

وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



جامعة عبد الحميد ابن باديس مستغانم
Université Abdelhamid Ibn Badis de Mostaganem

كلية العلوم والتكنولوجيا
Faculté des Sciences et de la Technologie



N° d'ordre : M2...../GE/2026

MEMOIRE DE FIN D'ÉTUDES DE MASTER ACADEMIQUE

Filière : Automatique.

Spécialité : Automatique et informatique Industrielle.

Thème

**Apprentissage profond pour la détection et la classification de
différentes tumeurs des tissus mous.**

Présentée par :

Mme GHARNAOUT Nor el houda.

Soutenu le 29/06/2026 à 08:30 devant le jury composé de :

Président : M. SOLTANE BENALLOU Abdelkader.

Université de Mostaganem

Examineur : M. ADDA Ahmed.

Université de Mostaganem

Encadreur : Mme MEHIDI Aïcha.

Université de Mostaganem

Co-Encadreur : Mme MIMI Malika.

Université de Mostaganem

Année Universitaire : 2025/2026

REMERCIEMENTS

Alhamdoulillah (الحمد لله)

Avant tout, je rends grâce à Dieu le Tout-Puissant de m'avoir accordé la santé, la force, la patience et le courage nécessaires pour mener à bien ce modeste travail. Sa bénédiction a été mon phare tout au long de mon parcours universitaire.

À mes encadrants et aux membres du jury

Mes remerciements les plus sincères s'adressent à mon éminent encadrante Mme MEHIDI Aïcha ainsi qu'à mon co-encadrante Mme MIMI Malika, pour avoir dirigé ce travail avec une immense générosité intellectuelle. Leur rigueur scientifique, leur disponibilité constante et leurs précieux conseils ont été une source d'inspiration inestimable.

Je tiens également à exprimer ma profonde gratitude au Président du jury monsieur SOLTANE BENALLOU Abdelkader ainsi qu'aux honorables Examineur monsieur ADDA Ahmed qui ont accepté d'évaluer ce travail. C'est un immense honneur pour moi de présenter mes recherches devant des esprits si éclairés.

À ma précieuse famille

Les mots me manquent pour exprimer ma gratitude envers mes chers parents. À ma tendre mère, à mon cher père et à mes Frères et Sœurs, source d'amour inconditionnel et de prières bienveillantes, qui a toujours été mon pilier et l'exemple de persévérance. Ce travail est le fruit de vos sacrifices.

Nous tenons à exprimer notre sincère gratitude au Laboratoire de recherche Signaux et Systèmes (LSS) de l'Université de Mostaganem et à tous ses membres pour l'aide qu'ils nous ont apportée en termes d'équipement, d'espaces de travail, de commodités, de conseils, d'orientation et de suivi jusqu'à l'achèvement de nos projets de fin d'études master.

DÉDICACE

Du plus profond de mon cœur, je dédie ce travail à ceux qui ont éclairé mon chemin et porté mes rêves.

À ma tendre Mère

À l'origine de mon existence, à la source de ma force : ma précieuse Maman. Aucun mot, aucune langue ne saurait traduire l'immensité de mon amour et de ma gratitude. Tu as été mes ailes quand je ne pouvais pas voler, et mes prières dans l'ombre de mes nuits. Ce succès est avant tout le tien. Que ce travail soit le reflet de tes sacrifices et la fierté de ton grand cœur.

À mon cher Père

À mon premier modèle, à mon pilier inébranlable : mon cher Papa. Toi qui as consenti à tant de sacrifices pour tracer la voie de ma réussite. Ta rigueur, ta persévérance et ta foi en mes capacités m'ont appris à ne jamais abandonner. J'espère, par ce modeste travail, honorer ton nom et être à la hauteur de tes espérances.

À mes Frères et Sœurs

À mes compagnons de vie, mes complices de toujours : mes frères et sœurs. Pour votre présence rassurante, vos éclats de rire qui ont allégé mes journées de stress, et votre soutien indéfectible.

À toute ma Famille et mes Amis

À mes précieux ma grande et chaleureuse famille, proche et alliés. Merci pour leurs encouragements constants et l'amour que vous me portez. À mes amis leurs soutient constant durant mon cursus universitaire.

Mme GHARNAOUT NOR ELHOUDA

Chapitre I :	page
Figure I.1 - Anatomie du sein.	06
Figure I.2 - Incidence standardisée de cancer du sein dans le monde pour 100000 femmes.	07
Figure I.3 - Répartition par tranche d'âges de cancer du sein pour 100 000 femmes, 2014.	08
Figure I.4 - Échographie mammaire.	12
Figure I.5 - IRM mammaire.	13
Figure I.6 - Appareil de mammographie	14
Figure I.7 - Biopsie et ponction.	15
 Chapitre II :	
Figure II.1 - Diagramme d'inclusion des sous-champs de l'Intelligence Artificielle, du Machine Learning et du Deep Learning.	20
Figure II.2 - Principe de l'apprentissage supervisé.	21
Figure II.3 - Modèle de réseau pour l'apprentissage non supervisé.	22
Figure II.4 - Principe de l'apprentissage par renforcement.	23
Figure II.5 - Extraction de caractéristiques dans un réseau profond.	24
Figure II.6 - Anatomie générale du neurone biologique.	29
Figure II.7 - Schéma de principe d'un neurone artificiel.	30
Figure II.8 - Analogie entre neurone biologique et neurone artificiel.	31
Figure II.9 - Architecture générale d'un réseau CNN.	34
Figure II.10 - La couche de convolution.	35
Figure II.11 - La fonction d'activation.	36
Figure II.12 - La couche de sous-échantillonnage (Pooling Layer).	36
Figure II.13 - La couche entièrement connectée (fully connected layer).	37

Figure II.14 – Le principe de l'apprentissage par transfert (Transfer Learning).	39
---	-----------

Chapitre III :

Figure III.1 - Schéma général de conception.	46
---	-----------

Figure III.2 - Résultat de prétraitement des images échographiques mammaires: (a) image originale, (b) image après le prétraitement.	51
--	-----------

Figure III.3 - Structure séquentielle du réseau VGG16.	53
---	-----------

Figure III.4 - Structure séquentielle du réseau DenseNet121.	54
---	-----------

Figure III.5 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de la validation du modèle VGG16.	61
---	-----------

Figure III.6 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de la validation du modèle DenseNet121.	62
---	-----------

LISTE DES TABLEAUX

Chapitre III	page
Tableau III.1 - Résultats MSE et PSNR après le prétraitement des images échographiques mammaires.	50
Tableau III.2 - Comparaison des performances des modèles VGG16 et DenseNet121 utilisant les couches Flatten et Global Average Pooling (GAP).	60

ADAM	Adaptive Moment Estimation
ACP	Analyse en Composantes Principales
AUC	Area under the Curve
BCE	Binary Cross-Entropy
BI-RADS	Breast Imaging-Reporting and Data System
BUSI	Breast Ultrasound Images / Dataset
CAD	Computer-Aided Diagnosis
CIRC	Centre International de Recherche sur le Cancer.
CNN	Convolutional Neural Network.
CPU	Central Processing Unit
DenseNet	Densely Connected Convolutional Networks
DenseNet121	DenseNet comprenant 121 Couche
DL	Deep Learning
DNN	Deep Dark Networks / Deep Neural Networks
ECG	Électrocardiogramme.
EEG	Électroencéphalogramme.
FN	Faux Négatifs.
FP	Faux Positifs.
FPR	False Positive Rate
GAP	Global Average Pooling
GLCM	Gray Level Cooccurrence Matrix
GPU	Graphics Processing Unit
IA	Intelligence Artificielle
IDE	Integrated Development Environment
IRM	Imagerie par Résonance Magnétique
LBP	Motifs binaires locaux
LLM	Large Language Model
LSTM	Long Short-Term Memory
ML	Machine Learning
MLP	Multilayer Perception
MSE	Mean Squared Error
NLP	Natural Language Processing

OMS	Organisation Mondiale de la Santé
PCA	Principal Component Analysis
PSNR	Peak Signal-to-Noise Ratio
RAM	Random Access Memory
ReLU	Rectified Linear Unit
RGB	Red, Green, Blue
RL	Reinforcement Learning
RNN	Recurrent Neural Network
TN	Vrais Négatifs
TP	Vrais Positifs
VGG	Visual Geometry Group
VGG16	VGG comprenant 16 couches.
VIT	Vision Transformers

La classification automatique des tumeurs mammaires à partir d'images d'échographie constitue un enjeu important dans le domaine de l'aide au diagnostic médical, car elle permet de faciliter le processus de détection et d'amélioration de la prise en charge des patientes. Cependant, cette tâche est considérée comme complexe en raison de plusieurs facteurs, notamment le bruit inhérent aux images échographiques, leur faible contraste ainsi que la grande variabilité morphologique des lésions. Ces contraintes rendent l'extraction de caractéristiques pertinentes particulièrement difficile et limitent les performances des approches classiques de traitement d'image.

Dans ce contexte, ce projet a pour objectif de concevoir et d'optimiser des modèles basés sur l'apprentissage profond afin d'améliorer la précision de la classification des tumeurs mammaires, ce qui pourrait représenter une avancée majeure dans la prise de décision. L'approche proposée repose sur l'utilisation de réseaux de neurones profonds capables d'extraire automatiquement des caractéristiques discriminantes à partir des données brutes, tout en renforçant la robustesse des modèles face aux variations de qualité des images échographiques.

Plus spécifiquement, ce travail a pour objectif le développement d'un système automatisé basé sur l'apprentissage par transfert, en tirant parti de réseaux de neurones convolutionnels (CNN), pour la détection et la classification des lésions mammaires en trois catégories : bénignes, malignes et normales. Le projet comporte deux étapes. La première, le prétraitement des images, a pour but d'améliorer la qualité et le contraste de ces dernières. La seconde consiste à concevoir et à entraîner un modèle performant. L'ensemble de cette approche vise à accroître l'efficacité et la fiabilité du diagnostic assisté des lésions mammaires.

Mots Clés : Transfert Learning, images échographiques mammaires, réseaux de neurones convolutifs (CNN), classification, prétraitement, amélioration du contraste, VGG16, DenseNet121.

ABSTRACT

The automatic classification of breast tumors based on ultrasound images is a crucial challenge in the field of medical diagnosis support, as it facilitates the detection process and improves patient care. However, this task is considered complex due to several factors, including the inherent noise in ultrasound images, their low contrast, and the high morphological variability of the lesions. These constraints make the extraction of relevant features particularly difficult and limit the performance of traditional image processing approaches.

In this context, the goal of this project is to design and optimize deep learning-based models to improve the accuracy of breast tumor classification, which could represent a major advance in the clinical decision. The proposed approach relies on the use of deep neural network capable of automatically extracting discriminative features from raw data, while enhancing the models' robustness against variations in ultrasound image quality.

More specifically, this work aims to develop an automated system based on transfer learning, leveraging convolutional neural networks (CNN), for the detection and classification of breast lesions into three categories: benign, malignant, and normal. The project consists of two stages. The first, image pre-processing, aims to improve image quality and contrast. The second involves designing and training a high-performance model. This comprehensive approach aims to increase the effectiveness and reliability of computer-aided diagnosis of breast lesions.

Keywords: Transfer Learning, Breast Ultrasound Images, Convolutional Neural Networks (CNN), Classification, Pre-processing, Contrast Enhancement, VGG16, DenseNet121.

