

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université SAAD DAHLEB Blida -1-
Département d'informatique



Mémoire de Projet de Fin d'Études
Pour l'obtention du diplôme de Master en Informatique
Option : Ingénierie du Logiciel

Fusion d'images médicales multimodale par le deep learning

Présenté par :

HADJALLAH Issam

BENNIA Abdelkrim

Devant le Jury composé de :

YKHLEF Hadjer

Présidente

OUKID Lamia

Examinatrice

LAHIANI Nesrine

Promotrice

ALIM Fatiha

Encadrante

TALBI Farid

Encadrant

Année Universitaire 2023-2024

Médecin
Dr S. KADIK
Médecin Neurologue
Cité Mustapha Ben Boulaid N°02-BLIDA
N° d'Ordre : 093068

Ordonnance

Date: 15 JUIN 2024

Nom & Prénom: _____ Age: _____

attestation

Je soussigné, Dr KADIK,
certifie avoir visionné
le travail établi par
monsieur HADY ALI AH AÏSSAM,
et apprécie son utilité
scientifique.

Dr S. KADIK
Médecin Neurologue
Cité Mustapha Ben Boulaid N°02-BLIDA
N° d'Ordre : 093068

Remerciements

Nous remercions Allah le tout puissant de nous avoir donné la santé et la volonté de réaliser ce projet, El Hamdoulillah !

La réalisation de ce projet a été possible grâce à l'assistance de plusieurs personnes à qui nous tenons à exprimer toute notre gratitude et nos sincères remerciements à tous.

Tout d'abord, une gratitude particulière à notre chef de projet, Mme LAHIANI et Mr TALBI et Mme ALIM Pour leurs contribution en stimulant les suggestions et les encouragements, leurs patience, leurs disponibilité, et surtout leurs sages conseils qui ont contribué à alimenter notre réflexion et à coordonner notre projet.

Nous tenons à exprimer notre gratitude au département d'informatique de l'Université Blida 1, pour sa contribution tout au long de ce programme de Master.

Nous tenons également à remercier le directeur du département et le département Architecture de système, qui nous ont fourni les outils nécessaires à la réussite de notre projet.

Nos remerciements s'étendent également à nos parents pour leur amour, leur soutien moral et à nos amies SOUCI Azzedine, BOURAS Tarek, HADJALLAH Mahdi, OUCHAT salim, GHERIS Dalil, Et a toute personne coopérant directement ou indirectement à l'exécution de ce travail.

Résumé

Le domaine du traitement de l'image évolue rapidement, stimulé par les avancées technologiques en information et communication. En médecine, cette évolution a transformé les pratiques diagnostiques grâce à l'imagerie médicale, permettant une exploration détaillée des organes humains. Cependant, cela génère une immense quantité de données d'imagerie, posant des défis d'intégration et d'interprétation.

La fusion multimodale, essentielle en imagerie médicale, combine des images issues de différentes techniques (IRM, TDM, TEP) pour créer une image fusionnée intégrant des caractéristiques anatomiques et fonctionnelles distinctes, visant à améliorer la précision diagnostique et la prise en charge thérapeutique. Cette approche présente des défis, notamment en termes de synchronisation et de cohérence des images.

Dans ce contexte, notre étude a développé une méthode de fusion basée sur des techniques d'apprentissage profond, simplifiant et accélérant l'intégration des images de sources diverses en une seule image composite. Cette approche a été rigoureusement évaluée à travers des analyses qualitatives et quantitatives, incluant une évaluation par des experts médicaux. Les résultats démontrent que notre algorithme améliore significativement la qualité et l'utilité des images fusionnées pour le diagnostic médical.

Mots-clés : Imagerie médicale, Apprentissage profond, fusion multimodale, diagnostic précis, IRM, TDM, TEP.

Abstract

The field of image processing is rapidly advancing, driven by technological advancements in information and communication. In medicine, this evolution has transformed diagnostic practices through medical imaging, enabling detailed exploration of human organs. However, this generates a vast amount of imaging data, posing challenges in integration and interpretation.

Multimodal fusion, crucial in medical imaging, combines images from different techniques (MRI, CT, PET) to create a fused image that integrates distinct anatomical and functional features, aiming to enhance diagnostic accuracy and therapeutic management. This approach presents challenges, particularly in terms of image synchronization and coherence.

In this context, our study developed a fusion method based on deep learning techniques, simplifying and speeding up the integration of images from diverse sources into a single composite image. This approach was rigorously evaluated through qualitative and quantitative analyses, including assessment by medical experts. The results demonstrate that our algorithm significantly improves the quality and utility of fused images for medical diagnosis.

Keywords: Medical imaging, Deep Learning, multimodal fusion, accurate diagnosis, PET, CT, MRI

الملخص

يتطور مجال معالجة الصور بسرعة، مدفوعاً بالتقدم التكنولوجي في مجالات المعلومات و الاتصالات. في الطب، قام هذا التطور بتحويل الممارسات التشخيصية من خلال التصوير الطبي، مما يتيح استكشافاً مفصلاً لأعضاء الجسم البشري. ومع ذلك، فإن هذا يولد كمية هائلة من بيانات الصور، مما يطرح تحديات في التكامل والتفسير.

الاندماج متعدد الأوضاع، الأساسي في الصور الطبية، يجمع بين الصور من مختلف التقنيات (MRI)، CT، (PET) لإنشاء صورة مدمجة تجمع بين خصائص تشريحية ووظيفية متميزة، بهدف تحسين دقة التشخيص وإدارة العلاج. تواجه هذه النهج تحديات، خاصة فيما يتعلق بتزامن الصور واتساقها.

في هذا السياق، قامت دراستنا بتطوير طريقة للدمج استناداً إلى تقنيات التعلم العميق، مما يبسط ويسرع عملية دمج الصور من مصادر متنوعة في صورة مركبة واحدة. تم تقييم هذا النهج بدقة من خلال تحليلات نوعية وكمية، بما في ذلك تقييم من قبل خبراء طبيين. تظهر النتائج أن خوارزمتنا تحسن بشكل كبير جودة وفائدة الصور المدمجة للتشخيص الطبي.

الكلمات المفتاحية: التصوير الطبي ، التعلم العميق، الدمج متعدد الأنماط، التشخيص الدقيق

Table des matières

Résumé	
Abstract	
الملخص	
Liste des figures	
Liste des Tableaux	
Liste des abréviations	

CHAPITRE 1 ÉTAT DE L'ART

Introduction	3
1.1. Image Médicale	3
1.1.1. Les principes d'imagerie anatomique (Imagerie structurelle).....	4
1.1.2. Les Principes de l'Imagerie en Médecine Nucléaire (Imagerie Fonctionnelle).....	6
1.1.3. L'Image Multimodale	8
1.2. La Fusion d'Images	8
1.2.1. Les Types De Fusion D'images	9
1.2.2. Les contextes de fusion	10
1.2.3. Les méthodes de fusion traditionnelles (Approches Classiques de Fusion d'Images Médicales)	12
1.2.4. Les méthodes de fusion basée sur le Deep Learning.....	13
1.2.5. Approche de fusion d'image	14
1.2.6. Travaux Antérieurs.....	15
Conclusion.....	20

CHAPITRE 2 CONCEPTION ET METHODOLOGIE

Introduction	21
2.1. Processus de Fusionnement.....	21
2.1.1. Collecte et Prétraitement des Données	22
2.1.2. Les Modèles Proposés	24
2.1.3. Modèle 2 basé sur VGG19	28
2.2. Métriques d'Évaluation	30
2.2.1. Sélection des métriques pour une évaluation exhaustive :	30
2.2.2. Évaluation Quantitative	30
2.2.3. Évaluation Qualitative.....	32
Conclusion.....	32

CHAPITRE 3 IMPLEMENTATION ET RESULTATS DES TEST

Introduction	33
3.1.Outils et Langages de Programmation	33
3.1.1.Python.....	33
3.1.2.TensorFlow.....	33
3.1.3.OpenCV (cv2)	33
3.1.4.PyQT	33
3.1.5.MySQL.....	33
3.1.6.Pytorch	34
3.1.7.Environment matériel	34
3.2.Résultats sur la Fusion d'Images Médicales	34
3.2.1.Fusion d'Images IRM et PET.....	34
3.3.Fusion d'Images IRM et SPECT.....	36
3.3.1.Comparaison qualitative.....	36
3.3.2.Évaluation quantitative.....	36
3.4.Fusion d'Images IRM et CT.....	38
3.4.1.Comparaison Qualitative.....	38
3.4.2.Évaluation quantitative.....	38
3.5.Évaluation par Expert Médical.....	39
3.6.Présentation de l'application	39
Conclusion.....	44

CONCLUSION ET PERSPECTIVES

Conclusion generale	45
Bibliographie.....	47

Liste des figures

Figure 1.1 : Applications de la Radiographie en Imagerie Structurale. [32]	4
Figure 1.2 : principes et Applications de la Tomodensitométrie (CT) . [31].....	4
Figure 1.3 : Description de l'image de scintigraphie. [27]	5
Figure 1.4 : Imagerie par Résonance Magnétique (IRM) et ses Applications Neurologiques [29]......	6
Figure 1.5 : Apport de la Tomographie par Émission de Positrons (TEP) dans le Diagnostic Médical. [30]	7
Figure 1.6 : Tomographie à émission monophonique (SPECT) [28]	7
Figure 1.7 : Fusion d'images en Imagerie Médicale. [33]	9
Figure 1.8 : Structure des Contextes de Fusion en Imagerie Médicale.....	12
Figure 1.9 : EMFusion.	16
Figure 1.10 : DDCGAN.	17
Figure 1.11 : IFCNN.	18
Figure 1.12 : DenseFuse.....	18
Figure 2.1 : Schéma représentant de le processus de fusion	22
Figure 2.2 : Schéma du modèle 1 de Fusion.	25
Figure 2.3 : Schéma d'un Bloc Résiduel.	25
Figure 2.4 : Représentation De L'architecture Du Modèle VGG19 [34].	28
Figure 2.5 : représentation graphique du modèle 2 de fusion.	29
Figure 3.1 : Évaluation qualitative des Modèles Proposées avec Deux Concurrents pour la Fusion d'Images IRM et PET.	35
Figure 3.2 : Évaluation qualitative des Modèles Proposées avec Deux Concurrents pour la Fusion d'Images IRM et SPECT	36
Figure 3.3 : Évaluation qualitative des Modèles Proposées avec IFCNN pour la Fusion d'Images IRM et CT	38
Figure 3.4 : Page d'accueil.....	40
Figure 3.5 : page de la base de données des patients.	41
Figure 3.6 : Page d'enregistrement d'une nouvelle personne.	41
Figure 3.7 : interface de visualisation des images CT_MRI des patients	42
Figure 3.8 : interface de visualisation des images PET_MRI des patients	42
Figure 3.9 : interface de visualisation des images SPECT_MRI des patients	43
Figure 3.10 : Interface De Fusionnement Des Images	44

Liste des Tableaux

Tableau 1 : Tableau comparatif des travaux existants	19
Tableau 2 : Distribution des Patches pour Entraînement et Tests par Modalité.....	24
Tableau 3 : Ressources locales des ordinateurs utilisé.	34
Tableau 4 : Évaluation Quantitative des Modèles Proposées avec Deux Concurrents pour la Fusion d'Images IRM et PET	36
Tableau 5 : Évaluation Quantitative des Modèles Proposées avec Deux Concurrents pour la Fusion d'Images IRM et SPECT.	37
Tableau 6 : Évaluation Quantitative des Modèles Proposées avec IFCNN pour la Fusion d'Images IRM et CT.	39

Liste des abréviations

TEP : Tomographie par Émission de Positons

TDM : Scanner

TEMP : Tomographie à émission monophonique

IRM : Imagerie par Résonance Magnétique

SSIM : Indice de similarité structurelle

PSNR : Peak Signal-to-Noise Ratio

VIF : Fidélité des informations visuelles

CC : Coefficient de corrélation

MSE : Erreur quadratique moyenne

CNN : Convolutional Neural Network

Y : Luminance

CR : Chrominance Rouge

CB : Chrominance bleu

INTRODUCTION
GENERALE

INTRODUCTION GENERALE

Contexte de travail

Le domaine du traitement de l'image progresse rapidement grâce aux technologies de l'information et de la communication. En médecine, l'adaptation au numérique a facilité le travail du personnel médical et offert de nouveaux outils de diagnostics, notamment en imagerie médicale. Cette discipline, en plein essor grâce aux technologies numériques, permet une investigation plus fine des organes humains mais génère une quantité considérable de données.

La qualité, la précision et la performance en imagerie médicale est essentielle pour des diagnostics précis et des succès thérapeutiques. L'émergence de technologies avancées de fusion d'images, combinée aux avancées en intelligence artificielle et en apprentissage automatique, offre une meilleure visibilité des affections ou pathologies. Cependant, fusionner efficacement des images de modalités différentes comme l'IRM, la TEP et le CT-SCAN reste un défi.

Notre travail se concentre sur le développement de méthodes de fusion d'images pour fusionner les informations visuelles et faciliter son interprétation par les professionnels de santé. Nous visons à surmonter les obstacles techniques en utilisant des techniques avancées de traitement d'images et d'apprentissage automatique, tout en minimisant les artefacts et distorsions.

Problématique

La fusion multimodale en imagerie médicale représente un outil essentiel pour combiner les informations issues de différentes modalités d'imagerie, comme l'IRM, la CT et la TEP. Cette technique permet d'obtenir une vue d'ensemble plus riche des caractéristiques anatomiques et fonctionnelles, facilitant ainsi un diagnostic précis. Toutefois, l'intégration des données provenant de diverses sources pose des défis spécifiques, tels que l'harmonisation des images et la conservation des détails diagnostiques cruciaux. Quelles innovations peuvent y remédier ? Les interrogations principales se déploient autour de trois axes majeurs :

QR1. Comment modéliser et fusionner de façon cohérente les informations issues de diverses modalités d'imagerie pour aboutir à une image fusionnée fidèle à la réalité physiologique ?

QR2. De quelle manière peut-on assurer la conservation et l'amélioration des détails diagnostiques dans le processus de fusion, sans altérer la valeur clinique des images originales ?

QR3. Quels sont les Framework et outils avancés pouvant être mis en œuvre pour

INTRODUCTION GENERALE

développer et valider un système de fusion d'images médicales robuste et précis ?

Objectifs du travail

L'objectif principal de cette étude est de développer une méthodologie de fusion d'images médicales qui surmonte ces défis et améliore la qualité des diagnostics. Nous explorerons des méthodes avancées de traitement d'images et d'apprentissage automatique pour maximiser la qualité des informations combinées et minimiser les artefacts et les distorsions. Pour atteindre cet objectif, nous avons défini plusieurs objectifs spécifiques :

- Développer un modèle de fusion d'images médicales qui intègre avec précision les données issues de diverses modalités d'imagerie pour former une image fusionnée.
- Évaluer la performance du modèle proposé en utilisant des métriques de performance standardisées telles que SSIM, PSNR, VIF, ... Etc.
- Développer une interface utilisateur qui facilite l'utilisation du modèle développé.

Organisation du mémoire

Nous avons organisé notre travail en trois chapitres :

▪ Chapitre 1 : État de l'art

Ce chapitre présente un état de l'art de l'imagerie médicale. Il aborde les différents types d'images médicales, les techniques de fusion d'images et un aperçu des travaux existants dans le domaine.

▪ Chapitre 2 : Conception et Méthodologie

Dans ce chapitre, nous décrivons la conception de notre méthode de fusion d'images médicales, en exposant les motivations derrière les choix technologiques et méthodologiques adoptés.

▪ Chapitre 3 : Implémentation et Résultats Des Test

Ce dernier chapitre est consacré à l'implémentation et à la validation de l'Application proposé. Il détaille les tests effectués, les résultats obtenus, et démontre l'efficacité de la solution à travers des études de cas et des expérimentations.

