et de la résolution spatiale de la structure.

L'examen du tableau IV.4 révèle la capacité de notre modèle à réduire efficacement le bruit tout en reconstruisant les informations spatiales avec une grande fidélité à l'image d'origine. Les valeurs élevées de SSIM confirment que notre modèle réussit à maintenir les structures d'image, un défi fréquemment rencontré dans l'interprétation visuelle des images TEP et TEMP. Les résultats LPIPS sont également prometteurs, car ils montrent une forte similarité perceptuelle entre l'image originale et l'image prédite par notre modèle, qui conserve un excellent contraste face au bruit. De plus, les résultats particulièrement pertinents concernant la FWHM, qui montrent que notre modèle améliore activement la netteté des contours et la résolution spatiale.

L'examen des courbes de perte du GAN dans la figure IV.21 démontre une stabilité remarquable sur l'ensemble des cent cinquante époques considérées. La perte du discriminateur atteint un optimum avec une grande célérité et se stabilise de manière constante entre 0,7 et 0,8, ce qui démontre sa compétence continue sans déséquilibre notable, condition essentielle pour fournir un signal d'apprentissage de qualité au générateur. Après une phase initiale de stress caractérisée par une augmentation de la perte jusqu'au moment 65, le générateur parvient à rectifier sa trajectoire, sa perte moyenne manifestant ensuite une tendance générale à la diminution jusqu'à la fin de la phase d'apprentissage. La stabilisation concomitante des deux courbes atteste d'une dynamique d'équilibre pérenne, favorisant ainsi le progrès du générateur et la production continue d'échantillons de qualité supérieure, sans être affecté par l'instabilité catastrophique constatée dans les résultats antérieurs. Il apparaît donc que la période optimale pour l'extraction du modèle optimisé se situe postérieurement à l'époque 65, puisque le générateur a alors dépassé sa phase d'apprentissage initiale la plus ardue.

Au-delà du nombre d'époque choisi (150 époques) et afin d'assurer la performance du modèle et de prévenir une altération de la qualité de la génération induite par la production

d'artefacts ou d'images répétitives, il est impératif de restreindre l'entraînement à cette phase stable.

La figure IV.22 démontre que dès les premières époques, le modèle atteint son meilleur score de qualité d'image avec une capacité d'apprentissage élevée. Le PSNR affiche des valeurs robustes, simultanément, le MSE confirme cette fidélité maximale au signal de référence en atteignant son minimum. Le SSIM et le LPIPS témoignent également d'une efficacité remarquable dans cette phase, l'indice SSIM s'établissant à un niveau élevé et la distance LPIPS (plus basse est meilleure) atteignant son plus bas niveau.

Ainsi, cette période d'entraînement représente le moment où l'apprentissage des caractéristiques de base est optimisé, durant lequel le modèle a produit les images de plus grande qualité sur le plan quantitatif. Par ailleurs, la chute abrupte de la mesure FWHM démontre que le modèle a la capacité, à certains moments, de reproduire des structures avec une résolution spatiale d'une finesse remarquable, dépassant les performances initiales. La stabilité élevée de la Perte du discriminateur durant toute la période d'entraînement assure que le signal adversaire a demeuré pertinent, garantissant par conséquent que le générateur a continuellement été incité à s'améliorer.

En conclusion, ces constatations soulignent la promesse du modèle dans la super-résolution, avec une période de sauvegarde optimale bien déterminée autour de l'époque 30 pour optimiser la fidélité. De plus, il y a des indications d'une nette amélioration de la clarté à des phases ultérieures de l'entraînement.

## 6. Conclusion

L'utilisation de l'apprentissage profond dans l'amélioration de la qualité d'image en médecine nucléaire est devenue une étape primordiale dans l'élaboration d'algorithmes fiables, robustes et facilement exécutables dont le but principal est d'aider les médecins spécialistes à donner un diagnostic précis et rapide.

Les résultats obtenus constituent une avancée significative dans le domaine de l'amélioration de la qualité d'image et de la résolution spatiale en médecine nucléaire. Ils exploitent les avantages de l'intelligence artificielle pour optimiser les données et générer des algorithmes capables de débruiter l'image, tout en préservant les informations pertinentes contenues dans les images médicales.

## Conclusion générale

La médecine nucléaire est une spécialité médicale qui permet de diagnostiquer et traiter diverses maladies, notamment les cancers, les maladies cardiaques et les troubles neurologiques. Cette technique d'imagerie est caractérisée par son utilisation de très faible dose de radiotraceurs afin de réduire l'exposition du patient aux rayonnements ce qui a des conséquences sur la qualité de l'image ainsi que la précision du diagnostic.

La présence du bruit, des artéfacts, et la perte effective de résolution dans l'image en médecine nucléaire peuvent masquer les structures fines pathologiques, causer du flou dans l'image et introduire de faux signaux ou fausses structures ce qui rend l'image difficile à interpréter.

