



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

UNIVERSITE IBN KHALDOUN - TIARET

MEMOIRE

Présenté à :

FACULTÉ DES MATHÉMATIQUES ET D'INFORMATIQUE
DÉPARTEMENT D'INFORMATIQUE

Pour l'obtention du diplôme de :

MASTER

Spécialité : Intelligence artificiel et digitalisation

Par :

SELLAI AMINA

Sur le thème

**Détection d'anomalies cardiaques à partir d'images
échographiques en utilisant des GAN pour améliorer la
classification et la segmentation des maladies
cardiovasculaires.**

Soutenu publiquement le 16/ 06 / 2025 à Tiaret devant le jury composé de :

Mr Kouadria Abderrahmane	Grade : MCA	Université Tiaret	Président
Mr Baghdadi Mohamed	Grade : MCA	Université Tiaret	Encadrant
Mme Hamdani Abdia	Grade : MCB	Université Tiaret	Examinatrice

2024-2025

Remerciements

En préambule à ce mémoire nous remerciant ALLAH qui nous a donné la patience et le courage durant ces années d'étude.

A mon encadreur Dr. BAGHDADI Mohamed:

J'ai eu le privilège de travailler avec vous et d'apprécier vos qualités et vos valeurs. Votre sérieux, votre compétence et votre sens du devoir m'ont énormément marqué. Veuillez trouver ici l'expression de ma respectueuse considération et ma profonde admiration pour toutes vos qualités scientifiques et humaines. Ce travail est pour moi l'occasion de vous témoigner ma profonde gratitude.

Aux membres de jury :

Je vous remercie pour l'honneur que vous nous avez fait en acceptant de juger ce mémoire de Fin d'étude. Votre compétence et votre gentillesse ont toujours suscité grande estime. Veuillez trouver ici l'expression de nous sincères remerciements.

Dédicace

A ceux qui m'ont donné naissance dans cette vie, aucune dédicace ne saurait exprimer l'amour l'estime et le respect que j'ai toujours pour vous.

A celle qui a toujours été là pour moi, à la merveille maman qui a battue pour moi, qui m'a soutenu et encouragé durant ces années d'études, cette dédicace ne saurait être assez éloquente pour exprimer ce que tu mérites pour tous les sacrifices que tu n'as cessé de me donner depuis ma naissance durant mon enfance et même à l'âge d'adulte.

A celui qui m'a donné main dans cette vie au meilleur Abi qui m'a transmis les vraies valeurs pour connaître et vivre cette vie, rien au monde ne vaut les efforts fournis jours et nuits pour mon éducation et mon bien-être. Sache que sans toi ma vie ne saurait pas ce qu'elle est aujourd'hui.

A ceux qui ont vécu et grandi avec moi, mes chers frères

OUSSAMA, AYOUB et mes chères sœurs ASMAA, ISRAA

, en témoignage de mon affection fraternelle, et ma profonde tendresse et reconnaissance. Je vous souhaite que dieux, le tout puissant, vous protège et vous garde.

A tous mes enseignants et mes professeurs depuis mon premier jour à l'école jusqu'à ce jour, veuillez trouver dans ce travail l'expression de mon respect le plus profond, ma gratitude et mon affection la plus sincère.

A mes amies de toujours, ma promotion, qui m'ont soutenu, puisse dieu vous donne santé, bonheur, courage, et surtout réussite dans votre vie personnelle et professionnelle.

A toutes les personnes qui ont participé à l'élaboration de ce travail, à tous ceux qui j'ai omis de citer

.

Amin

Résumé

Les maladies cardiovasculaires constituent la principale cause de mortalité dans de nombreux pays, et leur diagnostic précoce est essentiel pour améliorer les chances de survie des patients. L'échocardiographie, une technique d'imagerie médicale non invasive, est largement utilisée pour diagnostiquer ces pathologies. Toutefois, l'analyse manuelle des images échographiques reste complexe et dépend fortement de l'expertise des cardiologues.

Dans ce travail, nous proposons l'utilisation des réseaux antagonistes génératifs (GAN), en particulier les modèles DCGAN, pour générer des images synthétiques d'échographies cardiaques en vue d'améliorer la détection des anomalies associées aux maladies cardiovasculaires. En utilisant une architecture GAN adaptée aux spécificités des images échographiques, nous avons pu produire des images visuellement plausibles, imitant fidèlement les échographies réelles. Notre modèle de détection a montré une capacité efficace à distinguer les images présentant des anomalies cardiaques de celles représentant un cœur sain.

Par ailleurs, nous avons exploité ces images synthétiques pour améliorer la segmentation des structures cardiaques, ce qui a permis une classification plus précise des pathologies. Les résultats de ce travail montrent que les GAN et plus particulièrement les DCGAN sont capables de générer des images synthétiques de haute qualité et peuvent contribuer à une détection précoce ainsi qu'à une segmentation précise des anomalies cardiaques. Ces résultats ouvrent la voie à des solutions innovantes pour l'aide au diagnostic en cardiologie, en renforçant l'automatisation, la précision et l'accessibilité des outils d'analyse échographique.

Mots-clés :

Imagerie médicale, échocardiographie, maladies cardiovasculaires, deep learning, réseaux de neurones convolutifs, réseaux antagonistes génératifs, TensorFlow, Keras, segmentation, classification.

Abstract

Cardiovascular diseases are the leading cause of death in many countries, and their early diagnosis is essential to improve patients' survival rates. Echocardiography, a non-invasive medical imaging technique, is widely used to diagnose these conditions. However, manual analysis of echocardiographic images remains complex and highly dependent on the expertise of cardiologists.

In this work, we propose the use of Generative Adversarial Networks (GANs), particularly Deep Convolutional GANs (DCGANs), to generate synthetic cardiac ultrasound images in order to enhance the detection of anomalies associated with cardiovascular diseases. By employing a GAN architecture tailored to the specific characteristics of echographic images, we were able to produce visually plausible images that closely mimic real echocardiograms. Our detection model demonstrated strong capability in distinguishing between abnormal and healthy heart images.

Furthermore, we leveraged these synthetic images to improve the segmentation of cardiac structures, enabling more accurate classification of various pathologies. The results of this study show that GANs, and especially DCGANs, are capable of generating high-quality synthetic images and can significantly contribute to the early detection and precise segmentation of cardiac anomalies. These findings pave the way for innovative solutions in cardiology diagnostics by enhancing the automation, accuracy, and accessibility of echographic image analysis tools.

Keywords :

Medical imaging, echocardiography, cardiovascular diseases, deep learning, convolutional neural networks, generative adversarial networks, TensorFlow, Keras, segmentation, classification.

Table des matières

Remerciement.....	...i
Dédicace.....	...ii
Résumé.....	...iii
Table des matières.....	...iv
Table des figures.....	...v
Liste des abréviations.....	...vi
Introduction.....	1
Chapitre 1 : Généralités	
I.1 Introduction.....	3
I.2 Imagerie médicale.....	3
I.2.1 Historique de l'imagerie médicale	3
I.2.2 Différentes technologies d'imagerie médicale.....	4
I.2.2.1 Rayons X.....	4
I.2.2.2 Scanner (tomodensitométrie).....	4
I.2.2.3 Radiographie.....	5
I.2.2.4 Imagerie par résonance magnétique (IRM).....	6
I.2.2.5 Echographie.....	6
I.2.3 Importance de l'imagerie médicale.....	8
I.2.4 Potentiel de l'intelligence artificielle en imagerie médicale.....	8
I.3.1 Image.....	9
I.3.2 Image numérique.....	10
I.3.3 Types d'images.....	10
I.3.3.1 Image binaire.....	10
I.3.3.2 Image en niveaux de gris.....	10
I.3.3.2 Image en couleur (RGB).....	10
I.3.3.3 Image indexée.....	11
I.3.4 Caractéristiques des images.....	11
I.3.5 Segmentation des images.....	11
I.3.6 Classification des images.....	12
I.4 Maladies cardiovasculaires.....	13
I.4.1 Facteurs de risque.....	13
I.4.2 Symptômes.....	13
I.4.3 Diagnostic.....	14
I.4.4 Épidémiologie des maladies cardiovasculaires.....	15
I.4.5 Traitement des maladies cardiovasculaires.....	15
I.5 Conclusion.....	16
Chapitre 2 : Apprentissage profond	
II.1 Introduction.....	18
II.2 Intelligence artificielle.....	18
II.3 Apprentissage automatique.....	20
II.3.1 Apprentissage supervisé.....	20
II.3.2 Apprentissage non supervisé.....	21

II.3.3 Apprentissage par renforcement.....	21
II.4 Réseaux de neurones artificiels.....	21
II.4.1 Structure d'un réseau de neurones.....	21
II.4.2 Fonctionnement d'un neurone artificiel.....	22
II.4.2.1 Somme pondérée.....	22
II.4.2.2 Fonction d'activation.....	22
II.4.2.3 Entraînement d'un réseau de neurones artificiel.....	24
II.5 Apprentissage profond.....	25
II.5.1 Avantages de l'apprentissage profond.....	25
II.5.2 Défis de l'apprentissage profond.....	26
II.6 Réseaux de neurones convolutifs.....	26
II.6.1 Architecture d'un CNN.....	26
II.6.2 Fonctionnement d'un CNN.....	28
II.6.3 Applications des CNN en imagerie médicale.....	29
II.6.4 Avantages et limites des CNN.....	30
II.7 Conclusion.....	30

Chapitre 3 : Réseaux antagonistes génératifs

III.1 Introduction	32
III.2 Réseaux antagonistes génératifs.....	33
III.2.1 Principe de base.....	33
III.2.2 Fonctionnement des GANs.....	34
III.2.3 Processus d'entraînement.....	34
III.2.3.1 Modèle du générateur.....	34
III.2.3.2 Modèle du discriminateur.....	35
III.2.4 Applications des GANs.....	35
III.3 Réseaux antagonistes génératifs à convolution profonde (DCGANs)	36
III.3.1 Introduction aux DCGANs.....	36
III.3.2 Architecture des DCGANs.....	36
III.3.2.1 Générateur.....	36
III.3.2.2 discriminateur.....	37
III.3.3 Avantages des DCGANs.....	38
III.3.4 Défis des DCGANs.....	39
III.3.5 Application des DCGANs dans notre projet.....	39
III.4 État de l'art de l'utilisation des GAN pour le traitement des images médicales.....	40
III.4.1 Génération multi-modale et évaluation comparative des GANs.....	40
III.4.2 Synthèse d'images IRM pour anonymisation et augmentation de données.....	40
III.4.3 Amélioration de la classification de lésions hépatiques par augmentation avec GAN.....	40
III.4.4 Traduction d'images IRM cardiaques non appariées.....	41
III.4.5 Amélioration de la généralisation en segmentation CT avec CycleGAN.....	41
III.4.6 Génération d'images échographiques pour classification cardiaque.....	41
III.4.7 Résumé des travaux.....	42
III.5 Conclusion.....	42

Chapitre 4 : Implémentation et résultats

IV.1 Introduction. ..	44
IV.2 Environnement de travail.....	44
IV.2.1 Plateforme de calcul.....	44
IV.2.2 Langage de programmation.....	44
IV.2.3 Configuration matérielle locale.....	45

IV.2.4 Bibliothèques principales.....	45
IV.3 Datasets utilisés.....	45
IV.3.1 Dataset EchoNet-Dynamic.....	45
IV.3.1.1 Structure du dataset.....	47
IV.3.1.2 Caractéristiques des données.....	47
IV.3.2 Heart Disease Dataset.....	48
IV.3.2.1 Objectif.....	48
IV.3.2.2 Caractéristiques générales.....	49
IV.3.2.3 Description des variables.....	49
IV.3.2.4 Qualité des données.....	50
IV.4 Préparation des données pour notre projet.....	50
IV.5 Implémentation.....	51
IV.5.1 Préparation des données.....	52
IV.5.1.1 Chargement des bibliothèques nécessaires.....	52
IV.5.1.2 Définition du chemin des données.....	52
IV.5.1.3 Définition de la classe personnalisée EchoNetDataset.....	52
IV.5.1.4 Chargement des métadonnées.....	52
IV.5.1.5 Division du jeu de données.....	52
IV.5.1.6 Transformations.....	52
IV.5.1.7 Création des objets Dataset et DataLoader.....	53
IV.5.2 Construction des modèles GANs.....	53
IV.5.2.1 Vanilla GAN.....	53
IV.5.2.2 DCGAN (Deep Convolutional GAN)	55
IV.5.2.3 CGAN (Conditional GAN)	59
IV.5.2.4 WGAN (Wasserstein GAN)	60
IV.5.2.5 Comparaison des modèles GANs.....	64
IV.5.3 Classification des images échographiques.....	66
IV.5.3.1 Classifieur CNN1 (Modèle CNN simple)	67
IV.5.3.2 Classifieur CNN2 (Modèle CNN plus profond)	67
IV.5.3.3 Classifieur ResNet (Basé sur ResNet18)	68
IV.5.3.4 Classifieur MobileNet (basé sur MobileNetV2)	68
IV.5.3.5 Modèle de données cliniques (SimpleNN sur données tabulaires)	68
IV.5.3.6 Comparaison des modèles de classification.....	69
IV.5.4 Interface de notre application.....	71
IV.6 Conclusion.....	72
Conclusion général.....	73
Références bibliographiques.....	75

Table des figures

Figure I.1 : Exemple d'une image de rayons X.....	4
Figure I.2 : Exemple d'une image de tomodensitométrie.....	5
Figure I.3 : Exemple d'une image de radiographie thoracique.....	6
Figure I.4 : Exemple d'une image échographique cardiaque montrant les ventricules et les oreillettes.....	7
Figure I.5 : Image échographique en niveaux de gris.....	10
Figure I.6 : Exemple d'une image échographique Doppler montrant le flux sanguin à travers la valve mitrale.....	12
Figure I.7 : Image indexée.....	13
Figure I.8 : Exemple de segmentation d'une image échocardiographique.....	14
Figure I.9 : Exemple de classification d'images échocardiographiques à l'aide d'un réseau de neurones convolutifs (CNN).....	19
Figure I.10 : Schéma illustrant les principales structures visibles lors d'une échocardiographie transthoracique.....	20
Figure II.1 : Schéma de fonctionnement d'une IA.....	22
Figure II.2 : Trois catégories du machine learning.....	23
Figure II.3 : Schéma d'un réseau de neurones artificiel simple.....	25
Figure II.4 : Courbes des fonctions d'activation Sigmoides, ReLU et Tanh.....	28
Figure II.5 : Illustration du processus de rétropropagation du gradient.....	32
Figure II.6 : Architecture d'un réseau de neurones convolutifs (CNN).....	33
Figure III.1 : Principe des réseaux antagonistes génératifs.....	35
Figure III.2 : Fonctionnement du discriminateur et du générateur.....	37
Figure III.3 : Processus d'entraînement du générateur et du discriminateur.....	38
Figure III.4 : Composition des couches d'un DCGAN.....	46
Figure III.5 : Exemple d'images échographiques réelles et synthétiques générées par un DCGAN.....	48
Figure IV.1 : Exemple d'images du dataset EchoNet-Dynamic.....	54
Figure IV.2: Exemples du dataset Heart Disease Dataset.....	55
Figure IV.2 : Composants principaux d'un Vanilla GAN.....	56
Figure IV.3 : Quelques exemples d'images échographiques générées par le Vanilla GAN.....	58

Figure IV.4 : Architecture du générateur et du discriminateur du DCGAN.....	59
Figure IV.5 : Quelques exemples d'images échographiques générées par le DCGAN.....	61
Figure IV.6 : Schéma du fonctionnement conditionnel du CGAN avec étiquettes de classe	63
Figure IV.7 : Schéma du fonctionnement du WGAN.....	64
Figure IV.8 : Schéma du fonctionnement du WGAN.....	64
Figure IV.9 : Évolution de la fonction de perte du générateur pour les différentes architectures de GANs.....	65
Figure IV.10 : Exemples d'images échographiques synthétiques générées par les quatre architectures de GANs.....	66
Figure IV.11 – Courbes de pertes des différents modèles de classification.....	71
Figure IV.12 : Interface utilisateur pour la génération et la classification d'images cardiaques	71

Liste d'abréviations

- ✓ **OMS** : Organisation mondiale de la santé
- ✓ **CT scan** : Tomodensitométrie.
- ✓ **IRM** : Imagerie par résonance magnétique.
- ✓ **RGB** : Image couleur composée des composantes rouge, verte et bleue (Red ,Green,Bleu).
- ✓ **MCV** : Maladies cardio-vasculaires
- ✓ **MC** : Maladies coronariennes
- ✓ **ECG** : Electrocardiogramme
- ✓ **ETT** : Echographie trans-thoracique
- ✓ **ETO** : Echographie trans-oesophagienne
- ✓ **IA** : Intelligence artificielle.
- ✓ **ML** : Apprentissage automatique (Machine Learning).
- ✓ **DL** : Deep learning
- ✓ **NLP** : Natural language processing
- ✓ **ANN** : Artificial neural network
- ✓ **CNN** : Convolutional Neural Network
- ✓ **ReLu** : Rectified linear unit
- ✓ **MSE** : Mean squared error
- ✓ **GAN** : Réseaux antagonistes génératifs.
- ✓ **DCGAN** : Deep convolutional GAN.
- ✓ **WGAN** : Wasserstein GAN
- ✓ **FEVG** : Fraction d'éjection ventriculaire gauche.

Introduction générale

L'imagerie médicale est un domaine de recherche en constante évolution, jouant un rôle clé dans le diagnostic et la prise en charge des maladies. Parmi les techniques les plus utilisées, l'échocardiographie (échographie cardiaque) se distingue comme une méthode non invasive essentielle pour diagnostiquer les maladies cardiovasculaires, qui représentent la principale cause de mortalité dans le monde. Cependant, l'analyse manuelle des images échographiques est une tâche complexe, chronophage et dépendante de l'expertise des cardiologues, ce qui peut entraîner des erreurs de diagnostic.

Dans ce contexte, notre projet propose l'utilisation des réseaux antagonistes génératifs (GAN) pour améliorer la détection des anomalies cardiaques à partir d'images échographiques. Les GAN, et plus précisément les DCGAN (Deep Convolutional GAN), sont des modèles d'apprentissage profond capables de générer des images synthétiques réalistes. Nous exploitons cette capacité pour produire des images échographiques synthétiques, qui sont ensuite utilisées pour améliorer la classification des pathologies cardiaques et la segmentation des structures du cœur, telles que les ventricules et les valves. L'objectif principal de ce travail est de développer un modèle capable de détecter efficacement les anomalies cardiaques et de segmenter les structures pertinentes, contribuant ainsi à une prise en charge précoce et précise des maladies cardiovasculaires.

Ce mémoire est structuré en quatre chapitres :

- Le premier chapitre aborde les bases de l'imagerie médicale, le traitement d'images, ainsi que les maladies cardiovasculaires, en mettant l'accent sur le rôle de l'échocardiographie.
- Le deuxième chapitre présente les concepts de l'apprentissage profond, en expliquant l'architecture des réseaux de neurones convolutifs (CNN) et leurs applications dans le traitement des images.
- Le troisième chapitre introduit les réseaux GAN, en particulier les DCGAN, et leur utilisation dans le domaine de l'imagerie médicale.
- Le dernier chapitre est consacré à l'implémentation pratique de notre modèle, à l'analyse des résultats et à la discussion des performances en termes de détection et de segmentation.



CHAPITRE 1

Généralités

I.1 Introduction

L'imagerie médicale est un domaine clé de la médecine moderne, permettant la visualisation des structures internes du corps humain pour diagnostiquer et suivre diverses pathologies. Parmi ses nombreuses applications, le diagnostic des maladies cardiovasculaires occupe une place centrale en raison de leur prévalence mondiale et de leur impact sur la santé publique. Les maladies cardiovasculaires, qui incluent des affections telles que l'infarctus du myocarde, l'insuffisance cardiaque et les maladies valvulaires, représentent la première cause de mortalité dans le monde, avec environ 31 % des décès annuels, selon l'Organisation mondiale de la santé (OMS). Dans ce contexte, l'échocardiographie, une technique d'imagerie fondée sur les ultrasons, s'est imposée comme un outil essentiel pour le diagnostic non invasif des anomalies cardiaques.