يُعد التصنيف التلقائي لأورام الثدي استناداً إلى صور الموجات فوق الصوتية تحدياً مهماً في مجال المساعدة في التشخيص الطبي، حيث يتيح تسهيل عملية الكشف وتحسين رعاية المرضى. ومع ذلك، تُعتبر هذه المهمة معقدة بسبب عدة عوامل، لا سيما التشويش المتأصل في صور الموجات فوق الصوتية، وتباينها المنخفض، فضلاً عن التباين الشكلي الكبير للآفات. تجعل هذه القيود استخراج الخصائص ذات الصلة أمراً صعباً للغاية وتحد من أداء الأساليب التقليدية لمعالجة الصور.

في هذا السياق، يهدف هذا المشروع إلى تصميم وتحسين نماذج قائمة على التعلم العميق من أجل تحسين دقة تصنيف أورام الثدي، مما قد يمثل تقدماً كبيراً في عملية اتخاذ القرارات. يعتمد النهج المقترح على استخدام شبكات عصبية عميقة قادرة على استخراج الخصائص المميزة تلقائياً من البيانات الأولية، مع تعزيز متانة النماذج في مواجهة التباينات في جودة صور الموجات فوق الصوتية.

وبشكل أكثر تحديداً، يهدف هذا العمل إلى تطوير نظام آلي قائم على التعلم بالنقل، بالاستفادة من الشبكات العصبية الالتفافية، للكشف عن آفات الثدي وتصنيفها إلى ثلاث فئات: حميدة، وخبيثة، وطبيعية. يتألف المشروع من مرحلتين. تهدف المرحلة الأولى، وهي المعالجة المسبقة للصور، إلى تحسين جودة الصور وتباينها. أما المرحلة الثانية فتتمثل في تصميم وتدريب نموذج عالي الأداء. ويهدف هذا النهج في مجمله إلى زيادة فعالية وموثوقية التشخيص المدعوم للآفات الثديية.

كلمات مفتاحية : التعلم بالنقل، صور الموجات فوق الصوتية للثدي، الشبكات العصبية الالتفافية (CNN)، التصنيف، المعالجة المسبقة، تحسين التباين، VGG 16، DenseNet 121.

TABLE DES MATIÈRES

Liste des figures	A
Liste des tableaux	C
Abréviation	D
Résumé	F
Abstract	G
Résumé en arabe	H

INTRODUCTION GÉNÉRALE 01

CHAPITRE I : L'ÉTAT DE L'ART SUR LE CANCER DU SEIN

I.1. Introduction	05
I.2. L'approche médicale de l'imagerie du sein	05
I.2.1. Anatomie du sein	05
I.2.2. Cancer du sein	06
I.3. Incidence et évolution du cancer du sein	07
I.3.1. Dans le monde	07
I.3.2. En Algérie	08
I.4. Facteurs de risque et facteurs protecteur de cancer du sein	08
I.5. Les symptômes du cancer du sein	09
I.6. Les types de cancer du sein	09
I.6.1. Les tumeurs bénignes	10
I.6.1.1. Définition	10
I.6.1.2. Types	10
I.6.1.3. Caractéristiques	10
I.6.1.4. Évolution	10
I.6.2. Les tumeurs malignes	11
I.6.2.1. Définition	11
I.6.2.2. Types	11
I.6.2.3. Caractéristiques	11
I.6.2.4. Évolution	11
I.7. Les techniques d'imagerie médicale du sein	12

I.7.1. L'échographie	12
I.7.2. L'imagerie par résonance magnétique	13
I.7.3. La mammographie	13
I.7.4. Biopsie	14
I.8. Choix de l'échographie	15
I.9. Tests diagnostiques	16
I.9.1. Examen clinique	16
I.9.2. Examens d'imagerie	16
I.9.3. Examens histologiques	16
I.9.4. Examens biologiques	17
I.9.5. Bilan d'extension	17
I.10. Conclusion	17

CHAPITRE II : APPRENTISSAGE PROFOND POUR LA DÉTECTION ET LA CLASSIFICATION

II.1. Introduction	19
II.2. Concept d'intelligence artificielle (IA)	19
II.3. Apprentissage automatique (Machine Learning)	20
II.3.1. Définition	20
II.3.2. Apprentissage supervisé	21
II.3.3. Apprentissage non supervisé	22
II.3.4. Apprentissage par renforcement	22
II.4. Apprentissage profond (Deep Learning)	23
II.4.1. Définition et description de l'apprentissage profond	23
II.4.2. Historique du Deep Learning	24
II.4.3. Domaines d'application du Deep Learning	26
II.4.4. Principe de fonctionnement du Deep Learning	26
II.4.4.1. La propagation avant (Forward Propagation)	26
II.4.4.2. L'évaluation de l'erreur via la fonction de perte	27
II.4.4.3. La rétropropagation du gradient (Backward Propagation)	27
II.4.5. Architectures et algorithmes principaux	28
II.5. Les réseaux de neurones	28
II.5.1. Le neurone biologique	28
II.5.2. Le neurone formel	29

II.5.3. Réseaux de Neurones Artificiels (MLP)	31
II.5.4. Réseaux de neurones profonds	31
II.5.4.1. Les réseaux de neurones convolutifs (CNN)	32
II.5.4.2. Les réseaux de neurones récurrents (RNN)	33
II.6. Les réseaux de neurones convolutifs (CNN)	33
II.6.1. Principe d'architecture d'un CNN	33
II.6.2. Les différentes couches de CNN	34
II.6.2.1. La couche de convolution	34
II.6.2.2. La couche d'activation (Activation Layer)	35
II.6.2.3. La couche de sous-échantillonnage (Pooling Layer)	36
II.6.2.4. La couche entièrement connectée (Fully Connected Layer)	37
II.6.3. La fonction du coût	37
II.6.3.1. Définition	37
II.6.3.2. Réduction de la fonction du coût	38
II.6.4. Apprentissage par transfert (Transfer Learning)	38
II.7. Travaux de recherches connexes basées sur les CNN pour le cancer du sein	39
II.8. Conclusion	40

CHAPITRE III : MISE EN ŒUVRE DU SYSTEME D'ANALYSE

III.1. Introduction	42
III.2. Environnement de développement	42
III.2.1. Outil de développement : Python	43
III.2.1.1. Définition et justification du choix	43
III.2.2. Base de données	44
III.3. Mise en place du système de la détection et de la classification	44
III.3.1. Objectif	44
III.3.2. Schéma général de conception	45
III.3.2.1. Prétraitement des images	45
III.3.2.1.1. Importance du prétraitement	45
III.3.2.1.2. Correction des artefacts	45
III.3.2.1.3. Normalisation des intensités	47
III.3.2.1.4. Réduction du bruit	47
III.3.2.1.5. Évaluation de l'efficacité du processus de prétraitement	47
III.3.2.2. Détection et classification des images mammaires	50

III.3.2.2.1. Les architectures du DenseNet121& VGG16 : Modèles (CNN)	50
III.3.2.2.1.1. Le modèle VGG16	50
III.3.2.2.1.2. Le modèle DenseNet121	52
III.3.2.2.2. Les métriques d'évaluation de la classification	54
III.4. Résultats expérimentaux	57
III.4.1. Présentation des résultats	58
III.4.2. Analyse et discussion	59
III.5. Conclusion	63

CHAPITRE IV : CONCLUSION GÉNÉRALE

IV.1. Récapitulatif	64
IV.2. Perspectives	66

BIBLIOGRAPHIE	67
----------------------	----

INTRODUCTION GENERALE

Le cancer du sein constitue aujourd'hui un problème majeur de santé publique à l'échelle mondiale. Il s'agit du cancer le plus fréquemment diagnostiqué chez la femme et l'une des principales causes de mortalité féminine. Selon les rapports de l'organisation mondiale de la santé (OMS), des millions de nouveaux cas sont enregistrés chaque année, avec une augmentation notable dans les pays en développement. Cette situation s'explique par plusieurs facteurs, notamment le vieillissement de la population, l'évolution des modes de vie et l'amélioration des techniques de dépistage, qui permettent de détecter la maladie plus précocement.

En Algérie, le cancer du sein est également le premier cancer chez la femme, tant en termes d'incidence que de mortalité. Les statistiques publiées par les registres nationaux indiquent une progression continue du nombre de cas ces dernières années. Cette évolution souligne la nécessité de renforcer les mesures de prévention, de dépistage et de diagnostic précoce afin d'améliorer le traitement des patientes et de réduire les taux de mortalité.

Le diagnostic du cancer du sein repose principalement sur des techniques d'imagerie médicale, comme la mammographie, l'échographie et l'imagerie par résonance magnétique (IRM). L'échographie occupe une place importante dans ce cadre, notamment chez les femmes jeunes ou lorsque la densité mammaire rend la mammographie moins efficace. Elle permet d'identifier les anomalies et de distinguer les masses bénignes des masses suspectes. Cependant, l'interprétation des images échographiques est une tâche complexe qui dépend fortement de l'expertise du radiologue, ce qui peut entraîner des variations dans le diagnostic.

L'augmentation continue du volume et de la complexité des images médicales a rendu indispensable le recours à des outils informatiques pour faciliter leur traitement et leur analyse. Dans ce contexte, les algorithmes de classification d'images occupent une place centrale dans de nombreuses applications d'imagerie médicale, notamment pour automatiser la délimitation des structures anatomiques et l'identification des régions d'intérêt.

Par ailleurs, l'évolution rapide des technologies numériques a favorisé l'émergence de l'intelligence artificielle et de l'apprentissage automatique comme des approches particulièrement prometteuses dans le domaine médical. Plus récemment, les méthodes

d'apprentissage profond (Deep Learning), et plus particulièrement les réseaux de neurones convolutifs (CNN), ont démontré des performances remarquables dans l'analyse et la classification des images médicales. Ces techniques permettent d'automatiser la détection des anomalies, d'améliorer la précision du diagnostic et de réduire considérablement le risque d'erreur humaine.

L'objectif de ce travail est de proposer une approche basée sur le traitement d'images et l'intelligence artificielle pour détecter et classer les anomalies mammaires à partir d'images échographiques. Plus précisément, il s'agit d'appliquer des techniques de prétraitement adaptées pour améliorer la qualité des données, puis d'exploiter ces dernières pour optimiser les performances de modèles de classification capables de distinguer trois classes : tumeurs bénignes, tumeurs malignes et cas sains.

La méthodologie adoptée repose sur deux étapes principales. La première étape, une phase de prétraitement est mise en œuvre pour améliorer la qualité et la pertinence des images échographiques. Deuxième étape, des modèles de classification sont développés et évalués afin de distinguer efficacement les différentes catégories de pathologies.

Ce manuscrit est constitué de trois chapitres organisés comme suit :

- Dans le premier chapitre, nous proposons une présentation générale du cancer du sein, en mettant en évidence ses principaux facteurs de risque, ses différentes formes et son impact sur la santé publique ; Nous y abordons également les techniques d'imagerie médicale utilisées pour son dépistage et son diagnostic, en accordant une attention particulière à l'échographie mammaire. Nous y présentons également les principes de fonctionnement des appareils d'échographie et leur rôle dans la détection précoce des anomalies.
- Le deuxième chapitre introduit les concepts fondamentaux de l'intelligence artificielle et met en évidence ses domaines d'application et ses principales approches. Il présente ensuite les bases de l'apprentissage automatique en expliquant ses principes et ses différentes catégories. Nous détaillons ensuite le rôle des réseaux de neurones convolutifs (CNN), notamment leur architecture, leurs couches et les fonctions de coût utilisées pour l'optimisation. Enfin, le chapitre aborde le transfert d'apprentissage, en soulignant ses avantages et ses limites, puis passe en revue des travaux récents utilisant les CNN pour la détection et la classification des anomalies mammaires à partir d'images échographiques.
- Dans le troisième chapitre, nous présentons la mise en œuvre des méthodes suggérées, à savoir DenseNet121 et VGG16, ainsi que les tests effectués et l'analyse des résultats

obtenus. Pour évaluer les résultats du prétraitement, nous utilisons des critères tels que le rapport signal sur bruit de crête (PSNR) et l'erreur quadratique moyenne (MSE). Dans le cadre de la classification, plusieurs métriques d'évaluation permettent de mesurer les performances.