Dans le cadre de cette recherche, et afin de résoudre la problématique posée, nous avons proposé la modélisation d'un prototype de gamma caméra et d'une caméra TEP à l'aide du logiciel de simulation GEANT4. La simulation des interactions entre les rayonnements et les détecteurs nous a permis de mener une étude sur la résolution en énergie dans les systèmes d'imagerie en médecine nucléaire. Les résultats obtenus dans la simulation de la caméra TEP mettent en évidence une valeur moyenne de l'énergie déposée de 0,5115 MeV, une valeur extrêmement proche de l'énergie théorique du photon d'annihilation (511 keV). Afin d'analyser le comportement du détecteur en conditions idéales, les événements de diffusion ont été filtrés, ne retenant ainsi, parmi les événements simulés, que ceux correspondant à une absorption totale. Cette méthodologie de sélection rigoureuse a été essentielle pour valider les performances intrinsèques de notre modèle dans le cadre de cette étude. Les résultats de simulation de la gamma caméra et de comparaison entre différentes formes de détecteurs montrent qu'il n'existe pas de géométrie unique optimale pour toutes les énergies. Le monobloc rectangulaire s'avère être le meilleur compromis pour les hautes énergies, car il maximise l'absorption totale grâce à son grand volume actif. En revanche, la configuration à deux rectangles minces est plus adaptée aux basses énergies, car elle offre une meilleure résolution énergétique en limitant les effets de diffusion Compton dans le cristal, tout en assurant une absorption totale efficace.

Pour l'amélioration de la qualité des images en TEP, notre méthode basée sur le GAN a donné des résultats très satisfaisants pour le débruitage du sinogramme par apprentissage profond, ainsi que pour la reconstruction fiable et rapide des images par la méthode OSEM. Les résultats démontrent que la méthode proposée apporte une amélioration considérable de

10,89 % du PSNR et une réduction de 55,68 % du RMSE par rapport aux autres méthodes de débruitage, tout en préservant parfaitement les détails structurels.

Afin de remédier au problème d'insuffisance de données, nous avons appliqué le transfert d'apprentissage sur une base de données contenant peu de données. Les résultats obtenus grâce au transfert d'apprentissage sont prometteurs en termes de performance du modèle et sa capacité à généraliser entre des modalités d'imagerie semblables a été démontrée, et ce, malgré la taille limitée de l'ensemble de données utilisé pour l'évaluation. Les résultats du transfert d'apprentissage démontrent que le modèle a retenu les informations structurelles et anatomiques cruciales au cours du processus de transfert d'apprentissage, on note une performance remarquable et constante avec un PSNR  $> 47$  dB, un RMSE extrêmement bas, et un SSIM avoisinant les 0.99, indiquant que le modèle a su idéalement généraliser les attributs pertinents sur ces sections précises, confirmant ainsi l'utilité du transfert d'apprentissage pour la conservation des détails structurels dans la base de données TEMP restreinte.

Notre modèle proposé pour l'amélioration de la résolution spatiale de l'image à l'aide d'un GAN avec un générateur RCAN a démontré son efficacité sur les images TEP et TEMP, en augmentant considérablement la résolution spatiale des images. L'analyse comparative des performances entre les images basse résolution (BR) et haute résolution (HR) démontre une supériorité globale de ces dernières sur l'ensemble des métriques de qualité d'image. Pour les images HR, on observe une fidélité structurelle et une réduction du bruit significatives, avec une valeur moyenne de 30,57 dB pour le PSNR et un SSIM de 0,88, témoignant d'une excellente conservation des textures. La perception visuelle est également optimisée comme l'indique le score LPIPS moyen de 0,18, tandis que la précision radiométrique est confirmée par une MSE moyenne de 0,0088. Enfin, la qualité du contraste et la résolution spatiale des images HR sont nettement supérieures, avec un CNR moyen s'élevant à 724,13 et une finesse de détail caractérisée par un FWHM moyen de 58,87, confirmant ainsi l'efficacité du traitement haute résolution.

Les résultats obtenus sont satisfaisants et prometteurs et dépassent les résultats des travaux existants dans la littérature, c'est une amélioration qui permet d'aider les médecins dans l'interprétation et le diagnostic et de visualiser de manière plus nette les structures et les régions d'intérêts sur l'image médicale en médecine nucléaire.

Malgré les progrès réalisés dans cette thèse, nous avons rencontré des défis qui résident dans l'accès à une base de données locale de sinogrammes ainsi qu'à la complexité de mise en œuvre d'une chaîne de simulation complète sous GEANT4, exigeant une modélisation

rigoureuse de la géométrie de l'appareillage pour garantir la fidélité des sinogrammes TEP et TEMP générés.

### **Perspectives :**

Dans cette thèse nous avons réalisés des progrès méthodologiques significatifs, l'exploration de l'apprentissage profond dans le domaine de l'amélioration de la qualité d'image en médecine nucléaire reste un champ de recherche vaste et prometteur pour identifier de nouvelles stratégies et développer encore plus les algorithmes d'amélioration de la qualité d'images médicales.

Les perspectives de recherche qui pourraient enrichir ce travail sont les suivantes :

- Collecte d'une nouvelle base de données locale de sinogrammes.
- Réalisation d'une chaîne de simulation complète avec GEANT4, de la modélisation de l'appareillage jusqu'à la génération des sinogrammes TEP et TEMP.
- Optimisation du modèle proposé afin de l'adapter aux spécificités de diverses modalités d'imagerie médicale : IRM, échographie et TDM.
- Développement d'un logiciel de détection automatique des cas sains et pathologiques.
- Utilisation de méthodes de reconstruction purement basées sur l'intelligence artificielle.

Ces perspectives permettront de finaliser la transition de ce travail vers une application clinique plus fiable et généralisable.