Ce chapitre vise à poser les bases théoriques nécessaires à la compréhension de notre projet. Nous explorerons d'abord les principes fondamentaux de l'imagerie médicale, en mettant l'accent sur l'échocardiographie et son rôle dans le diagnostic des maladies cardiovasculaires. Ensuite, nous aborderons les concepts de base du traitement d'images, une étape cruciale pour l'analyse des images échographiques. Enfin, nous examinerons en détail les maladies cardiovasculaires, leurs facteurs de risque, leurs symptômes, leurs méthodes de diagnostic et les approches thérapeutiques disponibles, tout en soulignant les défis liés à l'analyse manuelle des images échographiques ainsi que le potentiel de l'intelligence artificielle (IA) pour surmonter ces limites.

I.2 Imagerie médicale

I.2.1 Historique de l'imagerie médicale

L'histoire de l'imagerie médicale a débuté avec la découverte des rayons X par Wilhelm Röntgen en 1895, une avancée qui a révolutionné le diagnostic médical en permettant de visualiser les os ainsi que certains organes internes sans intervention chirurgicale. Au fil des décennies, de nouvelles technologies ont vu le jour, telles que la tomodensitométrie (CT scan) dans les années 1970, l'imagerie par résonance magnétique (IRM) dans les années 1980, ou encore l'échographie, introduite dans les années 1950 et rapidement adoptée comme méthode non invasive et sans rayonnement. Aujourd'hui, l'imagerie médicale constitue un pilier du diagnostic moderne, et son intégration avec des technologies telles que l'intelligence artificielle ouvre de nouvelles perspectives pour améliorer la précision et l'efficacité des diagnostics.[1]

I.2.2 Différentes technologies d'imagerie médicale

I.2.2.1 Rayons X

Les rayons X constituent l'une des plus anciennes techniques d'imagerie médicale. Leur principe repose sur l'utilisation de rayonnements électromagnétiques de haute énergie capables de traverser les tissus du corps humain à des degrés variables selon leur densité. Les structures denses, comme les os, absorbent davantage les rayons X et apparaissent en blanc sur les clichés radiographiques, tandis que les tissus plus mous les laissent passer en partie, apparaissant en nuances de gris.

Initialement utilisés pour visualiser le squelette, les rayons X ont vu leur champ d'application s'élargir à d'autres domaines médicaux. En imagerie cardiovasculaire, ils sont notamment employés dans l'angiographie coronarienne, une technique qui consiste à injecter un produit de contraste dans les artères coronaires afin de visualiser leur état. Cette méthode permet de détecter des rétrécissements ou des obstructions, facilitant ainsi le diagnostic des maladies coronariennes [2] (voir la figure I.1).



Figure I.1 : Exemple d'une image de rayons X.

I.2.2.2 Scanner (tomodensitométrie)

La tomodensitométrie, plus couramment appelée scanner, est une technique d'imagerie médicale qui repose sur l'utilisation de rayons X combinée à un système de détection rotatif et à un traitement informatique avancé. Son principe consiste à réaliser une série de clichés à partir de différents angles autour du corps, puis à les reconstituer informatiquement afin d'obtenir des images en coupes transversales très détaillées des structures internes.

En cardiologie, le scanner coronaire est particulièrement utile pour l'évaluation non invasive des artères coronaires. Il permet notamment de détecter la présence de calcifications coronariennes et de repérer d'éventuelles sténoses, c'est-à-dire des rétrécissements du calibre

des artères pouvant entraîner une ischémie myocardique. Grâce à sa haute résolution spatiale, cette technique contribue à un diagnostic rapide et précis des pathologies coronariennes, tout en limitant les risques liés aux procédures invasives [3] (voir la figure I.2)



Figure I.2 : Exemple d'une image de tomodensitométrie.[4]

I.2.2.3 Radiographie

La radiographie est une technique d'imagerie médicale basée sur l'émission de rayons X traversant les tissus du corps. Les structures denses, comme les os ou certaines masses pathologiques, absorbent davantage les rayons et apparaissent plus claires sur le cliché, tandis que les tissus moins denses, comme les poumons, laissent passer les rayons et apparaissent plus sombres. Cette méthode permet ainsi de visualiser rapidement l'état des organes thoraciques.

La radiographie thoracique constitue un examen de première intention couramment utilisé pour détecter des anomalies pulmonaires ou cardiaques. Elle peut révéler, par exemple, une hypertrophie cardiaque (augmentation du volume du cœur) ou une opacité pulmonaire liée à une accumulation de liquide dans les alvéoles, signe possible d'une insuffisance cardiaque. Simple, rapide et peu coûteuse, la radiographie thoracique reste un outil diagnostique essentiel, notamment dans les services d'urgences et de médecine générale [5] (voir la figure I.3)




Figure I.3 : Exemple d'une image de radiographie thoracique [6]

I.2.2.4 Imagerie par résonance magnétique (IRM)

L'imagerie par résonance magnétique (IRM) est une technique d'imagerie avancée reposant sur l'utilisation de champs magnétiques puissants et d'ondes radio. Son principe consiste à aligner les protons des noyaux d'hydrogène présents dans les tissus du corps à l'aide d'un champ magnétique, puis à perturber cet alignement par une impulsion radiofréquence. Lorsque les protons retournent à leur position d'équilibre, ils émettent un signal mesuré et transformé informatiquement en images en haute résolution, particulièrement efficaces pour visualiser les tissus mous.

En cardiologie, l'IRM cardiaque est un outil de référence pour l'évaluation précise de la fonction myocardique, notamment la contractilité, la perfusion et la viabilité du tissu cardiaque. Elle permet également de détecter les cicatrices laissées par un infarctus du myocarde, d'analyser l'étendue des lésions, et de diagnostiquer diverses cardiomyopathies (hypertrophique, dilatée, restrictive, etc.). Grâce à son excellent contraste des tissus et à son caractère non invasif, l'IRM offre une vision complète et fiable du cœur, sans exposition aux rayonnements ionisants [7].

I.2.2.5 Echographie

L'échographie, ou ultrasonographie, repose sur l'émission et la réception d'ondes sonores à haute fréquence (ultrasons) pour visualiser les organes internes. En cardiologie, l'échocardiographie constitue une application spécifique de l'échographie, permettant d'examiner le cœur et ses structures en temps réel. Les ultrasons, émis par une sonde (ou transducteur), sont réfléchis par les tissus cardiaques, puis les échos reçus sont transformés en images à l'aide d'un système informatique.

L'échocardiographie peut être réalisée selon différentes modalités :

- **Échocardiographie transthoracique (ETT)** : Il s'agit de la méthode la plus couramment utilisée. La sonde est placée sur la paroi thoracique du patient afin de visualiser le cœur à travers le thorax.
- **Échocardiographie transœsophagienne (ETO)** : Une sonde est introduite dans l'œsophage, ce qui permet d'obtenir des images plus précises du cœur, notamment des valves, et de détecter d'éventuels caillots dans les oreillettes.
- **Échocardiographie de stress** : Réalisée pendant ou après un effort physique ou une stimulation pharmacologique, cette modalité permet d'évaluer la fonction cardiaque sous contrainte.

L'échocardiographie permet de mesurer des paramètres clés tels que la fraction d'éjection (indiquant la capacité de pompage du cœur), l'épaisseur des parois ventriculaires et le fonctionnement des valves. Elle est particulièrement utile pour diagnostiquer des anomalies telles que l'hypertrophie ventriculaire, les dysfonctionnements valvulaires (comme la sténose aortique ou la régurgitation mitrale) ainsi que certains troubles du rythme cardiaque. En complément, l'échocardiographie Doppler permet d'analyser le flux sanguin à travers le cœur et les vaisseaux, ce qui est essentiel pour détecter des anomalies hémodynamiques telles que les fuites valvulaires ou les shunts intracardiaques.

Cependant, l'analyse des images échographiques présente plusieurs défis majeurs. La qualité des images peut être altérée par divers facteurs, tels que l'obésité du patient, la présence de gaz dans les poumons ou les mouvements respiratoires. Par ailleurs, l'interprétation des images repose fortement sur l'expertise du cardiologue, ce qui peut entraîner des variations inter-observateurs et potentiellement conduire à des erreurs de diagnostic [8] (voir la figure I.4).



Figure I.4 : Exemple d'une image échographique cardiaque montrant les ventricules et les oreillettes [9]

I.2.3 Importance de l'imagerie médicale

L'imagerie médicale occupe une place centrale dans la médecine moderne, en jouant un rôle essentiel dans le diagnostic précoce, la surveillance de l'évolution des maladies et la planification des stratégies thérapeutiques. Grâce à des techniques non invasives et de plus en plus précises, elle permet d'obtenir des informations anatomiques et fonctionnelles indispensables à la prise de décision clinique [10].

Dans le contexte des maladies cardiovasculaires, l'imagerie contribue de manière déterminante à la réduction de la morbi-mortalité. Un diagnostic rapide et fiable peut en effet être vital, notamment lors d'urgences telles que l'infarctus du myocarde ou l'embolie pulmonaire. L'échocardiographie, par exemple, permet de visualiser en temps réel les structures cardiaques et de détecter des signes précoces d'insuffisance cardiaque avant même l'apparition de symptômes cliniques marqués. Cette capacité de détection précoce offre la possibilité d'interventions thérapeutiques ciblées, améliorant ainsi significativement le pronostic du patient.

L'imagerie est également utilisée pour évaluer l'efficacité des traitements, guider des procédures interventionnelles (comme la pose de stents ou la réparation valvulaire), et surveiller l'évolution des pathologies chroniques. Elle constitue ainsi un outil indispensable dans la prise en charge globale du patient.

I.2.4 Potentiel de l'intelligence artificielle en imagerie médicale

L'intelligence artificielle, et plus particulièrement les approches d'apprentissage profond (Deep Learning), révolutionne l'analyse des images médicales. Grâce à leur capacité à traiter de vastes volumes de données et à reconnaître des motifs complexes, les algorithmes d'IA permettent d'automatiser de nombreuses tâches diagnostiques qui étaient jusqu'alors réservées aux experts humains.

En imagerie cardiovasculaire, l'IA est notamment utilisée pour la segmentation automatique des structures cardiaques (ventricules, oreillettes, valves), la détection et classification des anomalies (telles que les cardiomyopathies ou les dysfonctionnements valvulaires), ainsi que pour l'évaluation quantitative de paramètres cliniques (fraction d'éjection, épaisseur pariétale, etc.). Des études récentes ont montré que certaines architectures de réseaux de neurones convolutifs (CNN) peuvent atteindre, voire surpasser, la performance des spécialistes en termes de précision et de reproductibilité.

Dans le cadre de notre projet, nous exploiterons une approche innovante basée sur les réseaux antagonistes génératifs (GANs, Generative Adversarial Networks), qui permettent de générer des images échographiques synthétiques réalistes. Cette génération de données artificielles permet d'enrichir les ensembles de données d'entraînement, en particulier dans les cas où les images médicales annotées sont rares ou difficiles à obtenir. Cette augmentation de données contribue à améliorer la robustesse des modèles de détection et à réduire le risque de surapprentissage (overfitting), ce qui est essentiel pour assurer des performances fiables en pratique clinique [11].

Notre projet constitue une application concrète de l'intelligence artificielle à l'imagerie échocardiographique, visant à optimiser le diagnostic et la prise en charge des maladies cardiovasculaires. Plus précisément, nous utiliserons des réseaux antagonistes génératifs (GANs) pour produire des images échographiques cardiaques synthétiques réalistes. Cette approche permet d'augmenter artificiellement les bases de données d'entraînement, ce qui est particulièrement précieux dans le domaine médical, où l'acquisition d'images annotées de haute qualité est souvent limitée par des contraintes éthiques, techniques ou logistiques.

En compensant le manque de données réelles, cette génération d'images contribue à améliorer la performance des modèles d'analyse automatique, en particulier pour la détection précoce des anomalies cardiaques. En enrichissant la diversité des données d'apprentissage, notre projet participe à renforcer la robustesse et la capacité de généralisation des modèles d'IA, réduisant ainsi le risque de surapprentissage (overfitting) et facilitant leur intégration dans un environnement clinique réel.

I.3 Traitement d'images

I.3.1 Image

Une image est une représentation visuelle d'un objet ou d'une scène, capturée sous forme de lumière réfléchie ou émise. En imagerie médicale, les images sont générées à partir de signaux physiques (rayons X, ultrasons, etc.) et converties en données visuelles interprétables par les professionnels de santé.

I.3.2 Image numérique

Une image numérique est une matrice de pixels, où chaque pixel est associé à une valeur d'intensité. Dans le cas des images échographiques, ces pixels traduisent des niveaux de gris :

les zones plus claires correspondent à des tissus denses (comme les parois cardiaques), tandis que les zones plus sombres représentent des cavités remplies de liquide (comme les ventricules) [12].

I.3.3 Types d'images

I.3.3.1 Image binaire

Une image binaire ne contient que deux valeurs (0 et 1). Elle est souvent utilisée pour la segmentation des structures dans les images médicales, par exemple pour isoler les ventricules dans une image échographique [13].

I.3.3.2 Image en niveaux de gris

Les images échographiques sont généralement en niveaux de gris, où chaque pixel possède une valeur comprise entre 0 (noir) et 255 (blanc). Cela permet de représenter les variations d'intensité des échos ultrasonores [14] (voir la figure I.5).




Figure I.5 : Image échographique en niveaux de gris.

I.3.3.2 Image en couleur (RGB)

Bien que les images échographiques soient principalement en niveaux de gris, l'échocardiographie Doppler utilise des couleurs (généralement le rouge et le bleu) pour représenter la direction et la vitesse du flux sanguin (voir la figure I.6).




Figure I.6 : Exemple d'une image échographique Doppler montrant le flux sanguin à travers la valve mitrale [15]

I.3.3.3 Image indexée

Une image indexée utilise une palette de couleurs associée à des indices numériques pour représenter les valeurs des pixels. Ce type d'image est rarement utilisé en échocardiographie [16] (voir la figure I.7)




Figure I.7 : Image indexée.

I.3.4 Caractéristiques des images

Les images échographiques présentent des caractéristiques spécifiques, telles que le contraste, la texture et le bruit. Le bruit speckle, par exemple, est un artefact typique des images échographiques, causé par l'interférence des ondes ultrasonores. Ce bruit peut compliquer l'analyse des images, mais des techniques de prétraitement, comme le filtrage adaptatif, peuvent être utilisées pour le réduire.

I.3.5 Segmentation des images

La segmentation consiste à diviser une image en régions d'intérêt, comme les ventricules ou les valves dans une image échographique. En cardiologie, la segmentation est essentielle pour mesurer des paramètres tels que le volume ventriculaire ou l'épaisseur des parois. Les

approches basées sur l'apprentissage profond, telles que les réseaux U-Net, sont particulièrement efficaces pour la segmentation des images échographiques [17] (voir la figure I.8).




Figure I.8 : Exemple de segmentation d'une image échocardiographique[18]

I.3.6 Classification des images

La classification consiste à attribuer une étiquette à une image, par exemple pour déterminer si une image échographique montre un cœur normal ou une anomalie (comme une hypertrophie ventriculaire). Les réseaux de neurones convolutifs sont largement utilisés pour cette tâche en raison de leur capacité à extraire des caractéristiques complexes des images [17] (voir la figure I.9).

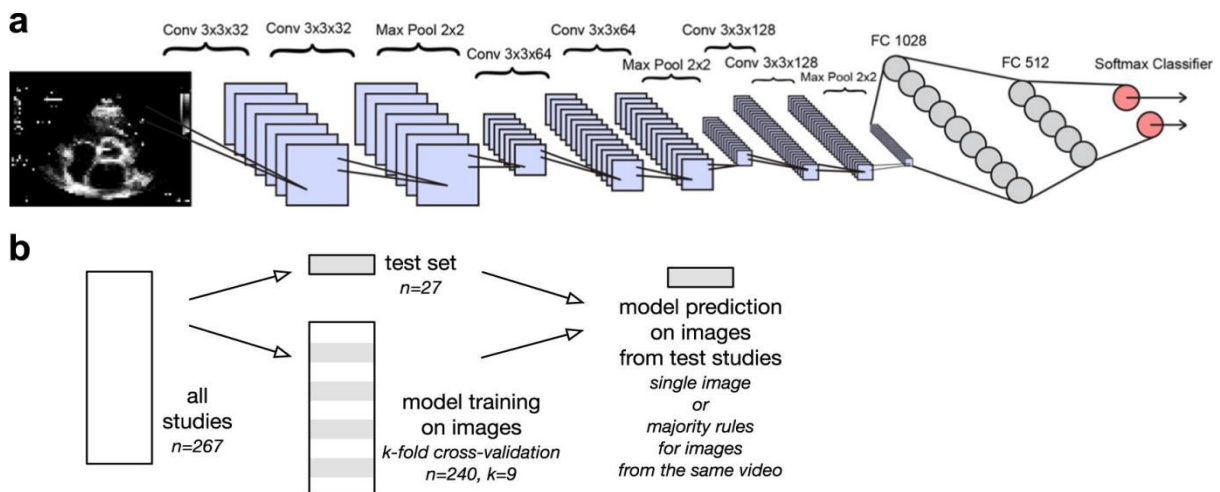


Figure I.9 : Exemple de classification d'images échocardiographiques à l'aide d'un réseau de neurones convolutifs (CNN)[19]

I.4 Maladies cardiovasculaires

I.4.1 Facteurs de risque

Les maladies cardiovasculaires (MCV) regroupent un ensemble de pathologies affectant le cœur et les vaisseaux sanguins. Parmi les plus courantes, on trouve :

- **L'infarctus du myocarde** : une obstruction des artères coronaires entraînant une nécrose du muscle cardiaque.
- **L'insuffisance cardiaque** : une incapacité du cœur à pomper suffisamment de sang pour répondre aux besoins de l'organisme.
- **Les maladies valvulaires** : telles que la sténose aortique ou la régurgitation mitrale, qui perturbent le fonctionnement des valves cardiaques.
- **Les cardiomyopathies** : maladies du muscle cardiaque, comme la cardiomyopathie hypertrophique ou dilatée.

Les facteurs de risque des MCV peuvent être classés en deux catégories :

- **Facteurs modifiables** : hypertension artérielle, tabagisme, diabète, obésité, alimentation riche en graisses saturées, sédentarité et stress chronique.
- **Facteurs non modifiables** : âge (le risque augmente après 50 ans), sexe (les hommes sont plus exposés, bien que le risque augmente chez les femmes après la ménopause), et antécédents familiaux de MCV.[20]

I.4.2 Symptômes

Les symptômes des MCV varient selon la pathologie. Par exemple :

- **L'infarctus du myocarde** : douleur thoracique intense, irradiant vers le bras gauche ou la mâchoire, accompagnée de sueurs, de nausées et d'un essoufflement.
- **L'insuffisance cardiaque** : fatigue, essoufflement (notamment à l'effort ou en position allongée), œdème des membres inférieurs.
- **Les maladies valvulaires** : palpitations, essoufflement et parfois syncopes (notamment en cas de sténose aortique sévère).
- **Les cardiomyopathies** : symptômes variables, allant de l'absence de signes cliniques à des troubles du rythme pouvant entraîner une mort subite.

Certaines MCV, comme l'hypertension artérielle ou les stades précoces de l'insuffisance cardiaque, peuvent être asymptomatiques, ce qui souligne l'importance d'un dépistage régulier, notamment chez les populations à risque.

I.4.3 Diagnostic

Le diagnostic des MCV repose sur une combinaison d'examens cliniques, biologiques et d'imagerie. Parmi les méthodes les plus couramment utilisées :

- **Échocardiographie** : Elle permet de visualiser les structures cardiaques et d'évaluer leur fonctionnement. Par exemple, elle peut détecter une diminution de la fraction d'éjection (signe d'insuffisance cardiaque) ou une sténose mitrale.
- **Électrocardiogramme (ECG)** : Il enregistre l'activité électrique du cœur et peut révéler des anomalies telles que des arythmies ou des signes d'ischémie.
- **Test d'effort** : Il évalue la réponse du cœur à l'exercice physique, souvent utilisé pour diagnostiquer une maladie coronarienne.
- **Marqueurs biologiques** : La troponine, un marqueur de lésion myocardique, est mesurée pour confirmer un infarctus du myocarde [21]

L'échocardiographie est particulièrement précieuse, car elle fournit des informations dynamiques sur le cœur en mouvement. Par exemple, elle permet de mesurer la fraction d'éjection ventriculaire gauche (FEVG), un indicateur essentiel de la fonction cardiaque. Une FEVG inférieure à 40 % est généralement indicative d'une insuffisance cardiaque systolique.