Enfin, nous présentons une conclusion et les perspectives envisagées.

CHAPITRE I

L'ÉTAT DE L'ART SUR LE CANCER DU SEIN

Le cancer du sein est de plus en plus fréquent dans le monde et constitue un enjeu majeur de santé publique. Le diagnostic précoce est essentiel pour augmenter les chances de traitement et de survie, ce qui souligne l'importance du dépistage et de la recherche.

Dans ce chapitre, nous présentons le contexte médical de l'imagerie mammaire afin de situer le cadre d'utilisation de notre application. Nous y présentons les principales caractéristiques de cette maladie, ainsi que les différentes altérations du tissu mammaire, qu'elles soient normales, bénignes ou malignes. Nous abordons également les différents types de tumeurs du sein et leur classification. Cette présentation, qui n'a pas la prétention d'être exhaustive, vise à mieux comprendre la problématique étudiée et à introduire les méthodes employées pour la détection et la classification des anomalies dans les images médicales.

I.1. Introduction

Le cancer du sein constitue aujourd'hui un enjeu majeur de santé publique à l'échelle mondiale, car il touche toutes les populations, partout dans le monde, et représente un coût pour les systèmes de santé. C'est le cancer le plus fréquent chez la femme et l'une des principales causes de mortalité féminine. Toutefois, les progrès réalisés dans le domaine médical et technologique ont permis le développement de méthodes de diagnostic. Ces méthodes sont de plus en plus performantes. Elles favorisent une détection précoce de la maladie. Cela améliore ainsi significativement les chances de guérison.

Dans ce contexte, les techniques d'imagerie médicale occupent une place essentielle, notamment la mammographie, l'échographie et l'imagerie par résonance magnétique. Parmi ces outils, l'échographie se distingue par sa simplicité d'utilisation, son faible coût et son efficacité dans la détection des anomalies mammaires. Toutefois, l'interprétation de ces images reste une tâche complexe, qui dépend fortement de l'expertise et de l'expérience du médecin.

Ces limites suscitent de plus en plus d'intérêt pour les approches axées sur le traitement d'images et l'intelligence artificielle, ce qui est un domaine de recherche en pleine expansion. Celles-ci offrent en effet des perspectives prometteuses pour assister les professionnels de santé, améliorer la précision du diagnostic et contribuer à une prise en charge plus efficace des patientes.

I.2. L'approche médicale de l'imagerie du sein

L'imagerie médicale désigne l'ensemble des techniques reposant sur des procédés physiques permettant de produire des images d'une région anatomique ou d'un organe exploitable et interprétable à des fins médicales, quelle que soit la nature des ondes ou des radiations utilisées pour explorer le patient. Elle joue un rôle essentiel dans les campagnes de dépistage et contribue à améliorer la prise en charge et le pronostic des maladies graves, notamment le cancer du sein. Elle joue également un rôle croissant dans l'avancement de la médecine prédictive et personnalisée et se trouve au centre de nombreux programmes de recherche multidisciplinaire [1].

I.2.1. Anatomie du sein

L'organe en question se situe dans la partie antérieure du thorax, plus précisément entre la troisième et la cinquième côte, au-dessus du muscle grand pectoral. Il est pair et

symétrique. Sa structure comprend une glande mammaire, des fibres de soutien et du tissu adipeux ; le tout est protégé par la peau (voir la figure. I.1). La quantité de chacune de ces composantes peut varier d'une femme à l'autre. On y trouve également des nerfs, des vaisseaux sanguins et lymphatiques. La glande mammaire est divisée en 15 à 20 lobes, eux-mêmes composés de lobules. Ceux-ci sont reliés à des canaux qui se rendent sous le mamelon, situé au centre du sein. On observe également des chaînes de ganglions lymphatiques qui filtrent les microbes et protègent le corps contre l'infection et la maladie. Le cancer du sein peut se développer dans un canal galactophore, un lobule ou un ganglion lymphatique [1].




Figure I.1 - Anatomie du sein.

I.2.2. Cancer du sein

Le terme « cancer » désigne un ensemble de maladies caractérisées par une prolifération anarchique de cellules anormales dans l'organisme. Ces cellules peuvent s'accumuler et former une masse appelée tumeur. Lorsqu'il débute dans le tissu mammaire, on parle de cancer du sein. Il s'agit de l'un des cancers les plus répandus chez la femme dans le monde, et il constitue l'une des principales causes de mortalité féminine. On estime qu'une femme sur dix peut être touchée au cours de sa vie [2].

Le cancer du sein apparaît généralement dans les canaux galactophores ou dans les lobules de la glande mammaire. Lorsqu'il prend naissance dans les canaux, on parle de carcinome canalaire, qui est la forme la plus fréquente. S'il se développe dans les lobules, il est appelé carcinome lobulaire. Dans certains cas, les cellules cancéreuses peuvent se détacher de la tumeur initiale et se propager à d'autres parties du corps par le système sanguin ou lymphatique. Ce processus est appelé métastase et on parle alors de cancer du sein métastatique [3], [4].

I.3. Incidence et évolution du cancer du sein

I.3.1. Dans le monde

Selon l'Organisation mondiale de la santé (OMS) et le Centre international de recherche sur le cancer (CIRC), le cancer du sein figure parmi les cancers les plus fréquemment diagnostiqués dans le monde, avec près de 1,3 million de nouveaux cas recensés chaque année (voir la figure I.2). En 2018, il représentait environ 11,6 % des nouveaux cas de cancer, se plaçant ainsi devant le cancer colorectal et le cancer du poumon. Il est également la cinquième cause de mortalité par cancer dans le monde, avec environ 627 000 décès, soit 6,6 % de l'ensemble des décès par cancer. Son pronostic reste relativement favorable, notamment dans les pays développés.

Chez la femme, il représente environ un cas de cancer sur quatre et un décès sur six, occupant ainsi la première place en termes d'incidence et de mortalité dans de nombreux pays (respectivement 159 et 110 pays). L'incidence est généralement plus élevée dans les pays développés que dans les pays en développement. Cette pathologie touche principalement les femmes de plus de 40 ans et seule une faible proportion (environ 5 %) est liée à des facteurs purement génétiques précoces [5].

La répartition mondiale des taux d'incidence standardisés pour 100 000 femmes montre de fortes disparités : les taux les plus faibles (inférieurs à 30 pour 100 000) sont observés en Asie centrale, du Sud, de l'Est et du Sud-Est, en Afrique et en Amérique centrale. Des niveaux intermédiaires (entre 40 et 70/100 000) sont enregistrés en Europe du Sud, en Asie du Nord et en Amérique du Sud. Enfin, les taux les plus élevés (supérieurs à 70/100 000) concernent l'Europe du Nord et de l'Ouest, l'Océanie ainsi que l'Amérique du Nord [7].




Figure I.2 - Incidence standardisée de cancer du sein dans le monde pour 100 000 femmes.

I.3.2. En Algérie

En Algérie, le cancer du sein est le cancer le plus fréquent chez la femme et la première cause de mortalité par cancer. On y enregistre environ 11 847 nouveaux cas et 3 367 décès par année, pour un taux d'incidence standardisé de 55,6 pour 100 000 femmes et un taux de mortalité de 16,2 pour 100 000 femmes. Il occupe la première place dans plusieurs registres nationaux, avec des variations régionales du taux d'incidence [8]. Par exemple, l'incidence a atteint 69,7 pour 100 000 femmes à Alger, 63 pour 100 000 à Oran en 2015, et environ 49,2 pour 100 000 à Sétif. De manière générale, l'incidence du cancer est plus élevée chez les femmes que chez les hommes, ce qui souligne l'importance du dépistage et du diagnostic précoce. La figure I.3 illustre la répartition du cancer du sein par tranche d'âge, exprimée pour 100 000 femmes, en 2014 (source : Épidémiologie du cancer du sein en Algérie).

Incidence de cancer du sein




Figure I.3 – Répartition par tranche d'âges de cancer du sein pour 100 00 femmes, année 2014.

I.4. Facteurs de risque et facteurs protecteur de cancer du sein

Le cancer du sein est une maladie multifactorielle et complexe dont le développement résulte de l'interaction de plusieurs éléments. Bien que sa cause exacte ne soit pas encore clairement identifiée, de nombreux facteurs de risque ont été mis en évidence par des recherches scientifiques. Certains de ces facteurs sont dits « modifiables », car ils peuvent être influencés par le mode de vie. Il s'agit notamment de l'alimentation, de la consommation d'alcool et de l'exposition à certaines substances chimiques présentes dans l'environnement. Maîtriser ces éléments peut contribuer à réduire le risque de développer la maladie [9].

D'autres facteurs, comme les prédispositions génétiques héritées des parents, y compris certaines mutations pouvant accroître la vulnérabilité au cancer du sein, sont en revanche non modifiables et ne peuvent pas être contrôlés individuellement. Les données scientifiques actuelles suggèrent ainsi que le cancer du sein ne résulte pas d'une cause unique, mais plutôt d'une combinaison de facteurs génétiques, environnementaux et liés au mode de vie qui interagissent entre eux dans le processus de développement de la maladie.

À l'inverse, certains éléments peuvent avoir un effet protecteur. On peut citer notamment l'allaitement maternel, l'activité physique régulière, le maintien d'un poids corporel sain et une alimentation équilibrée riche en fruits et légumes. Une grossesse précoce et plusieurs grossesses peuvent également réduire le risque de développer ce type de cancer.

I.5. Les symptômes du cancer du sein

Les symptômes de cette maladie varient d'une patiente à une autre et peuvent ne pas apparaître aux stades précoces. Cependant, certains signes cliniques sont fréquemment observés et doivent inciter à consulter. Le plus courant est l'apparition d'une masse ou d'un nodule au niveau du sein. Cette masse est généralement indolore et peut être détectée lors d'un auto-examen ou d'un examen clinique. Parmi les autres symptômes, on peut citer :

- Une modification de la taille ou de la forme du sein ;
- Une altération de la peau (aspect de « peau d'orange ») ;
- Un écoulement anormal au niveau du mamelon.
- Une rétraction du mamelon ;
- Une douleur persistante dans le sein ou l'aisselle.

Il est important de souligner que la présence de ces symptômes ne signifie pas nécessairement la présence d'un cancer, mais qu'une consultation médicale approfondie est nécessaire.

I.6. Les types de cancer du sein

Le sein peut être classé en trois états principaux : le sein sain, les lésions bénignes et les tumeurs malignes. Le sein sain correspond à un tissu mammaire normal, sans anomalie. Les lésions bénignes sont des anomalies non cancéreuses localisées, sans capacité d'invasion ou de métastase [9]. Les tumeurs malignes, en revanche, sont des proliférations cellulaires anormales et incontrôlées, capables d'envahir les tissus voisins et de se propager à d'autres organes.

I.6.1. Les tumeurs bénignes

I.6.1.1. Définition

Les tumeurs bénignes du sein sont des lésions non cancéreuses caractérisées par une prolifération cellulaire localisée et non invasive. Elles ne sont pas capables d'envahir les tissus voisins ni de produire des métastases. Bien qu'elles ne présentent généralement pas de danger vital, leur identification est importante pour écarter toute suspicion de malignité et assurer un suivi adéquat [10].