## Références

- [1] T. Nouioua, "Etude des Techniques d'Acquisition et des Méthodes de Reconstruction des Images Médicales et Accélération de leur Traitement par Calcul Parallèle," Thèse de doctorat en Sciences, Département de Génie Physique, Université des Sciences et de la Technologie Mohamed Boudiaf (USTOMB), Oran, Algérie, 2023.
- [2] L. Comte-Arassus, "L'imagerie médicale : un pilier des dispositifs médicaux modernes et de la médecine de précision," *Ann. Mines - Réal. Ind.*, pp. 69-71, Février 2025.
- [3] H. R. Saeidnia, F. Firuzpour, M. Kozak, et H. Soleymani majd, "Advancing cancer diagnosis and treatment: integrating image analysis and AI algorithms for enhanced clinical practice," *Artif. Intell. Rev.*, vol. 58, no. 105, Janvier 2025. doi: 10.1007/s10462-025-11117-w.
- [4] W. Mu, M. B. Schabath, et R. J. Gillies, "Images Are Data: Challenges and Opportunities in the Clinical Translation of Radiomics," *Cancer Res.*, vol. 82, no. 11, pp. 2066-2068, Juin 2022.
- [5] S. Huang, J. Yang, S. Fong, et Q. Zhao, "Artificial intelligence in cancer diagnosis and prognosis: Opportunities and challenges," *Cancer Lett.*, vol. 471, pp. 61–71, Février 2020.
- [6] E. S. Evans, C. A. Hahn, Z. Kocak, S. M. Zhou, et L. B. Marks, "The role of functional imaging in the diagnosis and management of late normal tissue injury," *Semin. Radiat. Oncol.*, vol. 17, no. 2, pp. 72–80, Avril 2007.
- [7] A. J. Golby, Ed., *Image-Guided Neurosurgery*. San Diego, CA, USA : Academic Press, 2015.
- [8] M. Khodatars *et al.*, "Deep learning for neuroimaging-based diagnosis and rehabilitation of Autism Spectrum Disorder: A review," *Comput. Biol. Med.*, vol. 139, p. 104949, 2021. doi: 10.1016/j.combiomed.2021.104949.
- [9] A. Gonzalez-Montoro *et al.*, "Nuclear-medicine probes: Where we are and where we are going," *Med. Phys.*, 2022. doi: 10.1002/mp.15690.
- [10] W. Echavidre *et al.*, "Recent Pre-Clinical Advancements in Nuclear Medicine: Pioneering the Path to a Limitless Future," *Cancers*, vol. 15, no. 19, p. 4839, 2023. doi: 10.3390/cancers15194839.
- [11] S. B. Hansen et D. Bender, "Advancement in Production of Radiotracers," *Semin. Nucl. Med.*, vol. 52, no. 3, pp. 266–275, 2022. doi: 10.1053/j.semnuclmed.2021.10.003.
- [12] Contemp. Phys. Educ. Proj. (CPEP), *A Guide to the Nuclear Science Wall Chart: Or You don't have to be a Nuclear Physicist to Understand Nuclear Science*. Berkeley, CA, USA : CPEP, 2019.
- [13] A. I. M. López et P. T. Marco, "Misconceptions, Knowledge, and Attitudes Towards the Phenomenon of Radioactivity," *Sci. Educ.*, vol. 31, no. 4, pp. 405–426, 2022. doi: 10.1007/s11191-021-00251-w.
- [14] M.-C. de La Souchère, *La Radioactivité : Découverte, Mécanismes, Applications, Problématiques*. Paris, France : Ellipses, 2022.

- [15] M. Robin, "Développement d'un processus de décontamination d'effluent radioactif - Application aux alliages métalliques décontaminés par voie chimique," Thèse de doctorat, École nationale supérieure Mines-Télécom Atlantique, France, 2024.
- [16] P. Rubini, "Des subtiles différences entre les isotopes des éléments chimiques, de leur immuabilité ou précarité, de leurs utilisations pour le meilleur et pour le pire," Présentation, Académie de Stanislas, [Ville, France], Juin 2024.
- [17] K. Elhadj, *Chimie Générale: Polycopié de cours pour 1ère Année Licence STU, Filière Géologie*, Université 8 Mai 1945 Guelma, Guelma, Algérie, 2018-2019.
- [18] F. Salvador *et al.*, "Gamma-ray spectroscopy for the characterization of uranium contamination in nuclear decommissioning," in *EPJ Web Conf. (ANIMMA 2023)*, vol. 288, p. 07005, 2023. doi: 10.1051/epjconf/202328807005.
- [19] B. Mehadjji, "Modélisation Monte Carlo d'une caméra Compton basée sur l'utilisation de détecteurs à scintillation sensibles à la position couplés à des SiPM," Thèse de doctorat, École doctorale N°352 Physique et Sciences de la matière, Aix-Marseille Université, Aix-en-Provence, France, 2021.
- [20] K. Latreche et G. Boussekra, "La différence dans l'effet des rayonnements ionisants sur la matière vivante et non vivante," Mémoire de Master en Physique, Département de Physique, Université Mohamed Seddik Ben Yahia – Jijel, Jijel, Algérie, 2022.
- [21] D. L. Bailey *et al.*, Eds., *Nuclear Medicine Physics: A Handbook for Teachers and Students*. Vienne, Autriche : Agence Internationale de l'Énergie Atomique, 2014.
- [22] S. Zhang *et al.*, "Radiopharmaceuticals and their applications in medicine," *Signal Transduct. Target. Ther.*, vol. 10, no. 1, 2025. doi: 10.1038/s41392-024-02041-6.
- [23] S. Salih, A. Alkatheeri, W. Alomaim, et A. Elliyanti, "Radiopharmaceutical Treatments for Cancer Therapy, Radionuclides Characteristics, Applications, and Challenges," *Molecules*, vol. 27, no. 16, p. 5231, 2022. doi: 10.3390/molecules27165231.
- [24] N. S. Dawood *et al.*, "Role of Gamma Camera Components in Radiological Diagnosis," *Cent. Asian J. Med. Nat. Sci.*, vol. 4, no. 4, pp. 456–462, 2023. doi: 10.51699/cajms.v4i4.1730.
- [25] M. Bocher *et al.*, "A fast cardiac gamma camera with dynamic SPECT capabilities: design, system validation and future potential," *Eur. J. Nucl. Med. Mol. Imaging*, vol. 37, no. 10, pp. 1887–1902, Oct. 2010. doi: 10.1007/s00259-010-1488-z.
- [26] S. R. Cherry, "The 2006 Henry N. Wagner Lecture: Of mice and men (and positrons)-- advances in PET imaging technology," *J. Nucl. Med.*, vol. 47, no. 11, pp. 1735–1745, Nov. 2006.
- [27] V. Israel-Jost *et al.*, "Théorie et état de l'art de l'imagerie scintigraphique du petit animal avec collimateur pinhole simple et multi-trous (Theory and state of the art of small animal scintigraphic imaging with single pinhole and multi-hole collimator)," Janv. 2003.
- [28] S. Shokouhi *et al.*, "Multi-pinhole collimator design for small-object imaging with SiliSPECT: A high-resolution SPECT," *Phys. Med. Biol.*, vol. 54, no. 2, pp. 207–225, Jan. 2009. doi: 10.1088/0031-9155/54/2/003.