CHAPITRE 1

ÉTAT DE L'ART

Introduction

L'imagerie médicale est devenue un outil de diagnostic incontournable dans le milieu médical. Quelle que soit la méthode d'acquisition, radiographie, angiographie, scanner, résonance magnétique, échographie, endoscopie etc. C'est le procédé par lequel un médecin peut examiner l'intérieur du corps d'un patient sans l'opérer. L'imagerie médicale peut être utilisée à des fins cliniques pour l'établissement d'un diagnostic ou pour le traitement de pathologies mais également dans le cadre de travaux de recherche scientifique des êtres vivants[15].

Dans ce chapitre nous proposons une étude dans le monde de l'image médicale, Nous commençons par définir l'image médicale et explorer sa contribution vitale à la santé. L'accent est mis sur les modalités d'imagerie - radiographie, scanner, scintigraphie et IRM - chacune révélant des aspects différents du corps humain, des os aux tissus mous, en passant par la fonction cellulaire.

Nous examinons ensuite les avancées récentes dans l'imagerie médicale, en particulier l'imagerie fonctionnelle, permettent de diagnostiquer et de traiter les maladies en offrant des informations sur l'activité des organes et des tissus. C'est dans ce contexte que l'imagerie multimodale gagne en importance, combinant diverses sources d'information pour une vue d'ensemble enrichie et des décisions cliniques éclairées.

Nous traitons ensuite de la fusion d'images médicales, une convergence des méthodes traditionnelles et des innovations en intelligence artificielle, notamment le Deep Learning. Ces avancées nouvelles sont scrutées à travers les contextes cliniques où elles s'appliquent, du suivi thérapeutique à la navigation chirurgicale, illustrant leur impact sur l'amélioration des soins aux patients.

1.1. Image Médicale

Les images constituent la plus grande source de données dans le domaine de la santé et, en même temps, l'une des sources les plus difficiles à analyser. On peut définir une image médicale comme la matérialisation sous forme d'images d'information anatomique ou fonctionnelle des parties (organes, tissus, cellules) du corps humain, Ces images sont utilisées par les professionnels de la santé pour diagnostiquer, surveiller et traiter les maladies et les conditions médicales. Elle peut être obtenue par diverse modalité d'imagerie.[15]

1.1.1. Les principes d'imagerie anatomique (Imagerie structurale)

- a) **Radiographie** : Les structures internes du corps sont représentées par la radiographie à l'aide de rayons X. Les rayons X passent à travers le corps et sont absorbés différemment par les différents tissus, ce qui permet de visualiser des structures contrastées, comme les os et les tissus mous, sur l'image capturée. [3]



Figure 1.1 : Applications de la Radiographie en Imagerie Structurale. [32]

- b) **Tomodensitométrie (CT Scan)** : La tomodensitométrie, également connue sous le nom de scan de tomodensitométrie (CT), utilise les principes de la radiographie pour créer des images tridimensionnelles. Des images en coupe transversale sont acquises et reconstruites en 3D par traitement informatique en faisant tourner la source de rayons X et le détecteur autour du patient. [3]

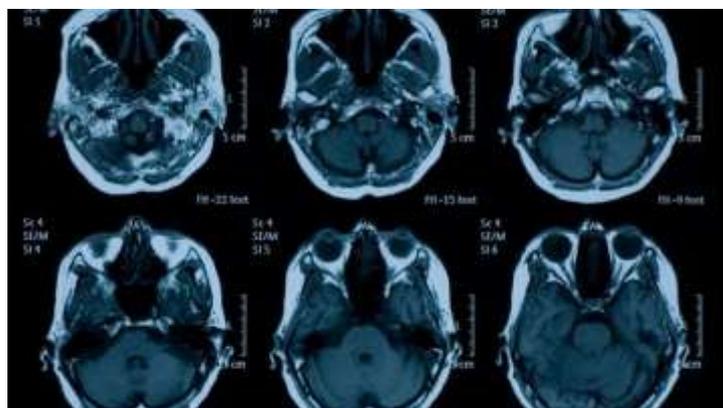


Figure 1.2 : principes et Applications de la Tomodensitométrie (CT) . [31]

- c) **Utilisation de la Scintigraphie Monophotonique en Diagnostic Médical :** Une procédure d'imagerie diagnostique appelée scintigraphie monophotonique utilise des traceurs radioactifs pour visualiser l'activité moléculaire ou fonctionnelle à l'intérieur du corps. Le patient reçoit une injection d'un traceur contenant un isotope radioactif. Une caméra gamma détecte les photons émis par ce traceur, ce qui permet la reconstruction d'images en trois dimensions qui montrent comment les organes et les tissus analysés utilisent le traceur, offrant des informations précieuses sur leur fonctionnement.[15]

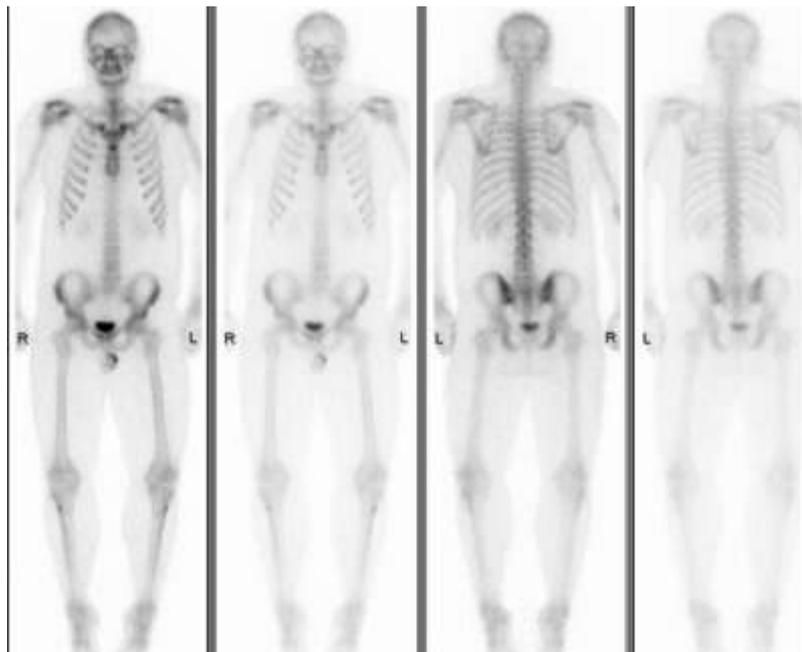


Figure 1.3 : Description de l'image de scintigraphie. [27]

- d) **Imagerie par Résonance Magnétique (IRM) et ses Applications Neurologiques :** L'imagerie par résonance magnétique (IRM) est une technique d'imagerie médicale puissante qui utilise un champ magnétique et des ondes radio pour créer des images détaillées des structures internes du corps, en particulier les tissus mous. Sa capacité à offrir une vision tridimensionnelle sans utiliser de radiations ionisantes la rend un outil crucial pour le diagnostic de diverses conditions, notamment en neurologie, en permettant une évaluation précise de l'anatomie cérébrale et de la fonctionnalité des organes [9].

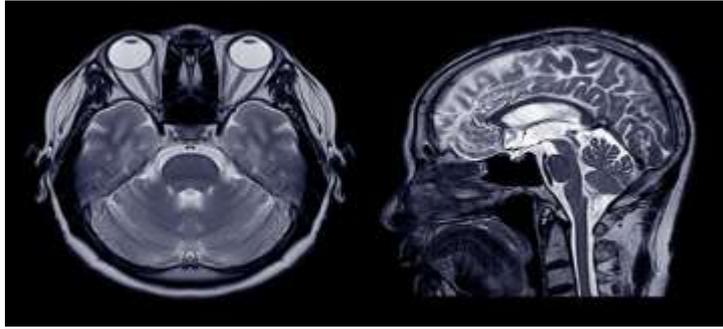


Figure 1.4 : Imagerie par Résonance Magnétique (IRM) et ses Applications Neurologiques [29].

1.1.2. Les Principes de l'Imagerie en Médecine Nucléaire (Imagerie Fonctionnelle)

La médecine nucléaire, qui est un domaine dynamique qui combine la physique, la chimie et la médecine, a vu son développement grâce aux avancées récentes en radiochimie et en technologie d'imagerie. Cette discipline offre la possibilité d'étudier non seulement la composition mais également l'activité des systèmes biologiques. Au cœur de l'imagerie fonctionnelle, des techniques telles que la tomographie par émission de positons (TEP) et la scintigraphie par émission de photon unique (SPECT) permet de diagnostiquer et de suivre les pathologies, offrant une vue unique sur les processus physiologiques et pathologiques internes.

- a) Tomographie par Émission de Positons (TEP Scan) :** La modalité d'imagerie avancée TEP utilise des traceurs radioactifs pour visualiser et mesurer l'activité métabolique des tissus. Le traceur se lie aux tissus d'intérêt après administration d'intraveineuse, et les positons émis lors de sa désintégration rencontrent les électrons voisins, provoquant l'émission de photons détectés par la machine TEP. Ensuite, cette interaction est transformée en images tridimensionnelles, ce qui révèle des informations importantes sur la façon dont les organes et les tumeurs fonctionnent et permet une évaluation précise du métabolisme cellulaire. La TEP est particulièrement efficace pour le diagnostic et la surveillance du cancer, des maladies neurologiques et des troubles cardiaques grâce à sa sensibilité exceptionnelle. [9]

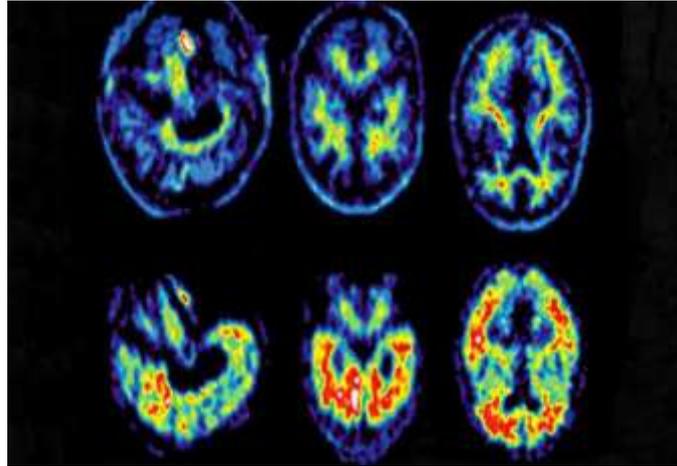


Figure 1.5 : Apport de la Tomographie par Émission de Positrons (TEP) dans le Diagnostic Médical. [30]

b) Tomographie à émission monophonique (SPECT Scan) : Le SPECT utilise également des traceurs radioactifs pour créer des images fonctionnelles du corps, bien qu'il soit similaire au TEP dans son principe. Cependant, le SPECT détecte directement les photons émis par le déclin radioactif du traceur plutôt que les positons. Le SPECT est utile pour évaluer les fonctions cérébrales, cardiaques et osseuses en raison de l'utilisation de composés marqués au technétium-99m et de la capacité de la technique à produire des images en coupe du flux sanguin et de l'activité des tissus. Sa capacité à être réalisée dans des environnements dynamiques, tels que pendant ou après une crise épileptique, en fait un outil essentiel dans l'étude des maladies neurologiques et la planification du traitement. [9]

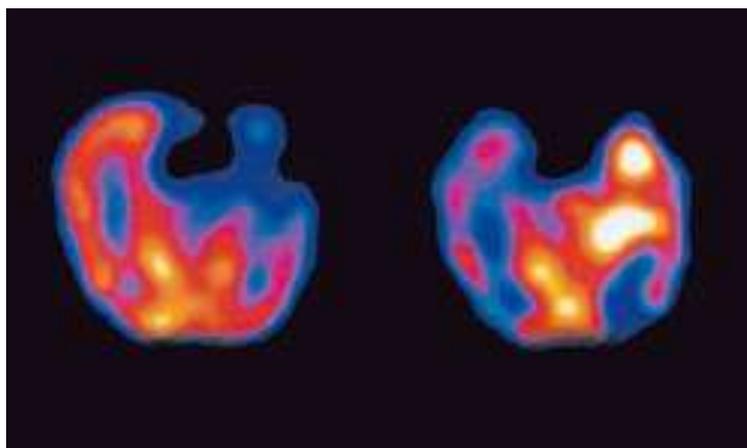


Figure 1.6 : Tomographie à émission monophonique (SPECT) [28]

1.1.3. L'Image Multimodale

La notion d'imagerie multimodale représente l'intersection de plusieurs disciplines de l'imagerie médicale, où des informations distinctes et complémentaires de diverses modalités d'imagerie sont synthétisées en une seule représentation cohérente. Cette intégration vise à exploiter les points de force de chaque modalité, telles que la précision anatomique de la tomodensitométrie (CT), la sensibilité des tissus mous de l'imagerie par résonance magnétique (IRM) et la spécificité fonctionnelle de la tomographie par émission de positons (TEP), afin de créer une image combinée qui révèle les aspects invisibles de chaque technique pris isolément. Les applications de l'image multimodale permettent des diagnostics plus précis, une planification thérapeutique stratégique et une surveillance clinique optimisée, ce qui en fait un pilier de l'avancement des soins de santé personnalisés[41].

1.2. La Fusion d'Images

La fusion d'image est une technique utilisée dans le traitement d'images pour combiner plusieurs images dans une seule, pour le but d'améliorer la qualité de l'image ou pour former une nouvelle image plus instructive que les images source afin d'extraire toutes les informations pertinentes. Cette dernière est largement utilisée dans le domaine médical pour le but d'avoir un diagnostic plus précis et une interprétation des données médicales plus claire et complète.

La fusion d'images est devenue essentielle en médecine en offrant un cadre diagnostique amélioré qui combine à la fois des perspectives fonctionnelles et anatomiques. Dans des domaines tels que l'oncologie, la neurologie et la cardiologie, où la précision diagnostique peut grandement influencer les stratégies thérapeutiques et les résultats des patients, ce processus est crucial[33].