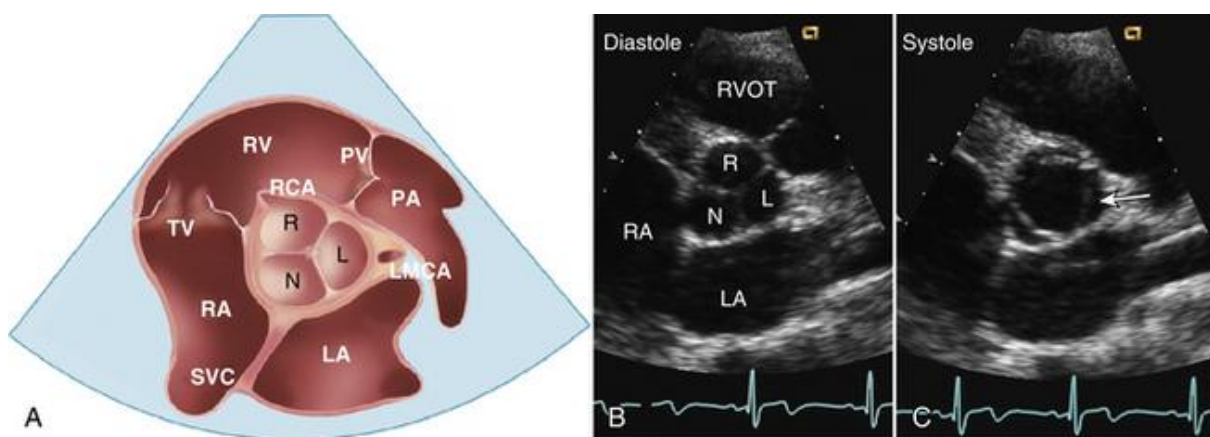


Figure I.10 : Schéma illustrant les principales structures visibles lors d'une échocardiographie transthoracique.

I.4.4 Épidémiologie des maladies cardiovasculaires

Selon l'OMS, les MCV sont responsables d'environ 17,9 millions de décès par an, soit près de 31 % de la mortalité mondiale. Elles touchent particulièrement les pays à revenu faible ou intermédiaire, où l'accès aux soins est limité. Les hommes sont généralement plus affectés que les femmes, bien que le risque augmente chez ces dernières après la ménopause, en raison de la diminution des œstrogènes, qui exercent un effet protecteur sur le système cardiovasculaire. En Algérie, les MCV représentent également un problème majeur de santé publique, avec une prévalence croissante liée à l'augmentation des facteurs de risque tels que l'obésité et le diabète [22].

I.4.5 Traitement des maladies cardiovasculaires

Le traitement des MCV dépend de la pathologie concernée et de sa gravité. Les approches thérapeutiques incluent :

- **Modifications du mode de vie** : adopter une alimentation saine (réduction des graisses saturées, augmentation de la consommation de fruits et légumes), pratiquer une activité physique régulière, arrêter de fumer et apprendre à gérer le stress.
- **Médicaments** :
 - Antihypertenseurs (inhibiteurs de l'enzyme de conversion de l'angiotensine (ECA), bêta-bloquants) pour contrôler la pression artérielle.
 - Statines pour réduire le taux de cholestérol.
 - Anticoagulants (aspirine, warfarine) pour prévenir la formation de caillots.
 - Diurétiques pour réduire l'œdème en cas d'insuffisance cardiaque.
- **Interventions chirurgicales** :
 - Angioplastie avec pose de stent pour traiter les sténoses coronariennes.
 - Remplacement valvulaire (par exemple, valve aortique en cas de sténose sévère).
 - Pontage coronarien dans les cas d'obstructions multiples des artères coronaires.
- **Thérapies avancées** : dans les cas les plus graves, une transplantation cardiaque ou l'implantation d'un dispositif d'assistance ventriculaire peut être envisagée.

La prévention demeure la stratégie la plus efficace pour réduire l'incidence des MCV. Elle repose sur le dépistage régulier des facteurs de risque (hypertension, diabète, hypercholestérolémie) et sur l'éducation des populations quant à l'importance d'un mode de vie sain [23]

I.5 Conclusion

Les maladies cardiovasculaires représentent un défi majeur pour la santé publique, tant à l'échelle mondiale que locale.

L'échocardiographie constitue un outil indispensable pour leur diagnostic précoce, mais l'analyse manuelle des images échographiques reste limitée par des facteurs tels que la variabilité inter-observateurs et la qualité souvent hétérogène des images.

L'intégration de l'intelligence artificielle, notamment à travers des techniques comme les réseaux antagonistes génératifs (GAN), offre des perspectives prometteuses pour surmonter ces obstacles. En générant des images synthétiques et en automatisant la détection ainsi que la segmentation des anomalies cardiaques, l'IA peut contribuer à une prise en charge plus rapide, plus fiable et plus précise des patients atteints de MC



CHAPITRE 2

Apprentissage profond

II.1 Introduction

L'apprentissage profond (Deep Learning) est une branche de l'intelligence artificielle (IA) qui a révolutionné de nombreux domaines, notamment le traitement d'images, la reconnaissance vocale et le diagnostic médical.

Dans le contexte de notre projet, qui vise à détecter les anomalies cardiaques à partir d'images échographiques en utilisant des réseaux antagonistes génératifs (GAN), une compréhension approfondie des concepts de l'apprentissage profond est essentielle.

Ce chapitre explore les fondements de l'intelligence artificielle, de l'apprentissage automatique (machine learning) et du deep learning, en mettant l'accent sur les réseaux de neurones artificiels et les réseaux de neurones convolutifs (CNN), qui constituent la base de nombreuses applications en imagerie médicale.

Nous commencerons par une introduction générale à l'intelligence artificielle, suivie d'une explication détaillée du machine learning et de ses principales approches. Ensuite, nous aborderons les réseaux de neurones artificiels, leur fonctionnement, ainsi que leur évolution vers des architectures plus complexes, telles que les réseaux de neurones profonds.

Enfin, nous nous concentrerons sur les réseaux de neurones convolutifs, en expliquant leur architecture, leur fonctionnement et leur rôle dans le traitement des images échographiques pour la détection et la segmentation des anomalies cardiaques.

II.2 Intelligence artificielle

L'intelligence artificielle (IA) est un domaine de l'informatique qui vise à développer des systèmes capables de simuler des comportements intelligents, similaires à ceux des êtres humains. Selon John McCarthy, l'un des pionniers de l'IA, elle peut être définie comme « la science et l'ingénierie de la création de machines intelligentes »[24].

L'IA englobe plusieurs sous-domaines, notamment :

- **La vision par ordinateur** : permet aux machines de comprendre et d'interpréter des images ou des vidéos, comme dans le cas de l'analyse des images échographiques.
- **Le traitement du langage naturel (NLP)** : permet aux machines de comprendre et de générer du texte ou de la parole.

- **La robotique** : combine l'IA avec des systèmes physiques pour créer des robots autonomes.
- **Les systèmes experts** : programmes qui imitent le raisonnement d'experts humains dans des domaines spécifiques, comme le diagnostic médical.

L'IA peut être classée en trois catégories principales :

- **IA faible (Narrow AI)** : conçue pour effectuer une tâche spécifique, comme la reconnaissance faciale ou la classification d'images. La plupart des applications actuelles de l'IA, y compris notre projet, relèvent de cette catégorie.
- **IA générale (General AI)** : vise à créer des systèmes capables de réaliser n'importe quelle tâche intellectuelle humaine. Ce type d'IA n'existe pas encore.
- **IA forte (Super AI)** : une IA hypothétique qui surpasserait l'intelligence humaine dans tous les domaines. Cela reste un concept théorique [25].

Dans le domaine médical, l'IA a permis des avancées significatives, notamment dans l'analyse des images médicales. Par exemple, des algorithmes d'IA peuvent détecter des tumeurs sur des images IRM, diagnostiquer des maladies pulmonaires à partir de radiographies ou, dans notre cas, identifier des anomalies cardiaques sur des images échographiques [26].

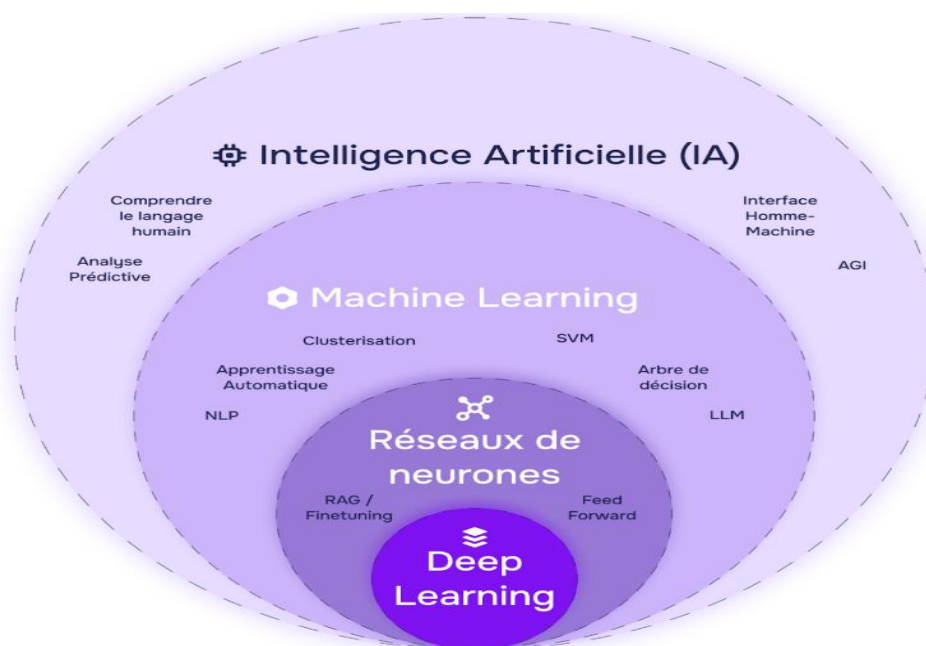


Figure II.1 : Schéma de fonctionnement d'une IA [27].

II.3 Apprentissage automatique

L'apprentissage automatique (Machine Learning, ML) est une sous-branche de l'IA qui se concentre sur le développement d'algorithmes permettant aux machines d'apprendre à partir de données, sans être explicitement programmées. Le ML repose sur l'idée qu'un système peut améliorer ses performances sur une tâche donnée en analysant des données et en ajustant ses paramètres en conséquence [28].

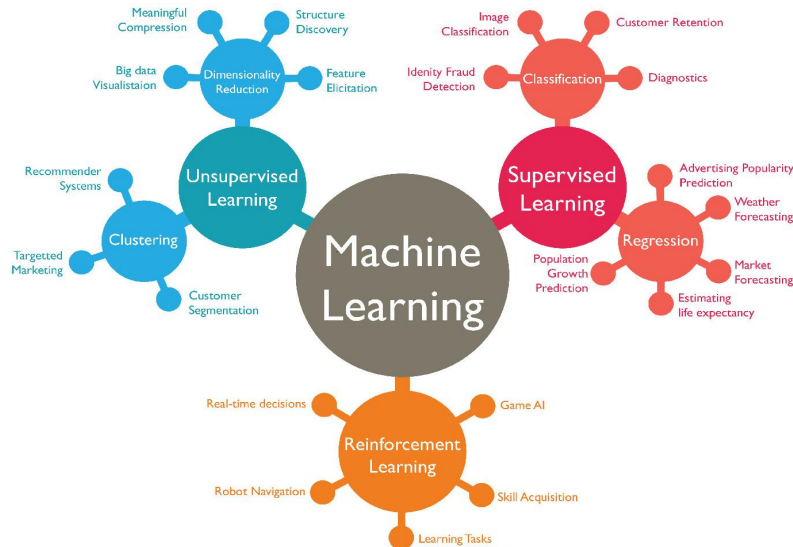


Figure II.2 : Trois catégories du machine learning [29]

Le ML peut être divisé en trois grandes catégories :

II.3.1 Apprentissage supervisé

Dans cette approche, l'algorithme est entraîné sur un ensemble de données étiquetées, c'est-à-dire des données où chaque exemple est associé à une sortie correcte (étiquette)[30]. Par exemple, pour la détection des anomalies cardiaques, un ensemble de données pourrait contenir des images échographiques étiquetées comme « normales » ou « anormales »[31]. Les algorithmes supervisés les plus courants incluent :

- La régression linéaire (pour les tâches de prédiction continue).
- La régression logistique (pour la classification binaire).
- Les machines à vecteurs de support (SVM).
- Les réseaux de neurones artificiels (ANN)[32].

II.3.2 Apprentissage non supervisé

Dans ce type d'apprentissage, l'algorithme travaille avec des données non étiquetées et tente de découvrir des structures ou des motifs cachés[33]. Par exemple, un algorithme non supervisé pourrait regrouper des images échographiques similaires sans connaître leur diagnostic. Les techniques courantes incluent :

- Le clustering (par exemple, l'algorithme K-means).
- L'analyse en composantes principales (PCA) pour la réduction de dimensionnalité.

II.3.3 Apprentissage par renforcement

Dans cette approche, l'algorithme apprend en interagissant avec un environnement et en recevant des récompenses ou des pénalités en fonction de ses actions [34]. Bien que cette méthode soit moins courante en imagerie médicale, elle est utilisée dans des domaines comme la robotique ou les jeux.

II.4 Réseaux de neurones artificiels

Les réseaux de neurones artificiels (Artificial Neural Networks, ANN) sont des modèles inspirés du fonctionnement du cerveau humain. Ils sont composés de nœuds (ou neurones) organisés en couches, qui collaborent pour résoudre des problèmes complexes[35].

II.4.1 Structure d'un réseau de neurones

Un réseau de neurones typique est composé de trois types de couches :

- **Couche d'entrée (Input Layer) :** Reçoit les données brutes, comme les pixels d'une image échographique. Chaque neurone de cette couche correspond à une caractéristique de l'entrée (par exemple, l'intensité d'un pixel).
- **Couches cachées (Hidden Layers) :** Effectuent des transformations sur les données d'entrée à l'aide de calculs mathématiques. Chaque neurone d'une couche cachée est connecté à tous les neurones de la couche précédente via des poids (weights), qui sont ajustés pendant l'entraînement.
- **Couche de sortie (Output Layer) :** Produit le résultat final, comme une classification (« normal » ou « anormal ») ou une prédiction continue (par exemple, la fraction d'éjection)[36].




Figure II.3 : Schéma d'un réseau de neurones artificiel simple[37]

II.4.2 Fonctionnement d'un neurone artificiel

Chaque neurone artificiel effectue les étapes suivantes :

II.4.2.1 Somme pondérée

Dans le cadre du fonctionnement d'un neurone artificiel au sein d'un réseau de neurones, la première étape consiste à calculer une somme pondérée (ou somme linéaire pondérée) des entrées. Cette opération est fondamentale pour déterminer l'activation du neurone et, par extension, la sortie qu'il produira. Elle permet de combiner les informations provenant des entrées en tenant compte de leur importance relative, définie par des poids, et d'ajuster le résultat à l'aide d'un biais.

Formellement, soit un neurone recevant n entrées notées x_1, x_2, \dots, x_n , où chaque entrée x_i est associée à un poids w_i . Les poids w_1, w_2, \dots, w_n , représentent l'importance ou l'influence de chaque entrée sur la sortie du neurone. La somme pondérée, notée z , est calculée selon l'équation suivante :

$$z = \sum_{i=1}^n x_i + b \quad (1)$$

II.4.2.2 Fonction d'activation

La somme pondérée est ensuite passée à travers une fonction d'activation afin d'introduire de la non-linéarité. Les fonctions d'activation courantes incluent[38] :

- **Unité linéaire redressée (ReLU, Rectified Linear Unit) :** Fonction la plus utilisée en raison de sa simplicité de mise en œuvre et de ses bonnes performances. Étant donné un élément x , la fonction est définie comme :

$$ReLU(x) = \max(x, 0) \quad (2)$$

- **Fonction sigmoïde (sigmoid)** : Elle transforme les entrées réelles en sorties comprises entre 0 et 1 :

$$sigmoid(x) = \frac{1}{1+e^{-x}} \quad (3)$$

- **Tangente hyperbolique (tanh)** : Elle produit des sorties dans l'intervalle $]-1,1[$:

$$tanh(x) = \frac{1-e^{-2x}}{1+e^{-2x}} \quad (4)$$

- **Fonction softmax** : La fonction softmax est couramment utilisée pour transformer des scores en probabilités normalisées. Elle est particulièrement adaptée aux tâches de classification. Supposons que l'on dispose d'un vecteur de scores $z = (z_1, z_2, \dots, z_k)$, où chaque z_i représente le score associé à la classe i . La fonction softmax transforme ces scores en probabilités normalisées selon la formule suivante :

$$\hat{y}_i = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (5)$$




Figure II.4 : Courbes des fonctions d'activation Sigmoid, ReLU et Tanh.

II.2.2.3 Entraînement d'un réseau de neurones artificiel

L'entraînement d'un réseau de neurones se déroule en deux phases principales :

- **Propagation avant (Forward Propagation)** : Les données d'entrée traversent les différentes couches du réseau, subissant des transformations à chaque étape, jusqu'à la production d'une sortie. Par exemple, pour une image échographique, le réseau peut prédire si l'image présente une anomalie.
- **Rétropropagation (Backpropagation)** : Si la prédiction est incorrecte, l'erreur est propagée en sens inverse à travers le réseau. Les poids et les biais sont alors ajustés pour minimiser cette erreur à l'aide d'un algorithme d'optimisation, tel que la descente de gradient.

L'erreur entre la sortie prédite par le réseau de neurones et la sortie attendue est mesurée à l'aide d'une fonction de perte (loss function). Cette fonction quantifie l'écart entre les valeurs prédites et les valeurs réelles, et guide la mise à jour des poids du réseau durant la phase de rétropropagation[39]. Deux fonctions de perte couramment utilisées sont :

- **L'erreur quadratique moyenne (Mean Squared Error, MSE)** : Utilisée principalement pour les problèmes de régression, elle mesure la moyenne des carrés des différences entre les valeurs réelles y_i et les valeurs prédites \hat{y}_i . Elle est définie par la formule :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (6)$$

où n est le nombre d'échantillons.

- **L'entropie croisée (Cross-Entropy)** : Fréquemment utilisée pour les tâches de classification, elle mesure la dissimilarité entre la distribution réelle des classes et la distribution prédite. Pour un problème de classification binaire, la fonction est définie par :

$$CrossEntropy = -\frac{1}{n} \sum_{i=1}^n [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (7)$$

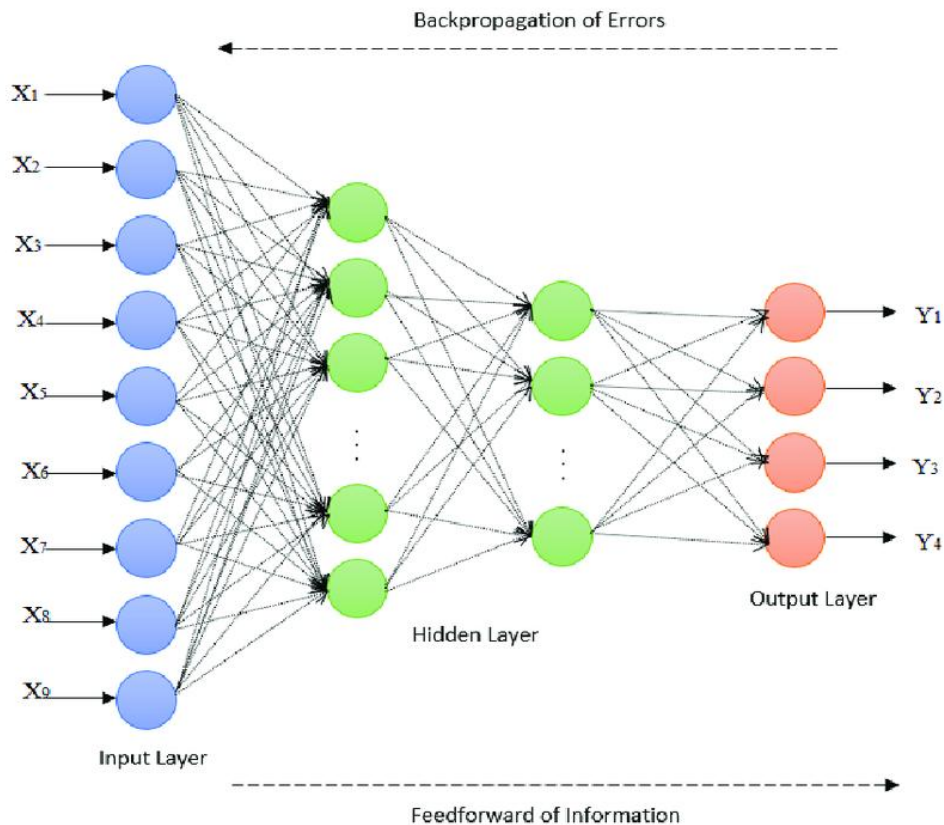


Figure II.5 : Illustration du processus de rétropropagation du gradient [40]

II.5 Apprentissage profond

L'apprentissage profond (Deep Learning) est une extension des réseaux de neurones artificiels, caractérisée par l'utilisation de réseaux comportant de nombreuses couches cachées (d'où le terme « profond »). Ces réseaux profonds sont capables d'extraire des caractéristiques complexes à partir de données brutes, ce qui les rend particulièrement adaptés au traitement des images, des vidéos et des signaux.