- [29] F. Gheisari, N. Ebrahimi, et R. Vali, "Artificial Intelligence in Nuclear Medicine: Current Applications and Future Prospects," *Am. J. Biomed. Sci. Res.*, vol. 21, no. 5, 2024. doi: 10.34297/AJBSR.2024.21.002879.
- [30] C. M. Tsai *et al.*, "Realization of collimated specific profiles in rotation-symmetrical beam shaping system with divergent light source," *Discov. Nano*, vol. 18, no. 160, 2023. doi: 10.1186/s11671-023-03934-1.
- [31] C. Stengl *et al.*, "Development and characterization of a versatile mini-beam collimator for pre-clinical photon beam irradiation," *Med. Phys.*, 2023. doi: 10.1002/mp.16432.
- [32] E. Tayebfard *et al.*, "Designing a combined guide and investigating the role of collimator in neutron intensity uniformity," *Ann. Nucl. Energy*, vol. 212, p. 111064, 2025. doi: 10.1016/j.anucene.2024.111064.
- [33] R. Figueroa *et al.*, "Monte Carlo study of a convergent X-ray beam for high resolution X-ray fluorescence imaging," *Appl. Radiat. Isot.*, vol. 170, p. 109610, 2021. doi: 10.1016/j.apradiso.2021.109610.
- [34] J. R. Berretta, "Développement d'un détecteur de neutrons utilisant un cristal scintillateur de CsI dopé au Li," Thèse de doctorat, Instituto de Pesquisas Energéticas e Nucleares, São Paulo, Brésil, 2023. doi: 10.11606/T.85.2023.tde-21062023-154456.
- [35] P. H. G. Durão, "Modeling of a preclinical PET system based on monolithic scintillator crystal using the GATE/GEANT4 and Castor codes," Instituto de Radioproteção e Dosimetria (IRD/CNEN-RJ), Rio de Janeiro, Brésil, 2022.
- [36] S. Mokadem, "Contrôle de qualité d'une Gamma-Caméra SPECT/CT," Mémoire de Master en Physique Médicale, Département de Physique, Université de Kasdi Merbah Ouargla, Ouargla, Algérie, 2023.
- [37] J. Dutreix, B. Bok, et A. Desgrez, *Biophysique des radiations et imagerie médicale*, 4e éd. Paris, France : Masson, 1997.
- [38] A. Houimli, "Optimisation de la reconstruction en tomographie d'émission monophotonique," Thèse de doctorat, Université de Tunis-El Manar, Tunis, Tunisie, 2022.
- [39] M. Héon, "Application des réseaux de neurones dans le développement d'algorithmes de restauration d'images appliqués à la tomographie par émission de positrons," Mémoire de Master, [Université non spécifiée], Mai 1998.
- [40] M. Defrise, "Reconstruction d'image en tomographie par émission," *Med. Nucl.*, vol. 31, no. 4, pp. 142–152, 2007. doi: 10.1016/j.mednuc.2007.02.004.
- [41] L. Desbat *et al.*, "MCDMMCetFDDCC en SPECT : Modélisation et correction du diffusé en SPECT par Méthode de Monte Carlo associées à la Fusion de Données SPECT/CT (ou IRM) par Data Consistency Conditions," Sept. 2003.
- [42] R. Vo *et al.*, "Approches Deep Learning sur Données Simulées pour la Tomographie Industrielle rapide," in *JOURNÉES COFREND 2023*, Marseille, France, Juin 2023.
- [43] J. Escoda *et al.*, "Utilisation de méthodes basées sur l'Intelligence Artificielle pour le contrôle non destructif par rayons X," in *JOURNÉES COFREND 2023*, Marseille, France, Juin 2023. doi: 10.58286/28495.