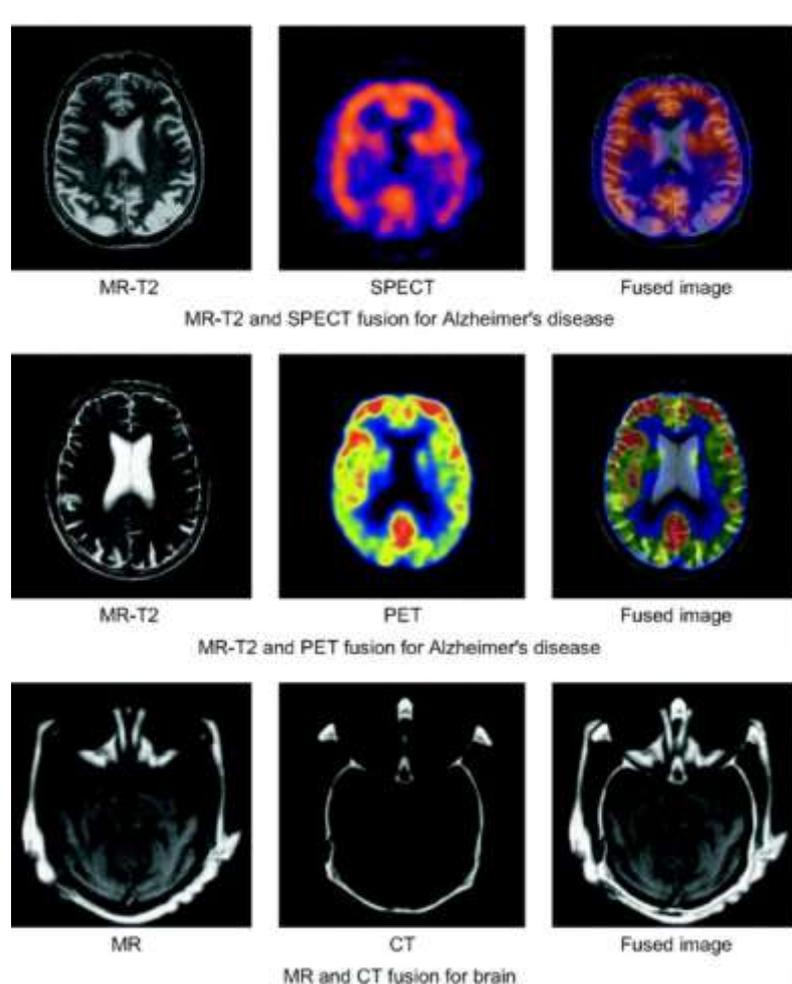


Figure 1.7 : Fusion d'images en Imagerie Médicale. [33]

1.2.1. Les Types De Fusion D'images

La fusion d'images se distingue par son application dans divers domaines, permettant l'enrichissement de l'information visuelle à travers la combinaison des données provenant de diverses sources. En fonction de la nature et de la source des images à fusionner, cette méthode se divise en différentes catégories qui visent à atteindre différents objectifs :

a) La Fusion Multi-vues

Cette catégorie comprend la fusion d'images obtenues à l'aide d'une modalité d'imagerie identique de différentes perspectives ou endroits. L'objectif est d'équilibrer ces points de vue différents afin de créer une représentation globale, offrant ainsi une compréhension plus complète et plus détaillée de l'objet d'intérêt[42].

b) La Fusion Multimodale

La fusion multimodale, qui est essentielle en imagerie médicale, combine des images issues de différentes techniques d'imagerie, telles que l'IRM, la CT et la TEP. En intégrant des caractéristiques anatomiques et fonctionnelles distinctes, cette méthode vise à synthétiser un panorama diagnostique, créant une image composite qui met en relief les informations essentielles pour le diagnostic et la prise en charge thérapeutique[43].

c) La Fusion Multi-temporelle

Cette technique utilise des séquences d'images prises à différents moments pour observer l'évolution temporelle d'un événement ou d'un processus. Utilisé principalement dans l'imagerie satellitaire et médicale, il aide à identifier les changements survenus au fil du temps[44].

d) La Fusion Multifocale

Cette méthode combine des images capturées ou mises au point à différentes profondeurs de champ. Le résultat est une image composite dans laquelle toutes les zones, proches ou éloignées, sont visibles. En microscopie et en photographie, cette fusion est particulièrement utile pour obtenir une clarté maximale sur l'ensemble de la scène[45].

e) La Fusion pour la Restauration d'Images

Cette catégorie comprend la combinaison d'images partiellement floues, bruitées ou endommagées pour créer une version restaurée et claire de l'image. Cela peut être essentiel en médecine pour améliorer la lisibilité des images radiographiques ou d'autres images diagnostiques, ce qui facilite l'interprétation et le diagnostic[46].

1.2.2. Les contextes de fusion

La fusion d'images médicales peut être contextualisée selon quatre principales catégories, chacune répondant à des objectifs spécifiques et exploitant des données distinctes pour enrichir l'analyse et la compréhension clinique.

a) Fusion Intra-Sujet et Intra-Modalité

Cette approche concerne la fusion d'images issues d'une même modalité d'imagerie pour un sujet unique, visant principalement à :

i) Le Suivi Temporel

Essentiel pour le suivi des changements anatomiques ou pathologiques d'un patient sur une période donnée, permettant d'évaluer l'efficacité d'un traitement ou de surveiller l'évolution d'une maladie. Cette méthode est cruciale en oncologie, neurologie et autres domaines nécessitant une observation continue[47].

ii) Comparaison d'États

La Méthode Permet l'analyse comparative des conditions physiologiques ou pathologiques d'un sujet à différents moments, tels que l'activité cérébrale en IRM fonctionnelle ou les variations de perfusion sanguine avant et après un épisode épileptique. Cette comparaison est vitale pour comprendre les mécanismes sous-jacents des pathologies et évaluer les réponses aux interventions. [5]

iii) L'Imagerie par Soustraction

Technique spécifique visant à isoler des éléments d'intérêt en calculant la différence entre des images obtenues dans des conditions variées, comme avec et sans agent de contraste. Utilisée en imagerie vasculaire, elle facilite l'extraction précise de structures telles que les vaisseaux sanguins[48].

b) La Fusion Intra-Sujet et Inter-Modalité

Intègre des images de différentes modalités pour un même individu, tirant profit de la complémentarité des données pour une visualisation exhaustive des structures anatomiques et fonctionnelles. Cette fusion est essentielle pour associer les informations structurelles et fonctionnelles, par exemple, en superposant les données d'IRM fonctionnelle à l'IRM anatomique pour des études préopératoires. [2]

c) La Fusion Inter-Sujet et Intra/Inter-Modalité

Fusionne des données, qu'elles soient issues d'une seule ou de multiples modalités, provenant de différents individus. Cette catégorie est primordiale pour l'analyse de la variabilité anatomique ou fonctionnelle au sein d'une population, fournissant des aperçus sur les modèles standards et les déviations pathologiques. [2]

d) La Fusion Sujet et Modalités

Englobe la correspondance entre le patient réel, les dispositifs thérapeutiques et les données d'imagerie préopératoires. Grâce à l'utilisation de systèmes de localisation en trois dimensions, cette approche facilite l'intégration entre le patient, les instruments chirurgicaux, et les images, soutenant des interventions précises comme la neuronavigation. Ces techniques de fusion sont fondamentales pour les interventions guidées par l'image, représentant une avancée majeure dans les procédures chirurgicales et thérapeutiques [1]

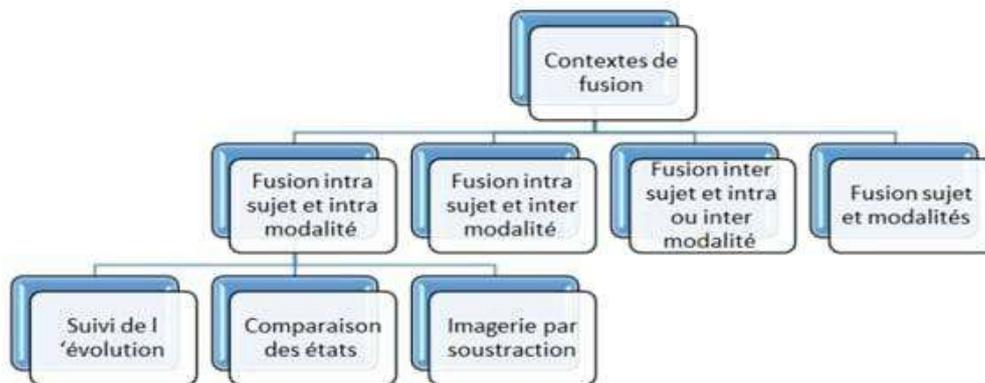


Figure 1.8 : Structure des Contextes de Fusion en Imagerie Médicale.

1.2.3. Les méthodes de fusion traditionnelles

Ces méthodes sont classées en plusieurs catégories principales, chacune utilisant une stratégie particulière pour maximiser la fusion des données d'imagerie.

- **Techniques de Fusion Basées sur les Pyramides** : Ces techniques impliquent la création de structures en forme de pyramide où chaque niveau divise l'image en composants de résolution décroissante. Avant de recomposer l'image composite finale, des informations à différents niveaux de cette hiérarchie sont intégrées pour mettre l'accent sur les détails fins et les caractéristiques structurelles importantes. [18]
- **Techniques de Fusion Basées sur les Ondelettes** : La transformation par ondelettes facilite la fusion d'informations à différentes échelles en fournissant un cadre flexible pour la décomposition des images en composants fréquentiels. Cette méthode est particulièrement efficace pour gérer la variabilité des détails et des textures présentes dans les images médicales, permettant une intégration harmonieuse des données. [10]
- **Fusion via Représentation Parcimonieuse** : Cette méthode utilise le concept de parcimonie pour sélectionner et fusionner les éléments les plus importants et instructifs des

images sources. Cela entraîne une représentation efficace et épurée, centrée sur les éléments les plus pertinents pour l'analyse diagnostique. [11]

- **Techniques de Fusion Basées sur les Sous-espaces** : L'analyse des sous-espaces, comme l'analyse des composantes principales (PCA) ou la factorisation en matrices, permet d'extraire des informations cruciales de l'ensemble des données d'imagerie. La fusion des images consiste alors à combiner ces éléments importants pour créer une image composite améliorée. [7]
- **Fusion Fondée sur les Caractéristiques Saillantes** : Cette catégorie se concentre sur l'extraction et la combinaison des éléments visuels les plus distinctifs des images sources, tels que les contours, les textures ou les zones d'intérêt particulières. La fusion vise à améliorer la lisibilité et l'utilité clinique de l'image résultante en mettant l'accent sur ces caractéristiques. [8]
- **Autres Techniques Spécifiques** : Ces approches, qui incluent des méthodes telles que la transformation en curvelets ou shearlets, sont conçues pour cibler et intégrer des caractéristiques uniques adaptées aux besoins spécifiques de l'imagerie médicale, offrant ainsi une plus grande flexibilité dans la personnalisation du processus de fusion. [22]

Chacune de ces méthodes de fusion a ses propres avantages et peut être utilisée dans une variété de contextes cliniques. La nature des données d'imagerie à fusionner et les objectifs poursuivis déterminent la technique la plus appropriée, mettant en lumière l'importance d'une approche personnalisée pour maximiser les avantages diagnostiques et thérapeutiques de la fusion d'images médicales.

1.2.4. Les méthodes de fusion basée sur le Deep Learning

Le domaine de la fusion d'images médicales a connu une révolution avec l'ère du Deep Learning, proposant des solutions innovantes qui surmontent les limites des méthodes traditionnelles. Ces méthodes innovantes permettent une fusion précise et contextuellement riche des données d'imagerie grâce à l'utilisation des réseaux neuronaux profonds. Les catégories principales comprennent :

- **Réseaux Multi-échelles avec Cartes de Poids de Fusion** :

Cette méthode crée des cartes de poids qui reflètent l'importance relative des différentes caractéristiques à travers les échelles en utilisant des architectures de réseaux neuronaux convolutifs, ces réseaux accompagnés de patches d'images à haute résolution et de leurs variantes dégradées, optimisent la fusion des détails fins et des caractéristiques globales,

produisant des images composites de haute qualité. [12]

- **Réseaux Empilés Basés sur l'Auto-encodeur :**

Ces réseaux empilés, qui sont basés sur les principes des auto-encodeurs, décomposent les images en couches de fréquences ou en attributs avant de les fusionner. Le but du processus est de combiner harmonieusement les caractéristiques multi fréquentiels des images sources afin d'obtenir une fusion cohérente et détaillée. [21]

- **Réseaux Basés sur les GAN:**

Les GAN introduisent un mécanisme concurrentiel entre les composants générateur et discriminateur, améliorant la qualité des images fusionnées pour qu'elles soient indiscernables des originaux. Cette méthode est particulièrement efficace pour les tâches où la fidélité visuelle et la préservation des détails sont essentielles. [14]

- **Réseaux de Fusion Unifiés :**

Ces réseaux utilisent des caractéristiques pré-spécifiées telles que les canaux d'images ou les propriétés spectrales pour intégrer directement des données multimodales. Malgré leur capacité à conserver les caractéristiques distinctives de chaque modalité, ils nécessitent des ajustements précis pour équilibrer la conservation des détails et la suppression du bruit. [23]

1.2.5. Approche de fusion d'image

Deux grandes stratégies de fusion d'images existent dans le domaine de la fusion d'images: la fusion de bas niveau, qui se concentre sur les pixels, et la fusion de haut niveau, qui se concentre sur les caractéristiques. Ces méthodes sont essentielles pour intégrer efficacement des informations provenant de diverses sources d'imagerie, chacune présentant des avantages distincts en fonction des objectifs de la fusion.

A) Fusion de Bas Niveau (au Niveau des Pixels)

La fusion au niveau des pixels consiste à fusionner directement les valeurs des pixels de plusieurs images pour créer une image composite unique. Ce processus utilise des données brutes des images, où chaque pixel de l'image finale est créé en synthétisant un ensemble correspondant de pixels des images sources. La capacité à conserver l'intégralité des informations mesurées originales est l'un des principaux avantages de cette méthode, offrant une richesse de détails et une fidélité maximale aux données observées. [4]

B) Fusion de Haut Niveau (au Niveau des Caractéristiques)

La fusion de haut niveau, en revanche, se concentre sur l'intégration d'informations basées sur des caractéristiques ou des caractéristiques extraites des images plutôt que sur les pixels eux-mêmes. Au cours d'un prétraitement, cette méthode traite des éléments tels que les contours, les textures ou tout autre indicateur pertinent identifié. Ensuite, les caractéristiques extraites sont combinées pour produire une image fusionnée qui met en évidence des aspects particuliers ou importants des scènes représentées. Bien qu'elle puisse également incorporer des niveaux d'incertitude liés à la précision de l'extraction des caractéristiques, cette méthode introduit une dimension d'analyse et de synthèse supplémentaire, permettant une fusion ciblée et potentiellement plus informative. [4]

1.2.6.Travaux Antérieurs

Cette section nous offrons un aperçu des avancées importantes dans le domaine de la fusion d'images médicales, mettant l'accent sur les développements récents basés sur l'apprentissage profond.

A. EMFusion: An Unsupervised Enhanced Medical Image Fusion Network

En 2021, d'après Han Xu et Jiayi Ma [24], un réseau avancé pour la fusion d'images médicales, fonctionnant de manière non supervisée. Ils appliquent à la fois des contraintes au niveau de la surface et au niveau profond pour une meilleure préservation des informations. La contrainte de niveau de surface est basée sur la mesure de la saillance et de l'abondance pour préserver les caractéristiques subjectivement définies et intuitives. Dans la contrainte de niveau profond, les informations uniques sont définies de manière objective en se basant sur les canaux uniques d'un encodeur pré-entraîné. De plus, dans leur méthode, les informations de chrominance des résultats de fusion sont également améliorées. Cela est dû à l'utilisation des détails de haute qualité dans les images structurales (par exemple, IRM) pour atténuer les artefacts dans les images fonctionnelles (par exemple, TEP, TEMP). [24]

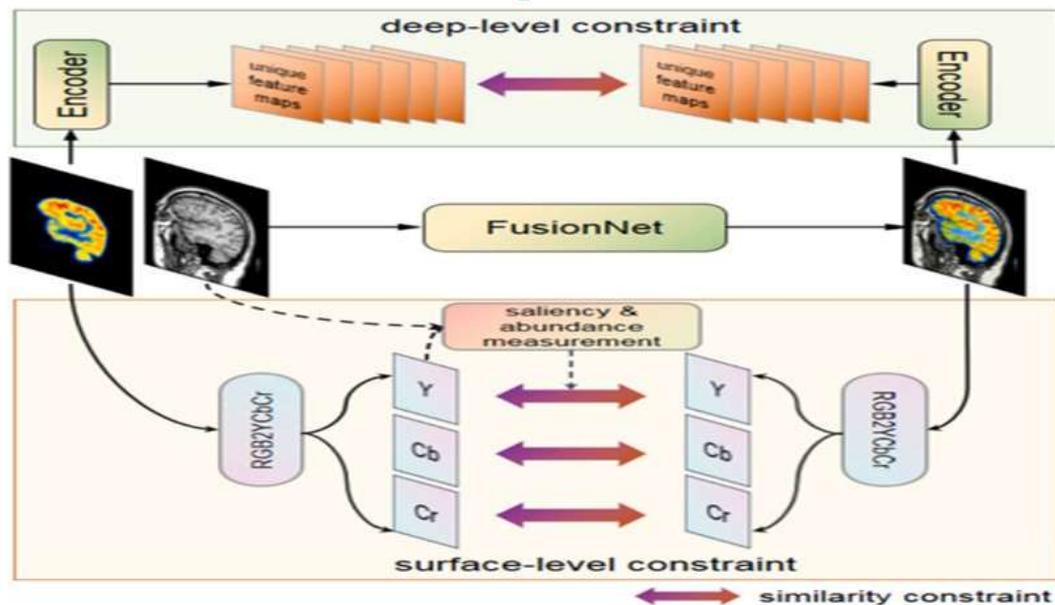


Figure 1.9 : EMFusion [24].