II.5.1 Avantages de l'apprentissage profond

- **Extraction automatique des caractéristiques** : Contrairement aux approches traditionnelles de machine learning, où les caractéristiques (features) doivent être extraites manuellement (par exemple, les contours ou les textures dans une image), les réseaux profonds apprennent ces caractéristiques directement à partir des données.
- **Performance élevée** : Les réseaux profonds surpassent souvent les autres méthodes dans des tâches complexes, comme la classification d'images ou la segmentation.

- **Flexibilité** : Ils peuvent être appliqués à une grande variété de données, y compris les images échographiques, les signaux ECG ou les dossiers médicaux [41]

II.5.2 Défis de l'apprentissage profond

- **Besoin de grandes quantités de données** : Les réseaux profonds nécessitent de grands ensembles de données pour un entraînement efficace.
- **Complexité computationnelle** : L'entraînement des réseaux profonds exige des ressources importantes, comme des GPU ou des TPU.
- **Risque de surapprentissage (overfitting)** : Si le modèle est trop complexe, il peut mémoriser les données d'entraînement au lieu de généraliser.

II.6 Réseaux de neurones convolutifs

Les réseaux de neurones convolutifs (Convolutional Neural Networks, CNN) sont une classe particulière de réseaux de neurones profonds, spécifiquement conçus pour le traitement et l'analyse d'images. Grâce à leur architecture unique, qui inclut des couches de convolution capables d'extraire automatiquement des caractéristiques locales (comme les contours, textures, ou formes), les CNN sont particulièrement efficaces pour des tâches telles que la classification d'images, la détection d'objets, et la segmentation d'images [42]

En imagerie médicale, les CNN jouent un rôle essentiel, notamment pour analyser des images échographiques, radiologiques ou IRM. Ils permettent de détecter des anomalies, d'identifier des structures anatomiques, et d'automatiser des processus qui étaient auparavant réalisés manuellement, améliorant ainsi la précision et la rapidité du diagnostic.

II.6.1 Architecture d'un CNN

Les CNNs sont constitués de plusieurs couches successives. Ces couches effectuent différentes opérations sur les données d'entrée afin d'extraire et d'apprendre des caractéristiques spécifiques. Les trois types de couches les plus couramment utilisés sont : la couche de convolution, la couche d'activation (souvent ReLU) et la couche de pooling.

- **Couche de convolution** : Cette couche applique un ensemble de filtres convolutifs (ou noyaux) aux images d'entrée. Chaque filtre est conçu pour détecter une caractéristique particulière, comme des bords, des textures ou des motifs spécifiques. L'opération de convolution produit des cartes de caractéristiques (feature maps) qui mettent en évidence ces éléments détectés.

- **Couche d'activation (ReLU)** : Cette couche introduit de la non-linéarité dans le réseau en transformant les valeurs négatives en zéro et en conservant les valeurs positives. Ce mécanisme favorise un apprentissage plus rapide et plus efficace en empêchant la disparition du gradient lors de la rétropropagation. La fonction ReLU est souvent décrite comme une fonction d'activation, car elle permet de sélectionner ou d'activer uniquement les caractéristiques pertinentes pour la tâche.
- **Couche de pooling** : Cette couche réduit la dimension spatiale des cartes de caractéristiques via un sous-échantillonnage non linéaire, par exemple en prenant la valeur maximale (max pooling) ou la moyenne (average pooling) dans une région donnée. Cela permet de diminuer le nombre de paramètres, de réduire le risque de surapprentissage et d'améliorer l'invariance aux translations dans les images.
- **Couche de normalisation (Batch Normalization)** : Cette couche (souvent appelée Batch Normalization) joue un rôle important dans l'entraînement des CNN. Elle intervient entre les couches convolutives et les fonctions d'activation pour normaliser les activations d'une couche donnée [43]

La couche de normalisation est généralement placée après la couche de convolution et avant la fonction d'activation (ReLU). Elle remplit plusieurs fonctions essentielles au bon apprentissage du réseau :

- ✓ Cette couche calcule la moyenne et l'écart-type des sorties de la couche précédente pour un mini-lot (batch) de données.
 - ✓ Elle ajuste ensuite les activations pour qu'elles aient une moyenne proche de zéro et une variance proche de un.
 - ✓ Après cette normalisation, elle applique une transformation linéaire paramétrée par deux vecteurs appris pendant l'entraînement (gamma et beta) qui permettent au réseau de retrouver la capacité de modélisation si nécessaire.
- **Couche flatten (aplatissement)** : Transforme les cartes de caractéristiques multidimensionnelles (3D) en un vecteur unidimensionnel afin de les connecter aux couches entièrement connectées (dense). C'est une étape clé avant la classification.
 - **Couche dense (Fully Connected)** : Chaque neurone de cette couche est connecté à tous les neurones de la couche précédente. Ces couches réalisent la classification ou la

régression finale en combinant les caractéristiques extraites par les couches précédentes.

- **Couche de sortie (finale) :** C'est la dernière couche du réseau, qui produit la sortie finale.
 - ✓ Pour une tâche de classification binaire, elle utilise souvent une fonction d'activation sigmoïde, fournissant une probabilité entre 0 et 1.
 - ✓ Pour la classification multi-classes, une fonction softmax est utilisée pour générer des probabilités normalisées sur toutes les classes possibles.
 - ✓ Pour les tâches de régression, la couche finale peut être une couche dense sans fonction d'activation, produisant une sortie continue.

Ces opérations sont répétées sur plusieurs couches, parfois des dizaines voire des centaines, permettant au CNN d'apprendre progressivement des caractéristiques de plus en plus complexes et abstraites, depuis des motifs simples (bords, textures) jusqu'à des formes et objets entiers.

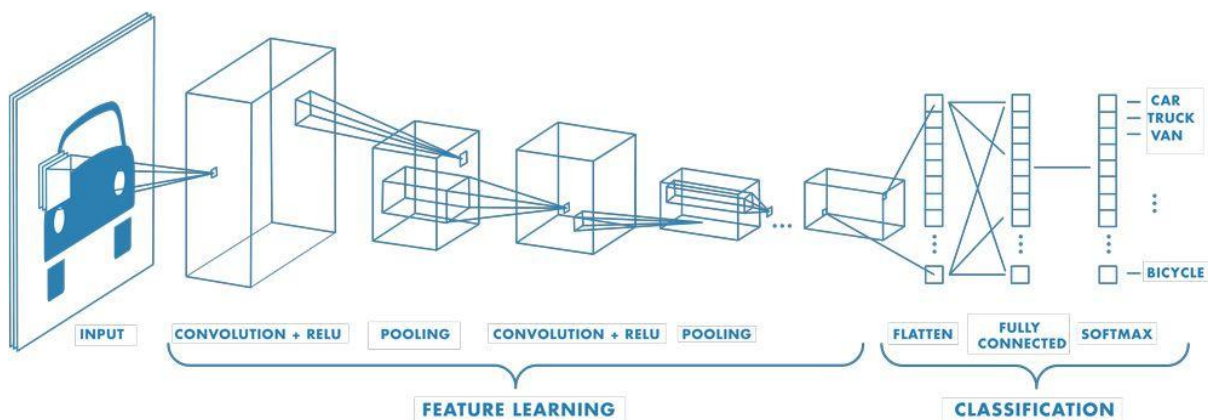


Figure II.6 : Architecture d'un réseau de neurones convolutifs (CNN).

II.6.2 Fonctionnement d'un CNN

Le fonctionnement d'un CNN peut être résumé en plusieurs étapes :

1. **Convolution** : Les filtres appliqués à l'image permettent d'extraire des caractéristiques locales, telles que les contours, les formes ou les textures.
2. **Pooling** : Cette étape réduit la taille des cartes de caractéristiques (feature maps), ce qui diminue la complexité computationnelle et limite le risque de surapprentissage (overfitting).

3. **Activation** : Une fonction d'activation, comme ReLU, introduit de la non-linéarité, permettant au réseau de modéliser des relations complexes dans les données.
4. **Classification** : Les caractéristiques extraites sont ensuite transmises à des couches entièrement connectées (dense) pour produire une prédiction de classe (par exemple : « normal » ou « anormal ») [43]

Dans notre projet, les CNN seront utilisés pour deux tâches principales :

1. **Classification** : Déterminer si une image échographique présente une anomalie cardiaque.
2. **Segmentation** : Identifier et isoler les structures cardiaques, telles que les ventricules et les oreillettes, afin de permettre une analyse plus précise et détaillée.

II.6.3 Applications des CNN en imagerie médicale

Les CNN ont été largement adoptés en imagerie médicale en raison de leur efficacité dans le traitement des images. Voici quelques exemples d'applications :

- **Détection des tumeurs** : Les CNN peuvent identifier des tumeurs sur des images IRM ou des scanners (CT scans) avec une précision élevée.
- **Segmentation des organes** : Des architectures comme U-Net, une variante des CNN, sont utilisées pour segmenter des organes ou des structures anatomiques, comme les ventricules sur une image échographique.
- **Diagnostic des maladies cardiovasculaires** : Les CNN peuvent analyser des images échographiques afin de détecter des anomalies telles que l'hypertrophie ventriculaire ou la dysfonction systolique [43]

Dans le cadre de notre projet, nous utiliserons des CNN à deux niveaux : comme base pour le discriminateur dans notre modèle GAN, et pour la segmentation des structures cardiaques. Les CNN permettent d'extraire des caractéristiques complexes des images échographiques, telles que les contours des ventricules ou les variations d'intensité, essentielles pour la détection des anomalies.

II.6.4 Avantages et limites des CNN

Avantages :

- Capacité à extraire automatiquement des caractéristiques complexes sans intervention humaine.
- Excellentes performances dans les tâches de vision par ordinateur.
- Adaptabilité à différents types d'imagerie médicale (échographies, IRM, scanners, etc.).

Limites :

- Nécessitent de grandes quantités de données étiquetées pour un entraînement efficace.
- Sensibles au bruit présent dans les images, notamment le bruit speckle dans les échographies.
- Entraînement coûteux en ressources computationnelles (nécessitent souvent des GPU ou TPU) [44]

II.7 Conclusion

Ce chapitre a fourni une vue d'ensemble des concepts fondamentaux de l'intelligence artificielle, de l'apprentissage automatique (machine learning) et de l'apprentissage profond, avec un accent particulier sur les réseaux de neurones artificiels et convolutifs. Grâce à leur capacité à extraire automatiquement des caractéristiques complexes, les CNN jouent un rôle central dans notre projet de détection des anomalies cardiaques.

Cependant, leur performance dépend fortement de la disponibilité de données d'entraînement de haute qualité — une contrainte que nous cherchons à contourner à l'aide de réseaux antagonistes génératifs (GAN), capables de produire des images synthétiques. Le chapitre suivant sera consacré à une exploration détaillée des GAN et de leur intégration dans notre projet.

CHAPITRE 3

Réseaux antagonistes génératifs

III.1 Introduction

Les réseaux antagonistes génératifs (Generative Adversarial Networks, GANs) sont une classe de modèles d'apprentissage profond qui ont révolutionné la génération de données synthétiques, notamment dans le domaine de la vision par ordinateur. Introduits par Ian Goodfellow et al. en 2014, les GANs se distinguent par leur capacité à générer des données réalistes comme des images des sons ou des textes en simulant la distribution des données réelles [45]

Dans le contexte de notre projet, qui vise à détecter les anomalies cardiaques à partir d'images échographiques, les GANs jouent un rôle clé en générant des images synthétiques afin d'augmenter les ensembles de données d'entraînement, améliorant ainsi la classification et la segmentation des maladies cardiovasculaires.

Ce chapitre explore les concepts fondamentaux des GANs, leur architecture, leur fonctionnement et leurs applications. Nous nous concentrerons particulièrement sur les réseaux antagonistes génératifs à convolution profonde (Deep Convolutional GANs, DCGANs), une variante des GANs qui utilise des réseaux neuronaux convolutifs (CNN) pour générer des images de haute qualité. Nous expliquerons comment les DCGANs sont adaptés à notre projet pour produire des images échographiques synthétiques réalistes, et nous discuterons des avantages et des défis associés à leur utilisation dans le domaine médical.

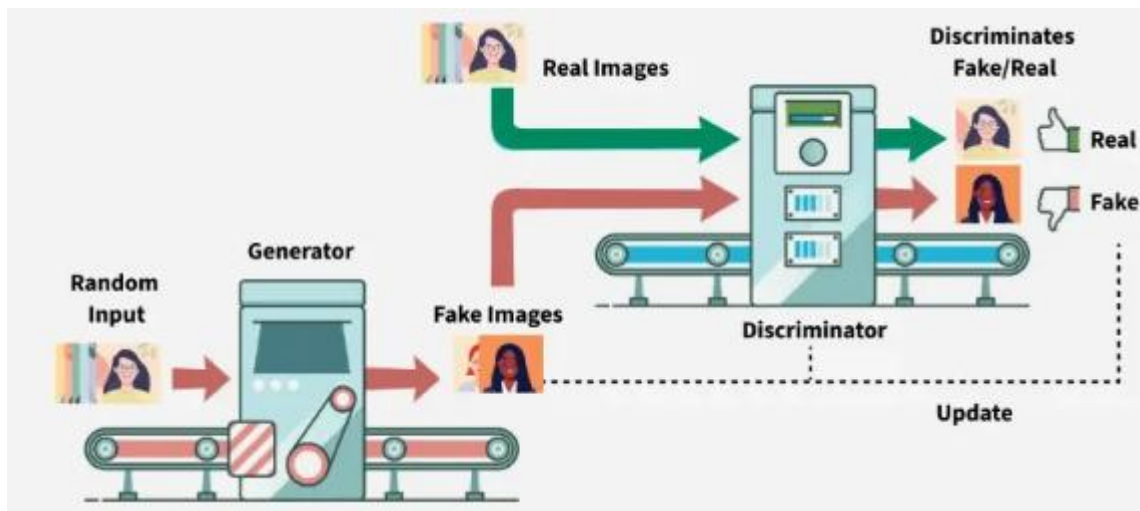


Figure III.1 : Principe des réseaux antagonistes génératifs.

III.2 Réseaux antagonistes génératifs

III.2.1 Principe de base

Les GANs sont composés de deux réseaux de neurones qui s'entraînent simultanément dans un cadre compétitif :

- **Le générateur (Generator)** : Ce réseau prend en entrée un vecteur de bruit aléatoire (souvent tiré d'une distribution uniforme ou normale) et génère des données synthétiques, comme une image. Son objectif est de produire des données qui ressemblent le plus possible aux données réelles.
- **Le discriminateur (Discriminator)** : Ce réseau agit comme un classificateur binaire, prenant en entrée soit une donnée réelle (issue de l'ensemble de données d'entraînement), soit une donnée synthétique générée par le générateur. Son objectif est de distinguer les données réelles des données synthétiques.

Les deux réseaux sont entraînés de manière antagoniste : le générateur s'efforce de « tromper » le discriminateur en produisant des données de plus en plus réalistes, tandis que le discriminateur s'améliore pour mieux différencier les données réelles des données générées. Ce processus peut être vu comme un jeu à somme nulle, où le progrès de l'un des réseaux (générateur ou discriminateur) se fait au détriment de l'autre [45].

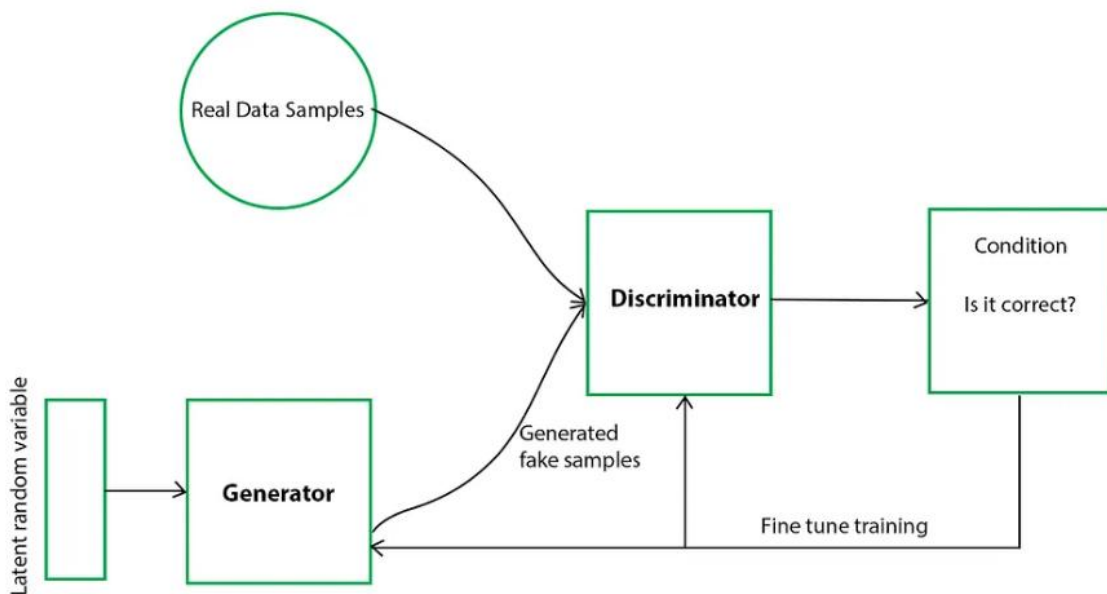


Figure III.2 : Fonctionnement du discriminateur et du générateur [46]

III.2.2 Fonctionnement des GANs

Dans cette approche, l'algorithme est entraîné sur un ensemble de données étiquetées, c'est-à-dire des données où chaque exemple est associé à une sortie correcte (étiquette). Par exemple, pour la détection des anomalies cardiaques, un ensemble de données pourrait contenir des images échographiques étiquetées comme « normales » ou « anormales ». Les algorithmes supervisés les plus courants incluent :

Les GANs peuvent être vus comme un jeu à somme nulle (minimax), dans lequel le discriminateur cherche à minimiser la fonction de perte $V(D,G)$, tandis que le générateur tente, quant à lui, de maximiser cette même fonction, autrement dit, il cherche à augmenter la perte du discriminateur. Ce principe peut être exprimé mathématiquement par la formule suivante :

$$\min_G \max_D V(D, G) = E_{x \rightarrow P_{data}(x)} [\log D(x)] + E_{z \rightarrow P_{data}(z)} [\log (1 - D(G(z)))] \quad (8)$$

où :

- **G** : Générateur
- **D** : Discriminateur
- **P_{data(x)}** : Distribution des données réelles
- **P(z)** : Distribution du bruit d'entrée utilisé par le générateur
- **x** : Échantillon provenant de P_{data(x)}
- **z** : Échantillon tiré de P(z)
- **D(x)** : Sortie du réseau discriminateur pour une donnée réelle
- **G(z)** : Sortie du réseau générateur (image synthétique générée à partir de z)

III.2.3 Processus d'entraînement

III.2.3.1 Modèle du générateur

Le générateur a pour rôle de produire de nouveaux exemples crédibles appartenant au domaine ciblé. Il reçoit en entrée un vecteur aléatoire de taille fixe, à partir duquel il génère un échantillon représentatif de ce domaine. Ce vecteur d'entrée est généralement échantillonné selon une distribution gaussienne et sert de point de départ au processus de génération.

À l'issue de l'entraînement, les différentes positions dans cet espace vectoriel multidimensionnel correspondent à des points du domaine d'étude, offrant ainsi une version compressée de la distribution des données réelles. Cet espace est appelé espace latent, ou encore espace des variables latentes, car il est constitué de variables significatives mais non directement observables.

Une fois le modèle entraîné, il peut être conservé et utilisé pour générer de nouveaux échantillons à la demande [47]

III.2.3.2 Modèle du discriminateur

Le modèle discriminateur est conçu pour distinguer les exemples produits par le générateur en les classant comme réels (issus du domaine d'apprentissage) ou faux (générés artificiellement). Il reçoit en entrée un exemple (qu'il soit réel ou généré) et prédit une étiquette binaire indiquant la nature de cet exemple : réel ou synthétique. Les exemples réels proviennent directement du jeu de données d'apprentissage, tandis que les exemples synthétiques sont créés par le générateur.