- [44] S. R. Cherry, J. A. Sorenson, et M. E. Phelps, *Physics in Nuclear Medicine*. Philadelphie, PA, USA : Elsevier Saunders, 2012.
- [45] M. Moreau, "Introduction à l'imagerie par Tomographie d'Émission de Positons : définitions, approches de reconstruction et initiation aux isotopes complexes," 2019.
- [46] S. Surti et J. S. Karp, "Advances in time-of-flight PET," *Phys. Med.*, vol. 32, no. 1, pp. 12–22, Janv. 2016. doi: 10.1016/j.ejmp.2015.12.007.
- [47] S. Nicol, "Étude et construction d'un tomographe TEP/TDM pour petits animaux, combinant modules phoswich à scintillateurs et détecteur à pixels hybrides," Thèse de doctorat, Université de la Méditerranée, Aix-Marseille II, Marseille, France, 2010.
- [48] J. Jones *et al.*, "Spatial resolution," *Radiopaedia.org*. doi: 10.53347/rID-6318 (Consulté le 28 Nov. 2025).
- [49] S. Agostinelli *et al.*, "GEANT4—A simulation toolkit," Elsevier Science, 2003.
- [50] S. Jan *et al.*, "GATE: a simulation toolkit for PET and SPECT," *Phys. Med. Biol.*, vol. 49, no. 19, pp. 4543–4561, Oct. 2004. doi: 10.1088/0031-9155/49/19/007.
- [51] D. Sarrut *et al.*, "Artificial Intelligence for Monte Carlo Simulation in Medical Physics," *Front. Phys.*, vol. 9, Oct. 2021. doi: 10.3389/fphy.2021.738112.
- [52] D. Sarrut *et al.*, "A review of the use and potential of the GATE Monte Carlo simulation code for radiation therapy and dosimetry applications," *Med. Phys.*, vol. 41, no. 6, p. 064301, Juin 2014. doi: 10.1118/1.4871617.
- [53] S. Incerti *et al.*, "Monte Carlo Microdosimetry for Targeted Irradiation of Individual Cells using a Microbeam Facility," *Radiat. Prot. Dosimetry*, vol. 133, no. 1, pp. 2–11, Fév. 2009. doi: 10.1093/rpd/ncp003.
- [54] H. Yu *et al.*, "Analytical reconstruction algorithm for multiple source-translation computed tomography (mSTCT)," *Appl. Math. Model.*, vol. 117, pp. 251–266, 2023. doi: 10.1016/j.apm.2022.12.024.
- [55] M. Beckmann et J. Nickel, "Optimized filter functions for filtered back projection reconstructions," *Inverse Probl. Imaging*, vol. 19, no. 5, pp. 903–939, Oct. 2025. doi: 10.3934/ipi.2025003.
- [56] M. Noori-Asl et A. Sadremomtaz, "Analytical image reconstruction methods in emission tomography," *J. Biomed. Sci. Eng.*, vol. 6, no. 1, pp. 100–107, Janv. 2013. doi: 10.4236/jbise.2013.61013.
- [57] H. Kudo, "Analytical Image Reconstruction Methods for Medical Tomography—Recent Advances and A New Uniqueness Result—," Présentation Soumise, Graduate School of Systems and Information Engineering, University of Tsukuba, Japon, Oct. 2006.
- [58] A. Ramage *et al.*, "Filtered back projection vs. iterative reconstruction for CBCT: effects on image noise and processing time," *Dentomaxillofac. Radiol.*, vol. 52, no. 8, p. 20230109, Nov. 2023. doi: 10.1259/dmfr.20230109.
- [59] M. O. Chandran *et al.*, "Influence of deep learning image reconstruction algorithm for reducing radiation dose and image noise compared to iterative reconstruction and filtered back projection for head and chest computed tomography examinations: a systematic review," *F1000Res.*, vol. 13, p. 274, Avr. 2024. doi: 10.12688/f1000research.147345.1.