I.6.1.2. Types

Les lésions bénignes les plus fréquentes sont les kystes et les fibroadénomes mammaires. Les kystes mammaires sont des cavités remplies de liquide, voire de contenu semi-solide. Ils sont souvent liés aux variations hormonales du cycle menstruel ou à une obstruction des canaux galactophores. Leur taille peut varier et ils peuvent se présenter de manière isolée ou multiple [11].

Les fibroadénomes sont des tumeurs bénignes solides composées de tissu glandulaire et de tissu fibreux. Ils sont particulièrement fréquents chez les femmes jeunes et se présentent généralement sous forme de nodules bien délimités [12].

D'autres lésions bénignes peuvent également exister, telles que les adénoses ou les papillomes intra-canaux, mais elles sont moins fréquentes.

I.6.1.3. Caractéristiques

Les tumeurs bénignes sont généralement bien délimitées, mobiles à la palpation et indolores dans la plupart des cas. Leur croissance est lente et progressive. Elles n'envahissent pas les structures adjacentes et restent limitées au tissu mammaire. À l'imagerie, elles présentent souvent des contours réguliers, ce qui facilite leur distinction par rapport aux lésions malignes [13].

I.6.1.4. Évolution

L'évolution des lésions bénignes est le plus souvent stable. Certaines peuvent tout de fois fluctuer en taille en fonction des variations hormonales, notamment les kystes. Dans la plupart des cas, elles ne dégénèrent pas en cancer, mais un suivi médical régulier est recommandé pour surveiller toute modification morphologique [11].

I.6.2. Les tumeurs malignes

I.6.2.1. Définition

Les tumeurs malignes du sein correspondent à une prolifération cellulaire anormale, rapide et incontrôlée, qui peut envahir les tissus environnants et se propager à d'autres organes par voie lymphatique ou sanguine. Elles constituent le cancer du sein et représentent une pathologie grave qui nécessite une prise en charge précoce [14].

I.6.2.2. Types

Les cancers du sein sont classés selon leur origine histologique. Les formes les plus fréquentes sont les carcinomes canaux, qui prennent naissance dans les canaux galactophores et représentent la majorité des cas, et les carcinomes lobulaires, qui se développent à partir des lobules mammaires. Il existe également des formes plus rares, dont le comportement biologique et le degré d'agressivité peuvent varier.

I.6.2.3. Caractéristiques

Les tumeurs malignes sont souvent mal délimitées, dures et peu mobiles. Elles se caractérisent par une croissance rapide et infiltrante, avec une destruction progressive des tissus environnants. Elles peuvent envahir les ganglions lymphatiques et donner lieu à des métastases touchant d'autres organes, comme les os, les poumons ou le foie. La vitesse de progression varie en fonction du type de tumeur et de ses caractéristiques biologiques [14].

I.6.2.4. Évolution

L'évolution des tumeurs malignes est généralement progressive. En l'absence de traitement, elles ont tendance à grossir, à envahir les tissus environnants et à se disséminer à distance par voie lymphatique ou sanguine, ce qui provoque la formation de métastases. La rapidité de cette évolution dépend de plusieurs facteurs, notamment du type histologique, du grade tumoral et du stade de la maladie. Une détection précoce est donc essentielle pour améliorer le pronostic et réduire le risque de complications [14].

Dans ce contexte, il est important de distinguer le tissu mammaire sain des lésions bénignes et malignes. L'imagerie médicale, associée aux programmes de dépistage, est un outil majeur pour identifier précocement les anomalies mammaires et optimiser leur prise en charge.

I.7. Les techniques d'imagerie médicale du sein

La sénologie radiologique correspond à l'ensemble des examens radiologiques qui explorent le sein, pouvant être réalisés dans le cadre d'un dépistage (recherche d'une anomalie) ou d'un diagnostic (caractérisation d'une anomalie visualisée lors d'un examen de dépistage). Les outils d'imagerie médicale utilisés pour le dépistage et le diagnostic du cancer du sein sont l'échographie (imagerie par ultrasons), l'imagerie par résonance magnétique (IRM) et la mammographie (imagerie par rayons X). Nous présentons ci-dessous les différentes techniques existantes ainsi que leurs caractéristiques.

I.7.1. L'échographie

L'échographie mammaire est un examen d'imagerie qui utilise des ultrasons pour visualiser la structure du sein. Réalisée par un radiologue, elle consiste à appliquer une sonde sur la peau, après l'avoir recouverte de gel. Les ultrasons émis traversent les tissus et sont renvoyés sous forme d'échos lorsqu'ils rencontrent des obstacles. Ces signaux sont ensuite traités par un système informatique qui affiche en temps réel des images du sein sur un écran.

Le radiologue peut ainsi confronter les images obtenues aux résultats de la palpation du sein et des zones axillaires afin d'identifier d'éventuelles anomalies telles que des ganglions, des nodules ou des kystes (voir la figure I.4). L'échographie mammaire peut également servir à guider des gestes médicaux, comme une biopsie ou une ponction. La durée de l'examen est généralement comprise entre 5 et 10 minutes, mais peut être prolongée si un prélèvement est nécessaire. Dans le cadre du dépistage du cancer du sein, elle est le plus souvent réalisée en complément d'une mammographie. Bien qu'elle ne constitue pas un examen de dépistage à elle seule, elle permet de préciser la nature d'une lésion (liquide ou solide) et d'explorer plus efficacement les seins denses ou difficiles à analyser par mammographie, contribuant ainsi à un bilan sénologique complet [4], [15].



Figure I.4 - Échographie mammaire.

I.7.2. L'imagerie par résonance magnétique

L'IRM mammaire est une technique d'imagerie médicale qui permet d'analyser avec précision d'éventuelles anomalies au niveau des seins. Lors de l'examen, la patiente est installée en position allongée sur le ventre, sur une table confortable située au centre de l'appareil muni d'un aimant. Une série d'images est réalisée après l'injection d'un produit de contraste spécifique dans une veine du pli du coude. Il est essentiel de rester parfaitement immobile pendant toute la durée de l'examen afin d'obtenir des images de qualité (voir la figure I.5). Cette technique est particulièrement indiquée pour compléter l'évaluation d'une anomalie détectée lors d'une échographie ou d'une mammographie, ainsi que pour le suivi des patientes présentant un risque élevé de cancer du sein [4].




Figure I.5 - IRM mammaire.

En règle générale, l'IRM mammaire n'est pas utilisée comme examen de dépistage, sauf chez certaines femmes présentant un risque élevé, notamment en raison d'une mutation génétique ou d'antécédents familiaux importants. L'un des principaux avantages de cette technique est la fiabilité de ses résultats négatifs. En effet, lorsque l'analyse conclut à l'absence de lésion maligne, la probabilité de présence d'une lésion est extrêmement faible [15].

I.7.3. La mammographie

La mammographie est un examen d'imagerie qui permet de détecter précocement des anomalies, avant même l'apparition de symptômes. Elle permet ainsi d'identifier des cancers à un stade très précoce, parfois bien avant qu'ils ne soient palpables. Pour la réaliser, le manipulateur utilise un mammographe (voir la figure I.6), un appareil composé d'un tube émettant des rayons X et d'un dispositif de compression du sein. On distingue aujourd'hui deux types d'équipements : les mammographes conventionnels, qui produisent des films

radiologiques classiques, et les mammographes numériques, dotés de détecteurs permettant le traitement des images (agrandissement, ajustement du contraste ou aide au diagnostic assisté par ordinateur).

L'examen consiste à comprimer successivement chaque sein, puis à l'exposer à une faible dose de rayons X. Cette compression, effectuée à l'aide d'une plaque spécialement conçue et ajustée par un professionnel qualifié, est généralement bien tolérée. Elle permet d'étaler les tissus mammaires, améliorant ainsi la qualité de visualisation des structures internes tout en limitant la dose de rayonnement nécessaire [4], [15].



Figure I.6 - Appareil de mammographie.

I.7.4. Biopsie

Il s'agit d'un examen médical qui consiste à prélever un fragment de tissu au niveau d'une zone suspecte afin de l'analyser au microscope. Dans le cadre des pathologies mammaires, elle est pratiquée lorsque les examens d'imagerie, tels que la mammographie ou l'échographie, révèlent une anomalie qui nécessite une confirmation diagnostique.

Le prélèvement est généralement effectué à l'aide d'une aiguille fine ou d'un dispositif spécifique, sous anesthésie locale, afin de limiter l'inconfort de la patiente (voir la figure I.7). Selon la localisation de la lésion, la biopsie peut être guidée par imagerie (échographie, mammographie ou IRM) afin d'assurer une grande précision du geste. Les échantillons recueillis sont ensuite envoyés à un laboratoire d'anatomopathologie où ils sont examinés afin de déterminer la nature de la lésion (bénigne ou maligne). Cet examen est une étape essentielle pour établir un diagnostic définitif et orienter la prise en charge thérapeutique.

La biopsie est généralement rapide, peu invasive et bien tolérée. Elle peut parfois entraîner de légers effets secondaires, tels qu'un petit hématome ou une sensibilité locale, qui disparaissent spontanément en quelques jours.




Figure I.7 - Biopsie et ponction

I.8. Choix de l'échographie

Le recours à l'échographie mammaire s'inscrit dans une stratégie diagnostique adaptée au contexte clinique et aux résultats des autres examens d'imagerie. Elle est particulièrement pertinente pour affiner l'analyse d'anomalies déjà détectées et orienter la prise en charge.

Elle est notamment privilégiée pour caractériser la nature des lésions en distinguant les formations liquidiennes des masses solides, ce qui est déterminant pour l'évaluation diagnostique. Elle présente également un intérêt majeur chez les femmes ayant les seins denses, car certaines anomalies peuvent être difficilement visibles par d'autres techniques.

L'échographie est indiquée dans plusieurs situations cliniques, notamment pour explorer une masse palpable, analyser une anomalie suspecte identifiée à la mammographie ou encore pour assurer le suivi de certaines lésions. Elle joue également un rôle essentiel dans le guidage des gestes interventionnels, comme les biopsies ou les ponctions, en garantissant précision et sécurité. Elle permet également une exploration dynamique et en temps réel, ce qui facilite l'adaptation de l'examen en fonction des observations. Elle permet également d'évaluer les régions axillaires, notamment pour rechercher des adénopathies [16].

Toutefois, l'interprétation des résultats dépend largement de l'expertise de l'opérateur, ce qui peut influencer la qualité de l'examen. Elle ne remplace pas les examens de dépistage systématique, mais vient en complément pour une analyse plus approfondie. Ainsi, le choix de l'échographie repose sur sa capacité à compléter efficacement les autres modalités d'imagerie en apportant des informations supplémentaires essentielles à une évaluation diagnostique précise.

I.9. Tests diagnostiques

Les tests diagnostiques désignent l'ensemble des examens réalisés pour identifier, confirmer ou exclure la présence d'une pathologie. Dans le contexte des affections mammaires, et en particulier du cancer du sein, ils s'inscrivent dans une démarche structurée allant du dépistage à la confirmation histologique [17].

I.9.1. Examen clinique

L'évaluation débute par un interrogatoire et un examen clinique réalisés par un professionnel de santé. Cette étape permet de rechercher des signes évocateurs, comme une masse palpable, une modification de la peau, une rétraction du mamelon ou un écoulement anormal. La palpation des aires ganglionnaires, notamment axillaires, est également essentielle.

I. 9.2. Examens d'imagerie

Les techniques d'imagerie occupent une place centrale dans la détection et la caractérisation des anomalies mammaires.