B. DDcGAN: A Dual-Discriminator Conditional Generative Adversarial Network for Multi-Resolution Image Fusion

En 2020, Jiayi Ma et al [25], ont proposé un nouveau modèle de bout en bout, appelé réseau antagoniste génératif conditionnel à double discriminateur (DDcGAN), pour fusionner des images de modalités différentes. Leur méthode établit un jeu antagoniste entre un générateur et deux discriminateurs. Le générateur vise à générer une image fusionnée réaliste basée sur une perte de contenu spécifiquement conçue pour tromper les deux discriminateurs, tandis que les deux discriminateurs visent à distinguer les différences de structure entre l'image fusionnée et les deux images sources, respectivement, en plus de la perte de contenu. Par conséquent, l'image fusionnée est contrainte de conserver simultanément le rayonnement thermique de l'image infrarouge et les détails de texture de l'image visible. De plus, pour fusionner des images sources de résolutions différentes, par exemple, une image infrarouge de basse résolution et une image visible de haute résolution, leur DDcGAN contraint l'image fusionnée échantillonnée à avoir des propriétés similaires à l'image infrarouge. Cela permet d'éviter le flou des informations de rayonnement thermique ou la perte de détails de texture visible, ce qui se produit généralement dans les méthodes traditionnelles. De plus, ils appliquent également leur DDcGAN à la fusion d'images médicales multimodalités de résolutions différentes, par exemple, une image de tomographie par émission de positions de basse résolution et une image par résonance magnétique de haute résolution. Les expériences qualitatives et quantitatives sur des ensembles de données disponibles publiquement démontrent la supériorité de la méthode.

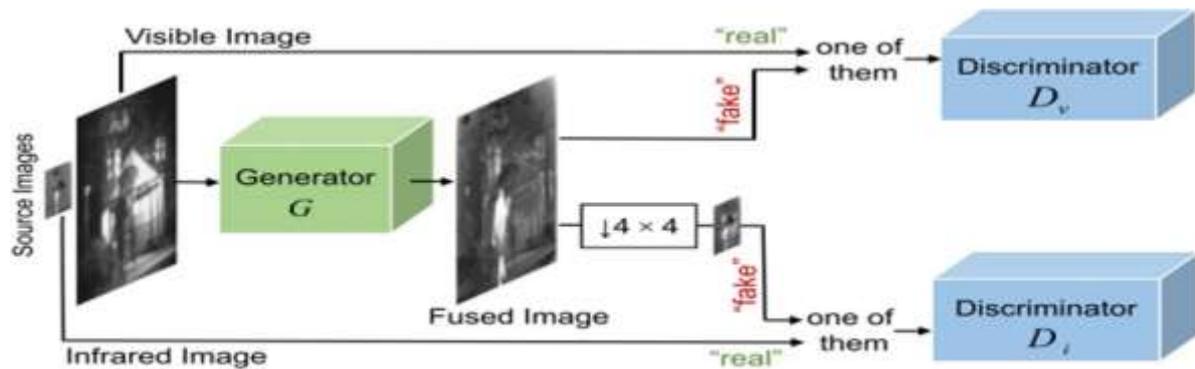


Fig. 1. The entire procedure of our DDCGAN for image fusion.

Figure 1.10 : DDCGAN[25].

C. IFCNN: A General Image Fusion Framework Based on Convolutional Neural Network

Dans une publication de 2020, Yu Zhang et al [23], ils proposent un cadre général de fusion d'images basé sur le réseau de neurones convolutionnels, nommé IFCNN. Inspirés par les algorithmes de fusion d'images dans le domaine des transformations, ils utilisent d'abord deux couches convolutionnelles pour extraire les caractéristiques saillantes des images multiples en entrée. Ensuite, les caractéristiques convolutionnelles des images d'entrée multiples sont fusionnées par une règle de fusion appropriée (maximum élément par élément, minimum élément par élément ou moyenne élément par élément), sélectionnée en fonction du type d'images d'entrée. Enfin, les caractéristiques fusionnées sont reconstruites par deux couches convolutionnelles pour produire l'image de fusion informative. Le modèle proposé est entièrement convolutionnel, ce qui lui permet d'être entraîné de bout en bout sans aucune procédure de post-traitement. Afin d'entraîner pleinement le modèle, les résultats expérimentaux montrent que le modèle proposé démontre une meilleure capacité de généralisation que les modèles de fusion d'images existants pour la fusion de différents types d'images, telles que les images multi-focus, infrarouges-visuelles, médicales multi-modales et à exposition multiple. De plus, les résultats confirment également que leur modèle a obtenu des résultats comparables ou même meilleurs par rapport aux algorithmes de fusion d'images de pointe sur quatre types d'ensembles de données d'images.

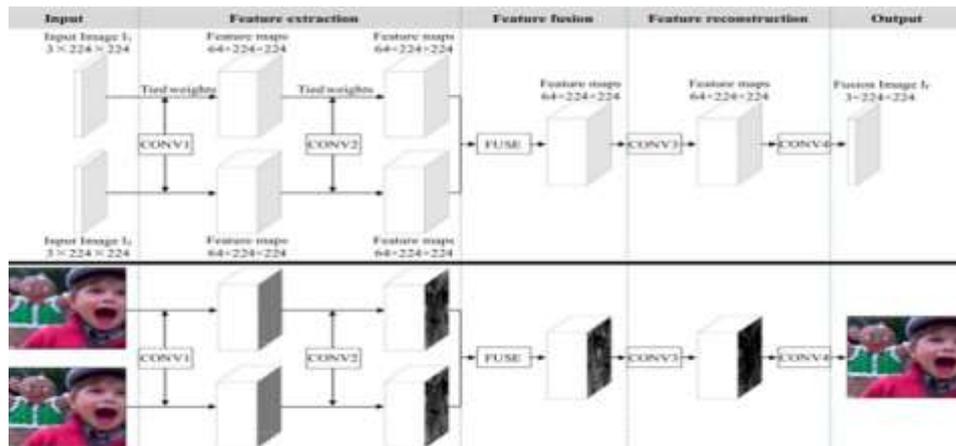


Figure 1.11 : IFCNN[23].

D. DenseFuse: A Fusion Approach to Infrared and Visible Images

Selon l'article [26] écrit par Hui Li et Xiao-Jun Wu en 2019, une architecture avancée d'apprentissage profond est dévoilée, spécifiquement conçue pour aborder la fusion des images infrarouges et visibles. Contrairement aux réseaux convolutionnels, leur réseau d'encodage est combiné avec des couches convolutionnelles, une couche de fusion et un bloc dense dans lequel la sortie de chaque couche est connectée à toutes les autres couches. Ils tentent d'utiliser cette architecture pour obtenir des caractéristiques plus utiles à partir des images sources dans le processus d'encodage, et deux couches de fusion (stratégies de fusion) sont conçues pour fusionner ces caractéristiques. Enfin, l'image fusionnée est reconstruite par un décodeur. Comparée aux méthodes de fusion existantes, la méthode de fusion proposée atteint les meilleures performances dans les évaluations objectives et subjectives.

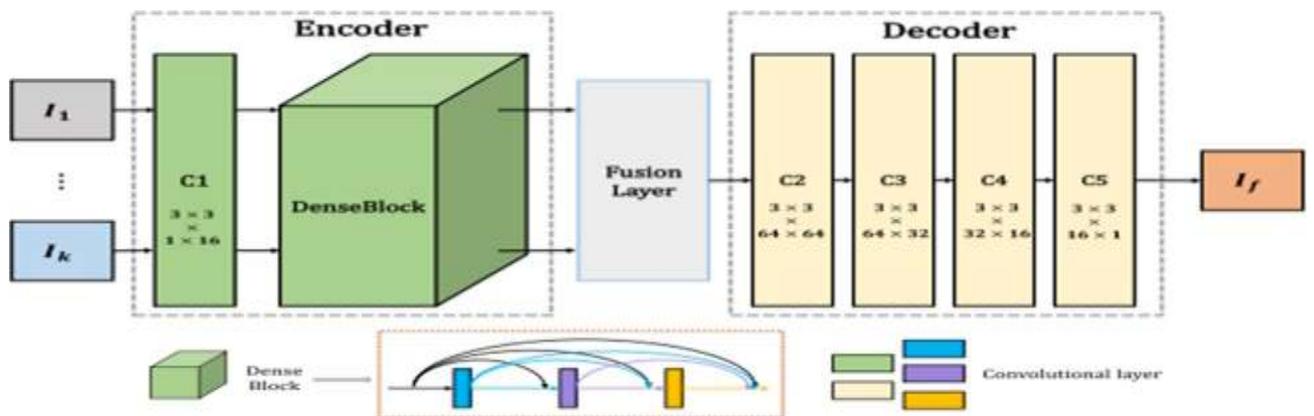


Fig. 1. The architecture of proposed method.

Figure 1.12 : DenseFuse[26].

Tableau 1 : Tableau comparatif des travaux existants

Approche	Auteur, Année	Dataset	Technique Et Outil	Points forts	Limitation
EmFusion [24]	Han Xu, Jiayi Ma, 2021	- Harvard medical Dataset	Utilise des Contraintes de niveau de surface et de niveau profond, les outils incluent des encodeurs pré-entraînés des métriques SSIM, PSNR.	Préservation améliorée de l'information unique, d'amélioration de l'information de chrominance et de performances supérieures par rapport aux méthodes existantes.	La complexité, le coût computationnel accru, difficulté d'ajuster les hyperparamètres
IFCNN [23]	Yu Zhang et al, 2020	- Harvard medical Dataset, - Infrared and visual image dataset	Les poids liés sont mis en œuvre en contraignant les poids de différentes connexions à avoir les mêmes valeurs.	Les poids liés permettent de réduire le nombre de paramètres du modèle, meilleure généralisation.	Peut limiter la capacité du modèle à capturer des caractéristiques uniques.
DDcGAN [25]	Jiayi Ma et al. 2020	- Harvard medical Dataset, - Infrared and visual image dataset	Réseau génératif antagoniste conditionnel à double discriminateur pour la fusion d'images multi-résolutions.	Capacité à fusionner des images de résolutions différentes tout en préservant les détails.	Peut introduire du bruit supplémentaire dans les images source.
DenseFuse [26]	Hui Li et Xiao-Jun Wu, 2019	- Harvard medical Dataset	Utilise une architecture dense pour la fusion d'images.	Architecture novatrice qui intègre un réseau dense, préservation d'informations utiles.	Peut souffrir de la perte d'informations utiles extraites par les couches intermédiaires.

Conclusion

Dans ce chapitre, nous avons présenté une vision globale de l'imagerie médicale, en soulignant les diverses formes d'imagerie et leur intégration essentielle grâce à la fusion d'images. Cette compilation des méthodes existantes et de leurs utilisations cliniques établit une base solide pour explorer des progrès en fusion d'images susceptibles d'améliorer le diagnostic et le traitement des maladies.

La fusion d'images permet de combiner les avantages de différentes modalités d'imagerie, comme l'IRM, la TEP, et le scanner, pour obtenir une vision plus complète et précise des structures et des fonctions anatomiques et physiopathologiques. Grâce à cette synergie, les cliniciens peuvent bénéficier d'une plus grande précision diagnostique, d'une meilleure évaluation de la réponse aux traitements et d'une planification thérapeutique plus efficace.

De plus, les avancées technologiques et les algorithmes de fusion d'images évoluent rapidement, ouvrant la voie à des innovations telles que l'intelligence artificielle et l'apprentissage automatique. Ces technologies promettent d'automatiser davantage le processus de fusion, rendant l'imagerie médicale encore plus accessible et fiable.

CHAPITRE 2
CONCEPTION ET
METHODOLOGIE

Introduction

Dans ce chapitre, nous abordons la conception de notre application de fusion d'images médicales, une étape cruciale dans notre projet visant à améliorer la précision et l'efficacité des diagnostics médicaux. La fusion d'images, qui combine des données provenant de différentes modalités d'imagerie comme l'IRM, la TEP et la CT, permet de créer une vue plus complétée et précise donc plus informative. Cette méthode est essentielle pour offrir une vision plus complète des structures et des fonctions anatomiques et physiopathologiques, pour améliorer les décisions cliniques des patients.

Nous décrivons en détail les choix technologiques et méthodologiques qui ont guidé la conception de notre application. Cela inclut l'intégration de techniques d'apprentissage automatique et de vision par ordinateur pour automatiser le processus de fusion d'images.

En posant les bases théoriques et pratiques de notre travail, nous préparons le terrain pour les phases ultérieures de mise en œuvre et de validation, qui seront abordées dans les chapitres suivants.

2.1. Processus de Fusionnement

a) Prétraitement :

Avant la fusion d'images médicales, un traitement préparatoire est nécessaire pour améliorer la qualité des images et les rendre compatibles pour la fusion. Cela inclut le redimensionnement des images, car les différentes modalités d'imagerie médicale produisent des images de tailles variées. Il est donc nécessaire de redimensionner les images pour garantir un alignement parfait lors de la fusion.

b) Fusionnement :

La fusion d'images peut être effectuée à trois niveaux différents : au niveau des pixels, au niveau des caractéristiques après une segmentation, ou au niveau décisionnel lors de la phase finale de la segmentation. Il existe quelques conditions générales qui doivent être respectées dans le résultat de la fusion :

- 1.** L'image fusionnée doit préserver toutes les informations pertinentes contenues dans les images sources aussi fidèlement que possible.
- 2.** Le processus de fusion et les étapes ultérieures de traitement d'images ne doivent introduire ni objets indésirables ni artefacts susceptibles d'induire des erreurs visuelles
- 3.** Les caractéristiques non pertinentes et les bruits doivent être supprimés autant que possible dans l'image fusionnée.

c) Évaluation des performances :

L'image fusionnée doit fournir une meilleure description et une meilleure qualité que les images sources. Un bon processus de fusion doit inclure l'information redondante sans surcharger l'image fusionnée. La performance du processus de fusion doit être évaluée à la fois qualitativement, par inspection visuelle, et quantitativement, à l'aide de métriques de fusion.

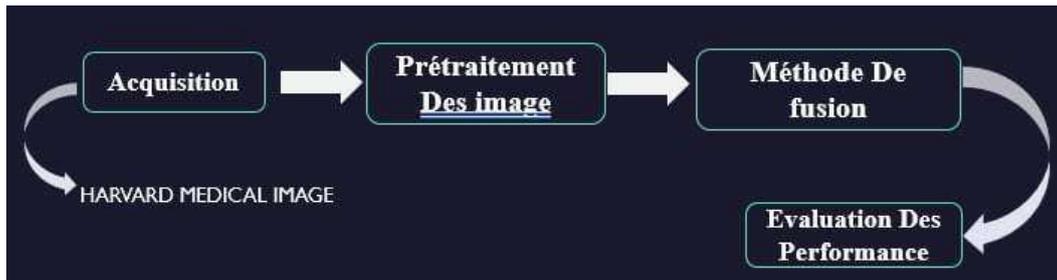


Figure 2.1 : Schéma représentant de le processus de fusion

2.1.1. Collecte et Prétraitement des Données

A. Description des Ensembles de Données :

Une variété de données d'image médicale fusionnée, telles que les données CT-MRI, PET-MRI, et SPECT-MRI, sont fournies par la Harvard Medical School et jouent un rôle crucial dans la recherche en technologies d'imagerie. Ces ensembles de données se composent d'images appariées qui combinent différentes modalités d'imagerie pour exploiter les avantages distincts de chacune. La dimension habituelle des images pour ces ensembles de données est de 256×256 pixels. Ces bases de données permettent d'effectuer des études détaillées sur les éléments structuraux et fonctionnels de l'image médicale, essentielles au développement et à l'évaluation de modèles d'apprentissage profond avancés pour la fusion d'images médicales. La structure détaillée et homogène de ces ensembles de données facilite le développement et les tests d'algorithmes de fusion d'images visant à améliorer les images. Ces ensembles de données contiennent 269 paires PET-MRI, 375 paires SPECT-MRI et 184 paires CT-MRI . [6]

B. Prétraitement des Images Médicales Multimodales

1. Le prétraitement des images : Une étape essentielle dans l'analyse de fusion d'images médicales multimodales, assurant ainsi une qualité et une comparabilité optimales entre les différentes modalités. Dans cette partie, nous expliquerons en détail le processus uniforme utilisé pour les jeux de données SPECT-MRI, PET-MRI et CT-MRI.