- [60] K. Hartling *et al.*, "A comparison of algebraic reconstruction techniques for a single-detector muon computed tomography system," *Nucl. Instrum. Methods Phys. Res. A, Accel., Spectrom., Detect. Assoc. Equip.*, vol. 987, p. 164834, 2021. doi: 10.1016/j.nima.2020.164834.
- [61] J. Sheng *et al.*, "A novel cardiac SPECT system and imaging method," *Imaging Sci. J.*, 2020.
- [62] D. Bhatt *et al.*, "CNN Variants for Computer Vision: History, Architecture, Application, Challenges and Future Scope," *Electronics*, vol. 10, no. 20, p. 2470, 2021. doi: 10.3390/electronics10202470.
- [63] S. M. Al-Selwi *et al.*, "RNN-LSTM: From applications to modeling techniques and beyond—Systematic review," *J. King Saud Univ. Comput. Inf. Sci.*, vol. 36, no. 5, p. 102068, 2024. doi: 10.1016/j.jksuci.2024.102068.
- [64] H. W. L. Mak, R. Han, et H. H. F. Yin, "Application of Variational AutoEncoder (VAE) Model and Image Processing Approaches in Game Design," *Sensors*, vol. 23, no. 7, p. 3457, 2023. doi: 10.3390/s23073457.
- [65] M. K. AnbuDevi et K. Suganthi, "Review of Semantic Segmentation of Medical Images Using Modified Architectures of UNET," *Diagnostics*, vol. 12, no. 12, p. 3064, 2022. doi: 10.3390/diagnostics12123064.
- [66] J. P. Kozak *et al.*, "Stability, Reliability, and Robustness of GaN Power Devices: A Review," *IEEE Trans. Power Electron.*, vol. 38, no. 7.
- [67] Z. Lin *et al.*, "Revisiting RCAN: Improved Training for Image Super-Resolution," Pré-publication, arXiv, arXiv:2201.11279 [cs.CV], Janv. 2022. [En ligne]. Disponible sur : doi: 10.48550/arXiv.2201.11279.
- [68] I. Goodfellow *et al.*, "Generative adversarial networks," *Commun. ACM*, vol. 63, no. 11, pp. 139–144, Oct. 2020. doi: 10.1145/3422622.
- [69] A. Dash, J. Ye, et G. Wang, "A Review of Generative Adversarial Networks (GANs) and Its Applications in a Wide Variety of Disciplines: From Medical to Remote Sensing," *IEEE Access*, vol. PP, no. 99, pp. 1–1, Janv. 2023. doi: 10.1109/ACCESS.2023.3346273.
- [70] M. Krichen, "Les Generative Adversarial Networks," 2022. [En ligne]. Disponible sur : hal-04140057.
- [71] T. Chakraborty *et al.*, "Ten years of generative adversarial nets (GANs): a survey of the state-of-the-art," *Mach. Learn.: Sci. Technol.*, vol. 5, no. 1, p. 011001, Janv. 2024. doi: 10.1088/2632-2153/ad1f77.
- [72] S. K. Zhou *et al.*, "A Review of Deep Learning in Medical Imaging: Imaging Traits, Technology Trends, Case Studies With Progress Highlights, and Future Promises," *Proc. IEEE*, vol. 109, no. 5, pp. 820–838, Mai 2021. doi: 10.1109/JPROC.2021.3054390.
- [73] Z. Ramzi, "Advanced deep neural networks for MRI image reconstruction from highly undersampled data in challenging acquisition settings," Thèse de doctorat, Université Paris-Saclay, France, 2022. [En ligne]. Disponible sur : tel-03623570.
- [74] Z. Wang, "Reconstruction des images médicales de tomodensitométrie spectrale par apprentissage profond," Thèse de doctorat, Brest, France, 2024.
- [75] F. Jia *et al.*, "A super-resolution network using channel attention retention for pathology images," *PeerJ Comput. Sci.*, vol. 9, p. e1196, Janv. 2023. doi: 10.7717/peerj-cs.1196.
- [76] X. Gao *et al.*, "Residual multi-branch distillation network for efficient image super-resolution," *Multimed. Tools Appl.*, vol. 83, no. 30, pp. 1–25, Fév. 2024. doi: 10.1007/s11042-024-18504-5.

- [77] G. Santin *et al.*, "GATE: a Geant4-based simulation platform for PET and SPECT integrating movement and time management," *IEEE Trans. Nucl. Sci.*, vol. 50, no. 5, pp. 1516–1521, Oct. 2003. doi: 10.1109/TNS.2003.817974.
- [78] A. Hashemi *et al.*, "Versatile Geant4 simulation application with high performance for complex nuclear medicine imaging scanners," *J. Nucl. Med.*, vol. 64, no. supplement 1, p. P1323, Juin 2023.
- [79] M. Cañadas *et al.*, "Validation of a small-animal PET simulation using GAMOS: a GEANT4-based framework," *Phys. Med. Biol.*, vol. 56, no. 1, p. 273, 2011. doi: 10.1088/0031-9155/56/1/016.
- [80] F. Poignant *et al.*, "GEANT4 simulation of cyclotron radioisotope production in a solid target," *Phys. Med.*, vol. 32, no. 5, pp. 728–734, 2016. doi: 10.1016/j.ejmp.2016.04.006.
- [81] R. Freudenberg et J. Kotzerke, "Cellular Dosimetry Using the Geant4 Monte Carlo Toolkit," *J. Nucl. Med.*, vol. 51, no. 9, pp. 1488–1489, Sept. 2010. doi: 10.2967/jnumed.110.078832.
- [82] S. Lo Meo *et al.*, "A Geant4 simulation code for simulating optical photons in SPECT scintillation detectors," *J. Instrum.*, vol. 4, p. P07002, Juil. 2009. doi: 10.1088/1748-0221/4/07/P07002.
- [83] R. Vashistha *et al.*, "Modular GAN: positron emission tomography image reconstruction using two generative adversarial networks," *Front. Radiol.*, vol. 4, p. 1466498, Août 2024. doi: 10.3389/fradi.2024.1466498.
- [84] M. D. K. K. Manoj et J. C. Chen, "Utilizing deep learning techniques to improve image quality and noise reduction in preclinical low-dose PET images in the sinogram domain," *Med Phys.*, vol. 51, no. 1, pp. 209–223, Janv. 2024. doi: 10.1002/mp.16830.
- [85] A. Bousse *et al.*, "A Review on Low-Dose Emission Tomography Post-Reconstruction Denoising with Neural Network Approaches," Pré-publication, arXiv, arXiv:2401.00232 [physics.med-ph], Janv. 2024. [En ligne]. Disponible sur : doi: 10.48550/arXiv.2401.00232.
- [86] A. Reader, "Self-Supervised and Supervised Deep Learning for PET Image Reconstruction," Pré-publication, arXiv, arXiv:2302.13086, Fév. 2023. [En ligne]. Disponible sur : doi: 10.48550/arXiv.2302.13086.
- [87] I. Häggström *et al.*, "DeepPET: A deep encoder–decoder network for directly solving the PET image reconstruction inverse problem," *Med. Image Anal.*, vol. 54, pp. 253–262, Mai 2019. doi: 10.1016/j.media.2019.03.013.
- [88] A. Mehranian et A. J. Reader, "Model-Based Deep Learning PET Image Reconstruction Using Forward-Backward Splitting Expectation-Maximization," *IEEE Trans. Radiat. Plasma Med. Sci.*, vol. 5, no. 1, pp. 54–64, Juin 2020. doi: 10.1109/TRPMS.2020.3004408.
- [89] X. Hong *et al.*, "Enhancing the Image Quality via Transferred Deep Residual Learning of Coarse PET Sinograms," *IEEE Trans. Med. Imaging*, vol. 37, no. 10, pp. 2322–2332, Oct. 2018. doi: 10.1109/TMI.2018.2830381.
- [90] Q. Feng et H. Liu, "Rethinking PET Image Reconstruction: Ultra-Low-Dose, Sinogram and Deep Learning," in *Proc. Med. Image Comput. Comput. Assist. Interv. (MICCAI 2020)*, pp. 783–792, Sept. 2020.
- [91] J. Cui *et al.*, "CT-guided PET parametric image reconstruction using deep neural network without prior training data," in *Proc. SPIE Med. Imaging 2019: Phys. Med. Imaging*, San Diego, CA, USA, Mars 2019, p. 109480Z. doi: 10.1117/12.2513077.
- [92] J. Xu *et al.*, "200x Low-dose PET Reconstruction using Deep Learning," Pré-publication, arXiv, arXiv:1712.04119 [cs.CV], Déc. 2017. [En ligne]. Disponible sur : doi: 10.48550/arXiv.1712.04119.