- La mammographie est l'examen de référence pour le dépistage. Elle permet de détecter des lésions infracliniques, notamment des microcalcifications.
- L'échographie mammaire est utilisée en complément pour préciser la nature d'une lésion (solide ou liquidienne) et pour explorer les seins denses.
- L'IRM mammaire est indiquée dans des situations spécifiques, notamment en cas de doute diagnostique ou chez les patientes à haut risque.

I. 9.3. Examens histologiques

Lorsque les examens d'imagerie détectent une anomalie suspecte, un prélèvement tissulaire est effectué pour confirmer le diagnostic. La biopsie est l'examen de référence, car elle permet d'analyser les cellules et les tissus au microscope afin de déterminer si la lésion est bénigne ou maligne. Différentes techniques peuvent être utilisées, comme la cytoponction à l'aiguille fine ou la microbiopsie, généralement réalisées sous guidage échographique ou radiologique afin d'assurer un prélèvement précis.

Les résultats histologiques sont essentiels pour confirmer le diagnostic et orienter la prise en charge thérapeutique.

I. 9.4. Examens biologiques

Des analyses complémentaires peuvent être réalisées, notamment après confirmation du diagnostic. Elles incluent l'étude des récepteurs hormonaux et d'autres marqueurs tumoraux, qui sont essentiels pour orienter le choix du traitement.

I. 9.5. Bilan d'extension

Une fois le diagnostic de cancer confirmé, des examens supplémentaires peuvent être prescrits pour évaluer l'étendue de la maladie (métastases). Ce bilan peut inclure un scanner, une scintigraphie osseuse ou une IRM, selon les cas.

I.10. Conclusion

L'imagerie mammaire joue un rôle essentiel dans la compréhension, la détection et la prise en charge des pathologies mammaires, en particulier du cancer du sein, dont l'incidence est en augmentation à l'échelle mondiale comme en Algérie. Cette pathologie complexe peut être mieux appréhendée si l'on prend le temps de se familiariser avec l'anatomie mammaire, les facteurs de risque, les symptômes et les différents types de tumeurs.

Dans le cadre d'une démarche diagnostique, les techniques d'imagerie telles que la mammographie, l'échographie, l'IRM et la biopsie sont complémentaires et indispensables. Elles permettent non seulement de détecter précocement les lésions, mais aussi de les caractériser avec précision et d'orienter la prise en charge, ce qui se révèle être un atout considérable dans le cadre d'une approche médicale complète et efficace.

Dans ce contexte, l'échographie mammaire occupe une place importante, car elle permet d'analyser les lésions et de compléter les autres examens. Le diagnostic du sein repose ainsi sur une approche globale et multidisciplinaire visant à améliorer la précision du diagnostic et le suivi des patientes.

CHAPITRE II

APPRENTISSAGE PROFOND POUR LA DÉTECTION ET LA CLASSIFICATION

L'évolution des technologies numériques et de l'intelligence artificielle a profondément révolutionné le secteur médical, entraînant des changements majeurs dans les pratiques médicales et ouvrant de nouvelles opportunités pour les patients. Dans le domaine de l'imagerie médicale, les techniques fondées sur l'apprentissage profond offrent une opportunité significative d'optimiser l'analyse des images, en particulier dans le contexte de l'échographie mammaire. Elles contribuent à améliorer le diagnostic assisté, la détection des anomalies et la classification des pathologies.

Ce chapitre présente les notions fondamentales de l'intelligence artificielle, du Machine Learning, du Deep Learning et des réseaux neuronaux artificiels, qui sont des sujets d'actualité et qui sont au cœur des avancées technologiques actuelles. Il décrit également les architectures CNN. Ces dernières sont utilisées pour la classification des images médicales. Il évoque également différents travaux de recherche récents. Ces travaux sont consacrés à la détection du cancer du sein.

II.1. Introduction

L'évolution des technologies numériques et de l'intelligence artificielle a profondément transformé le domaine médical. Cela s'est notamment vérifié en oncologie mammaire. Les techniques d'imagerie médicale, telles que la mammographie, l'IRM et l'échographie, jouent un rôle essentiel dans le dépistage précoce du cancer du sein. Toutefois, l'interprétation des images reste dépendante de l'expertise des radiologues. Elle peut être affectée par plusieurs limitations. Celles-ci comprennent la fatigue cognitive et la variabilité des évaluations.

Des systèmes d'aide au diagnostic assisté par ordinateur (CAD), qui ont été développés grâce à l'intelligence artificielle, ont été conçus pour améliorer la précision du diagnostic. Les techniques de Deep Learning ont montré des performances remarquables. Cela concerne en particulier les réseaux de neurones convolutifs (CNN). Ces techniques ont été utilisées pour l'analyse automatique des images médicales. Elles ont notamment permis de détecter et de classer les tumeurs mammaires [18].

II.2. Concept d'intelligence artificielle (IA)

Le concept d'intelligence artificielle (IA), appelé en anglais *artificial intelligence* (AI), a été introduit par le mathématicien John McCarthy en 1956. L'expression « intelligence artificielle » fait référence à l'ensemble des méthodes, modèles et algorithmes qui permettent de créer des machines capables d'exécuter des tâches requérant habituellement l'intelligence humaine. Ces tâches comprennent notamment la compréhension, le raisonnement, la prise de décision ou encore l'apprentissage à partir de données. Selon le dictionnaire français, l'intelligence artificielle regroupe un ensemble de théories et de techniques. Ces dernières visent à développer des systèmes informatiques. Ces systèmes sont capables de reproduire certaines capacités cognitives de l'être humain. Ces capacités sont telles que l'apprentissage, la perception ou la résolution de problèmes [19].

Autrement dit, l'IA est un domaine de l'informatique qui vise à créer des systèmes intelligents, capables de fonctionner de manière autonome ou semi-autonome. Ces systèmes peuvent analyser des informations, détecter des schémas, tirer des conclusions et s'adapter à de nouvelles situations sans intervention humaine constante. L'intelligence d'un système est ainsi évaluée par sa capacité à apprendre à partir de données. Elle est aussi évaluée par sa

capacité à s'améliorer avec l'expérience. Enfin, elle est évaluée par sa capacité à effectuer des tâches avec précision et efficacité.

Aujourd'hui, l'intelligence artificielle, qui est un domaine de recherche en pleine expansion, occupe une place importante dans de nombreux secteurs, allant des sciences de l'ingénierie aux sciences de la vie, en passant par les technologies de l'information et les sciences sociales. Dans le domaine médical, elle aide au diagnostic et à la détection de maladies. Dans le secteur financier et bancaire, elle est employée pour la détection de fraudes et l'évaluation des risques. Dans les transports, elle permet de développer des véhicules autonomes et d'optimiser les trajets. Elle est également présente dans des domaines aussi divers que la sécurité, le droit, la logistique, l'industrie, la robotique, ainsi que dans le domaine militaire, où elle permet d'automatiser certaines tâches complexes et d'améliorer la prise de décision.

II.3. Apprentissage automatique (Machine Learning)

II.3.1. Définition

L'apprentissage automatique, ou Machine Learning, est une branche de l'intelligence artificielle (voir figure II.1). Elle permet à un système informatique d'apprendre à partir de données pour améliorer ses performances dans une tâche donnée. Contrairement à l'apprentissage par renforcement, l'apprentissage automatique n'exige pas que le système soit programmé de manière explicite pour chaque situation. Autrement dit, au lieu de coder des règles fixes, l'entraînement d'un modèle à reconnaître des régularités dans un ensemble de données permet ensuite de faire des prédictions ou des décisions sur de nouvelles données.




Figure II.1 - Diagramme d'inclusion des sous-champs de l'Intelligence Artificielle, du Machine Learning et du Deep Learning.

En Machine Learning, on distingue trois grands types d'apprentissage : l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement. Le processus d'apprentissage est divisé en deux phases. La première, l'entraînement, permet au modèle d'ajuster ses paramètres internes pour réduire l'écart entre ses prédictions et les valeurs réelles. Une phase de test permet ensuite d'évaluer sa capacité à généraliser, c'est-à-dire à appliquer à un ensemble d'exemples les connaissances acquises en réponse à des questions précises [20].

II.3.2. Apprentissage supervisé

En diagnostic médical automatisé, l'apprentissage supervisé est une approche centrale. Elle est basée sur l'utilisation de données annotées par des experts. Chaque échantillon est représenté par des caractéristiques. Ces caractéristiques sont extraites des images. Elles sont associées à une étiquette. Cette étiquette correspond au diagnostic réel. Vous pouvez voir ce diagnostic réel dans la figure II.2.

Ce paradigme se base essentiellement sur deux types de tâches : la classification, qui permet d'attribuer une catégorie (tumeur bénigne ou maligne), et la régression, qui sert à prédire des valeurs continues (comme la taille d'une tumeur ou des indicateurs biologiques). L'objectif est de construire un modèle performant en minimisant l'erreur entre, d'une part, les prédictions et, d'autre part, les valeurs réelles. Dans ce cadre, on utilise plusieurs méthodes classiques, notamment la régression logistique, les machines à vecteurs de support, les modèles bayésiens et les arbres de décision [20].




Figure II.2- Principe de l'apprentissage supervisé.

II.3.3. Apprentissage non supervisé

L'apprentissage non supervisé est une branche du machine learning. Il consiste à travailler sur des données non étiquetées. Ces données ne possèdent pas de variable cible. Elles ne donnent pas de réponses connues à l'avance. À la différence de l'apprentissage supervisé, il ne cherche pas à prédire une sortie, mais plutôt à analyser et à comprendre la structure interne des données. Son objectif principal est que des regroupements naturels, des relations cachées ou des patterns difficiles à identifier manuellement soient découverts automatiquement (cf. figure II.3).

Dans le domaine médical, on utilise l'apprentissage non supervisé pour regrouper des patients selon leurs similitudes, identifier des sous-types de maladies et détecter des anomalies dans les images médicales. Il permet également d'explorer de grandes bases de données pour découvrir des relations entre maladies et traitements. Cependant, ses résultats restent difficiles à interpréter et nécessitent une validation par des experts avant toute utilisation clinique [21].

Les méthodes les plus courantes pour cela incluent le clustering, comme l'algorithme K-means, qui regroupe les données similaires, ainsi que des techniques de réduction de dimension comme l'Analyse en Composantes Principales (ACP), qui simplifie les données tout en conservant l'essentiel de l'information.




Figure II.3- Modèle de réseau pour l'apprentissage non supervisé.

II.3.4. Apprentissage par renforcement

L'apprentissage par renforcement est un paradigme d'apprentissage où un agent apprend à prendre des décisions en interagissant directement avec un environnement

dynamique, sans disposer d'exemples de bonnes réponses (voir figure II.4). Il apprend par essais et erreurs, en fonction des récompenses ou pénalités reçues après chaque action.

À l'origine, l'apprentissage par renforcement était utilisé dans les domaines des jeux et de la robotique. Aujourd'hui, il a des applications importantes en médecine, notamment pour l'optimisation dynamique des traitements et l'aide à la prise de décision dans des systèmes médicaux intelligents. Les processus de décision markoviens formalisent ce processus. Dans ces processus, l'agent observe un état, choisit une action, puis reçoit une récompense et un nouvel état en retour. L'objectif est de maximiser les récompenses cumulées sur le long terme, en accordant plus ou moins d'importance aux gains futurs, en fonction des circonstances.




Figure II.4 - Principe de l'apprentissage par renforcement.