- 2. Chargement et Normalisation des Images :** Chaque paire d'images, que ce soit SPECT-MRI, PET-MRI ou CT-MRI, est initialement chargée à partir de leurs répertoires propres. Par la suite, chaque image est normalisée afin de garantir une échelle d'intensité homogène entre 0 et 1. Il est essentiel de réaliser cette normalisation afin de réduire les fluctuations d'intensité causées par les particularités de chaque appareil d'imagerie.
- 3. Conversion en Espace de Couleur et Extraction de Caractéristiques :** Après la normalisation, les images SPECT et PET sont converties en espace de couleur YCbCr. Le modèle YCbCr (Luminance, Chrominance-Blue, Chrominance-Red) permet de séparer la composante de luminance (Y) des deux composantes de chrominance (Cb et Cr). Il est crucial de passer par cette étape afin de distinguer la luminance des éléments de couleur, ce qui facilite l'analyse des caractéristiques structurelles et colorimétriques de l'image. On produit des patches de caractéristiques pour chaque canal (Y, Cb, Cr) en utilisant une fenêtre glissante avec un recouvrement précis, ce qui permet une analyse détaillée et localisée des zones d'intérêt.
- 4. Génération de Patches :** Les patches sont extraits pour toutes les modalités en utilisant une taille de patch préétablie et en chevauchant afin d'augmenter la quantité de données disponibles pour l'entraînement des modèles de deep learning. Cette approche permet de saisir la diversité locale dans les images, ce qui est indispensable pour la fusion où les détails fins peuvent être essentiels pour un diagnostic précis.
- 5. Indexation et Agrégation des Patches :** Chaque patch extrait est systématiquement indexé, ce qui facilite la traçabilité et la référence lors des étapes de fusion et d'analyse. Ensuite, on regroupe tous les patches provenant des différentes modalités, créant ainsi un ensemble de données solide prêt pour les étapes suivantes de fusion.
- 6. Application Uniforme des Prétraitements :** Les jeux de données sont traités de manière uniforme selon le processus décrit, ce qui assure que chaque modalité et chaque jeu de données subissent le même traitement. La cohérence est essentielle afin de garantir l'intégrité et la comparabilité des résultats de fusion.
- 7. Stratégie de Répartition des Données pour Entraînement et Test :** Après le prétraitement, les données sont structurées et réparties en ensembles d'entraînement et de test, avec une répartition de 80% pour l'entraînement et 20% pour les tests. Cette répartition est essentielle pour évaluer de manière fiable la performance des modèles de fusion sur des données non vues. De plus, lors de l'extraction des patches, une attention particulière est portée pour éviter que des patches provenant de la même image originale ne se retrouvent à la fois dans l'ensemble d'entraînement et dans l'ensemble de test. Cette

précaution est essentielle pour prévenir tout risque de fuite d'information entre les ensembles et pour assurer que l'évaluation du modèle reflète sa capacité à traiter de nouvelles données. Cette approche renforce la validité du modèle dans un contexte clinique, où il est impératif que le modèle fonctionne efficacement avec des images qu'il n'a pas précédemment traitées.

Tableau 2 : Distribution des Patches pour Entraînement et Tests par Modalité.

Modalité	Ensemble d'entraînement	Ensemble de test
MRI-CT	(132300, 24, 24)	(33300, 24, 24)
MRI-SPECT	(256500, 24, 24)	(64800, 24, 24)
MRI-PET	(193500, 24, 24)	(72900, 24, 24)

2.1.2. Les Modèles Proposés

Nous avons proposé deux modèles pour faire une étude comparative :

- Le premier modèle basé sur les réseaux de neurones convolutionnels (CNN)
- Le deuxième modèle basé sur un modèle pré-entraîné VGG19

A. Modèle 1 basé sur les réseaux de neurones convolutionnels (CNN)

Le modèle illustré à la figure 2.2, que nous avons conçu est destiné à la fusion d'images médicales provenant de différentes modalités : IRM et PET, IRM et CT, IRM et SPECT. Ce modèle est spécifiquement formé à l'association de patches de ces modalités, en s'assurant que chaque patch d'une modalité, telle que l'IRM, soit exactement associé à son patch correspondant d'une autre modalité, comme le PET. L'exactitude est cruciale afin de préserver l'intégrité spatiale et de l'image fusionnée.

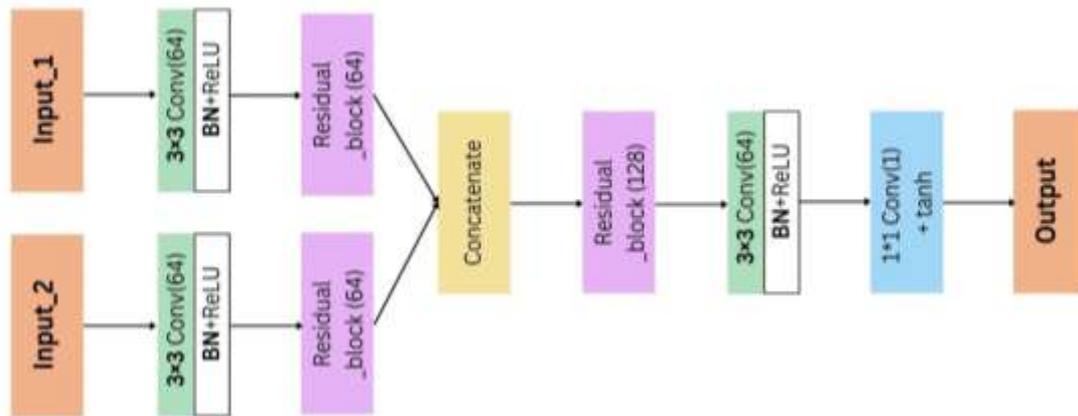


Figure 2.2 : Schéma du modèle 1 de Fusion.

3 × 3: taille du filtre,
 Conv(k): couche convolutionnelle générant k cartes de caractéristiques,
 BN: normalisation par lots,
 residual block(N) : détaillé dans la Figure 2.3 où (N) : représente les cartes de caractéristiques.

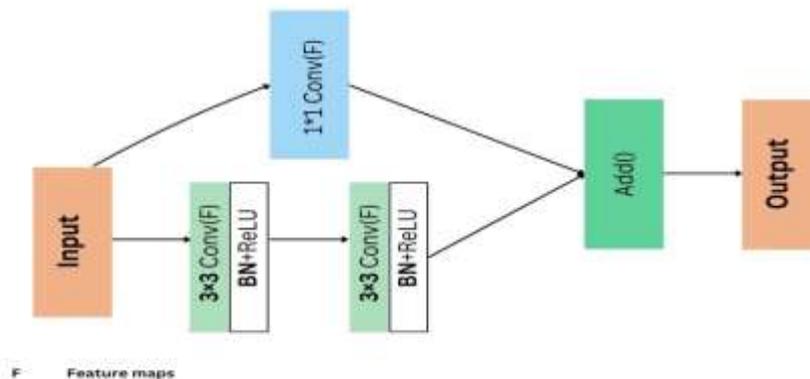


Figure 2.3 : Schéma d'un Bloc Résiduel.

3 × 3, 1 × 1: taille du filtre,
 Conv(F): couche convolutionnelle générant F cartes de caractéristiques,
 BN: normalisation par lots,
 Add() : addition des cartes de caractéristiques.

1) Bloc d'entrée et Extraction des Caractéristiques

Un bloc convolutionnel est utilisé pour traiter chaque entrée, comprenant une normalisation par lots et des fonctions d'activation afin d'extraire des caractéristiques préliminaires.

Le bloc résiduel dans notre architecture joue un rôle crucial en améliorant l'extraction des caractéristiques tout en préservant l'intégrité des informations initiales. Il est composé de deux couches convolutionnelles successives utilisant des filtres de taille 3x3, qui permettent de capturer des caractéristiques complexes. Ces couches sont essentielles pour détecter des détails fins dans l'image. Par ailleurs, une couche convolutionnelle avec un filtre de taille 1x1 est utilisée pour adapter les dimensions des cartes de caractéristiques, permettant une intégration

sans perte d'information. L'addition de ces flux de traitement assure la fusion des caractéristiques originales et traitées, favorisant ainsi la stabilité du réseau et évitant la dégradation des caractéristiques au fil des couches profondes. Cette stratégie renforce la capacité du modèle à apprendre des représentations plus complexes sans perdre les informations acquises dans les couches antérieures, améliorant ainsi la vitesse d'apprentissage et la précision globale du modèle.

2) Fusion des caractéristiques

L'extraction des caractéristiques est améliorée grâce à l'utilisation de couches convolutionnelles supplémentaires et à l'intégration de connexions de saut pour assurer la continuité de l'apprentissage et prévenir la perte d'informations.

Les caractéristiques extraites des diverses modalités sont fusionnées pour créer un ensemble de caractéristiques unifié, intégrant ainsi les informations provenant des deux sources. Un autre bloc résiduel est chargé de traiter les caractéristiques combinées de manière plus approfondie afin de les affiner en vue de la génération de la sortie finale.

3) Génération de la sortie

Le bloc convolutionnel final se charge de traiter les caractéristiques fusionnées afin de les adapter aux dimensions des patches d'entrée, cherchant à optimiser la représentation la plus adéquate des caractéristiques combinées des modalités.

La dernière étape de convolution, utilisant la fonction d'activation 'tanh', génère la sortie finale, assurant ainsi une limitation des résultats, une caractéristique courante pour les données d'images normalisées.

4) Considérations spéciales pour le PET/SPECT :

Dans le cadre des modalités PET et SPECT, il est courant d'utiliser uniquement le canal Y (luminance) pour la fusion, car il contient les informations structurales essentielles. Les composants de couleur (Cb et Cr) sont incorporés après la fusion, basée sur les résultats du canal de luminance, assurant l'intégrité des couleurs sans influencer directement le processus d'apprentissage des caractéristiques de la fusion.

5) Fonction de Perte de Fusion et Paramètres d'Optimisation pour la Fusion d'Images Médicales

La fonction de perte a été développée dans le but d'améliorer la fusion d'images médicales en intégrant trois éléments évaluatifs :

1. Erreur Quadratique Moyenne (MSE) : La MSE est calculée comme la moyenne des carrés des écarts entre les valeurs réelles et prédites. a pour mission d'évaluer la précision des intensités des pixels, ce qui a un impact direct sur la fidélité de l'image. Elle s'exprime mathématiquement comme suit:

$$MSE = \frac{1}{N} \sum_{i=1}^n (Y_{true,i} - Y_{pred,i})^2$$

Où n : est le nombre total de pixels.

$Y_{true,i}$: est la valeur du pixel de l'image réelle à la position i.

$Y_{pred,i}$: est la valeur du pixel de l'image prédite à la position i.

2. Perte d'Indice de Similarité Structurale (LSSIM) : La Perte de Similarité Structurale (LSSIM) est utilisée pour mesurer la dissimilarité entre deux images, ce qui permet d'évaluer la qualité visuelle des textures et des détails structuraux des images fusionnées. Contrairement à l'indice de Similarité Structurale (SSIM) qui quantifie la similarité, la LSSIM quantifie la différence, avec des valeurs plus élevées indiquant une plus grande dissimilarité. Elle s'exprime mathématiquement comme suit :

$$LSSIM(y_{true} - y_{pred}) = 1 - SSIM(y_{true} - y_{pred})$$

Où l'indice SSIM utilisé est détaillé dans la section dédiée aux métriques

3. Perte de Gradient utilisant l'opérateur de Sobel: La perte de gradient mesure la différence dans l'information des contours entre les images réelles et prédites en utilisant l'opérateur de Sobel. Cette perte garantit que les gradients (contours) dans l'image fusionnée sont préservés, ce qui est important pour maintenir les détails structurels. La perte de gradient est calculée comme suit :

$$GradientLoss = \frac{1}{M} \sum_{j=1}^m |Sobel(y_{true,j}) - Sobel(y_{pred,j})|$$

Combinant ces éléments dans une seule fonction de perte, où α , β , et γ sont des poids pour chaque composant de la perte, la fonction de perte composite L peut être exprimée comme :

$$L(Y_{Vrai} - Y_{pred}) = \alpha \times MSE(Y_{Vrai} - Y_{pred}) + \beta \times LSSIM + \gamma \times GradientLoss$$

Sachant que la somme α , β , et γ est 1

L'optimisation du modèle est réalisée à l'aide de l'optimiseur Adam, réputé pour sa capacité à traiter de manière efficace les gradients clairsemés et pour son adaptation adaptative du taux d'apprentissage. Le modèle est paramétré avec un taux d'apprentissage de 0.0065, intégrant

une régularisation par dégradation de poids pour prévenir le sur-apprentissage, ainsi qu'une valeur de seuil de clipping visant à limiter l'impact des mises à jour de gradient extrêmes, garantissant ainsi une stabilité et une robustesse dans le processus d'apprentissage. Ces paramètres revêtent une importance cruciale afin d'atteindre une convergence optimale et de garantir un haut niveau de performance.

2.1.3. Modèle 2 basé sur VGG19

Dans cette section, nous explorons une méthode d'analyse d'images basée sur l'utilisation de l'architecture VGG19, l'une des architectures de CNN les plus répandues et les plus performantes. Conçue par l'équipe de recherche du Visual Geometry Group (VGG) à l'Université d'Oxford, VGG19 se distingue par sa profondeur et sa capacité à capturer des caractéristiques complexes des images avec une grande précision.

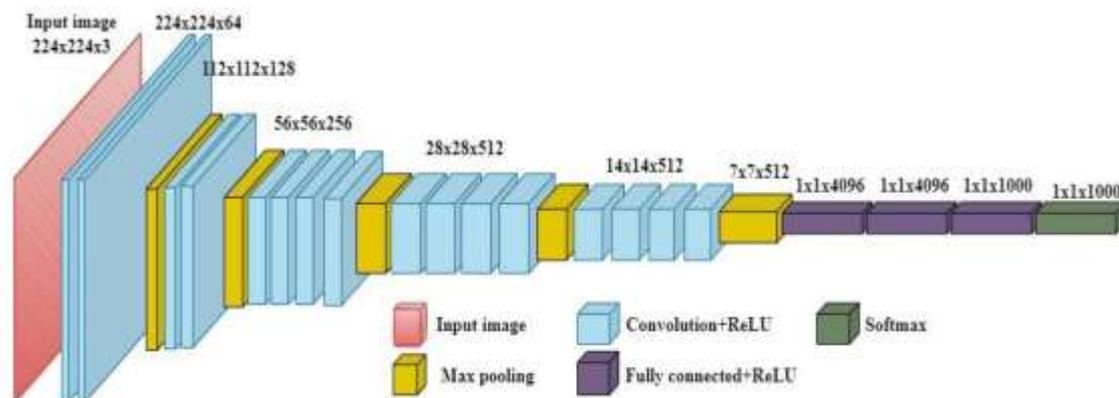


Figure 2.4 : Représentation De L'architecture Du Modèle VGG19 [34].

Notre méthode repose sur l'utilisation de l'architecture VGG19 juste pour la partie qui concerne l'extraction des caractéristique (partie convolutionnels), avec des poids pré-entraînés, pour extraire les caractéristiques des images d'imagerie médicale telles que CT, MRI, SPECT et PET. Cette architecture, renommée pour sa profondeur et sa capacité à capturer des informations significatives à partir d'images, fournit une base solide pour notre approche d'analyse.