- [93] Sorbonne Université, "Algorithms, models and methods for images and signals of the human brain," Sorbonne Université, [En ligne]. Disponible sur : URL (à spécifier). (Consulté le Nov. 29, 2025).
- [94] D. Y. Lee, J. Y. Kim, et S. Y. Cho, "Improving Medical Image Quality Using a Super-Resolution Technique with Attention Mechanism," *Appl. Sci.*, vol. 15, no. 2, p. 867, 2025. doi: 10.3390/app15020867.
- [95] B. Lim *et al.*, "Enhanced Deep Residual Networks for Single Image Super-Resolution," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. Workshops (CVPRW)*, Honolulu, HI, USA, Juil. 2017, pp. 1132–1140. doi: 10.1109/CVPRW.2017.151.
- [96] J. Kim, J. K. Lee, et K. M. Lee, "Accurate Image Super-Resolution Using Very Deep Convolutional Networks," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, Las Vegas, NV, USA, Juin 2016. [En ligne]. Disponible sur : doi: 10.48550/arXiv.1511.04587.
- [97] T. A. Song *et al.*, "PET image super-resolution using generative adversarial networks," *Neural Netw.*, vol. 125, pp. 83–91, 2020. doi: 10.1016/j.neunet.2020.01.029.
- [98] G. Yang *et al.*, "Quasi-supervised learning for super-resolution PET," *Comput. Med. Imaging Graph.*, vol. 113, p. 102351, 2024. doi: 10.1016/j.compmedimag.2024.102351.
- [99] T. Yoshimura *et al.*, "Medical Radiation Exposure Reduction in PET via Super-Resolution Deep Learning Model," *Diagnostics*, vol. 12, no. 4, p. 872, 2022. doi: 10.3390/diagnostics12040872.
- [100] S. Ren *et al.*, "Super-resolution PET Brain Imaging using Deep Learning," in *Proc. IEEE Nucl. Sci. Symp. Med. Imaging Conf. (NSS/MIC)*, Piscataway, NJ, USA, Oct. 2021, pp. 1–6. doi: 10.1109/NSS/MIC44867.2021.9875548.
- [101] J. A. Kennedy *et al.*, "Super-resolution in PET imaging," *IEEE Trans. Med. Imaging*, vol. 25, no. 2, pp. 137–147, Fév. 2006. doi: 10.1109/TMI.2005.861705.
- [102] M. Liu *et al.*, "Super resolution reconstruction of PET images based on deep learning," *Acad. J. Comput. Inf. Sci.*, vol. 4, no. 1, pp. 48–52, 2021. doi: 10.25236/AJCIS.2021.040108.
- [103] L. Ma *et al.*, "Intelligent medical image reconstruction: PET image denoising and super-resolution joint processing based on generating adversarial network," in *Proc. 2nd Conf. Fully Actuated Syst. Theory Appl. (CFASTA)*, Qingdao, Chine, Sept. 2023, pp. 648–653. doi: 10.1109/CFASTA57821.2023.10243264.
- [104] Parkinson's Progression Markers Initiative (PPMI), "PPMI Database Access (via LONI IDA)." Laboratory of Neuro Imaging (LONI). [En ligne]. Disponible sur : <https://ida.loni.usc.edu/login.jsp?project=PPMI>. [Consulté le : 2 déc. 2025].
- [105] Geant4 Collaboration, "Geant4: A Toolkit for the Simulation of the Passage of Particles through Matter." CERN. [En ligne]. Disponible sur : <https://geant4.web.cern.ch/>. [Consulté le : 2 déc. 2025].
- [106] MathWorks, "Previous Release Overview." MathWorks. [En ligne]. Disponible sur : [https://www.mathworks.com/products/new\\_products/previous\\_release\\_overview.html](https://www.mathworks.com/products/new_products/previous_release_overview.html). [Consulté le : 2 déc. 2025].
- [107] Spyder, "The Scientific Python Development Environment." Spyder IDE. [En ligne]. Disponible sur : <https://www.spyder-ide.org/>. [Consulté le : 2 déc. 2025].
- [108] Anaconda, "spyder." Anaconda.org. [En ligne]. Disponible sur : <https://anaconda.org/anaconda/spyder>. [Consulté le : 2 déc. 2025].
- [109] Z. Zhao, L. Alzubaidi, J. Zhang, Y. Duan, Y. Gu, "A comparison review of transfer learning and self-supervised learning: Definitions, applications, advantages and limitations," *Expert Syst. Appl.*, vol. 242, Art. no. 122807, 2024.
- [110] X. Yu, J. Wang, Q.-Q. Hong, R. Teku, S.-H. Wang, Y.-D. Zhang, "Transfer learning for medical images analyses: A survey," *Neurocomputing*, vol. 489, pp. 230–254, 2022.