II.4. Apprentissage profond (Deep Learning)

II.4.1. Définition et description de l'apprentissage profond

L'apprentissage profond (ou Deep Learning, DL) s'affirme comme une rupture épistémologique majeure au sein de l'intelligence artificielle, marquant un tournant décisif dans la recherche en matière d'IA. Techniquement, on qualifie cette sous-catégorie d'apprentissage automatique de spécialisée. Elle repose sur l'implémentation de réseaux de neurones artificiels dits « profonds ». Ces derniers sont structurés par un empilement successif et massif de couches de calcul cachées.

La différence entre le Deep Learning et la machine learning classique est la suivante : le Deep Learning apprend automatiquement des représentations hiérarchiques à partir de données brutes, sans passer par une étape d'extraction manuelle de caractéristiques. À la différence des méthodes traditionnelles qui exigent un travail de « feature engineering », le Deep Learning fonctionne en apprentissage de bout en bout. Le modèle analyse directement

les données (comme des images) et apprend lui-même les éléments pertinents pour la classification [22].

Cette extraction hiérarchique s'opère selon une logique ascendante de bas niveau vers le haut niveau, comme l'illustre la figure II.5.

- Les couches initiales ont pour fonction de détecter des caractéristiques simples de l'image. Ces caractéristiques incluent les contours, les lignes et les variations d'intensité.
- Les couches intermédiaires permettent d'identifier des formes et des textures plus complexes en combinant ces éléments de base.
- Les couches profondes sont responsables de la construction de représentations sémantiques de haut niveau. Ces dernières correspondent à des signes diagnostiques pertinents. Ils permettent la classification finale de la lésion. Cette classification va de la malignité à la bénignité, avec une grande précision.




Figure II.5 - Extraction de caractéristiques dans un réseau profond.

II.4.2. Historique du Deep Learning

L'histoire du Deep Learning est une chronique scientifique et financière. Elle est caractérisée par de grandes percées théoriques. Puis, il y a des périodes de stagnation technologique et de scepticisme académique. Ces périodes sont communément appelées les « hivers de l'intelligence artificielle ».

La genèse mathématique et l'ère du perceptron (1943-1969) : l'acte de naissance conceptuel remonte à 1943. En effet, cette année-là, le neurophysiologiste Warren McCulloch et le mathématicien Walter Pitts publient un modèle logique. Ce modèle formalise le fonctionnement synaptique d'un neurone biologique [23]. C'est en 1958 que Frank Rosenblatt fait la démonstration concrète de cette théorie en mettant au point le perceptron : une machine

câblée qui a la capacité d'apprendre à classer des formes simples par ajustement itératif de poids. Toutefois, l'enthousiasme est brutalement freiné en 1969 par la publication de Marvin Minsky et Seymour Papert. Ces derniers démontrent rigoureusement que le perceptron linéaire est incapable de résoudre des problèmes de logique non linéaire. Ces problèmes sont aussi élémentaires que la fonction OU exclusif (XOR). Cette preuve mathématique, qui plonge le domaine dans son premier hiver, tarit les financements de la recherche pendant plus d'une décennie.

La renaissance de la discipline par la rétropropagation et l'émergence des CNN (1980 - 1998) : c'est au milieu des années 1980 que le domaine a connu un renouveau, grâce à la popularisation de l'algorithme de rétropropagation du gradient (backpropagation), développé par David Rumelhart, Geoffrey Hinton et Ronald Williams. La solution mathématique de cet algorithme permet d'entraîner des réseaux possédant des couches cachées (perceptrons multicouches ou MLP) en propageant l'erreur vers l'arrière selon la règle de dérivation en chaîne. En 1989, un tournant majeur dans l'histoire de la recherche est marqué par l'avènement du réseau de neurones convolutifs LeNet-5, conçu par le chercheur français Yann LeCun. Il s'agit d'une étape historique, car c'est la première fois qu'un réseau de ce type est mis en œuvre de manière fonctionnelle [24]. Les concepts modernes de filtres partagés et de sous-échantillonnage spatiaux sont introduits par LeNet-5, conçu pour la reconnaissance des chèques bancaires. Cependant, à la fin des années 1990, le manque crucial de données numérisées et la puissance de calcul limitée des processeurs de l'époque (CPU) empêchent ces modèles de passer à l'échelle, ce qui a des conséquences sur leur développement et leur utilisation. Les chercheurs se détournent à nouveau des réseaux de neurones pour se tourner vers les Machines à Vecteurs de Support (SVM), provoquant ainsi un second hiver dans la communauté scientifique.

L'explosion contemporaine et la révolution d'AlexNet (2012 à nos jours) : le grand tournant de l'histoire moderne de l'informatique se produit en 2012 lors de la compétition internationale ImageNet (ILSVRC). L'équipe d'Alex Krizhevsky et de Geoffrey Hinton y présente l'architecture AlexNet, un réseau convolutif profond qui pulvérise littéralement les méthodes classiques de vision par ordinateur en réduisant le taux d'erreur de classification de plus de 10 % [24]. Cette renaissance définitive n'est pas uniquement due à une modification des théories mathématiques, mais à la convergence de trois facteurs exogènes :

- L'avènement du Big Data (disponibilité de millions d'images pour l'entraînement) ;

- L'exploitation des processeurs graphiques (GPU - Graphics Processing Units) capables de paralléliser les milliards de multiplications matricielles inhérentes aux réseaux ;
- L'introduction d'astuces algorithmiques cruciales, comme la fonction d'activation ReLU et la régularisation par Dropout, qui ont permis de résoudre définitivement le problème d'évanouissement du gradient.

II.4.3. Domaines d'application du Deep Learning

Grâce à sa flexibilité architecturale, l'apprentissage profond (Deep Learning) trouve ses applications dans de nombreux domaines, ce qui en fait une technologie clé de la quatrième révolution industrielle. En vision par ordinateur, il est notamment utilisé dans les systèmes de navigation des véhicules autonomes, la reconnaissance faciale et la surveillance industrielle. Dans le traitement automatique du langage naturel (NLP), il permet de développer des modèles capables de comprendre, de traduire et de générer du texte de manière fluide. Il est également exploité en robotique, en finance algorithmique et en bio-informatique. Son impact est particulièrement important en imagerie biomédicale, où il permet de détecter des maladies telles que la rétinopathie diabétique, de segmenter des tumeurs cérébrales et d'analyser des cancers du sein en mammographie et échographie, jouant ainsi un rôle essentiel dans l'aide au diagnostic médical [21], [24].

II.4.4. Principe de fonctionnement du Deep Learning

Le fonctionnement interne d'un réseau de neurones profonds repose sur un processus mathématique itératif d'optimisation structuré en trois phases fondamentales : la propagation avant (ou Forward Propagation), qui permet de produire une prédiction à partir des données d'entrée ; le calcul de l'erreur (ou fonction de perte), qui mesure l'écart entre la prédiction et la valeur attendue ; et la rétropropagation du gradient (ou Backward Propagation), qui permet de mettre à jour les paramètres à l'aide d'un algorithme d'optimisation afin de réduire progressivement cette erreur.

II.4.4.1. La propagation avant (Forward Propagation)

Lors de cette étape, les données brutes sont injectées dans la couche d'entrée du réseau. Le signal se propage de couche en couche. À chaque couche successive notée l , les neurones effectuent une transformation affine des activations de la couche précédente $A^{[l-1]}$, pondérée

par une matrice de poids $W^{[l]}$ et ajustée par un vecteur de biais $b^{[l]}$. Le résultat intermédiaire $Z^{[l]}$ est ensuite soumis à une fonction d'activation non linéaire $g^{[l]}$ pour générer l'activation de sortie $A^{[l]}$:

$$\begin{aligned} Z^{[l]} &= W^{[l]} A^{[l-1]} + b^{[l]} \\ A^{[l]} &= g^{[l]}(Z^{[l]}) \end{aligned} \quad \dots \text{ (II.1)}$$

II.4.4.2. L'évaluation de l'erreur via la fonction de perte

Une fois la prédiction $\hat{y}$ obtenue, il est nécessaire de quantifier mathématiquement l'écart entre cette prédiction et l'étiquette réelle y . Dans le cadre d'un problème de classification multiclassées comportant trois catégories (normale, bénigne et maligne), la métrique de perte la plus couramment utilisée est l'entropie croisée catégorielle (Categorical Cross-Entropy, CCE) [25]. Pour un échantillon donné, elle s'exprime par la formule suivante :

$$L(\hat{y}, y) = - \sum_{i=1}^3 y_i \cdot \log(\hat{y}_i) \quad \dots \text{ (II.2)}$$

Où y_i représente la valeur réelle de la classe i et $\hat{y}_i$ la probabilité prédite par le modèle pour cette même classe.

Cette fonction de perte mesure la divergence entre la distribution de probabilités prédite par le réseau et la réalité. Elle atteint sa valeur minimale lorsque le modèle attribue une forte probabilité à la bonne classe et de faibles probabilités aux autres. À l'inverse, la perte augmente lorsque le modèle attribue une forte probabilité à une classe incorrecte. Lorsque la probabilité prédite pour la classe réelle tend vers zéro, la perte devient très élevée, ce qui pénalise fortement les erreurs de classification et oriente l'apprentissage vers des prédictions plus précises.

II.4.4. 3. La rétropropagation du gradient (Backward Propagation)

Afin de remédier à cette erreur, il incombe au réseau de procéder à une mise à niveau de ses millions de paramètres. C'est le rôle de la rétropropagation. La perte est calculée par l'algorithme en fonction de chaque poids de chaque couche. Pour cela, il exploite la règle de dérivation des fonctions composées (Chain Rule). Le résultat est un vecteur de gradients.

$$\nabla_W L = \partial L / \partial W \quad \dots \text{ (II.3)}$$

Une fois les gradients calculés, un algorithme d'optimisation (comme la descente de gradient stochastique ou l'optimiseur Adam) met à jour les poids en se déplaçant dans la direction opposée au gradient. Cela permet de minimiser la perte. Cette mise à jour est modulée par un hyperparamètre critique, auquel est attribuée la dénomination « taux d'apprentissage » (Learning Rate, α).

$$W^{[l]} \leftarrow W^{[l]} - \alpha \cdot \frac{\partial L}{\partial W^{[l]}} \quad \dots \text{(II.4)}$$

Ce cycle (Propagation avant $\rightarrow$ Calcul de la perte $\rightarrow$ Rétropropagation $\rightarrow$ Mise à jour) est répété sur des milliers d'itérations jusqu'à ce que le réseau converge vers un état de performance stable.

II.4.5. Architectures et algorithmes principaux

Le Deep Learning dispose d'un catalogue diversifié d'architectures, chacune optimisée pour une topologie de données spécifique :

- Les Perceptrons Multicouches (MLP) : Réseaux à propagation avant classiques, limités aux données tabulaires ou de faible dimension.
- Les Réseaux de Neurones Convolutifs (CNN) : Rois de la vision par ordinateur, exploitant des filtres glissants pour extraire les corrélations spatiales locales des images.
- Les Réseaux de Neurones Récurrents (RNN) et LSTM : Adaptés aux données séquentielles et temporelles (signaux ECG, texte) grâce à l'intégration de boucles de mémoire internes.
- Les Vision Transformers (ViT) : Modèles récents basés sur les mécanismes de self-attention, capables de capturer des relations contextuelles à l'échelle globale d'une image.

II.5. Les réseaux de neurones

II.5.1. Le neurone biologique

La conception des architectures neuronales artificielles est le fruit d'une analogie bio-inspirée qui cherche à imiter les mécanismes de traitement de l'information du système nerveux central humain. Dans le tissu cérébral, le neurone biologique constitue l'unité cellulaire fondamentale de calcul. Sur le plan morphologique, il se compose de trois structures anatomiques interconnectées (voir l'illustration II.6) [26] :

- Les dendrites : Il s'agit d'un réseau arborisé de filaments fins qui agissent comme des canaux de réception. Elles collectent les signaux électrochimiques (potentiels d'action) émis par les neurones en amont.