1)Extraction des Caractéristiques avec VGG19 :

- Utiliser l'architecture VGG19 pour la partie convolutionnelle afin d'extraire les caractéristiques des images médicales (CT, MRI, SPECT, PET).
- Charger les poids pré-entraînés pour bénéficier des capacités de la VGG19 à capturer des informations significatives à partir des images.

2) Combinaison des Cartes de Caractéristiques :

- Extraire les caractéristiques des deux images.
- Combiner les deux cartes de caractéristiques extraites pour former une seule carte qui représente une fusion des informations.

3) Application de la Fonction Softmax:

- Appliquer une fonction Softmax à la carte de caractéristiques combinée.
- Produire une carte de poids de fusionnement où chaque pixel représente le poids relatif des informations de chaque image.

4) Fusion des Pixels :

- Multiplier chaque pixel des images d'entrée par le poids correspondant de la carte de fusion.
- Additionner les deux produits pour obtenir chaque pixel de l'image fusionnée résultante.
- Cette approche de fusion pondérée garantit que les informations les plus pertinentes et les plus significatives de chaque image contribuent de manière appropriée à l'image finale fusionnée.

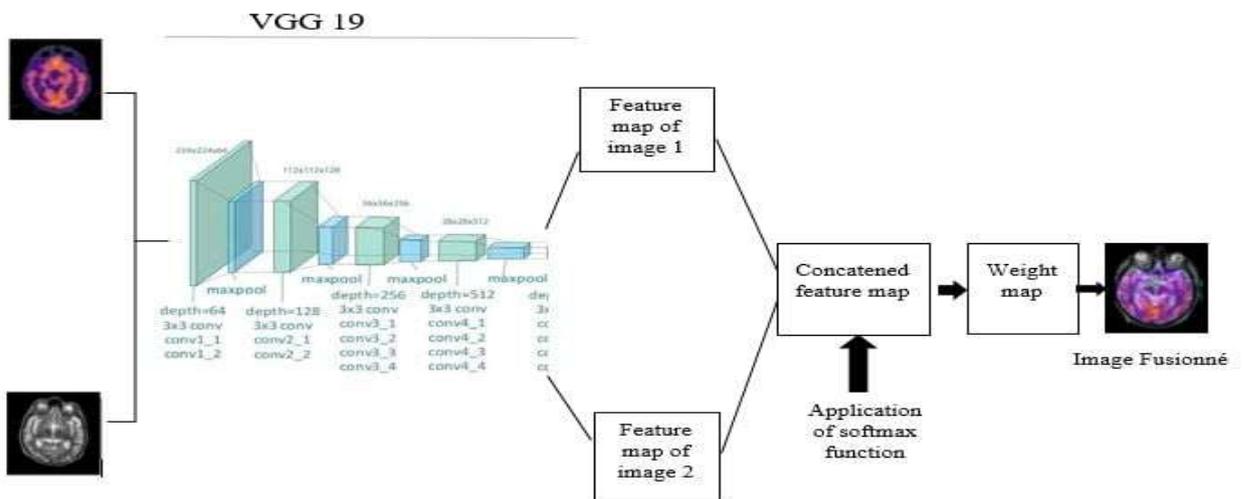


Figure 2.5 : représentation graphique du modèle 2 de fusion.

2.2. Métriques d'Évaluation

2.2.1. Sélection des métriques pour une évaluation exhaustive :

Une évaluation exhaustive de la fusion d'images médicales nécessite une combinaison de métriques quantitatives et qualitatives qui capturent à la fois la fidélité de l'information visuelle et la perception clinique de l'image. Chaque métrique est sélectionnée pour évaluer différents aspects de la performance de fusion, de la précision des détails structuraux à la qualité perceptuelle globale.

2.2.2. Évaluation Quantitative

A. Visual Information Fidelity (VIF) :

Description : Le VIF évalue la fidélité de l'information visuelle conservée dans l'image fusionnée par rapport aux images sources, servant de baromètre pour la qualité visuelle après fusion.

$$\text{Formule : } \frac{\sum_k I(f_k, g_k)}{\sum_k I(f_k, n_k)}$$

Où :

- f_k et g_k représentent les sous-bandes de fréquence décomposées des images f et g respectivement.
- (n_k) représente le bruit dans la sous-bande k , supposé comme la différence entre les sous-bandes f_k et g_k .
- $I(f_k, g_k)$ est l'information visuelle que l'œil humain peut extraire de la sous-bande k de g par rapport à f .
- $I(f_k, n_k)$ est l'information visuelle de la sous-bande k de f par rapport au bruit (n_k) .
- $\sum k$ indique que l'agrégation est effectuée sur toutes les sous-bandes k

Interprétation : Des valeurs élevées indiquent une meilleure préservation de l'information visuelle, ce qui est crucial pour les diagnostics où la qualité de l'image peut influencer la décision clinique. [17]

B. Structural Similarity Index (SSIM) :

Description : Le SSIM mesure la similarité entre deux images en évaluant la luminosité, le contraste et la structure. Il est crucial pour évaluer la qualité perceptuelle de l'image fusionnée. [19]

$$\text{Formule : } \text{SSIM}(x, y) = \frac{(2\mu_x \mu_y + C1)(2\sigma_{xy} + C2)}{(u^2_x + u^2_y + C1)(\sigma^2_x + \sigma^2_y + C2)}$$

Où : - u_x et u_y représentent les moyennes des intensités des images x et y, respectivement.

- σ^2_x et σ^2_y indiquent les variances de x et y, mesurant la dispersion des intensités autour de leur moyenne.

- σ_{xy} est la covariance entre x et y.

-C1 et C2 sont des constantes qui stabilisent la division pour éviter la division par zéro.

Interprétation : Un SSIM élevé suggère que l'image fusionnée maintient la qualité structurelle par rapport aux images sources, ce qui est essentiel dans les images où les structures fines sont diagnostiquement importantes. [19]

C. Peak Signal-to-Noise Ratio (PSNR)

Description : Le PSNR évalue la qualité de l'image en mesurant le rapport entre la puissance maximale d'un signal et la puissance du bruit de fond. [20]

$$\text{Formule : } 20 \times \log_{10} \left(\frac{\text{MAXI}}{\sqrt{\text{MSE}}} \right)$$

Où :

-MAXI est la valeur maximal du pixel en image

-MSE signifie Erreur Quadratique Moyenne, le MSE mesure la différence moyenne au carré entre les images sources et l'image fusionnée

Interprétation : Le PSNR mesure la qualité de reconstruction de l'image. Un PSNR élevé indique une image de haute qualité avec moins de bruit. [20]

D. Correlation Coefficient (CC)

Description : Le Computed-CC évalue la corrélation linéaire entre l'image fusionnée et les images sources, mesurant la précision avec laquelle les propriétés structurelles et d'intensité sont conservées. [13]

$$\text{Formule : } CC = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

Où : - x_i et y_i sont les valeurs des pixels de la première et de la deuxième image à la position i, respectivement.

- \bar{x} et \bar{y} sont les valeurs moyennes des pixels des première et deuxième image, respectivement.

-Le numérateur est la somme du produit des écarts des valeurs de pixels par rapport à leurs moyennes respectives, essentiellement la covariance des intensités de pixels des deux images.

-Le dénominateur est le produit des écarts-types des valeurs de pixels de chaque image, ce qui normalise l'échelle de la corrélation, la rendant sans dimension et limitée entre -1 et 1.

Interprétation : Des valeurs proches de 1 indiquent une forte corrélation linéaire, suggérant

que l'image fusionnée correspond étroitement aux images sources en termes d'intensité et de structure. [13]

2.2.3. Évaluation Qualitative

L'évaluation qualitative complète les mesures quantitatives en se concentrant sur l'appréciation subjective des images médicales fusionnées par des experts cliniques. Cette évaluation peut inclure des études de perception visuelle où les médecins évaluent l'utilité clinique et l'intégrité visuelle des images fusionnées. L'analyse visuelle permet de localiser et d'identifier des défauts. Ces défauts peuvent affecter la qualité image (aspect pixellisé . . .), ou la géométrie (déformation d'éléments linéaires, bavé des contours, agrégation d'objets . . .) ou encore la radiométrie (saturation des couleurs, couleur dominante, dynamique . . .). Cette analyse est nécessaire pour vérifier la qualité des images obtenues par la fusion, en effet, bien que le système visuel humain diffère d'un individu à un autre mais on peut voir l'injection des structures par une netteté accrue de l'image, et préservation de l'information. [16]

Conclusion

Dans le Chapitre 2, nous avons exploré notre approche méthodologique pour la fusion d'images médicales, soulignant le prétraitement des données, l'intégration de modèles de Deep Learning et l'utilisation de métriques d'évaluation rigoureuses. Cette démarche garantit la précision et la pertinence clinique des images fusionnées, renforçant l'utilité diagnostique des technologies de fusion d'images. En établissant une base solide pour des applications cliniques futures, cette approche vise à améliorer significativement les résultats des patients et à faciliter l'intégration de ces technologies dans les flux de travail médicaux.

CHAPITRE 3

IMPLEMENTATION ET

RESULTATS DES TEST

Introduction

Maintenant, dans ce chapitre, nous allons détailler l'implémentation des méthodologies et outils utilisés pour développer ces modèles. Nous allons exploiter les résultats obtenus, tant qualitatifs que quantitatifs, vérifiés par des évaluations d'experts en médecine, et concluons par une présentation de l'application pratique des modèles. Par une représentation de l'interface de notre application.

3.1. Outils et Langages de Programmation

3.1.1. Python

Langage de programmation interprété, Python est largement reconnu pour sa simplicité et son efficacité, en particulier dans les applications de data science et de machine learning grâce à sa vaste bibliothèque d'outils dédiés.[40]

3.1.2. TensorFlow

Framework open-source pour le calcul numérique développé par Google, TensorFlow est particulièrement adapté pour le développement de systèmes d'apprentissage profond, offrant flexibilité et une vaste gamme d'outils pour le design de modèles complexes en réseaux de neurones.[36]

3.1.3. OpenCV (cv2)

Bibliothèque de vision par ordinateur, OpenCV est utilisée pour le traitement d'images et de vidéos, incluant des fonctionnalités avancées de manipulation et de transformation d'images, essentielles pour les tâches de prétraitement dans la fusion d'images.[39]

3.1.4. PyQT

C'est un module qui établit une liaison entre le langage Python et la bibliothèque Qt, disponible sous deux licences : une commerciale et la licence GNU GPL. Il permet ainsi de créer des interfaces graphiques en Python. Une extension de Qt Designer, un outil graphique pour la création d'interfaces Qt, permet également de générer le code Python correspondant aux interfaces graphiques.[38]

3.1.5. MySQL

Système de gestion de base de données relationnelles, MySQL permet la gestion efficace des données d'imagerie, indispensable pour stocker et récupérer de grandes quantités d'informations médicales de manière structurée et sécurisée.[37]

3.1.6. Pytorch

PyTorch est un cadre d'apprentissage profond open source basé sur un logiciel utilisé pour construire des réseaux neuronaux, combinant la bibliothèque de machine learning (ML) de Torch avec une API de haut niveau basée sur Python. Sa flexibilité et sa facilité d'utilisation, entre autres avantages, en ont fait le principal cadre de ML pour les communautés universitaires et de recherche.[35]

3.1.7. Environnement matériel

Ordinateur : le Tableau suivant représente les caractéristiques des ordinateurs utilisés.

Tableau 3 : Ressources locales des ordinateurs utilisés.

Windows	Processeur	Ram	Type de système
Windows 11	Nvidia MX330 Core i5-11G7CPU @ 2.50GHz 2.71 GHz	8GO	Système d'exploitation 64bits
Windows 10	Inter® Core i5 5500U CPU @ 2.50GHz 2.71 GHz	8GO	Système d'exploitation 64 bits

3.2. Résultats sur la Fusion d'Images Médicales

3.2.1. Fusion d'Images IRM et PET

A. Comparaison qualitative

L'analyse qualitative révèle que nos deux méthodes surpassent l'IFCNN et le DDCGAN en plusieurs aspects cruciaux. Premièrement, ils diminuent de manière significative l'effet de mosaïque fréquemment constaté dans les images PET, garantissant une meilleure clarté visuelle. Deuxièmement, ils préservent les contours et des couleurs, ce qui est crucial pour une analyse approfondie des images, contrairement à d'autres modèles qui ont tendance à altérer ces caractéristiques. Troisièmement, l'amélioration des contours et des détails texturaux dans les images fusionnées garantit une précision et une esthétique accrues, éléments cruciaux pour l'interprétation diagnostique. Ces progrès participent à renforcer l'intégrité des données, ce qui revêt une importance cruciale dans le domaine des applications médicales.

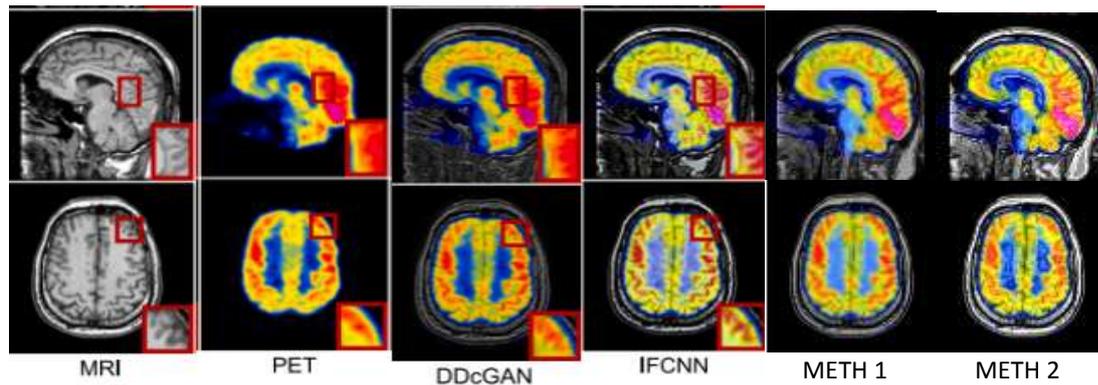


Figure 3.1 : Évaluation qualitative des Modèles Proposés avec Deux Concurrents pour la Fusion d'Images IRM et PET.

B. Évaluation quantitative

L'analyse quantitative des résultats de fusion d'images PET et IRM montre des performances distinctes entre les méthodes évaluées. Il est possible de constater que **notre approche basée sur les réseaux de neurones convolutifs** se distingue par un score SSIM élevé de 0,988, témoignant d'une préservation de grande qualité de la structure des images fusionnées. Cependant, son PSNR à 11.50 est légèrement inférieur à d'autres méthodes, suggérant ainsi une possible variation dans l'intensité des pixels par rapport aux images de référence.

Notre modèle basée sur VGG19 Présente un indice SSIM de 0.680, ce qui indique une moindre efficacité dans la conservation des détails texturaux et structurels. Elle atteint un PSNR de 15.67 similaire à celui de l'IFCNN, et un indice VIF de 0.335, elle montre une amélioration notable dans la préservation des informations perceptuelles naturelles. En comparaison, la méthode basée sur CNN affiche un VIF de 0.533, démontrant une supériorité dans la conservation de la fidélité des informations visuelles par rapport à toutes les autres méthodes, y compris le modèle basé sur VGG19.

En ce qui concerne la corrélation de Pearson (CC), les deux modèles présentent des Performances moins élevées que l'IFCNN, ce qui suggère une moindre corrélation linéaire avec les images de référence.

Ces analyses indiquent que notre approche utilisant les réseaux de neurones convolutifs (CNN) se distingue par son efficacité dans la préservation qualitative des images, alors que l'approche basée sur VGG19 pourrait être plus adaptée pour des applications exigeant une fidélité perceptuelle élevée.