- [111] X. Chen, R. Yang, Y. Xue, M. Huang, R. Ferrero et Z. Wang, "Deep Transfer Learning for Bearing Fault Diagnosis: A Systematic Review Since 2016," *IEEE Trans. Instrum. Meas.*, vol. 72, pp. 1–21, 2023, Art no. 3508221.
- [112] Y. Al-Najjar, "Comparative Analysis of Image Quality Assessment Metrics: MSE, PSNR, SSIM and FSIM," *Int. J. Sci. Res. (IJSR)*, vol. 13, no. 3, pp. 110–114, Mar. 2024.
- [113] M. Arabboev et al., "Development of a Novel Method for Image Resizing Using Artificial Neural Network," dans *Intelligent Human Computer Interaction*, K. Kyamakya et al., Éd. Cham: Springer Nature Switzerland, 2023, pp. 671–682.
- [114] M. Arabboev et al., "Development of a novel method of adaptive image interpolation for image resizing using artificial intelligence," dans *Proc. 27th Int. Conf. Inf. Soc. Univ. Stud. (IVUS 2022)*, Kaunas, Lituanie, 2024.
- [115] U. Sara, M. Akter, et M. S. Uddin, "Image Quality Assessment through FSIM, SSIM, MSE and PSNR—A Comparative Study," *J. Comput. Commun.*, vol. 7, no. 3, pp. 11–24, Mar. 2019.
- [116] S. Katta, P. Singh, D. Garg, et M. Diwakar, "A Hybrid Approach for CT Image Noise Reduction Combining Method Noise-CNN and Shearlet Transform," *Biosci. Biotechnol. Res. Asia*, vol. X, no. X, pp. Page range, 2024.
- [117] R. Zhang, P. Isola, A. A. Efros, E. Shechtman, et O. Wang, "The Unreasonable Effectiveness of Deep Features as a Perceptual Metric," dans *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR)*, Salt Lake City, UT, USA, 2018, pp. 586–595.
- [118] L. Onac et al., "An image-domain deep-learning denoising technique for accelerated parallel brain MRI: prospective clinical evaluation," *Radiol. Adv.*, vol. 1, no. 3, Art. no. uma022, Sep. 2024.
- [119] M. Seo et al., "Effects of Deep Learning-Based Reconstruction on the Quality of Accelerated Contrast-Enhanced Neck MRI," *Korean J. Radiol.*, vol. 26, no. 5, pp. 446–455, May 2025.
- [120] A. Benyelles et A. Korti, "Scintigraphy images reconstruction and simulation of gamma camera," Communication présentée au *Computational and Applied Physics Symposium 2023 (CAPS2023)*, Université de Khemis Miliana, Algérie, Mai 2023.
- [121] A. Benyelles et A. Korti, "Study and Simulation of Gamma Camera components," Communication orale présentée à la *1st International Conference on Frontiers in Academic Research (ICFAR)*, Konya, Turquie, 18-21 Février 2023.
- [122] A. Benyelles et A. Korti, "PET Images reconstruction using analytical and iterative methods," Communication orale présentée à la *4th International Conference on Applied Engineering and Natural Sciences (ICAENS 2022)*, Konya, Turquie, 10-13 Novembre 2022.
- [123] A. Benyelles et A. Korti, "Tomographic image reconstruction using analytical and iterative methods," Communication présentée au *Symposium on Innovation and Research in Biomedical Engineering (SIRBE'2024)*, Oran, Algérie, 17-20 Avril 2024.
- [124] A. Benyelles et A. Korti, "Enhancing the Quality of PET Images Reconstructed by Filtered Back Projection and Ordered Subsets Expectation Maximization," Communication orale présentée à l'*International Conference on Engineering, Natural Sciences, and Technological Developments (ICENSTED 2024)*, Erdek, Turquie, 19-21 Juillet 2024.
- [125] A. Benyelles et A. Korti, "Comparative Analysis of Deep Learning-Improved PET Reconstruction Methods," Communication orale présentée à la *National Conference on Innovation in Data Engineering and Artificial Intelligence Science (IDEAS'2025)*, Oran, Algérie, 11-12 Juin 2025.

- [126] A. Benyelles et A. Korti, "Evaluating Hybrid Deep Learning and Traditional Methods for PET Image Reconstruction: A Comparative Study," *Global Clinical Engineering Journal*, vol. 7, no. 4, pp. 6–15, Année 2025.
- [127] A. Benyelles et A. Korti, "Advanced deep learning for PET image reconstruction and quality improvement," *The Imaging Science Journal*, 2025, doi: 10.1080/13682199.2025.2558374.
- [128] A. Benyelles et A. Korti, "Generative Adversarial Networks for Optimized Scintigraphy Image Reconstruction," Communication présentée à la *Biomedical Engineering International Conference (BIOMEIC2025)*, Tlemcen, Algérie, 9-11 Novembre 2025.