Figure II.6 - Anatomie générale du neurone biologique.

- Le corps cellulaire (ou soma) : le noyau central de la cellule qui accumule, intègre et centralise la somme des charges électriques reçues à travers les dendrites. Si la charge électrique totale franchit un certain seuil critique, le soma génère un nouveau signal d'influx nerveux.
- L'axone : canal conducteur unique et allongé qui propage le signal électrique produit par le soma vers d'autres cellules nerveuses distantes.

La communication entre les neurones s'effectue au niveau des synapses. L'apprentissage biologique repose sur la plasticité synaptique : plus une connexion neuronale est sollicitée, plus elle se renforce. Ce mécanisme est comparable, en intelligence artificielle, à l'ajustement des poids des connexions entre neurones artificiels [26].

II.5.2. Le neurone formel

Le neurone formel, dont la première introduction a été faite par McCulloch et Pitts, est la transcription mathématique et cybernétique de la cellule biologique (voir figure II.7). Il s'agit d'un opérateur logique et algébrique élémentaire. Cet opérateur transforme un vecteur d'entrées en un signal scalaire de sortie [27]. Considérons un neurone artificiel recevant un ensemble de signaux d'entrée regroupés dans une vectrice colonne $X = [x_1, x_2, \dots, x_n]^T \in R_n$. À chaque entrée x_i est attribué un coefficient multiplicateur $w_i \in R$, appelé poids

synaptique, qui quantifie l'importance ou l'influence de cette entrée spécifique sur la décision du neurone. De plus, une constante additive $b \in R$, baptisée biais, est introduite pour contrôler le niveau d'excitation global du neurone (indépendamment des entrées).




Figure II.7 - Schéma de principe d'un neurone artificiel.

L'activité du neurone formel est segmentée en deux opérations mathématiques successives :

- **La combinaison linéaire (ou somme pondérée) :** Le neurone calcule le produit scalaire entre le vecteur d'entrée X et le vecteur de poids W , augmenté du biais b , pour générer une variable intermédiaire $z \in R$:

$$z = \sum_{i=1}^n w_i x_i + b = W^T X + b \quad \dots (II.5)$$

- **La transformation non linéaire (Fonction d'activation) :** Afin de doter le réseau d'une capacité de modélisation complexe, le signal z est soumis à une fonction d'activation non linéaire $g(\cdot)$ pour produire l'activation finale a :

$$a = g(z) = g(W^T X + b) \quad \dots (II.6)$$

L'évolution des fonctions d'activation a profondément marqué les performances des réseaux :

- **La fonction sigmoïde (ou logistique) :** transforme toute valeur réelle en une valeur comprise dans l'intervalle $[0, 1]$, ce qui permet d'interpréter la sortie comme une probabilité. Elle est principalement utilisée pour les problèmes de classification binaire (deux classes). Elle est définie par :

$$\sigma(z) = \frac{1}{1+e^{-z}} \quad \dots (II.7)$$

- **La fonction Softmax** : utilisée pour les problèmes de classification multiclasse. Cela veut dire que si on a plus de deux classes, par exemple trois classes, on utilise la fonction Softmax dans la couche de sortie. Elle convertit les scores bruts (logits) en probabilités dont la somme est égale à 1, ce qui permet d'identifier la classe la plus probable. Elle est définie par :

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}, \quad i = 1, \dots, K \quad \dots \text{ (II.8)}$$

où K représente le nombre de classes. Dans le cas d'une classification à trois classes ($K=3$), la fonction Softmax calcule les probabilités des trois classes de manière à vérifier :

$$P(C_1) + P(C_2) + P(C_3) = 1.$$

- **La fonction ReLU (Rectified Linear Unit)** : La fonction ReLU (Rectified Linear Unit) est aujourd'hui la fonction d'activation de référence pour les couches cachées des réseaux de neurones profonds. Elle remplace les valeurs négatives par zéro tout en conservant les valeurs positives inchangées, ce qui permet de résoudre le problème de la disparition du gradient et d'accélérer l'entraînement des modèles. Elle est définie par [27] :

$$\text{ReLU}(z) = \max(0, z) \quad \dots \text{ (II.9)}$$

II.5.3. Réseaux de Neurones Artificiels (MLP)

Le Perceptron Multicouche (Multi layer Perceptron - MLP) représente l'extension structurelle du neurone formel (Comme présenté dans la figure II.8). Il s'agit d'une architecture en réseau à propagation avant (Feedforward) où les neurones sont regroupés par structures horizontales appelées couches [27]. Un MLP comprend obligatoirement :




Figure II.8 - Analogie entre neurone biologique et neurone artificiel.

Un réseau de neurones artificiels comprend une couche d'entrée qui reçoit les données, une ou plusieurs couches cachées qui les transforment et en extraient les caractéristiques importantes, ainsi qu'une couche de sortie qui génère la prédiction finale.

II.5.4. Réseaux de neurones profonds

L'émergence des réseaux de neurones profonds (Deep Neural Networks - DNN) est issue d'une observation théorique et empirique liée à la structure des espaces de décision. Selon le Théorème d'Approximation Universelle (Cybenko, 1989), un réseau de neurones à propagation avant doté d'une seule et unique couche cachée contenant un nombre suffisant de neurones peut, en théorie, approcher n'importe quelle fonction continue sur un espace compact, avec une précision arbitraire [28]. Une seule couche cachée peut théoriquement résoudre des tâches complexes, mais elle nécessite un nombre très important de neurones lorsque la dimension des données augmente. Cela rend l'entraînement difficile et favorise le surapprentissage.

L'augmentation du nombre de couches cachées permet aux réseaux profonds de résoudre des problèmes complexes en les décomposant en opérations plus simples, ce qui les rend plus faciles à traiter. Chaque couche produit des représentations plus abstraites à partir des informations extraites par la précédente. Ce processus améliore la capacité d'apprentissage tout en nécessitant moins de paramètres qu'un réseau peu profond de performance équivalente [28].

II.5.4.1. Les réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs sont l'architecture spécialisée par excellence pour l'analyse d'images numériques, ce qui en fait une solution de pointe pour le traitement d'images. Les réseaux de type MLP classiques s'effondrent face aux images haute définition : si l'on injecte une simple image échographique de taille 256×256 pixels dans un MLP, le vecteur d'entrée possède 65536 dimensions, ce qui signifie qu'un seul neurone de la première couche cachée nécessitera 65536 poids. Une telle interconnexion globale entraîne une augmentation massive du nombre de paramètres. Cette situation conduit à une saturation de la mémoire et à un surapprentissage inévitable.

Les CNN résolvent cette limite fondamentale en introduisant une connectivité locale basée sur des champs récepteurs locaux, ce qui permet de créer des réseaux de communication plus étendus et plus efficaces. Les travaux de Hubel et Wiesel sur le cortex

visuel des mammifères ont inspiré les chercheurs. Ces derniers ont alors conçu des neurones pour un CNN. Ces derniers ne traitent pas l'image globalement. Ils le font par petites fenêtres spatiales successives [28]. De plus, le partage des poids implique que les mêmes filtres de convolution doivent être appliqués à l'ensemble de l'image. Cela réduit le nombre de paramètres à optimiser et confère au réseau une propriété mathématique cruciale : l'invariance par translation.

II.5.4.2. Les réseaux de neurones récurrents (RNN)

Pour établir une vue d'ensemble exhaustive de l'état de l'art en matière de calculs, il s'avère impératif de mettre en regard les réseaux de neurones convolutifs (convolutional neural networks - CNN) avec les réseaux de neurones récurrents (recurrent neural networks - RNN). Les CNN sont conçus pour manipuler des données spatiales et statiques, comme les matrices de pixels. Les RNN, quant à elles, sont structurées pour gérer des données séquentielles, ordonnées ou temporelles. Cela inclut des éléments tels que le texte, les séries chronologiques ou les signaux physiologiques continus, comme les ECG.

La spécificité architecturale d'un RNN réside dans la présence de connexions cycliques ou de boucles de rétroaction internes. À la différence des réseaux de propagation avant, où le flux d'information est unidirectionnel, un RNN garde une trace des calculs antérieurs. Il réexpose la sortie de l'état caché précédent comme entrée pour le calcul actuel.

II.6. Les réseaux de neurones convolutifs (CNN)

II.6.1. Principe d'architecture d'un CNN

L'architecture d'un réseau de neurones convolutif (CNN) est spécialement conçue pour exploiter la structure spatiale des images numériques, ce qui la rend particulièrement efficace pour ce type de données. À la différence des réseaux classiques qui transforment l'image en vecteur, les CNN traitent directement les données sous forme structurée. Cela permet de préserver les relations locales entre les pixels et d'extraire efficacement les informations visuelles pertinentes. L'architecture CNN standard est généralement composée de deux modules principaux organisés en série, comme illustré dans la figure II.9.

Le premier module, appelé bloc d'extraction de caractéristiques, applique une série d'opérations successives visant à identifier et à transformer les motifs présents dans l'image. Il combine des couches de convolution. Cela permet de filtrer les informations. Il inclut aussi

des fonctions d'activation. Celles-ci servent à introduire la non-linéarité. Il y a également des couches de sous-échantillonnage. Cela permet de réduire la dimension des données. Les éléments essentiels sont conservés.




Figure II.9 - Architecture générale d'un réseau CNN.

Le second module s'appelle bloc de classification. Il exploite les caractéristiques extraites. Cela permet de produire la décision finale. Les données sont d'abord aplaties. Elles sont ensuite transformées en un vecteur. Puis, elles sont traitées par des couches entièrement connectées. Cela permet de réaliser la classification finale à partir des représentations apprises.

II.6.2. Les différentes couches de CNN

II.6.2.1. La couche de convolution

La couche de convolution est la clé de voûte algorithmique d'un CNN. Son objectif principal est d'appliquer un ensemble de filtres numériques bidimensionnels, également appelés noyaux de convolution (kernels), sur l'espace de l'image d'entrée afin de capturer des signatures morphologiques locales (voir la figure II.10).

Sur le plan mathématique, si l'on considère une matrice d'entrée X de taille $(H \times W)$ et un noyau de convolution K de dimensions finies $(k_h \times k_w)$, l'opération de convolution discrète génère une nouvelle matrice S , appelée carte de caractéristiques. La valeur numérique de chaque coordonnée spatiale $S(i, j)$ est rigoureusement définie par la formule suivante :

$$S(i,j) = (X * K)(i,j) = \sum_{m=0}^{k_h-1} \sum_{n=0}^{k_w-1} X(i+m, j+n) \cdot K(m,n) + b \quad \dots (II.10)$$

Où $b \in \mathbb{R}$ représente le biais scalaire associé au filtre en cours d'application.




Figure II.10 - La couche de convolution.

L'évolution de la topologie spatiale des cartes de caractéristiques en sortie de cette couche est strictement gouvernée par la configuration de trois hyper paramètres fondamentaux :

- La taille du noyau ($k_h \times k_w$) : Généralement choisie impaire et symétrique (le plus souvent 3×3 ou 5×5) afin de garantir l'existence d'un pixel central unique.
- Le pas de glissement (Stride - S) : ce hyper paramètre définit le nombre de pixels dont le filtre se déplace le long de l'image à chaque étape de son balayage.
- Le rembourrage (Padding - P) : Opération consistant à injecter des lignes et des colonnes de pixels virtuels (généralement de valeur nulle, d'où le terme de Zero-Padding) tout autour de la périphérie externe de la matrice d'entrée.