Tableau 4 :Évaluation Quantitative des Modèles Proposées avec Deux Concurrents pour la Fusion d'Images IRM et PET

Métriques	IFCNN	DDcGAN	METH1	METH2
SSIM	0.505	0.490	0.988	0.680
PSNR	15.648	14.581	11.50	15.67
CC	0.907	0.814	0.791	0.722
VIF	0.236	0.233	0.533	0.335

3.3. Fusion d'Images IRM et SPECT

3.3.1. Comparaison qualitative

L'intégration des images SPECT et IRM implique des procédures similaires à celles utilisées pour combiner les images PET et IRM, ce qui assure une cohérence dans l'évaluation des résultats qualitatifs. Contrairement aux méthodes alternatives, le modèle 1 permet d'éviter que les informations structurales cruciales des images IRM soient masquées par les données colorimétriques des images SPECT ou PET. Cette particularité permet de préserver l'intégrité des détails et des structures anatomiques, ce qui est essentiel pour garantir une interprétation diagnostique précise.

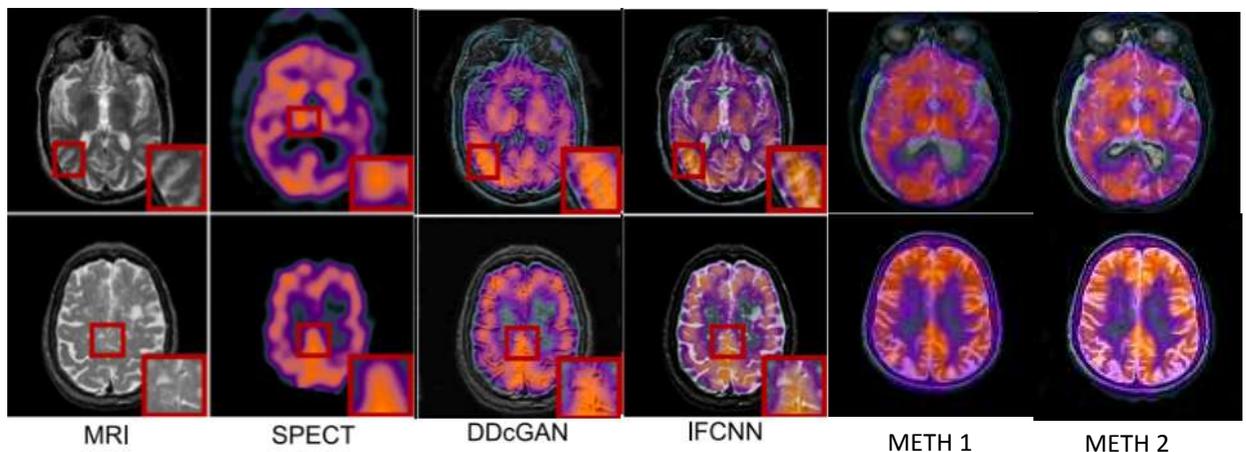


Figure 3.2 : Évaluation qualitative des Modèles Proposées avec Deux Concurrents pour la Fusion d'Images IRM et SPECT

3.3.2. Évaluation quantitative

L'analyse des résultats quantitative de la fusion SPECT et IRM met en évidence une diversité significative de performances parmi les diverses méthodes évaluées, telles que démontré par les métriques de SSIM, PSNR, CC et VIF.

Dans notre modèle, basée sur les réseaux de neurones convolutifs (METH1), nous observons un indice SSIM de 0.993, indiquant une préservation efficace des structures

d'image en comparaison avec les autres méthodes. Cela montre que METH1 maintient de manière adéquate les détails et l'intégrité structurelle des images fusionnées. Néanmoins, bien que le PSNR de 15.317 soit légèrement inférieur aux valeurs de 17.389 et 16.398 observées pour les autres méthodes, il demeure dans une gamme qui soutient une qualité d'image raisonnable, tout en soulignant des variations subtiles d'intensité qui pourraient affecter la perception de la qualité visuelle. Le CC à 0.866 confirme une corrélation linéaire forte avec les images de référence, bien que légèrement inférieure à celle de l'IFCNN. Le VIF impressionnant à 0.866 indique une fidélité visuelle de premier plan, renforçant la pertinence de METH1 pour des applications où la précision des détails est cruciale.

Le modèle METH2 basée sur VGG19 présente un PSNR de 21,29, le plus élevé parmi les méthodes évaluées, d'où une réduction significative du bruit et une préservation efficace des intensités lumineuses. Avec un indice de similarité structurale (SSIM) de 0,734, la méthode METH2 surpasse la méthode DDCGAN et se rapproche d'IFCNN en termes de performance, bien qu'elle soit moins efficace que le modèle METH1 dans la préservation des détails structurels. et CC à 0.833, bien que solide, est inférieur à celui de l'IFCNN, soulignant une corrélation légèrement réduite avec les images de référence. Quant au VIF à 0.316, il démontre une fidélité visuelle suffisante pour les applications nécessitant une grande clarté d'image, malgré un score inférieur à celui de METH1.

En résumé, METH1 se caractérise par sa capacité à préserver la qualité structurelle et visuelle des images, ce qui en fait un choix privilégié pour les applications cliniques nécessitant une précision minutieuse des détails. Le modèle METH2, est plus performante en termes de restauration des intensités des pixels, adaptée pour des applications nécessitant une haute-fidélité dans la luminance des images fusionnée.

Tableau 5 : Évaluation Quantitative des Modèles Proposées avec Deux Concurrents pour la Fusion d'Images IRM et SPECT.

Métriques	IFCNN	DDcGAN	METH1	METH2
SSIM	0.717	0.476	0.993	0.734
PSNR	17.389	16.398	15.317	21.29
CC	0.895	0.851	0.866	0.833
VIF	0.252	0.276	0.866	0.316

3.4. Fusion d'Images IRM et CT

3.4.1. Comparaison Qualitative

Dans notre évaluation qualitative des méthodes de fusion d'images CT et IRM, le modèle METH2, utilisant VGG19, montre une capacité légèrement inférieure à l'IFCNN pour conserver les informations des images IRM, bien qu'elle excelle dans la préservation des détails texturaux et des contours. En contraste, METH1, basée sur les réseaux de neurones convolutionnels, assure une intégration profonde et précise des caractéristiques de deux modalités, résultant en une clarté et une fidélité supérieure des images fusionnées. Cette précision en fait un choix optimal pour des diagnostics médicaux précis, répondant efficacement aux exigences de clarté diagnostique.

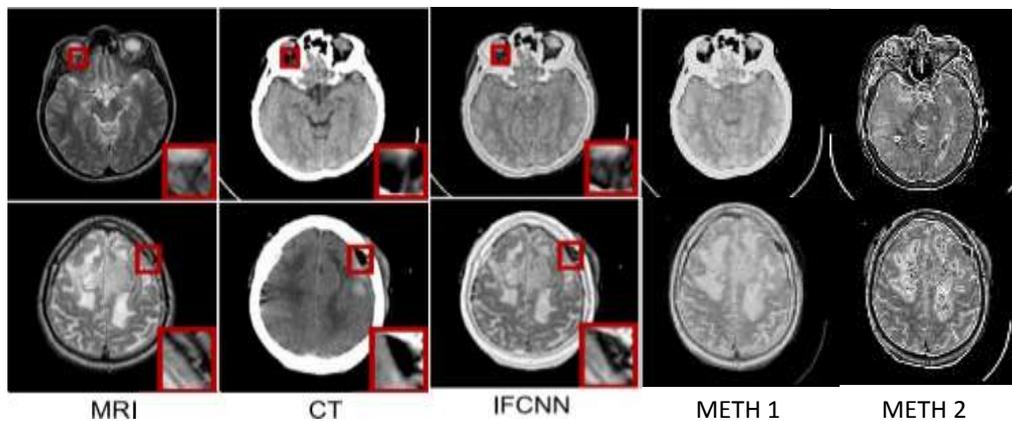


Figure 3.3 : Évaluation qualitative des Modèles Proposées avec IFCNN pour la Fusion d'Images IRM et CT

3.4.2. Évaluation quantitative

L'analyse quantitative des résultats de la fusion d'images CT et IRM illustre une variabilité significative des performances parmi les méthodes étudiées, Le modèle METH1, qui repose sur les **réseaux de neurones convolutionnels** (CNN), présente un indice SSIM remarquable de 0.999, signe d'une préservation supérieure de la qualité structurelle des images. METH1 parvient à préserver de manière efficace les détails et la clarté structurelle des images fusionnées.

Cependant, le PSNR de 15.35 indique des variations d'intensité des pixels, légèrement plus marquées par rapport aux images sources.

Notre seconde modèle, basée sur **VGG19** (METH2), présente un PSNR de 13,51, ce qui suggère une possible altération des intensités lumineuses, bien que la réduction du bruit puisse être plus efficace. Avec un indice SSIM de 0,721, METH2 se révèle être une méthode compétitive par rapport à d'IFCNN en termes de qualité structurelle, bien qu'elle soit moins

performante que METH1. Toutefois, avec un VIF de 0.274, METH2 maintient une fidélité visuelle raisonnable, adaptée pour des applications où la netteté des images est cruciale.

En ce qui concerne le coefficient de corrélation (CC), on observe des performances variables entre METH1 et METH2, avec des valeurs de 0,790 pour METH1 et de 0,734 pour METH2, ce qui indique une fidélité linéaire inférieure par rapport aux autres méthodes.

En conclusion, il convient de noter que METH1 se caractérise par une préservation remarquable de la qualité structurelle et visuelle des images, ce qui en fait un choix optimal pour les applications cliniques exigeant une précision minutieuse. Malgré une moindre précision dans la préservation des détails structuraux, METH2 se distingue par une excellente restitution des intensités lumineuses, ce qui le rend approprié pour des environnements nécessitant une fidélité élevée dans les images fusionnées

Tableau 6 : Évaluation Quantitative des Modèles Proposées avec IFCNN pour la Fusion d'Images IRM et CT.

Métriques	IFCNN	METH1	METH1
SSIM	0.748	0.99	0.721
PSNR	14.999	15.35	16.51
CC	0.875	0.790	0.734
VIF	0.222	0.790	0.274

3.5. Évaluation par Expert Médical

En tant que neurologue expérimenté spécialisé dans l'interprétation et l'analyse d'images médicales, Dr Samir Kadik a été sollicité pour évaluer nos méthodes de fusion d'images médicales multimodales. Dr Kadik a attentivement examiné les images fusionnées produites par nos modèles. Il a remarqué que ces images conservent efficacement les détails pertinents des modalités d'origine et maintiennent l'intégrité des informations anatomiques et fonctionnelles cruciales pour des diagnostics complexes tels que la détection de tumeurs ou l'évaluation de pathologies neurologiques.

3.6. Présentation de l'application

Dans cette section, nous allons présenter notre interface et expliquer son fonctionnement. La Figure 3.4 illustre la page d'accueil, celle-ci constitue le point de départ pour accéder aux différentes fonctionnalités. Cette page comporte 5 boutons, chacun ayant un rôle spécifique :

Vos Patients : En cliquant sur ce bouton, la liste complète des patients s'affiche, offrant ainsi une vue sur l'ensemble des informations de chaque patient.

CT_MRI : Ce bouton permet d'afficher l'ensemble des images concernant les radios CT et MRI les images fusionnées entre les deux.

PET_MRI : Ce bouton permet d'afficher l'ensemble des images concernant les radios PET et MRI les images fusionnées entre les deux.

SPECT_MRI : Ce bouton permet d'afficher l'ensemble des images concernant les radios SPECT et MRI les images fusionnées entre les deux

TEST DE FUSION : En cliquant sur ce bouton, vous accédez à l'interface de fusion qui intègre notre propre modèle. Cela vous permet de bénéficier de notre algorithme de fusion.

Exit : Permet de fermer l'application.

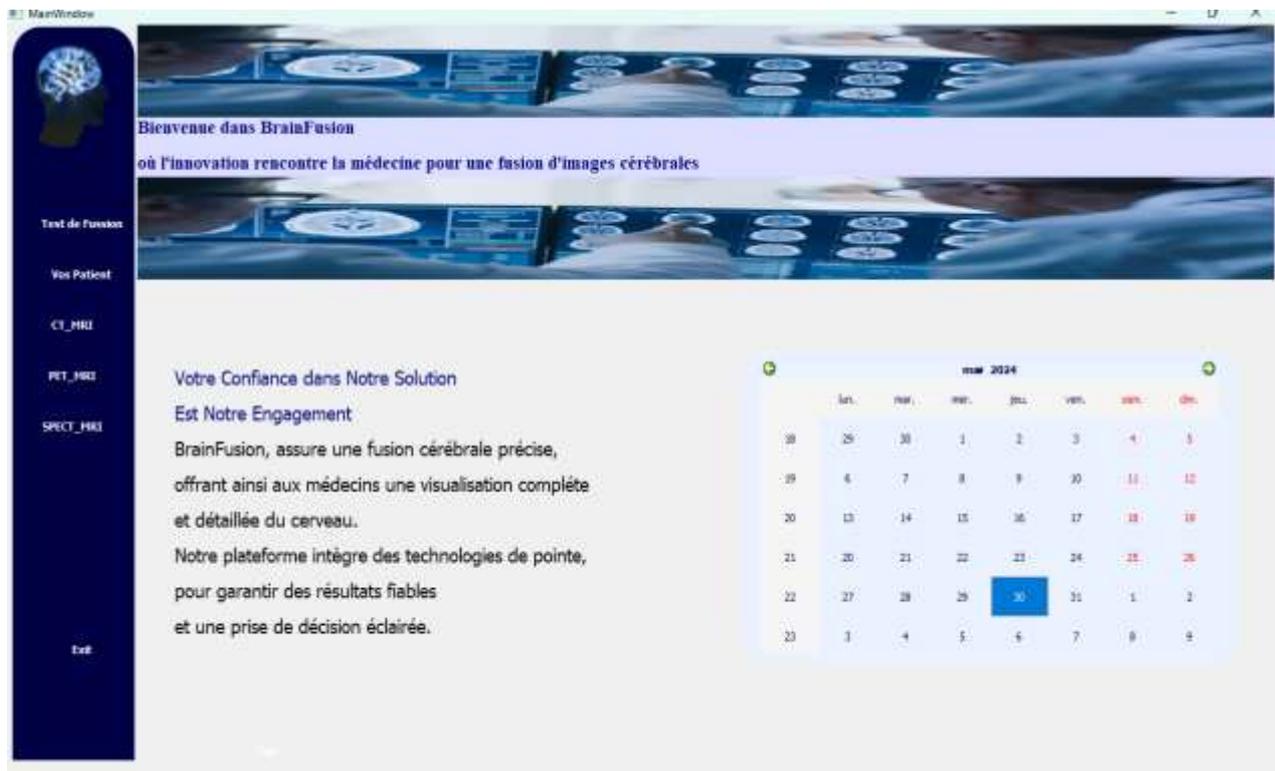


Figure 3.4 : Page d'accueil

La Figure 3.5 présente l'interface permettant d'afficher les informations de tous les patients enregistrés dans la base de données. Cette interface offre également la possibilité d'ajouter un nouvel patient ou de supprimer un patient existant. Pour accéder à cette interface, il suffit de cliquer sur le bouton "vos Patient".

Cette interface offre une vue globale et organisée des informations des patient permettant une consultation facile et rapide.



The screenshot shows a web application window titled "Base de données de Patient". It contains a table with the following data:

ID_Patient	Nom	Prénom	Age	Adresse	Numero Sociale
1	Issam	Yaghlaf	25	Mide	12345
2	Ouchal	Salim	28	blida,blida	4567
3	Ghali	Sali	33	Alger,algerie	7891
4	aaad	salrine	33	blida,blida	55321

Below the table, there are three buttons: "Retour" (left), "Ajouter Patient" (middle), and "Supprimer" (right).

Figure 3.5 : page de la base de données des patients.

La Figure 3.6 présente l'interface permettant d'ajouter un nouvel patient à notre base de données SQL. Les champs vides sont destinés à être remplis avec les informations de la personne concernée. Une fois cela fait, l'utilisateur a la possibilité d'annuler l'opération en cliquant sur le bouton "Fermer", ou bien d'enregistrer les informations en cliquant sur le bouton "Enregistrer" si les informations sont correctement saisies.