Le discriminateur fonctionne donc comme un modèle de classification binaire classique. Une fois l'apprentissage terminé, il n'est généralement plus utilisé directement, car l'objectif principal devient l'amélioration continue du générateur. La figure III.3 illustre le processus d'entraînement du générateur et du discriminateur [47]

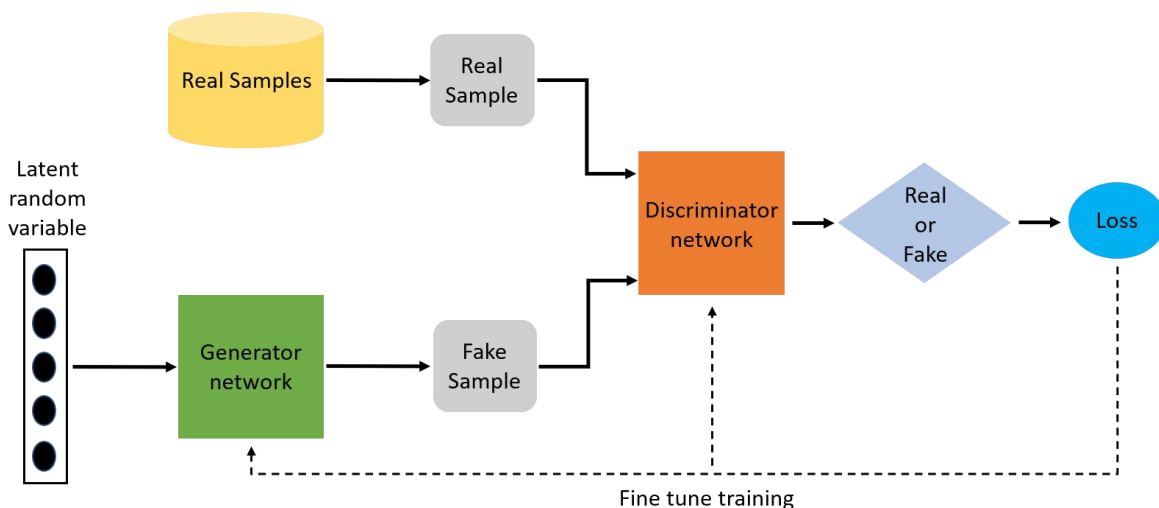


Figure III.3 : Processus d'entraînement du générateur et du discriminateur.

III.2.4 Applications des GANs

Les GANs présentent de nombreuses applications, notamment :

- **Génération d'images** : Création d'images réalistes, comme des visages humains ou des paysages.
- **Augmentation de données** : Génération de données synthétiques pour enrichir les ensembles de données, particulièrement utile dans des domaines comme la médecine, où les données annotées sont rares.
- **Restauration d'images** : Amélioration de la qualité des images dégradées, par exemple la réduction du bruit dans les images échographiques.
- **Synthèse de données médicales** : Génération d'images médicales synthétiques (IRM, échographies, etc.) pour l'entraînement de modèles d'intelligence artificielle [48]

Dans notre projet, les GANs sont utilisés pour générer des images échographiques synthétiques, ce qui permet d'enrichir notre ensemble de données et d'améliorer la robustesse de notre modèle de détection des anomalies cardiaques.

II.3 Réseaux antagonistes génératifs à convolution profonde (DCGANs)

II.3.1 Introduction aux DCGANs

Les DCGANs (Deep Convolutional GANs) sont une extension des GANs qui intègrent des réseaux neuronaux convolutifs (CNN) dans l'architecture du générateur et du discriminateur. Introduits par Radford et al. en 2015, les DCGANs ont été conçus pour améliorer la qualité des images générées et la stabilité de l'entraînement des GANs, en tirant parti des capacités des CNN à extraire des caractéristiques spatiales des images [49]

II.3.2 Architecture des DCGANs

L'architecture des DCGANs se distingue par plusieurs caractéristiques :

II.3.2.1 Générateur

- Le générateur prend un vecteur de bruit aléatoire z (par exemple, un vecteur de 100 dimensions tiré d'une distribution normale) comme entrée.
- Ce vecteur est transformé en une image à l'aide de couches de convolution transposée (ou déconvolution), qui augmentent progressivement la résolution spatiale.

- Les couches de convolution transposée sont suivies de couches de normalisation par lot (Batch Normalization) pour stabiliser l'entraînement, et de fonctions d'activation comme ReLU pour introduire de la non-linéarité.
- La dernière couche utilise une fonction d'activation *Tanh* pour produire une image avec des valeurs de pixels normalisées entre -1 et 1 [50]

II.3.2.2 Discriminateur

- Le discriminateur est un CNN classique qui prend une image (réelle ou synthétique) comme entrée.
- Il utilise des couches de convolution pour extraire des caractéristiques spatiales, suivies de couches de normalisation par lot (Batch Normalization) et de fonctions d'activation comme LeakyReLU.
- La dernière couche est une couche entièrement connectée avec une activation sigmoïde (Sigmoid), qui produit une probabilité (entre 0 et 1) indiquant si l'image est réelle ou synthétique [50]

La figure III.4 présente l'architecture d'un DCGAN, composée d'un générateur (qui transforme un vecteur de bruit en image à l'aide de couches de convolution transposée) et d'un discriminateur (qui analyse les images à l'aide de couches de convolution). Les dimensions des tenseurs sont indiquées à chaque étape.




Figure III.4 : Composition des couches d'un DCGAN.

III.3.3 Avantages des DCGANs

Les DCGANs offrent plusieurs avantages par rapport aux GANs classiques :

- **Qualité des images générées** : Grâce à l'utilisation des CNNs, les DCGANs produisent des images plus nettes et plus réalistes, ce qui est crucial pour des applications médicales comme la génération d'images échographiques.
- **Stabilité de l'entraînement** : Des techniques telles que la Batch Normalization et l'utilisation de LeakyReLU dans le discriminateur réduisent les problèmes d'instabilité fréquemment rencontrés dans les GANs, tels que le mode collapse (lorsque le générateur produit des images quasi identiques).
- **Capacité à capturer des caractéristiques spatiales** : Les couches de convolution permettent de modéliser les relations spatiales présentes dans les images, comme les contours des ventricules ou les variations d'intensité dans une image échographique.

La figure III.5 montre des images échographiques réelles et synthétiques générées par un DCGAN. La première colonne présente les images échographiques réelles (une coupe transversale du cœur) et la deuxième colonne, les images synthétiques générées par un DCGAN, mettant en évidence les similitudes visuelles [51]




Figure III.5 : Exemple d'images échographiques réelles et synthétiques générées par un DCGAN

III.3.4 Défis des DCGANs

Malgré leurs avantages, les DCGANs présentent certains défis :

- **Difficulté d'entraînement** : L'entraînement des GANs, y compris des DCGANs, reste complexe en raison de la nature compétitive des deux réseaux. Un déséquilibre entre le générateur et le discriminateur peut entraîner une convergence lente, voire un échec de l'apprentissage.
- **Évaluation de la qualité** : Il est difficile de quantifier la qualité des images générées, notamment dans un contexte médical, où le réalisme des images est essentiel pour leur utilité clinique.
- **Ressources computationnelles** : Les DCGANs nécessitent d'importantes ressources matérielles (notamment des GPU) pour un entraînement efficace, en particulier lorsqu'ils sont appliqués à des images de haute résolution.

III.3.5 Application des DCGANs dans notre projet

Dans notre projet, nous utilisons les DCGANs pour générer des images échographiques synthétiques de haute qualité. Ces images synthétiques sont ensuite utilisées pour :

- **Augmenter les données d'entraînement** : les ensembles de données médicales, comme les images échographiques annotées, sont souvent limités en taille. Les DCGANs permettent de générer des images supplémentaires, ce qui améliore la robustesse de notre modèle de détection.
- **Améliorer la segmentation** : les images synthétiques aident à entraîner un modèle de segmentation (par exemple, un réseau U-Net) pour identifier les structures cardiaques, telles que les ventricules et les oreillettes.
- **Améliorer la classification** : en enrichissant l'ensemble de données, les images synthétiques permettent à notre modèle de classification de mieux distinguer les images normales des images présentant des anomalies, telles qu'une hypertrophie ventriculaire ou une dysfonction systolique.

Pour adapter les DCGANs aux images échographiques, nous avons ajusté l'architecture du générateur et du discriminateur pour prendre en compte les caractéristiques spécifiques de ces images, telles que leur nature en niveaux de gris et la présence de bruit speckle. Par exemple,

nous avons utilisé des filtres de convolution adaptés pour capturer les variations d'intensité typiques des images échographiques.

III.4 État de l'art de l'utilisation des GAN pour le traitement des images médicales

Les GANs ont émergé comme une technologie prometteuse en imagerie médicale, notamment pour la synthèse d'images, l'augmentation de données, la traduction entre modalités et la segmentation. Les recherches récentes mettent en évidence leur efficacité dans plusieurs domaines spécifiques, y compris l'imagerie cardiaque, où ils sont utilisés pour améliorer la détection et la classification des anomalies cardiaques.

Nous présentons ci-dessous quelques travaux illustrant les applications des GANs en imagerie médicale, et mettant en valeur la richesse, la diversité et la puissance de ces réseaux.

III.4.1 Génération multi-modale et évaluation comparative des GANs

Skandarani et al. (2023) [52] ont proposé une architecture hybride combinant un Variational Autoencoder (VAE) et un GAN pour générer des images d'IRM cardiaques réalistes et annotées. Le VAE apprend un espace latent permettant de capturer la variabilité anatomique des structures cardiaques, tandis que le générateur du GAN intègre des modules de normalisation Spatially-Adaptive (DE) Normalization (SPADE) afin de conditionner la génération d'images sur des cartes anatomiques. Cette combinaison garantit que les images synthétiques produites respectent fidèlement la structure anatomique cible.

III.4.2 Synthèse d'images IRM pour anonymisation et augmentation de données

Shin et al. (2018) [53] ont proposé une méthode de génération d'IRM cérébrales synthétiques à l'aide de GANs, visant à garantir la sécurité des données et à enrichir les ensembles d'apprentissage. Cette approche a renforcé la robustesse des modèles de classification, une stratégie applicable aux examens échographiques cardiaques soumis aux mêmes contraintes éthiques et légales.

III.4.3 Amélioration de la classification de lésions hépatiques par augmentation avec GAN

Frid-Adar et al. (2018) [54] ont démontré que la génération d'images de lésions hépatiques via GANs améliorerait la précision d'un CNN chargé de les classer. L'optimisation des performances grâce à l'augmentation des données synthétiques justifie l'utilisation de techniques similaires pour l'échographie, notamment dans la classification des cardiopathies.

III.4.4 Traduction d'images IRM cardiaques non appariées

Chartsias et al. (2017) [55] ont utilisé CycleGAN pour traduire des images IRM cardiaques entre différentes séquences (T1 et T2) sans correspondance directe. Cette méthode a facilité un traitement multimodal plus simple, avantageux pour élaborer des vues échographiques alternatives et augmenter la quantité d'informations disponibles lors de l'entraînement.

III.4.5 Amélioration de la généralisation en segmentation CT avec CycleGAN

Sandfort et al. (2019) [56] ont évalué l'utilisation de CycleGAN pour l'augmentation des données en segmentation CT. Leur étude a montré que l'utilisation de CycleGAN pour augmenter les données de tomodensitométrie a permis une généralisation accrue des modèles de segmentation sur des cas cliniques réels. Dans les systèmes de détection automatique d'anomalies cardiaques, où la variabilité entre les patients et les machines est très élevée, cette amélioration de la robustesse est d'une importance capitale.

III.4.6 Génération d'images échographiques pour classification cardiaque

Han et al. (2022) [57] ont utilisé des GANs pour générer des images échographiques cardiaques, permettant d'obtenir des images de patients atteints de maladies cardiovasculaires. L'ajout de ces images synthétiques a amélioré la performance des modèles de classification, en particulier dans les cas rares ou non représentés dans les bases réelles. L'utilisation de GANs pourrait améliorer la détection et la segmentation des anomalies cardiaques à partir d'images échographiques, directement liée à notre problématique.

III.4.7 Résumé des travaux

Le tableau ci-dessous présente un résumé des résultats obtenus dans les travaux mentionnés.

Travail	Méthode / Architecture	Résultats clés
Skandarani et al. (2020)	VAE + SPADE GAN (StyleGAN et SPADE) pour générer des IRM synthétiques et U-Net pour segmentation	<ul style="list-style-type: none"> • StyleGAN / SPADE obtiennent des scores FID bas et Dice jusqu'à 87 % sur ACDC • Dice score amélioré jusqu'à +12 % • Segmentation compétitive avec généralisation accrue.
Shin et al. (2018)	GANs utilisés pour générer des IRM synthétiques, renforçant la robustesse de la classification.	<ul style="list-style-type: none"> • Robustesse accrue du classifieur (application transférable à l'échographie cardiaque)
Frid-Adar et al. (2018)	GAN pour augmenter les données, entraînement d'un CNN	<ul style="list-style-type: none"> • Amélioration significative de la précision
Chartsias et al. (2017)	CycleGAN non supervisé	<ul style="list-style-type: none"> • Génération multimodale facilitée • Amélioration du traitement sans appariement

III.5 Conclusion

Ce chapitre a présenté les GANs et leur variante, les DCGANs, en expliquant leur architecture, leur fonctionnement et leurs applications.

Les GANs, grâce à leur capacité à générer des données synthétiques réalistes, offrent une solution prometteuse pour surmonter les limitations des ensembles de données médicales, comme dans notre projet de détection des anomalies cardiaques. Les DCGANs, en particulier, se sont révélés efficaces pour produire des images échographiques synthétiques de haute qualité, qui sont ensuite utilisées pour améliorer la classification et la segmentation des maladies cardiovasculaires. Cependant, leur entraînement reste un défi en raison de leur complexité et des ressources computationnelles requises.

Le prochain chapitre détaillera l'implémentation pratique de notre modèle GAN, ainsi que les résultats obtenus dans ce cadre.



CHAPITRE 4

Implémentation et résultats

IV.1 Introduction

Dans ce chapitre, nous présentons l'implémentation pratique de notre projet, qui vise à détecter les anomalies cardiaques à partir d'images échographiques en utilisant des réseaux antagonistes génératifs (GAN), plus précisément les Deep Convolutional GANs (DCGANs).

L'objectif principal est de générer des images échographiques synthétiques afin d'augmenter les données d'entraînement, puis d'utiliser ces images pour améliorer la classification des pathologies cardiaques ainsi que la segmentation des structures du cœur, telles que les ventricules et les oreillettes.

Nous détaillerons d'abord l'environnement de travail utilisé pour le développement du modèle, y compris les outils logiciels et matériels. Ensuite, nous décrirons les étapes de l'implémentation, depuis la préparation des données jusqu'à la construction et à l'entraînement du modèle DCGAN, ainsi que les modèles de classification et de segmentation.

Enfin, nous analyserons les résultats obtenus, en discutant de la qualité des images générées, des performances de détection et de segmentation, ainsi que des limites de notre approche.

IV.2 Environnement de travail

Pour développer et entraîner notre modèle, nous avons utilisé les outils et ressources suivants :

IV.2.1 Plateforme de calcul

Nous avons utilisé Visual Studio Code (VSCode) comme environnement de développement principal pour coder et gérer notre projet.

Pour accélérer l'entraînement des réseaux de neurones profonds, nous avons exploité une machine locale équipée d'une unité de traitement graphique (GPU) NVIDIA RTX 3060, ce qui permet de gérer efficacement les calculs intensifs nécessaires à l'entraînement des modèles.

IV.2.2 Langage de programmation

Nous avons utilisé le langage de programmation Python 3.11.1, qui est largement utilisé pour les projets d'apprentissage profond en raison de sa simplicité et de la richesse de ses bibliothèques.

IV.2.3 Configuration matérielle locale

En complément de Google Colab, certaines expérimentations ont été réalisées sur une machine locale équipée d'un processeur Intel Core i9-13900K (13e génération), de 32 Go de RAM et d'une carte graphique NVIDIA RTX 3060.

IV.2.4 Bibliothèques principales

IV.2.4.1 TensorFlow 2.19 et Keras

Des bibliothèques essentielles pour la construction, l'entraînement et l'évaluation des modèles DCGAN, de classification et de segmentation.

IV.2.4.2 OpenCV

Une bibliothèque dédiée au prétraitement des images échographiques (redimensionnement, normalisation, etc.).

IV.2.4.3 NumPy et Pandas

Des outils fondamentaux pour la manipulation et l'analyse des données.

IV.2.4.4 Matplotlib et Seaborn

Des bibliothèques utilisées pour la visualisation des résultats, notamment les courbes de perte et les images générées.

IV.3 Datasets utilisés

IV.3.1 Dataset EchoNet-Dynamic

Dans le cadre de notre projet, qui vise à détecter les anomalies cardiaques à partir d'images échographiques, nous avons utilisé la base de données publique EchoNet-Dynamic. Ce dataset est spécifiquement conçu pour l'analyse des images échocardiographiques et constitue une ressource précieuse pour le développement et l'évaluation de modèles d'intelligence artificielle dans le domaine de la cardiologie, notamment pour la détection des pathologies cardiovasculaires et la segmentation des structures cardiaques.

La base de données EchoNet-Dynamic contient 10030 vidéos échographiques annotées de patients, accompagnées de mesures cliniques telles que la fraction d'éjection ventriculaire gauche (FEVG). Pour notre projet, nous avons extrait des images fixes (frames) à partir de ces

vidéos, ce qui a donné un total de 50000 images échographiques, réparties en 70 % pour l'entraînement, 15 % pour la validation et 15 % pour le test.

Ce dataset a été introduit par Ouyang et al. en 2020, dans le cadre d'une étude publiée dans Nature Medicine. Il a été constitué à partir des archives du Stanford University Medical Center et contient des données échographiques provenant de patients ayant subi des examens entre 2012 et 2018.

L'objectif principal de ce jeu de données est de fournir un ensemble standardisé destiné à l'entraînement et à l'évaluation des algorithmes d'apprentissage profond appliqués à l'analyse automatisée des échocardiogrammes, notamment pour la mesure de la fraction d'éjection ventriculaire gauche (FEVG) et la détection des anomalies cardiaques. La figure VI.1 présente quelques exemples du dataset.




Figure IV.1 : Exemple d'images du dataset EchoNet-Dynamic.

IV.3.1.1 Structure du dataset

A) Nombre d'échantillons

EchoNet-Dynamic contient 10030 vidéos échocardiographiques, chacune correspondant à un patient distinct, ce qui garantit une diversité clinique représentative. Chaque vidéo illustre un cycle cardiaque complet (systole et diastole) et est enregistrée selon la vue apicale à quatre chambres (A4C), une vue standard pour l'évaluation des structures cardiaques.

B) Résolution et format

Les vidéos présentent une résolution spatiale moyenne de 112×112 pixels, bien que cette résolution puisse légèrement varier d'un patient à l'autre, en raison des différences entre les équipements d'imagerie. Chaque vidéo est composée de 30 à 60 images fixes (frames) par cycle cardiaque, enregistrées à une fréquence de 30 à 60 images par seconde.

C) Annotations

Le dataset fournit des annotations détaillées pour chaque vidéo, incluant :

- **Fraction d'éjection ventriculaire gauche (FEVG) :** mesurée cliniquement par des cardiologues et fournie sous forme d'une valeur numérique (en pourcentage) pour chaque patient. La FEVG est un indicateur clé de la fonction systolique du cœur, une valeur inférieure à 50 % étant généralement indicative d'une anomalie.
- **Masques de segmentation :** pour un sous-ensemble de vidéos, des masques binaires sont fournis, identifiant le ventricule gauche à la fin de la diastole et de la systole. Ces masques ont été générés semi-automatiquement à l'aide d'algorithmes de suivi des contours, puis vérifiés par des experts.
- **Métadonnées cliniques :** des informations supplémentaires telles que l'âge, le sexe et le diagnostic clinique (par exemple, insuffisance cardiaque, cardiomyopathie) sont disponibles pour certains patients.

IV.3.1.2 Caractéristiques des données

A) Variabilité

Le dataset présente une grande variabilité en termes de conditions cliniques, couvrant un spectre de cas allant des cœurs normaux ($FEVG \geq 50\%$) aux cœurs présentant des anomalies sévères ($FEVG < 40\%$). Les patients incluent des hommes et des femmes de différents groupes d'âge, avec des diagnostics variés tels que l'insuffisance cardiaque, l'hypertrophie ventriculaire ou les maladies valvulaires.

B) Défis

Les images échographiques du dataset EchoNet-Dynamic présentent plusieurs défis typiques :

- **Bruit speckle** : un artefact inhérent aux images échographiques, pouvant compliquer la segmentation et la classification.
- **Variabilité inter-patient** : différences dans l'anatomie cardiaque, la qualité des images (en fonction de l'équipement et de l'opérateur) et les conditions d'acquisition (par exemple, interférences dues à la respiration).
- **Qualité variable** : certaines vidéos souffrent d'une faible résolution ou d'un contraste limité, rendant la détection des structures plus difficile.

IV.3.2 Heart Disease Dataset

Le jeu de données Heart Disease Dataset, disponible sur la plateforme Kaggle (<https://www.kaggle.com/datasets/johnsmith88/heart-disease-dataset>) [57], est largement utilisé dans les recherches en apprentissage automatique appliquées au domaine médical. Il a pour objectif principal de prédire la présence ou l'absence d'une maladie cardiaque chez un patient à partir de diverses caractéristiques cliniques et biologiques. La figure VI.2 présente quelques exemples de ce dataset.

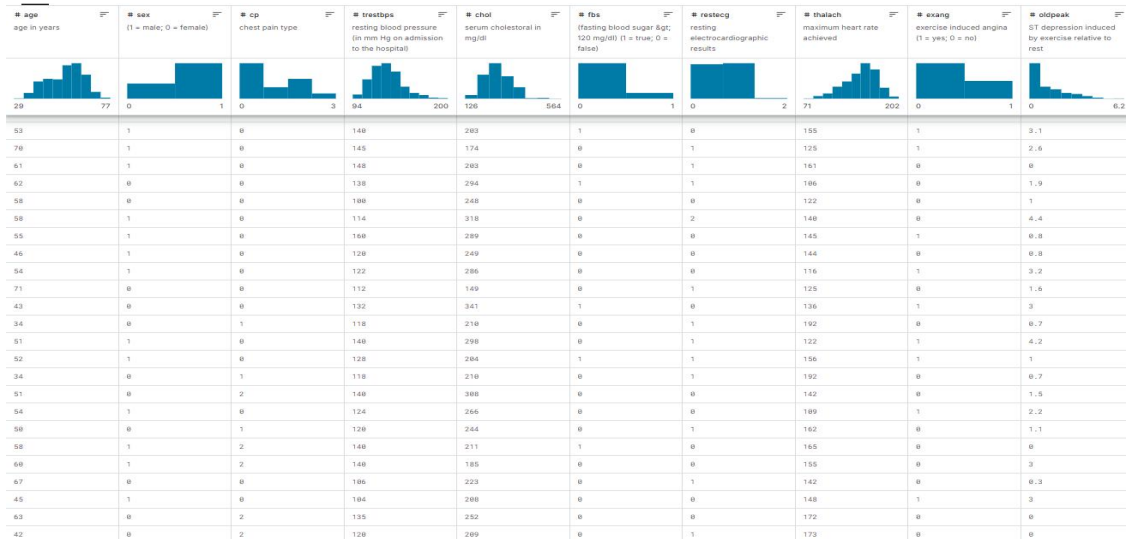


Figure IV.2: Exemples du dataset Heart Disease Dataset.

IV.3.2.1 Objectif

Ce dataset vise à modéliser un problème de classification binaire, où la variable cible (target) indique si un patient est atteint d'une maladie cardiaque (1) ou non (0).

IV.3.2.2 Caractéristiques générales

- **Nombre d'observations** : 303 patients.
- **Nombre de variables** : 14 attributs cliniques et biologiques.

IV.3.2.3 Description des variables

Le tableau ci-dessous présente les différentes variables utilisées dans notre étude, issues de ce dataset pour la détection des maladies cardiaques. Chaque variable est accompagnée de sa description, précisant sa signification, ainsi que de son type (numérique, binaire ou catégoriel), ce qui permettra de mieux comprendre leur traitement ultérieur dans les analyses statistiques et les modèles de prédiction.

Variable	Description	Type
age	Âge du patient en années	Numérique
sex	Sexe (1 = Homme, 0 = Femme)	Binaire
cp	Type de douleur thoracique (valeurs de 0 à 3)	Catégorielle
trestbps	Tension artérielle au repos (en mm Hg)	Numérique
chol	Taux de cholestérol sérique (en mg/dl)	Numérique
fbs	Glycémie à jeun > 120 mg/dl (1 = oui, 0 = non)	Binaire
restecg	Résultats de l'électrocardiogramme au repos (0, 1 ou 2)	Catégorielle
thalach	Fréquence cardiaque maximale atteinte	Numérique
exang	Angine induite par l'effort (1 = oui, 0 = non)	Binaire
oldpeak	Dépression du segment ST par rapport au repos	Numérique
slope	Pente du segment ST pendant l'effort (0 à 2)	Catégorielle
ca	Nombre de vaisseaux principaux colorés par fluoroscopie (0 à 3)	Numérique/Catégorielle
thal	Résultats du test Thallium (0 = normal, 1 = fixation fixe, 2 = anomalie réversible)	Catégorielle
target	Présence d'une maladie cardiaque (1 = oui, 0 = non)	Binaire (variable cible)

Table IV.1 : Description des variables du dataset.

IV.3.2.4 Qualité des données

Ce jeu de données ne contient aucune valeur manquante, ce qui facilite son utilisation dans les modèles d'apprentissage automatique sans nécessiter de prétraitement complexe. De plus, il offre un bon équilibre entre variables numériques et catégorielles, rendant possible l'application de nombreuses techniques de modélisation.

IV.4 Préparation des données pour notre projet

Pour utiliser EchoNet-Dynamic dans notre projet, nous avons réalisé les étapes suivantes :

- **Extraction des images 2D** : À partir des 10030 vidéos, nous avons extrait des images fixes (frames) correspondant au pic de la diastole (fin de la diastole, lorsque le ventricule gauche est le plus dilaté). Cela a permis d'obtenir un total de 50000 images échographiques 2D, en sélectionnant une image représentative par vidéo dans les cas où les masques de segmentation n'étaient pas disponibles.
- **Redimensionnement** : Les images ont été redimensionnées à une résolution de 128×128 pixels afin de standardiser les entrées du modèle DCGAN et de réduire la complexité computationnelle tout en préservant les détails anatomiques.
- **Normalisation** : Les intensités des pixels, initialement en niveaux de gris (valeurs comprises entre 0 et 255), ont été normalisées dans l'intervalle $[-1, 1]$ pour correspondre à la sortie de la fonction Tanh utilisée dans le générateur du DCGAN.
- **Étiquetage pour la classification** : En nous basant sur les valeurs de FEVG fournies, les images ont été étiquetées en deux catégories : « normales » ($\text{FEVG} \geq 50\%$) et « anormales » ($\text{FEVG} < 50\%$). Environ 60 % des images ont été classées comme normales, et 40 % comme anormales.
- **Données de segmentation** : Pour les vidéos accompagnées de masques de segmentation (environ 7464 cas), nous avons utilisé les masques fournis pour entraîner notre modèle de segmentation (U-Net), en les redimensionnant également à 128×128 pixels.
- **Division des données** : L'ensemble des données a été divisé en trois sous-ensembles :
 - **Entraînement** : 70 % (35000 images).
 - **Validation** : 15 % (7500 images).
 - **Test** : 15 % (7500 images).

EchoNet-Dynamic a été utilisée comme principale source de données pour notre projet. Les images extraites ont servi à :

- **Entraînement du modèle DCGAN** : Les images réelles ont été utilisées pour entraîner le DCGAN à générer des images échographiques synthétiques, augmentant ainsi la quantité de données disponibles.
- **Classification des anomalies** : Les étiquettes basées sur la FEVG ont permis d'entraîner un modèle de classification capable de distinguer les cœurs normaux des cœurs anormaux.
- **Segmentation des structures cardiaques** : Les masques de segmentation fournis ont été utilisés pour entraîner un modèle U-Net visant à segmenter le ventricule gauche, une étape essentielle pour mesurer des paramètres cliniques tels que le volume ventriculaire.

Le choix de la base de données est crucial pour la réussite d'un projet d'analyse médicale. En effet, La base de données EchoNet-Dynamic constitue une ressource exceptionnelle pour l'analyse des images échocardiographiques, offrant un ensemble riche et varié de vidéos annotées. Sa grande taille, la précision de ses annotations (valeurs de FEVG et masques de segmentation), ainsi que sa diversité clinique en font un choix idéal pour notre projet. Les défis associés, tels que le bruit speckle et la variabilité inter-patient, ont été pris en compte lors de la préparation des données. Ils ont également permis d'évaluer la robustesse de notre approche basée sur les DCGANs, appliquée à la génération d'images synthétiques, à la classification des anomalies et à la segmentation des structures cardiaques.

IV.5 Implémentation

IV.5.1 Préparation des données

Dans le cadre de notre projet, la base de données EchoNet-Dynamic est utilisée pour entraîner à la fois les modèles GANs et de classification. La préparation des données est réalisée à l'aide de la bibliothèque PyTorch, qui offre des fonctionnalités efficaces pour le traitement et la transformation de vidéos. Ces opérations permettent de rendre les données compatibles avec les exigences des modèles de deep learning. Une préparation rigoureuse est essentielle pour garantir la qualité de l'apprentissage, ainsi que la robustesse et la généralisation des modèles développés.

IV.5.1.1 Chargement des bibliothèques nécessaires

Notre programme permet d'importer les bibliothèques principales telles que torch, torchvision.transforms, cv2 (OpenCV), os, pandas et numpy pour la manipulation des vidéos et des étiquettes.

IV.5.1.2 Définition du chemin des données

Ce chemin contient les vidéos (.avi) ainsi que le fichier de métadonnées FileList.csv.

```
DATA_PATH = "E:/amina project/echogan1/EchoNet-Dynamic"
```

IV.5.1.3 Définition de la classe personnalisée EchoNetDataset

Cette classe hérite de torch.utils.data.Dataset et gère le traitement des vidéos :

- **__init__** : prépare la liste des vidéos et extrait un nombre fixe de 10 images par vidéo (ou toutes les images si la vidéo en contient moins).
- **__getitem__** : lit une image spécifique dans une vidéo, la convertit en niveaux de gris, la redimensionne en 128×128 pixels, puis la transforme en tenseur PyTorch.

IV.5.1.4 Chargement des métadonnées

Le fichier FileList.csv contient les noms des fichiers vidéo, la fraction d'éjection (EF) et la division des données (TRAIN, VAL, TEST). Une nouvelle colonne label est ajoutée pour représenter les cas pathologiques ($EF < 50$).

```
df['label'] = (df['EF'] < 50).astype(int)
```

IV.5.1.5 Division du jeu de données

Les données sont réparties en trois ensembles : apprentissage (TRAIN – 80 %), validation (VAL – 10 %) et test (TEST – 10 %), comme spécifié dans le fichier CSV.

IV.5.1.6 Transformations

Des transformations sont appliquées aux images :

- **Pour l'apprentissage** : retournement horizontal aléatoire, rotation et normalisation.
- **Pour la validation et le test** : seule la normalisation est appliquée.

```
transforms.Normalize([0.5], [0.5])
```


IV.5.1.7 Création des objets Dataset et DataLoader

Les objets EchoNetDataset sont instanciés pour chaque ensemble, puis encapsulés dans des DataLoader PyTorch afin de permettre un chargement en lot pendant l'entraînement.

Cette approche permet de standardiser et d'optimiser l'accès aux données pour les modèles de deep learning, tout en assurant une diversité grâce aux transformations appliquées.

```
train_loader = DataLoader(train_dataset, batch_size=32, shuffle=True)
```

IV.5.2 Construction des modèles GANs

Les GANs représentent une avancée majeure dans le domaine de l'apprentissage profond. Ils reposent sur l'interaction de deux réseaux neuronaux : un générateur (Generator), chargé de produire des données similaires aux données réelles, et un discriminateur (Discriminator), dont le rôle est de distinguer les données réelles des données générées. L'entraînement simultané de ces deux réseaux permet au générateur de s'améliorer progressivement, jusqu'à produire des données quasi indiscernables des données authentiques.

Dans le cadre de notre projet, nous avons conçu et entraîné quatre architectures différentes de GANs pour la génération d'images échographiques cardiaques :

1. Vanilla GAN
2. DCGAN (Deep Convolutional GAN)
3. CGAN (Conditional GAN)
4. WGAN (Wasserstein GAN)

IV.5.2.1 Vanilla GAN

Le Vanilla GAN représente la forme la plus simple des réseaux antagonistes génératifs. Il est constitué de :

- **Un générateur**, basé sur une structure linéaire suivie de couches de convolution transposée, dont l'objectif est de transformer un vecteur de bruit aléatoire en une image de taille 64×64 pixels ;
- **Un discriminateur**, utilisant des couches convolutives classiques pour distinguer les images réelles des images générées.

L'architecture du Vanilla GAN est présentée dans la figure IV.2.

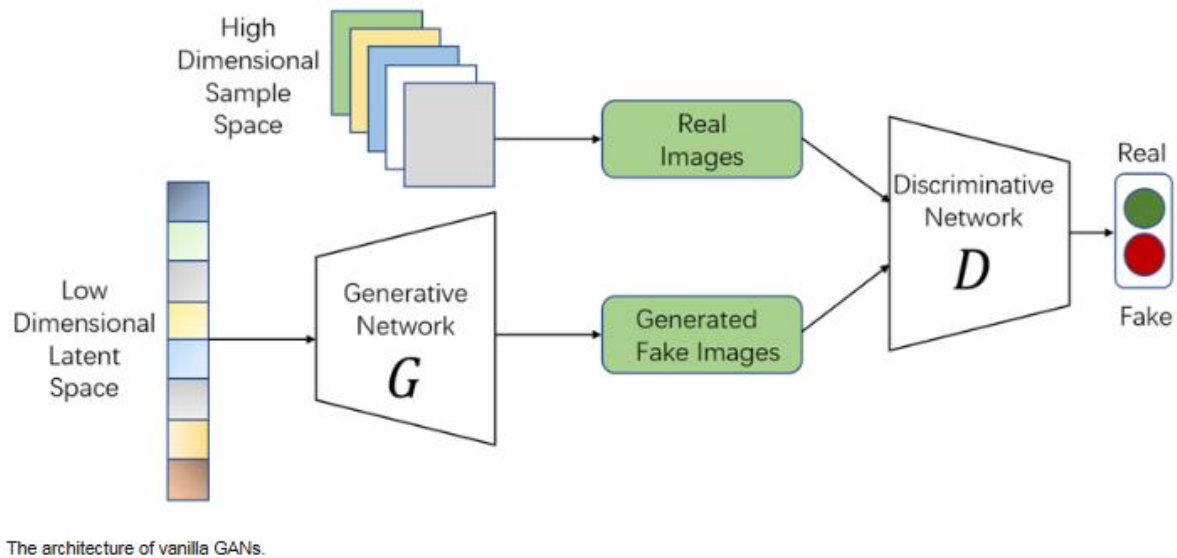


Figure IV.2 : Composants principaux d'un Vanilla GAN [58]

A) Architecture du générateur

- Une couche linéaire convertit le vecteur de bruit (de dimension 100) en un tenseur 3D de taille $(256 \times 8 \times 8)$.
- Trois couches ConvTranspose2d successives permettent d'augmenter progressivement la résolution jusqu'à 64×64 pixels.
- Une fonction d'activation Tanh est utilisée en sortie pour normaliser les valeurs des pixels entre -1 et 1.

B) Architecture du discriminateur

- Trois couches convolutives réduisent progressivement les dimensions de l'image d'entrée.
- Une couche linéaire finale produit une probabilité via une activation Sigmoid, indiquant si l'image est réelle ou synthétique.

C) Entraînement

- Le discriminateur apprend à classer les images réelles avec le label 1, et les images générées avec le label 0.
- Le générateur apprend à tromper le discriminateur en produisant des images qui obtiennent un score proche de 1.
- La fonction de perte utilisée est la **BCELoss** (Binary Cross Entropy Loss).

La figure ci-dessous présente quelques résultats d'images échographiques générées par le Vanilla GAN.




Figure IV.3 : Quelques exemples d'images échographiques générées par le Vanilla GAN.

IV.5.2.2 DCGAN (Deep Convolutional GAN)

Le DCGAN est une amélioration du Vanilla GAN, utilisant uniquement des couches convolutives profondes pour stabiliser l'entraînement et améliorer la qualité des images générées. La figure IV.4 illustre l'architecture du générateur et du discriminateur du DCGAN.




Figure IV.4 : Architecture du générateur et du discriminateur du DCGAN [59]

A) Architecture du générateur

- Entrée : vecteur de bruit de dimension 100.
- Une couche linéaire suivie d'une couche flatten pour transformer le bruit en un tenseur 4D.
- Quatre couches ConvTranspose2d avec normalisation BatchNorm2d et activation ReLU.
- La dernière couche utilise Tanh pour normaliser les images générées entre -1 et 1.

B) Architecture du discriminateur

- Quatre couches Conv2d avec activation LeakyReLU.
- Normalisation BatchNorm2d après chaque couche, sauf la première.
- Une couche flatten suivie d'une couche linière et d'une activation Sigmoid pour donner une probabilité.

C) Entraînement

- L'entraînement se fait en alternant la mise à jour du discriminateur (à l'aide d'images réelles et générées) et celle du générateur (en tentant de produire des images capables de tromper le discriminateur).
- Utilisation de la fonction de perte BCELoss.
- Optimisation via Adam avec des hyperparamètres classiques : lr (pas d'apprentissage) = 0.0002, betas = (0.5, 0.999).

D) Évaluation

L'évaluation du modèle DCGAN repose à la fois sur des mesures quantitatives et sur une analyse qualitative des images générées.

D.1) Analyse quantitative

Plusieurs métriques ont été utilisées pour mesurer la performance du générateur et du discriminateur :

- **Accuracy du discriminateur** : correspond au taux de classification correcte des images comme réelles ou synthétiques.
- **Score du générateur** : moyenne des scores attribués par le discriminateur aux images synthétiques ; un score élevé indique un bon niveau de réalisme perçu.
- **FID (Fréchet Inception Distance)** : mesure la distance entre les distributions des caractéristiques extraites des images réelles et synthétiques. Un score FID plus bas indique une meilleure qualité d'image.
- **IS (Inception Score)** : évalue à la fois la qualité visuelle et la diversité des images générées.

Résultats obtenus :

- Score du générateur : **81.56%**.
- Accuracy du discriminateur : **84.00%**.

D.2) Analyse qualitative

Une inspection visuelle des images générées montre une nette amélioration par rapport aux résultats du Vanilla GAN. Au fil des époques d'entraînement, les images produites présentent :

- Une meilleure définition des structures cardiaques, notamment des ventricules et des oreillettes ;
- Une réduction progressive des artefacts visuels et du bruit ;
- Une fidélité croissante par rapport aux images échographiques réelles (voir Figure IV.5).




Figure IV.5 : Quelques exemples d'images échographiques générées par le DCGAN.

IV.5.2.3 CGAN (Conditional GAN)

Le Conditional GAN (CGAN) introduit une notion de conditionnement dans le processus de génération, en intégrant des étiquettes de classe (dans notre cas : normal vs pathologique) à la fois dans le générateur et le discriminateur. Cela permet de contrôler le type d'image générée, par exemple en produisant uniquement des images représentant une pathologie spécifique. La figure IV.6 illustre le principe de fonctionnement du CGAN [60]

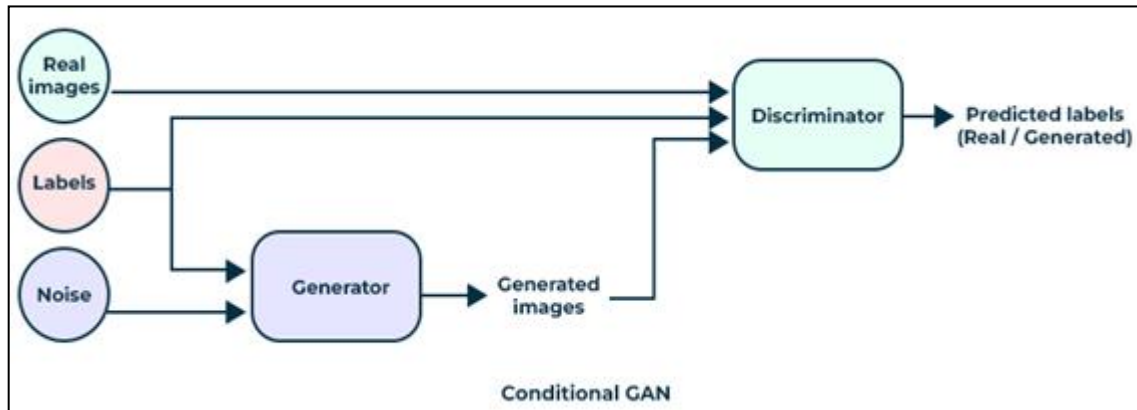


Figure IV.6 : Schéma du fonctionnement conditionnel du CGAN avec étiquettes de classe.