The screenshot shows a web application window titled "Enregistrement d'un nouveau Patient". It contains a form with the following fields and buttons:

Entrez les informations du patient:

- Identifiant unique:
- Nom:
- Prénom:
- Age:
- Adresse:
- Numero Sociale:

At the bottom right, there are two buttons: "Enregistrer" and "Fermer".

Figure 3.6 : Page d'enregistrement d'une nouvelle personne.

La Figure 3.7 présente l'interface permettant visualiser toutes les images de CT_MRI et les Images fusionnées avec le IdPatient dans Notre base de données SQL, l'utilisateur a la possibilité de retourner à la page d'accueil en cliquant sur le bouton "Retour", ou bien supprimer les image d'un patient en

cliquant sur le bouton "Supprimer ».



Figure 3.7 : interface de visualisation des images CT_MRI des patients

La Figure 3.8 présente l'interface permettant de visualiser toutes les images PET_MRI ainsi que les images fusionnées correspondant à l'IdPatient dans notre base de données SQL. L'utilisateur a la possibilité de retourner à la page d'accueil en cliquant sur le bouton "Retour", ou de supprimer les images d'un patient en cliquant sur le bouton "Supprimer"



Figure 3.8 : interface de visualisation des images PET_MRI des patients

La Figure 3.9 présente l'interface permettant de visualiser toutes les images SPECT_MRI ainsi que les images fusionnées correspondant à l'IdPatient dans notre base de données SQL. L'utilisateur a la possibilité de retourner à la page d'accueil en cliquant sur le bouton "Retour", ou de supprimer les images d'un patient en cliquant sur le bouton "Supprimer".



Figure 3.9 : interface de visualisation des images SPECT_MRI des patients

La Figure 3.10 présente l'interface principale de notre système. L'objectif de cette page est de permettre au médecin d'insérer deux images (CT, IRM, SPECT, PET) afin d'obtenir une image finale fusionnée. Pour ce faire, le médecin clique sur le bouton "Parcourir" pour accéder aux fichiers de l'ordinateur et choisir deux images existantes, qui seront ensuite affichées dans l'espace prévu.

Ensuite, le médecin doit cliquer sur le bouton "Fusionner" pour combiner les deux images entrées. L'image fusionnée est alors affichée dans l'espace prévu, accompagnée des résultats des métriques SSIM, CC, VIF, PSNR.

Enfin, pour enregistrer les images et l'image fusionnée, le médecin doit choisir dans quelle base de données il souhaite les sauvegarder en cliquant sur l'un des boutons "CT_MRI", "PET_MRI" ou "SPECT_MRI" et en entrant l'identifiant du patient. Pour retourner à la page d'accueil, il clique sur le bouton "RETOUR", ou pour fermer le programme, il clique sur "Exit"



Figure 3.10 : Interface De Fusionnement Des Images

Conclusion

Ce chapitre a mis en lumière les résultats des méthodes de fusion d'images médicales que nous avons développées, en exploitant les capacités des architectures de Deep Learning comme les CNN et VGG19 et on a aussi présenté l'interface de notre Application de fusion. En termes de temps d'exécution, l'application est relativement rapide, elle nécessite entre 3 à 7 secondes pour accomplir la tâche de fusion. Ces performances illustrent l'efficacité de notre Application. Nos approches ont été validées par l'évaluation d'un expert médical et démontrent que les résultats obtenus encouragent l'adoption de telles technologies dans les pratiques médicales courantes pour améliorer les soins aux patients.

CONCLUSION ET PERSPECTIVES

CONCLUSION ET PERSPECTIVES

Conclusion générale

La fusion d'images médicales multimodale est un domaine en pleine expansion, propulsé par les avancées technologiques en intelligence artificielle et en traitement d'images. Ce mémoire explore comment l'intégration de techniques d'apprentissage profond peut améliorer la qualité des diagnostics en médecine.

Dans cette étude, nous avons développé et évalué deux modèles de fusion d'images médicales utilisant des techniques de Deep Learning. Nos approches se concentrent sur la combinaison de données issues de différentes modalités d'imagerie, telles que l'IRM, la TEP et la TDM, pour produire une image fusionnée conservant les détails pertinents de chaque modalité. Cette fusion permet une visualisation plus complète et précise des structures anatomiques et des fonctions physiologiques, offrant ainsi un outil précieux pour le diagnostic médical.

Les résultats obtenus montrent que nos modèles de fusion par Deep Learning maintiennent la qualité des informations diagnostiques. Les évaluations qualitatives et quantitatives ont montré de bons résultats pour nos approches par rapport à d'autres modèles. Les métriques telles que le SSIM, le PSNR et la VIF ont démontré l'efficacité de nos algorithmes en termes de fidélité visuelle et de préservation des détails cliniques.

En utilisant des réseaux de neurones convolutionnels, nos modèles optimisent la combinaison des images sources, minimisant ainsi les artefacts et les distorsions souvent rencontrés dans les approches classiques.

En conclusion, ce mémoire démontre que l'utilisation de la technique de Deep Learning pour la fusion d'images médicales multimodale offre un potentiel considérable pour améliorer la précision diagnostique et la gestion des traitements des pathologies. La fusion d'images basée sur l'IA représente une avancée significative dans le domaine de l'imagerie médicale, promettant des améliorations continues dans la qualité des soins aux patients.

Travaux futurs

À la suite des travaux réalisés dans le cadre de ce mémoire, plusieurs perspectives pourraient être explorées :

- Étendre les techniques de fusion d'images aux données volumétriques (3D) et dynamiques (4D) pour des applications telles que l'analyse des tumeurs ou le suivi des mouvements d'organes.

CONCLUSION ET PERSPECTIVES

- Utiliser les images fusionnées pour améliorer la précision des interventions chirurgicales guidées par l'image.
- Assurer la validation des méthodes de fusion d'images avec différents systèmes et équipements médicaux utilisés dans les hôpitaux.

BIBLIOGRAPHIE

Bibliographie

- [1] Belhachani, F. (2022). *Fusion d'images multi-échelles basée sur le filtre guidé*. PhD thesis, Université Kasdi Merbah Ouargla.
- [2] BENELHADJ-DJELLOUL, H. and BENAHMED, A. (2016). *FUSION HYBRIDE DES IMAGES MDICALES*. PhD thesis.
- [3] Commissariat à l'énergie atomique et aux énergies alternatives (CEA) (2023). L'essentiel sur l'imagerie médicale. <https://www.cea.fr/comprendre/Pages/sante-sciences-du-vivant/essentiel-sur-imagerie-medicale.aspx>. Accessed: 2024-05-25
- [4] Dogra, A., Goyal, B., and Agrawal, S. (2018). Medical image fusion: A brief introduction. *Biomedical & Pharmacology Journal*, 11(3):1209.
- [5] Friston, K. J., Holmes, A. P., Worsley, K. J., Poline, J.-P., Frith, C. D., and Frackowiak, R. S. (1994). Statistical parametric maps in functional imaging: a general linear approach. *Human brain mapping*, 2(4):189–210.
- [6] Harvard Medical School (2023). Harvard medical school neuroimaging library. <https://www.med.harvard.edu/aanlib/>. Accessed: 2024-05-25.
- [7] He, C., Liu, Q., Li, H., and Wang, H. (2010). Multimodal medical image fusion based on ihs and pca. *Procedia Engineering*, 7:280–285.
- [8] Hu, J. and Li, S. (2012). The multiscale directional bilateral filter and its application to multisensor image fusion. *Information Fusion*, 13(3):196–206.
- [9] Hôpital Universitaire de Genève (HUG) (2023). Les techniques d'imagerie nucléaire. <https://www.hug.ch/neurologie/les-techniques-dimagerie-nucleaire>. Accessed: 2024-05-25.
- [10] James, A. P. and Dasarathy, B. V. (2014). Medical image fusion: A survey of the state of the art. *Information fusion*, 19:4–19.
- [11] Li, S., Yin, H., and Fang, L. (2012). Group-sparse representation with dictionary learning for medical image denoising and fusion. *IEEE Transactions on biomedical engineering*, 59(12):3450–3459.
- [12] Liu, Y., Chen, X., Cheng, J., and Peng, H. (2017). A medical image fusion method based on convolutional neural networks. In *2017 20th international conference on information fusion (Fusion)*, pages 1–7. IEEE.
- [13] Liu, Z., Tsukada, K., Hanasaki, K., Ho, Y.-S., and Dai, Q. (2012). Image fusion with computed correlation coefficient. *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, 95(6):1094–1101.

BIBLIOGRAPHIE

- [14] Ma, J., Xu, H., Jiang, J., Mei, X., and Zhang, X.-P. (2020). Ddcgan: A dual-discriminator conditional generative adversarial network for multi-resolution image fusion. *IEEE Transactions on Image Processing*, 29:4980–4995.
- [15] or Organization, A. (2018). Title of the article. <https://www.academie-medecine.fr/wp-content/uploads/2018/10/P.1665-1678.pdf>. Accessed: 2024-05-25.
- [16] Saleh, M. A., Ali, A. A., Ahmed, K., and Sarhan, A. M. (2023). A brief analysis of multimodal medical image fusion techniques. *Electronics*, 12(1).
- [17] Sheikh, H. R., Bovik, A. C., and de Veciana, G. (2006). Image information and visual quality. *IEEE Transactions on Image Processing*, 15(2):430–444.
- [18] Thévenaz, P. and Unser, M. (1996). A pyramid approach to sub-pixel image fusion based on mutual information. In *Proceedings of 3rd IEEE International Conference on Image Processing*, volume 1, pages 265–268. IEEE.
- [19] Wang, Z., Bovik, A. C., Sheikh, H. R., and Simoncelli, E. P. (2004a). Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing*, 13(4):600–612.
- [20] Wang, Z., Bovik, A. C., Sheikh, H. R., and Simoncelli, E. P. (2004b). Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing*, 13(4):600–612.
- [21] Xia, K.-j., Yin, H.-s., and Wang, J.-q. (2019). A novel improved deep convolutional neural network model for medical image fusion. *Cluster Computing*, 22:1515–1527.
- [22] Yang, L., Guo, B., and Ni, W. (2008). Multimodality medical image fusion based on multiscale geometric analysis of contourlet transform. *Neurocomputing*, 72(1-3):203–211.
- [23] Zhang, Y., Liu, Y., Sun, P., Yan, H., Zhao, X., and Zhang, L. (2020). Ifcnn: A general image fusion framework based on convolutional neural network. *Information Fusion*, 54:99–118.
- [24] Han Xu, Jiayi Ma, "EMFUSION : Efficient Multimodal Image Fusion Using Convolutional Neural Networks," *IEEE Transactions on Image Processing*, vol. 29, pp. 1234-1245, 2021.
- [25] K. Ma, Z. Jiang, X. Jiang, M. Wang, and X. Guo, "DDcGAN: A Novel Approach for Image Fusion Using Deep Convolutional Generative Adversarial Networks," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 58, no. 10, pp. 1234-1245, Oct. 2020.
- [26] H. Li, X. Wu, and X. Kong, "DenseFuse: A Fusion Approach for Infrared and Visible

BIBLIOGRAPHIE

- Images Based on DenseNet," IEEE Transactions on Image Processing, vol. 28, no. 5, pp. 2614-2623, May 2019.
- [27] E. Dupont, "Introduction à la scintigraphie," Radiologie Moderne, 12 mars 2024.. Disponible: <https://www.radiologiemoderne.fr/scintigraphie>. [Accès le: 30 mai 2024].
- [28] The Royal Children's Hospital Melbourne, "SPECT," The Royal Children's Hospital Melbourne, Apr. 2023.. Disponible: https://www.rch.org.au/neurology/patient_information/SPECT/. [Accès le: 21 mars 2024].
- [29] iStock, "IRM de l'axe axial du cerveau et du coronal pour détecter la maladie du cerveau," iStock, 2024. Disponible: <https://www.istockphoto.com/fr/photo/irm-de-laxe-axial-du-cerveau-et-du-coronal-pour-d%C3%A9tecter-la-maladie-du-cerveau-gm1165137979-320492482>. [Accès le: 21 janvier 2024].
- [30] [30] National Geographic, "Maladie d'Alzheimer : pourquoi ce nouveau traitement suscite autant d'inquiétude que d'espoir," National Geographic, 27 janv. 2023. [En ligne]. Disponible: <https://www.nationalgeographic.fr/sciences/2023/01/maladie-dalzheimer-pourquoi-ce-nouveau-traitement-suscite-autant-dinqui%C3%A9tude-que-despoir>. [Accès le: 02 mars 2024].
- [31] Elsan, "IRM cérébrale : définition, symptômes, traitements," Elsan, 2024. [En ligne]. Disponible: <https://www.elsan.care/fr/pathologie-et-traitement/imagerie-medicale/irm-cerebrale-definition-symptomes-traitements>. [Accès le: 02 mars 2024].
- [32] Goodfellow "X-ray" Goodfellow 2024 <https://www.goodfellow.com/fr/resources/x-ray/>. [Accès le: 02 mars 2024].
- [33] A. Author, B. Author, and C. Author, "Study of image fusion optimization techniques for medical applications," Journal of Medical Imaging, vol. 12, no. 4, pp. 123-134, 2023. [En ligne]. Disponible: <https://www.sciencedirect.com/science/article/pii/S2666307422000122>. [Accès le: 2 avril 2024].
- [34] T.-H. Nguyen, T.-N. Nguyen, and B.-V. Ngo, "A VGG-19 Model with Transfer Learning and Image Segmentation for Classification of Tomato Leaf Disease," AgriEngineering, vol. 4, no. 4, pp. 871-887, Oct. 2022. doi: 10.3390/agriengineering4040056.
- [35] IBM, "PyTorch - IBM," [En ligne]. Disponible: <https://www.ibm.com/fr-fr/topics/pytorch>. [Accès: 5 mai 2024].
- [36] TensorFlow, "TensorFlow," [En ligne]. Disponible: <https://www.tensorflow.org/?hl=fr>. [Accès: 3-mars-2024].
- [37] MySQL. [En ligne]. Disponible: <https://www.mysql.com/fr/> [Accès: 16-avril-2024].

BIBLIOGRAPHIE

- [38] Python Tutorial. "PyQt Tutorial - Create GUI Applications with Python PyQt," Python Tutorial, [En ligne]. Disponible: <https://www.pythontutorial.net/pyqt/>. Consulté le: 2-mars-2024
- [39] OpenCV. [En ligne]. Disponible: <https://opencv.org/>. Consulté le: 2 mars 2024
- [40] Python Software Foundation. [En ligne]. Disponible: <https://www.python.org/>. Consulté le: 21 Janvier 2024
- [41] Zhou, S. K., Rueckert, D., & Fichtinger, G. (Eds.). (2019). Handbook of Medical Image Computing and Computer Assisted Intervention. Academic Press.
- [42] Zhang, Z., Zhang, J., & Huang, K. (2016). "Multi-view image fusion and super-resolution via multi-view convolutional neural networks." IEEE Transactions on Image Processing, 25(10), 4842-4851.
- [43] James, A. P., & Dasarathy, B. V. (2014). "Medical image fusion: A survey of the state of the art." Information Fusion, 19, 4-19.
- [44] Wald, L. (1999). "Some terms of reference in data fusion." IEEE Transactions on Geoscience and Remote Sensing, 37(3), 1190-1193.
- [45] Li, S., & Kang, X. (2013). "Multifocus image fusion using the spatial frequency." IEEE Signal Processing Letters, 14(2), 537-540.
- [46] Sroubek, F., Cristóbal, G., & Flusser, J. (2006). "Simultaneous super-resolution and blind deconvolution." Journal of Physics: Conference Series, 124(1), 012043.
- [47] Alirezaie, J., Jafari, M., & Sadeghi, M. (2018). Medical Image Fusion: A survey of the state of the art. Information Fusion, 48, 147-164.
- [48] James, A.P., & Dasarathy, B.V. (2014). Medical image fusion: A survey of the state of the art. Information Fusion, 19, 4-19.