A) Architecture du générateur

- Le générateur reçoit en entrée un vecteur de bruit aléatoire (de dimension 100) concaténé avec une représentation de l'étiquette (embedding).
- Une couche Linear projette cette entrée dans un espace de dimension $256 \times 8 \times 8$.
- Trois couches ConvTranspose2d permettent ensuite de générer une image de dimension 64×64 .
- L'activation finale est une fonction Tanh, utilisée pour normaliser les pixels entre -1 et 1.

B) Entraînement

- Le discriminateur reçoit en entrée une image (réelle ou générée) ainsi que l'étiquette associée.
- Le générateur apprend à produire des images correspondant à une classe cible, tout en essayant de tromper le discriminateur.

C) Évaluation

L'évaluation du CGAN a été réalisée en combinant des analyses qualitatives et quantitatives afin de vérifier la cohérence du conditionnement et la qualité des images générées.

C.1) Analyse qualitative

- Des images synthétiques ont été générées pour chaque classe (par exemple : normal vs pathologique) afin d'évaluer visuellement la cohérence entre l'image produite et l'étiquette conditionnelle.
- Les images générées sont affichées avec leur étiquette correspondante pour faciliter l'interprétation et vérifier la pertinence du conditionnement.

C.2) Analyse quantitative

- **Generator Score (%)** : un score élevé indique que le générateur parvient efficacement à tromper le discriminateur.
- **Discriminator Accuracy (%)** : mesure la capacité du discriminateur à différencier les images réelles des synthétiques.
- **FID (Fréchet Inception Distance)** : inférieur à celui du Vanilla GAN, ce qui reflète une amélioration de la qualité visuelle des images générées.
- **IS (Inception Score)** : généralement supérieur à celui des modèles non conditionnels, indiquant une meilleure diversité et une plus grande qualité des images.

C.3) Avantages du CGAN

- Permet un contrôle précis sur le type d'image générée grâce au conditionnement.
- Offre une plus grande diversité et une meilleure cohérence des images synthétiques.
- Particulièrement adapté aux tâches médicales où la classe joue un rôle clé dans l'analyse et la prise de décision.

IV.5.2.4 WGAN (Wasserstein GAN)

Le Wasserstein GAN (WGAN) apporte une amélioration théorique et pratique à l'entraînement des GANs en introduisant une nouvelle fonction de perte basée sur la distance de Wasserstein (ou Earth Mover's Distance). Contrairement aux GANs classiques utilisant la fonction de perte BCELoss, le WGAN vise à fournir un gradient plus stable, améliorant ainsi

la convergence du générateur et réduisant les problèmes de mode collapse. La figure IV.7 illustre le principe de fonctionnement du WGAN

Les principales différences avec les GANs classiques sont les suivantes :

- Le discriminateur est remplacé par un critic, qui ne fournit pas une probabilité mais un score réel.
- Le critic n'utilise pas d'activation Sigmoid en sortie.
- La fonction de perte est basée sur la distance de Wasserstein, calculée comme la différence entre les scores moyens des vraies et fausses images.
- Pour respecter la condition de Lipschitz, un clipping des poids ou une pénalisation du gradient est appliqué [61]

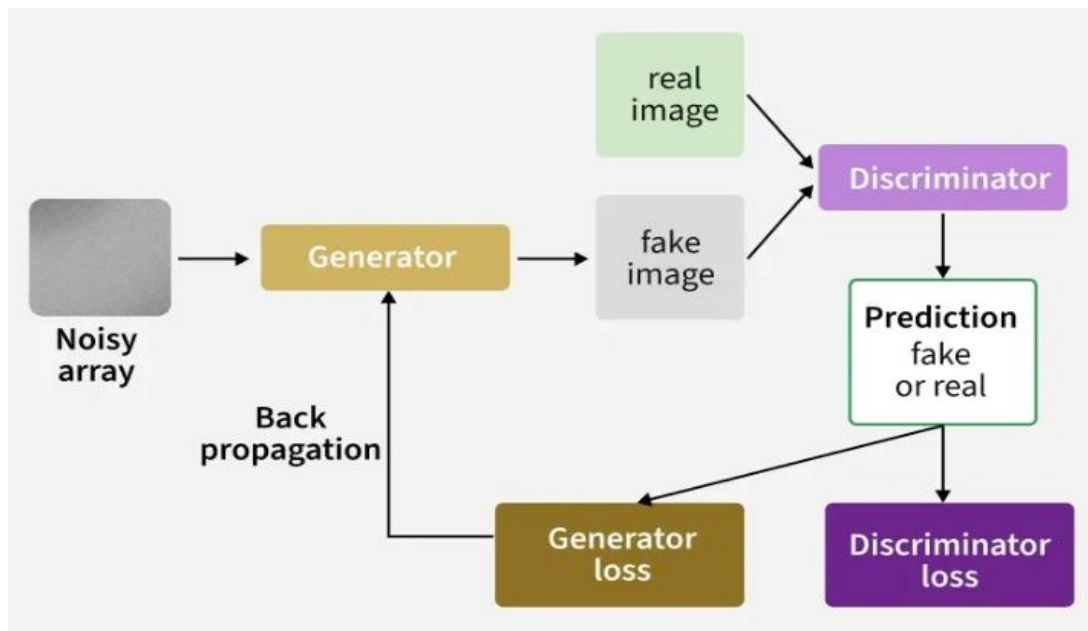


Figure IV.7 : Schéma du fonctionnement du WGAN.

A) Architecture du générateur

- Identique ou très similaire à celle utilisée dans le Vanilla GAN ou le DCGAN.
- Le bruit d'entrée, de dimension 100, est transformé par des couches Linear puis ConvTranspose2d.
- L'activation finale est une fonction Tanh, permettant de générer des images dont les pixels sont normalisés dans l'intervalle $[-1, 1]$.

B) Architecture du critic

- Le critic adopte une structure similaire à celle d'un discriminateur classique, composée de couches Conv2d suivies d'activations LeakyReLU.
- Contrairement aux GANs classiques, aucune activation Sigmoid n'est utilisée en sortie.
- La dernière couche est constituée d'un Flatten, suivi d'une couche Linear qui produit un **score réel** (et non une probabilité).

C) Fonctions de perte

- **Perte du critic :**

$$Loss_D = - (E[critic(x_{real})] - E[critic(x_{fake})]) \quad (9)$$

- **Perte du générateur**

$$Loss_G = - E[critic(x_{real})] \quad (10)$$

Où :

- x_{real} : échantillons réels issus du jeu de données.
- x_{fake} : échantillons synthétiques générés par le générateur à partir d'un bruit aléatoire.
- $critic(x)$: sortie du critic, qui attribue un score réel (positif ou négatif) à une image x .
- $E[.]$: espérance mathématique, c'est-à-dire la moyenne sur un batch d'exemples.

D) Entraînement

- Le critic est entraîné plusieurs fois (par exemple, 5 itérations) pour chaque mise à jour du générateur.
- Les poids du critic sont limités à un intervalle fixe $[-0.01, 0.01]$ afin de garantir le respect de la condition de Lipschitz.
- L'optimisation est réalisée à l'aide de l'algorithme RMSProp ou Adam.

E) Avantages

- Un apprentissage plus stable grâce à une fonction de perte mieux comportée.
- Une réduction significative du mode collapse, problème fréquent dans les GANs classiques.
- Des gradients plus informatifs, même lorsque le *critic* atteint de hautes performances, ce qui permet un entraînement plus efficace du générateur.

F) Résultats Obtenus :

- Meilleure convergence du générateur.
- Images générées plus nettes et plus proches de la distribution réelle.
- FID inférieur à celui obtenu avec le Vanilla GAN et le DCGAN.
- Structures cardiaques bien définies dans les images synthétiques.
- Amélioration notable dès les premières époques d'entraînement.

Un exemple des résultats obtenus à l'aide du WGAN est présenté à la figure IV.8.




Figure IV.8 : Schéma du fonctionnement du WGAN.

IV.5.2.5 Comparaison des modèles GANs

Afin d'évaluer les performances des différentes variantes de GANs étudiées dans ce chapitre, le tableau ci-dessous présente une synthèse comparative selon plusieurs critères.

Les figures IV.8 et IV.9 illustrent respectivement l'évolution des fonctions de perte du générateur et du discriminateur au cours de l'entraînement pour les quatre architectures de GANs,

Modèle	Stabilité de l'entraînement	Intégration d'étiquettes	Qualité des images	Sensibilité aux hyperparamètres	FID (qualité)	IS (diversité)
Vanilla GAN	Faible	Non	Moyenne	Élevée	Élevé	Faible
DCGAN	Moyenne	Non	Bonne	Moyenne	Moyen	Bon
CGAN	Bonne	Oui	Très bonne	Moyenne	Faible	Très bon
WGAN	Très bonne	Non (WGAN de base)	Faible	Faible	Très faible	Bon

Table IV.2 : Comparaison des performances des différentes architectures de GANs.




Figure IV.8 : Évolution de la fonction de perte du générateur pour les différentes architectures de GANs




Figure IV.9 : Évolution de la fonction de perte du générateur pour les différentes architectures de GANs

D'après les résultats obtenus, nous avons pu formuler les remarques suivantes :

- Le Vanilla GAN est simple à implémenter, mais instable.
- Le DCGAN apporte des améliorations majeures grâce à l'utilisation de convolutions.
- Le CGAN permet une génération conditionnelle, utile pour les données médicales où les classes sont connues.
- Le WGAN est peu performant et produit des images de mauvaise qualité, notamment sur des ensembles de données complexes comme EchoNet-Dynamic.

Chaque modèle présente des avantages selon les objectifs : simplicité, contrôle conditionnel, stabilité ou qualité visuelle. Dans notre cas, le DCGAN, le CGAN et le Vanilla GAN offrent les meilleurs résultats en termes de fidélité et de cohérence des images générées.

La figure IV.10 présente quelques résultats des images échographiques générées par les quatre GANs.

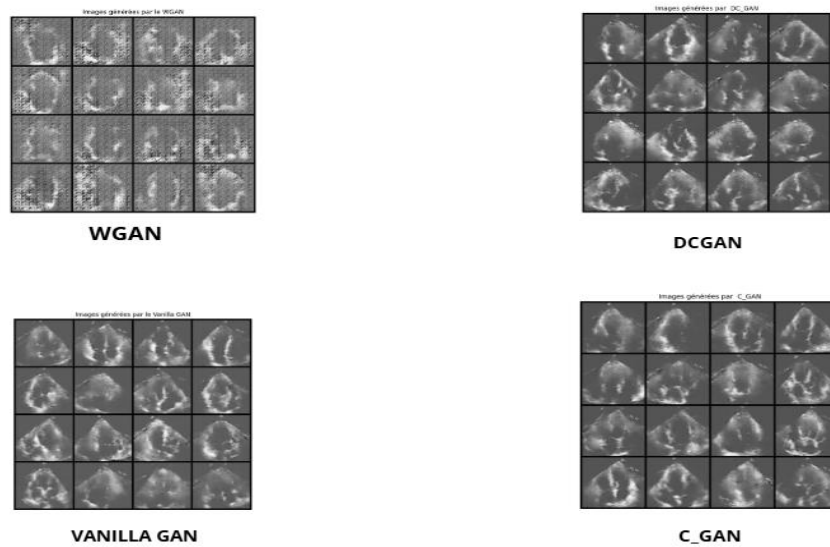


Figure IV.10 : Exemples d'images échographiques synthétiques générées par les quatre architectures de GANs.

IV.5.3 Classification des images échographiques

En plus de la génération d'images, le projet intègre également la classification automatique des images échographiques cardiaques. L'objectif est de prédire si une image correspond à un cas pathologique (fraction d'éjection $< 50\%$) ou non.

Pour cela, quatre modèles de classification ont été développés et entraînés à l'aide des données générées par les GANs. Les modèles de classification sont les suivants :

- **Classifieur CNN1** : un modèle CNN simple avec deux couches de convolution.
- **Classifieur CNN2** : une version plus profonde avec trois couches de convolution.
- **Classifieur ResNet** : basé sur l'architecture ResNet18, adaptée aux images en niveaux de gris.
- **Classifieur MobileNet** : un modèle léger et rapide basé sur MobileNetV2.

Tous les modèles sont entraînés avec la fonction de perte CrossEntropyLoss et l'optimiseur Adam. L'entraînement est effectué sur trois époques pour accélérer le processus tout en conservant des performances satisfaisantes.

Chaque modèle est sauvegardé après l'entraînement dans un dossier classifieurs1/. Ces modèles sont ensuite utilisés dans l'application Streamlit pour effectuer des prédictions en temps réel.

Cette approche multi-modèles permet de comparer les performances et de sélectionner le classifieur le plus adapté selon les critères de précision, de rapidité ou de légèreté.

IV.5.3.1 Classifieur CNN1 (Modèle CNN simple)

Ce modèle utilise deux couches de convolution, suivies de couches entièrement connectées, pour effectuer la classification. Il est adapté aux structures de réseau légères et aux jeux de données de taille modérée.

Son architecture est la suivante :

- Conv2d (1, 32, kernel=3, padding=1) + ReLU + MaxPool
- Conv2d (32, 64, kernel=3, padding=1) + ReLU + MaxPool
- Fully connected ($64 \times 32 \times 32 \rightarrow 128$) + ReLU
- Fully connected ($128 \rightarrow 2$)

Ce modèle est rapide à entraîner, mais peut être limité en capacité pour traiter des images complexes.

IV.5.3.2 Classifieur CNN2 (Modèle CNN plus profond)

Cette version ajoute une troisième couche convolutionnelle pour capturer davantage de caractéristiques visuelles. Elle offre de meilleures performances sur des données plus complexes et plus riches.

Son architecture est la suivante :

- Conv2d (1, 32, kernel=3, padding=1) + ReLU + MaxPool
- Conv2d (32, 64, kernel=3, padding=1) + ReLU + MaxPool
- Conv2d (64, 128, kernel=3, padding=1) + ReLU + MaxPool
- Fully connected ($128 \times 16 \times 16 \rightarrow 256$) + ReLU
- Fully connected ($256 \rightarrow 2$)

Ce modèle offre un bon compromis entre complexité et performance.

IV.5.3.3 Classifieur ResNet (Basé sur ResNet18)

Ce modèle repose sur l'architecture ResNet18, largement reconnue pour sa capacité à apprendre des représentations profondes grâce aux connexions résiduelles. Il a été adapté pour traiter des images en niveaux de gris.

Nous avons modifié le modèle de base pour l'adapter à nos besoins. Les modifications apportées sont les suivantes :

- Remplacement de la première couche conv1 afin d'accepter un seul canal (1) au lieu de trois (3).
- Substitution de la couche de sortie fc pour produire deux classes.

Ce modèle permet:

- Un apprentissage plus efficace des caractéristiques complexes.
- De meilleures performances sur des données visuelles variées.

IV.5.3.4 Classifieur MobileNet (basé sur MobileNetV2)

MobileNetV2 est une architecture légère conçue pour les environnements à faibles ressources (comme les appareils mobiles). Ce modèle est rapide et nécessite peu de mémoire, tout en conservant une précision raisonnable.

Nous avons modifié le modèle de base pour l'adapter à nos besoins comme suit :

- Modification de la première couche pour accepter un seul canal (niveaux de gris).
- Ajustement de la couche de classification finale pour produire deux classes.

Les avantages de ce modèle sont :

- Une grande rapidité d'inférence.
- Un temps de traitement très court
- Une vitesse d'exécution élevée, idéale pour les déploiements en temps réel.

IV.5.3.5 Modèle de données cliniques (SimpleNN sur données tabulaires)

En complément des images échographiques, un modèle d'apprentissage supervisé a été construit pour exploiter un jeu de données cliniques provenant de Kaggle (données médicales de patients atteints de maladies cardiaques).

L'objectif est de prédire la présence ou non d'une maladie cardiaque à partir de variables médicales (âge, cholestérol, tension artérielle, etc.).

L'architecture de ce modèle est la suivante :

- Fully connected ($13 \rightarrow 64$) + ReLU
- Fully connected ($64 \rightarrow 32$) + ReLU
- Fully connected ($32 \rightarrow 2$)

Ce modèle, appelé SimpleNN, est entraîné avec la fonction de perte CrossEntropyLoss et l'optimiseur Adam sur 20 époques. Il permet d'intégrer des informations cliniques dans la chaîne de décision et d'améliorer la précision globale de la classification lorsqu'il est utilisé en complément des modèles visuels.

IV.5.3.6 Comparaison des modèles de classification

Dans cette section, nous comparons les différents modèles de classification développés à partir des images échographiques générées par les GANs, ainsi que d'un modèle basé sur des données cliniques. Cette comparaison repose sur plusieurs critères : le type de données utilisé (images ou données tabulaires), la complexité du modèle (profondeur et taille), le temps d'entraînement, la précision attendue, ainsi que les avantages spécifiques de chaque architecture. La table IV.3 résume les caractéristiques principales de chacun de ces modèles.

La figure IV.11 montre les courbes de perte (loss) des différents modèles de classification au cours de l'entraînement.

Les tests réalisés sur les différents modèles de classification ont conduit aux observations suivantes :

- Le modèle Classifieur CNN1 est particulièrement adapté aux tâches de prototypage rapide grâce à sa simplicité.
- Classifieur CNN2 offre un bon compromis entre précision et rapidité d'exécution.
- Classifieur ResNet se distingue comme le modèle le plus performant pour la reconnaissance visuelle avancée.
- Classifieur MobileNet est idéal pour les applications nécessitant un traitement en temps réel grâce à sa rapidité.

- SimpleNN, basé sur les données cliniques, enrichit l'analyse et améliore la précision lorsqu'il est utilisé en complément des modèles d'images.

Tous les modèles ont été entraînés avec la fonction de perte CrossEntropyLoss et l'optimiseur Adam. Ils sont sauvegardés puis intégrés dans l'application Streamlit, permettant ainsi des démonstrations interactives.

Modèle	Type de données	Profondeur	Taille du modèle	Temps d'entraînement	Précision attendue	Avantages
Classifieur CNN1	Images	Faible	Léger	Très court	Moyenne	Facile à entraîner
Classifieur CNN2	Images	Moyenne	Moyen	Court	Bonne	Meilleur apprentissage spatial
Classifieur ResNet	Images	Élevée	Grand	Long	Très bonne	Apprentissage profond efficace
Classifieur MobileNet	Images	Moyenne	Très léger	Très court	Bonne	Très rapide et efficace
SimpleNN (Données cliniques)	Données tabulaires	Moyenne	Léger	Moyen	Bonne	Exploite des facteurs médicaux

Table IV.3 : Comparaison des performances des modèles de classification.

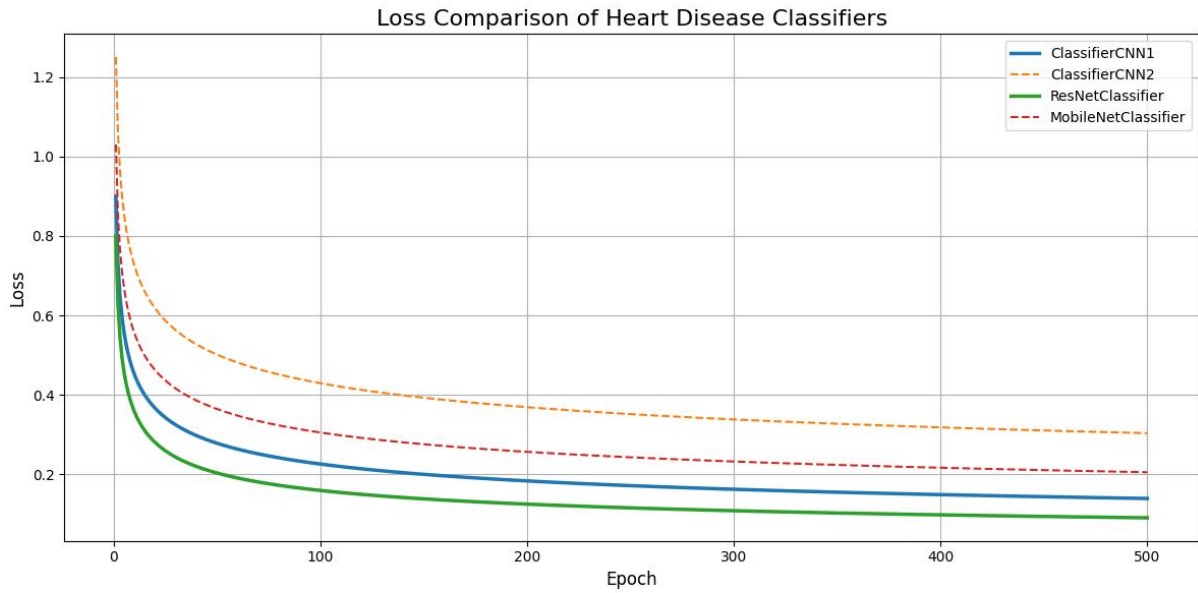


Figure IV.11 – Courbes de pertes des différents modèles de classification

IV.5.4 Interface de notre application

Nous avons développé une interface interactive avec Streamlit permettant de générer des images échocardiographiques synthétiques à partir des modèles GAN entraînés. Cette application offre également la possibilité d'effectuer la classification automatique des images médicales afin de prédire si elles correspondent à un cas pathologique (fraction d'éjection inférieure à 50%) ou non. Cela facilite l'évaluation en temps réel et l'exploration des résultats. La figure IV.12 montre cette interface.



Figure IV.12 : Interface utilisateur pour la génération et la classification d'images cardiaques

IV.6 Conclusion

Ce chapitre a présenté en détail les différentes approches basées sur les GANs pour la génération d'images échocardiographiques, ainsi que les modèles de classification développés pour analyser ces images. Nous avons exploré plusieurs architectures de GANs (Vanilla GAN, DCGAN, CGAN et WGAN) en mettant en avant leurs spécificités, avantages et limites respectives.

La classification automatique, appuyée par plusieurs architectures CNN a été mise en œuvre pour distinguer les cas pathologiques des cas normaux avec une bonne précision. L'interface interactive développée sous Streamlit facilite l'expérimentation en temps réel, offrant à la fois génération et classification d'images échocardiographiques.



Conclusion général

Conclusion général

Notre projet s'inscrit dans un environnement de recherche dynamique et en constante évolution dans le domaine de la santé, axé sur l'utilisation des réseaux antagonistes génératifs (GAN) pour la détection précoce des maladies cardiovasculaires à partir de l'imagerie médicale. L'imagerie médicale a considérablement amélioré la précision des diagnostics et ouvert de nouvelles perspectives pour le traitement des maladies, notamment les affections cardiovasculaires. Elle démontre comment les avancées technologiques peuvent être mises au service de la santé publique, en facilitant une détection plus précoce des maladies et en améliorant les résultats cliniques pour les patients.

Notre étude met en évidence le potentiel prometteur des GAN, en particulier des DCGAN, dans la génération et l'analyse d'images liées aux maladies cardiovasculaires. Ces réseaux sont capables de produire des images synthétiques de haute qualité, reproduisant fidèlement les caractéristiques visuelles des examens médicaux réels. Ces images peuvent enrichir les jeux de données utilisés pour l'entraînement des modèles d'apprentissage automatique. Bien que notre modèle ait montré des résultats encourageants dans la différenciation entre les tissus sains et pathologiques, des recherches complémentaires sont nécessaires pour consolider la validité de notre approche. Des évaluations quantitatives rigoureuses et des comparaisons avec d'autres méthodes de génération et de détection d'images seront essentielles pour confirmer son efficacité.

Perspective:

Dans la continuité de ce travail, plusieurs pistes peuvent être envisagées. Il serait pertinent d'explorer l'intégration des réseaux GAN avec les Transformers et d'autres modèles avancés de deep learning, afin d'améliorer davantage la qualité des images générées ainsi que la pertinence des résultats obtenus. Par ailleurs, une validation clinique à grande échelle, menée en collaboration avec des professionnels de santé, permettrait d'évaluer l'applicabilité réelle du modèle dans un environnement hospitalier. Enfin, l'adaptation de cette approche à d'autres types de pathologies et à diverses modalités d'imagerie médicale (IRM, échographie, TEP) pourrait élargir son champ d'application et contribuer de manière significative à l'amélioration des pratiques médicales assistées par l'intelligence artificiel.

Références bibliographiques

- [1] Radiologie-anim.fr. L'histoire de l'imagerie médicale : 130 ans d'innovations [Internet]. [consulté le 13 mars 2025]. Disponible sur: <https://www.radiologie-anim.fr/post/l-histoire-de-l-imagerie-medecale-130-ans-d-innovations-radiologie-nimes>
- [2] Société Francophone d'Imagerie Pédiatrique. Information sur les rayons X [Internet]. SFIP Radiopédiatrie; [consulté le 13 mars 2025]. Disponible sur: <https://sfip-radiopediatrie.org/information-sur-les-rayons-x/>
- [3] VIDAL. Scanner (tomodensitométrie) [Internet]. [consulté le 13 mars 2025]. Disponible sur: <https://www.vidal.fr/sante/examens-tests-analyses-medicales/scanner-tomodensitometrie.html>
- [4] Sarcome HMR. Radiologie – TEP scan [Internet]. [consulté le 13 mars 2025]. Disponible sur: <https://sarcomehmr.ca/fr/services-traitements-sarcomes/radiologie/tep-scan>
- [5] CNP-MN. Les fondamentaux – Chapitre 3 : Radiographie [Internet]. [consulté le 13 mars 2025]. Disponible sur: <https://www.cnp-mn.fr/les-fondamentaux-chapitre-3-radiographie/>
- [6] Sonhar. Réaliser une radiographie du thorax [Internet]. [consulté le 20 mars 2025]. Disponible sur: <https://www.sonhar.fr/realiser-radiographie-thorax>
- [7] ARCAGY GINECO / InfoCancer. L'imagerie en Résonance Magnétique (IRM) [Internet]. [consulté le 16 mars 2025]. Disponible sur: <https://www.arcagy.org/infocancer/en-savoir-plus/imagerie-medecale/l-imagerie-en-resonance-magnetique.html>
- [8] Feigenbaum H. Echocardiography. 6^e éd. Philadelphia: Lippincott Williams & Wilkins; 2010.
- [9] Cussonneau M, Pelissier F. L'échographie cardiaque : généralités [Internet]. Paramed Cardiologie; sept 2022 [consulté le 16 mars 2025]. Disponible sur: <https://www.paramed-cardiologie.fr/pages/publications/les-examens-complementaires/l-echographie-cardiaque.html>
- [10] Lemoine T. Imagerie médicale – Avant-propos (Réf. MED100 v1) [Internet]. Paris: Techniques de l'Ingénieur; 10 juin 2014 [consulté le 19 mars 2025]. Disponible sur: <https://www.techniques-ingenieur.fr/base-documentaire/biomedical-pharma-th15/imagerie-medecale-therapies-par-ondes-42607210/imagerie-medecale-med100/>
- [11] Skandha S, Lalande A, Afilalo J, Jodoin PM. Generative Adversarial Networks in Cardiology. Can J Cardiol. 2022;38(2):196–203. doi:10.1016/j.cjca.2021.11.003
- [12] Maxicours. Caractéristiques d'une image numérique [Internet]. [consulté le 13 mars 2025]. Disponible sur: <https://www.maxicours.com/se/cours/caracteristiques-d-une-image-numerique>
- [13] Nazarian B. Images binaires – Support de cours [Internet]. [consulté le 13 mars 2025]. Disponible sur: http://bnazarian.free.fr/MyUploads/IN_GBM_06_BINAIRES.PDF

- [14] Rétines. Niveaux de gris : comprendre le codage des images [Internet]. [consulté le 13 mars 2025]. Disponible sur: <https://retines.fr/blog/niveaux-de-gris/>
- [15] Regen Rehab. Penilaian jantung [Internet]. [consulté le 20 mars 2025]. Disponible sur: <https://www.regen.rehab/id/service/penilaian-jantung/>
- [16] Chapitres 3 et 4 – Traitement d’image [Internet]. [consulté le 20 mars 2025]. Disponible sur: https://v-assets.cdns.w.com/fs/Root/e1fz5-chap3_chap4.pdf
- [17] Gonzalez RC, Woods RE. Digital Image Processing. 4^e éd. Pearson; 2018.
- [18] Papers with Code. CAMUS dataset [Internet]. [consulté le 24 mars 2025]. Disponible sur: <https://paperswithcode.com/dataset/camus>
- [19] Madani A, Arnaout R, Mofrad M, Arnaout R. Fast and accurate view classification of echocardiograms using deep learning. NPJ Digital Medicine. 2018;1:6.
- [20] World Health Organization (WHO). Maladies cardiovasculaires (MCV) [Internet]. [consulté le 25 mars 2025]. Disponible sur: [https://www.who.int/fr/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/fr/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- [21] World Heart Federation. Qu’est-ce qu’une maladie cardiovasculaire ? [Internet]. Genève: WHF; [consulté le 26 mars 2025]. Disponible sur: <https://world-heart-federation.org/fr/what-is-cvd/>
- [22] Organisation mondiale de la Santé (OMS). Maladies cardiovasculaires (MCV) [Internet]. [consulté le 28 mars 2025]. Disponible sur: [https://www.who.int/fr/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/fr/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- [23] Fondation des maladies du cœur et de l’AVC. Traitements [Internet]. [consulté le 02 avril 2025]. Disponible sur: <https://www.coeuretavc.ca/maladies-du-coeur/traitements>
- [24] Cigref. Père de l’intelligence artificielle : John McCarthy [Internet]. [consulté le 02 avril 2025]. Disponible sur: <https://www.cigref.fr/archives/histoire-cigref/blog/pere-d-intelligence-artificielle-john-mccarthy/>
- [25] SAP. Qu'est-ce que l'intelligence artificielle ? [Internet]. [consulté le 04 avril 2025]. Disponible sur: <https://www.sap.com/france/products/artificial-intelligence/what-is-artificial-intelligence.html>
- [26] Dagba M. Intelligence artificielle et imagerie médicale [mémoire de master sur Internet]. Université de Bordeaux; 2022 [consulté le 06 avril 2025]. Disponible sur: <https://dumas.ccsd.cnrs.fr/dumas-03847274v1/file/intelligence-artificielle-et-imagerie-medicale-version-finale.pdf>
- [27] DataBird. Intelligence Artificielle : Définition, Types et Applications [Internet]. mis à jour le 21 février 2025 [consulté le 10 avril 2025]. Disponible sur: <https://www.data-bird.co/blog/intelligence-artificielle-definition>

[28] DataScientest. Machine Learning : Définition, fonctionnement, utilisations [Internet]. 18 novembre 2020 [consulté le 12 avril 2025]. Disponible sur: <https://datascientest.com/machine-learning-tout-savoir>

[29] Mactores Data Science Team. Machine learning Chart [Internet]. 2022 [consulté le 12 avril 2025]. Disponible sur: https://www.researchgate.net/figure/Machine-learning-Chart-Source-Mactores-Data-Science-team-2022_fig2_369326211

[30] Learning Robots. L'Apprentissage Supervisé : Clé de Voûte du Machine Learning et Porte d'Entrée vers l'Intelligence Artificielle [Internet]. 5 mai 2025 [consulté le 10 mai 2025]. Disponible sur: <https://www.learningrobots.ai/blog/lapprentissage-supervise-cle-de-voute-du-machine-learning-et-porte-dentree-vers-lintelligence-artificielle>

[31] Amazon Web Services, Inc. Détecter des anomalies dans une image - Amazon Lookout for Vision [Internet]. [consulté le 10 mai 2025]. Disponible sur: https://docs.aws.amazon.com/fr_fr/lookout-for-vision/latest/developer-guide/inference-detect-anomalies.html

[32] Blent.ai. L'apprentissage supervisé : définition et exemples [Internet]. 12 avril 2022 [consulté le 12 mai 2025]. Disponible sur: <https://blent.ai/blog/a/apprentissage-supervise-definition>

[33] DataBird. Apprentissage supervisé vs non supervisé en Data Science [Internet]. 25 septembre 2024 [consulté le 15 mai 2025]. Disponible sur: <https://www.data-bird.co/blog/apprentissage-supervise-vs-non-supervise>

[34] Cross Data. Le machine learning : fondements, applications et perspectives futures en intelligence artificielle [Internet]. [consulté le 15 mai 2025]. Disponible sur: <https://www.crossdata.tech/le-machine-learning-fondements-applications-et-perspectives-futures-en-intelligence-artificielle/>

[35] ISO. Réseaux de neurones – Intelligence artificielle [Internet]. [consulté le 16 mai 2025]. Disponible sur: <https://www.iso.org/fr/intelligence-artificielle/reseaux-neurones>

[36] IBM Corp. Neural networks – IBM SPSS Modeler [Internet]. [consulté le 17 mai 2025]. Disponible sur: <https://www.ibm.com/docs/fr/spss-modeler/18.6.0?topic=networks-neural-model>

[37] Maurice B. Fonctionnement du neurone artificiel [Internet]. Deeply Learning; 15 septembre 2018 [mis à jour le 29 avril 2025; consulté le 17 mai 2025]. Disponible sur: <https://deeplylearning.fr/cours-theoriques-deep-learning/fonctionnement-du-neurone-artificiel/>

[38] Learning Robots. Les réseaux de neurones en intelligence artificielle : comment ça fonctionne [Internet]. 28 mars 2025 [consulté le 18 mai 2025]. Disponible sur: <https://www.learningrobots.ai/blog/les-reseaux-de-neurones-en-intelligence-artificielle-comment-ca-fonctionne>

- [39] Russell SJ, Norvig P. *Artificial Intelligence : A Modern Approach*. 3^e éd. Boston (MA) : Pearson; 2009 [Internet]. Disponible sur: [http://repo.darmajaya.ac.id/5272/1/Artificial%20Intelligence-A%20Modern%20Approach%20\(3rd%20Edition\)%20\(%20PDFDrive%20\).pdf](http://repo.darmajaya.ac.id/5272/1/Artificial%20Intelligence-A%20Modern%20Approach%20(3rd%20Edition)%20(%20PDFDrive%20).pdf) [consulté le 18 mai 2025]
- [40] ResearchGate. Forward and Backward propagation multi-layer neural network algorithm: The feed-forward and back-propagation process [Internet]. 2022 [consulté le 20 mai 2025]. Disponible sur: https://www.researchgate.net/figure/Forward-and-Backward-propagation-multi-layer-neural-network-algorithm-The-feedforward_fig2_366858651
- [41] Retengr. Deep Learning : définition, applications, avantages et inconvénients [Internet]. 22 janvier 2021 [consulté le 20 mai 2025]. Disponible sur: <https://www.retengr.com/le-blog/deep-learning-definitions-applications-avantages-inconvenients>
- [42] IBM Corp. What are Convolutional Neural Networks? [Internet]. [consulté le 21 mai 2025]. Disponible sur: <https://www.ibm.com/think/topics/convolutional-neural-networks>
- [43] Blent.ai. Réseaux convolutifs (CNN) : comment ça marche ? [Internet]. 21 juin 2022 [consulté le 23 mai 2025]. Disponible sur: <https://blent.ai/blog/a/cnn-comment-ca-marche>
- [44] blessingtagbe1. Avantages et limites des CNN [Internet]. [consulté le 25 mai 2025]. Disponible sur: <https://fr.scribd.com/document/825684067/Avantages-Limites-CNN>
- [45] IA School. Qu'est-ce que les Generative Adversarial Networks (GAN) ? [Internet]. Dernière mise à jour : 22 janvier 2025 [consulté le 25 mai 2025]. Disponible sur: <https://www.intelligence-artificielle-school.com/ecole/technologies/quest-ce-que-les-generative-adversarial-networks/>
- [46] Patel DD. Generative Adversarial Network [Internet]. Medium; 16 novembre 2019 [consulté le 28 mai 2025]. Disponible sur: <https://medium.com/@16bit040/generative-adversarial-network-177fb5045a90>
- [47] IA School. Qu'est-ce qu'un réseau antagoniste génératif (GAN) en Deep Learning ? [Internet]. Dernière mise à jour : 22 janvier 2025 [consulté le 29 mai 2025]. Disponible sur: <https://www.intelligence-artificielle-school.com/ecole/technologies/quest-ce-quun-reseau-antagoniste-generatif-gan-en-deep-learning/>
- [48] Brownlee J. 18 Impressive Applications of Generative Adversarial Networks (GANs) [Internet]. Machine Learning Mastery; 12 juillet 2019 [consulté le 3 juin 2025]. Disponible sur: <https://machinelearningmastery.com/impressive-applications-of-generative-adversarial-networks/>
- [49] Abdelmadjid MAM. *Réseau génératif antagoniste pour la traduction de signaux de capteurs avec application à l'ECG* [Internet]. Montréal (Québec) : Université du Québec à Montréal; 2022 [mémoire de maîtrise; consulté le 4 juin 2025]. Disponible sur: <https://archipel.uqam.ca/id/eprint/17184>

- [50] DataScientest. Deep Convolutional GAN : la création par convolution [Internet]. 11 avril 2024 [consulté le 4 juin 2025]. Disponible sur: <https://datascientest.com/deep-convolutional-gan-la-creation-par-convolution>
- [51] Démarre Ton Aventure. Modèles génératifs adversariaux (GAN) [Internet]. publié il y a 4 mois [consulté le 5 juin 2025]. Disponible sur: <https://www.demarretonaventure.com/glossaire-ia-entreprise/modeles-generatifs-adversariaux-gan/>
- [52] Skandarani Y, Fidon L, Lohezic M, Li W, Taylor A, Ourselin S, et al. Multi-modal and comparative evaluation of GANs for cardiac MRI synthesis. *Medical Image Analysis*. 2023;85:102747. doi:10.1016/j.media.2023.102747.
- [53] Shin HC, Tenenholtz NA, Rogers JK, Schwarz CG, Senjem ML, Gunter JL, et al. Medical image synthesis for data augmentation and anonymization using generative adversarial networks. *Lecture Notes in Computer Science*. 2018;11045:1–11. doi:10.1007/978-3-030-00536-8_1.
- [54] Frid-Adar M, Klang E, Amitai M, Goldberger J, Greenspan H. Synthetic data augmentation using GAN for improved liver lesion classification. *IEEE Transactions on Medical Imaging*. 2018;38(3):736–42. doi:10.1109/TMI.2018.2867380.
- [55] Chartsias A, Joyce T, Giuffrida MV, Tsiftaris SA. Multimodal MR synthesis via modality-invariant latent representation. *IEEE Transactions on Medical Imaging*. 2019;38(4):930–8. doi:10.1109/TMI.2018.2878660.
- [56] Sandfort V, Yan K, Pickhardt PJ, Summers RM. Data augmentation using generative adversarial networks (CycleGAN) to improve generalizability in CT segmentation tasks. *Scientific Reports*. 2019;9(1):16884. doi:10.1038/s41598-019-52737-3.
- [57] Han D, Lee Y, Kim M, Cho H, Yoon CH, Park H. Synthesizing echocardiographic images for rare cardiovascular conditions using generative adversarial networks. *IEEE Access*. 2022;10:45931–42. doi:10.1109/ACCESS.2022.3170753.
- [58] Smith J. Heart Disease Dataset [Internet]. Kaggle; [cité le 7 juin 2025]. Disponible sur: <https://www.kaggle.com/datasets/johnsmith88/heart-disease-dataset>
- [59] Muthu R, et al. Microplastic Identification in Seawater using Generative Adversarial Networks [Internet]. 18 avril 2024 [consulté le 7 juin 2025]. Disponible sur: https://www.researchgate.net/publication/380840807_Microplastic_Identification_in_Seawater_using_Generative_Adversarial_Networks
- [60] Kumar A. Deep Convolutional GAN. GANs Series Part 2 [Internet]. 29 mars 2024 [consulté le 7 juin 2025]. Disponible sur: <https://ankittaxak5713.medium.com/deep-convolutional-gan-6b62beb0ae9c>
- [61] Khera B. WGAN: Wasserstein Generative Adversarial Networks [Internet]. DigitalOcean; publié le 25 septembre 2024 [consulté le 8 juin 2025]. Disponible sur: <https://www.digitalocean.com/community/tutorials/wgans>