Pour un volume d'entrée de dimensions ($H_{in} \times W_{in}$), les dimensions exactes de la carte de caractéristiques résultante ($H_{out} \times W_{out}$) sont mathématiquement régies par les équations suivantes :

$$\begin{aligned} H_{out} &= \lfloor H_{in} - k_h + 2P/S \rfloor + 1 \\ W_{out} &= \lfloor W_{in} - k_w + 2P/S \rfloor + 1 \end{aligned} \quad \dots (II.11)$$

II.6.2.2. La couche d'activation (Activation Layer)

La convolution étant une opération linéaire, l'empilement de plusieurs couches sans transformation supplémentaire reviendrait à une seule opération linéaire globale. Pour permettre au réseau d'apprendre des relations complexes, il est donc nécessaire d'introduire une non-linéarité après chaque convolution. La fonction d'activation la plus utilisée est la

ReLU, définie par $f(x) = \max(0, x)$, en raison de sa simplicité et de son efficacité computationnelle (cf. figure II.11).




Figure II.11 - La fonction d'activation (ReLU).

La fonction ReLU accélère l'apprentissage des réseaux de neurones et limite le problème de disparition du gradient grâce à sa dérivée constante pour les valeurs positives.

II.6.2.3. La couche de sous-échantillonnage (Pooling Layer)

Insérée périodiquement entre les blocs de convolution, la couche de pooling (ou réduction de la résolution spatiale) réduit les dimensions de hauteur et de largeur des cartes de caractéristiques tout en conservant le nombre de canaux intact (voir la figure II.12). Cette réduction présente l'avantage de limiter les risques de surapprentissage et de conférer au réseau une invariance locale par translation.




Figure II.12 - La couche de sous-échantillonnage (Pooling Layer).

Le pooling s'exécute en déplaçant une fenêtre glissante sur la carte de caractéristiques. Deux variantes mathématiques dominent la littérature :

• **Le Max-Pooling** : cette méthode extrait et conserve uniquement la valeur d'intensité maximale identifiée au sein de la fenêtre de calcul ;

$$P_{max} = \max_{i,j \in R} X(i, j) \quad \dots (II.12)$$

• **L'Average-Pooling** : Cette méthode calcule la moyenne arithmétique simple de l'ensemble des valeurs numériques contenues dans la fenêtre :

$$P_{avg} = \frac{1}{|R|} \sum_{i,j \in R} X(i, j) \quad \dots (II.13)$$

II.6.2.4. La couche entièrement connectée (Fully Connected Layer)

La couche entièrement connectée (Fully Connected Layer) constitue l'organe décisionnel final de l'architecture du CNN. Une fois que l'image d'entrée a été dépouillée de sa dimensionnalité spatiale par les filtres de convolution et les opérations de pooling, le tenseur tridimensionnel résultant est converti en un vecteur linéaire de taille d par l'opération d'aplatissement (flatten).

Chaque unité neuronale de la couche entièrement connectée possède un lien synaptique avec l'ensemble des éléments du vecteur d'entrée (voir la figure II.13). Pour la couche ultime du réseau (la couche de sortie), la fonction d'activation finale est choisie de manière à correspondre à la nature formelle du problème de classification posé.




Figure II.13 - La couche entièrement connectée (Fully Connected Layer).

II.6.3. La fonction du coût

II.6.3.1. Définition

La fonction du coût (ou fonction de perte) est une mesure mathématique qui évalue l'écart entre les prédictions du modèle et les valeurs réelles. Elle permet de quantifier la

performance du réseau pendant l'entraînement. Dans un CNN, la fonction du coût dépend du type de problème. Pour la classification, on utilise souvent : la Binary Cross-Entropy pour la classification binaire ou la Cross-Entropy pour la classification multiclasse

II.6.3.2. Réduction de la fonction du coût

L'objectif de l'apprentissage est de minimiser la fonction de coût afin d'améliorer la précision du modèle. Cette minimisation est réalisée de manière itérative à l'aide d'algorithmes d'optimisation. Des variantes plus avancées, telles qu'Adam, RMSprop ou la descente de gradient stochastique (SGD) avec momentum, permettent d'accélérer la convergence et d'améliorer la stabilité de l'apprentissage.

II.6.4. Apprentissage par transfert (Transfer Learning)

L'apprentissage par transfert, qui est une méthode d'apprentissage automatique, repose sur la réutilisation des connaissances acquises par un modèle préalablement entraîné sur une base de données de grande taille, généralement composée d'images généralistes comme ImageNet. Au lieu de concevoir un modèle entièrement à partir de zéro, cette approche consiste à utiliser un réseau préentraîné comme base, puis à l'adapter à une tâche spécifique en ajustant certaines couches du modèle (voir la figure II.14). Les couches initiales, qui apprennent des caractéristiques visuelles générales telles que les contours, les textures et les formes, sont conservées, tandis que les couches finales sont réentraînées pour répondre aux exigences de la tâche cible.

Cette approche est particulièrement pertinente en imagerie médicale, où les informations annotées sont souvent restreintes par le coût et le temps nécessaires à l'intervention des experts. En utilisant des images déjà apprises, l'apprentissage par transfert permet de réduire la quantité de données nécessaires pour l'entraînement tout en améliorant la capacité des modèles à comprendre et à utiliser des informations générales. Il permet également d'accélérer le processus d'apprentissage, de diminuer les ressources de calcul nécessaires et de limiter le risque de surapprentissage [29].

Dans la classification des images d'échographie mammaire, l'apprentissage par transfert est largement utilisé pour adapter des modèles préentraînés à des bases de données spécialisées. Après une phase de « fin-tuning », ces modèles apprennent les caractéristiques propres aux tissus mammaires et permettent de distinguer les cas sains, bénins ou malins. Cette approche permet d'améliorer les performances de classification en termes de précision,

de sensibilité et de spécificité, tout en réduisant le temps d'entraînement et les ressources de calcul nécessaires par rapport à un apprentissage à partir de zéro [30], [31].




Figure II.14 – Le principe de l'apprentissage par transfert (Transfer Learning).

II.7. Travaux de recherche connexes basées sur les CNN pour le cancer du sein

Parmi les architectures de réseaux de neurones convolutifs (CNN) les plus utilisées, on trouve VGG et DenseNet, qui sont deux modèles de réseaux de neurones convolutifs très performants. L'application de ces architectures à l'analyse des pathologies mammaires par ultrasons a donné lieu à d'importantes contributions scientifiques. Cette section passe en revue les travaux de référence qui valident l'utilisation de ces modèles dans le domaine biomédical.

L'étude menée par Byra et al. (2018) a porté sur l'évaluation du potentiel de l'apprentissage par transfert (Transfer Learning), en exploitant la régularité des filtres de la famille VGG pour caractériser les masses mammaires. Leurs expériences ont démontré que l'agencement de filtres fins 3×3 au sein de ces architectures permettait de capturer avec une grande précision les micro-textures tissulaires ainsi que l'irrégularité des contours des nodules malins. En ajustant le modèle sur une base d'échographies, ils ont obtenu une aire sous la

courbe (AUC) de 0,936, confirmant l'efficacité des descripteurs VGG pour l'imagerie ultrasonore [32].

Dans le cadre de l'exploitation de la base de données publique de référence BUSI (Breast Ultrasound Images), des chercheurs tels qu'Al-Dhabyani et al. (2020) ont mis en évidence la supériorité des connexions denses pour l'imagerie médicale. Leurs travaux ont démontré que l'architecture DenseNet, grâce au mécanisme de concaténation et de réutilisation des caractéristiques, s'avère particulièrement performante pour préserver les indices cliniques subtils tels que les ombres acoustiques postérieures générées par les carcinomes invasifs. Leur approche a validé une précision globale de 94,2 %, tout en affichant une convergence plus stable que les réseaux à connexions résiduelles classiques [33].

II.8. Conclusion

Ce deuxième chapitre a posé les bases théoriques, mathématiques et architecturales de l'intelligence artificielle appliquée au diagnostic médical automatisé. Il a retracé l'évolution de l'IA, des systèmes symboliques au machine learning, puis au Deep learning. Les principes des neurones formels, des MLP (Machine Perceptron Learning) et des CNN (Convolutional Neural Networks) ont fait l'objet d'une explication, avec la mise en évidence de l'intérêt de l'apprentissage de bout en bout pour l'extraction automatique des caractéristiques. Enfin, la fonction de perte et la rétropropagation ont été présentées pour expliquer le mécanisme d'optimisation des réseaux. Ce chapitre prépare ainsi le terrain pour le suivant, qui présentera la méthodologie expérimentale, le prétraitement des données et l'analyse des résultats.

CHAPITRE III

MISE EN ŒUVRE DU SYSTEME D'ANALYSE

Le dépistage, l'analyse et le diagnostic précoce du cancer du sein sont essentiels à l'amélioration du pronostic des patientes et à la réduction des coûts de prise en charge. Cependant, l'implémentation de méthodes de détection et de classification précoces efficaces est confrontée à de nombreux défis, qui dépendent des ressources médicales, des infrastructures sanitaires et des capacités technologiques de chaque pays.

Dans la section antérieure, une analyse approfondie des méthodologies de traitement d'images et des architectures de réseaux de neurones convolutifs (CNN) a été présentée. Ces sections ont ainsi permis de mettre en lumière les procédés et les structures spécifiques employées dans le cadre de la présente investigation. Dans le cadre de cette étude, les résultats de la détection et de la classification des images du sein sont présentés ici. L'objectif de cette étude est d'évaluer la capacité des différents modèles proposés à classer correctement les images mammaires en trois catégories : normales, bénignes ou malignes. Cette avancée permettra de contribuer à l'amélioration du diagnostic précoce du cancer du sein et d'assister les praticiens dans leur processus décisionnel.

III.1. Introduction

Le cancer du sein est une pathologie caractérisée par une prolifération anormale des cellules mammaires, aboutissant à la formation de tumeurs malignes. Ces tumeurs peuvent être bénignes lorsqu'elles restent localisées ou malignes lorsqu'elles envahissent les tissus adjacents et peuvent se propager à d'autres organes. La détection précoce, notamment par échographie mammaire, joue un rôle essentiel dans l'amélioration des chances de traitement et de guérison [34].

L'intelligence artificielle (IA), et plus particulièrement les réseaux de neurones convolutifs (CNN), occupe une place croissante dans le domaine de l'analyse automatisée des images médicales. Dans le cadre des échographies mammaires, ces techniques permettent de détecter et de classer les différents tissus. Elles contribuent ainsi à améliorer la précision du diagnostic et à soutenir la prise de décision clinique dans le cadre du dépistage précoce du cancer du sein [35].

Dans ce contexte, l'objet de notre travail porte sur l'utilisation de deux modèles d'apprentissage profond, à savoir le réseau de neurones DenseNet121 et le réseau de neurones convolutifs VGG16, pour la classification des images échographiques du sein. Ces modèles ont été sélectionnés en raison de leurs performances avérées dans la classification d'images médicales et de leur capacité à extraire des caractéristiques pertinentes et discriminantes.

L'objet de la présente étude est de concevoir et d'évaluer un système automatisé de détection et de classification du cancer du sein à partir de données échographiques. Ce système s'appuie sur l'utilisation de réseaux de neurones convolutifs (CNN), une architecture de réseau neuronal qui permet de traiter des images et de reconnaître des patterns spécifiques. Les CNN sont conçus pour distinguer les images normales des images présentant des lésions bénignes ou malignes. L'étude inclut une méthodologie rigoureuse qui comprend le prétraitement des images, l'entraînement des modèles et l'évaluation de leurs performances à l'aide de diverses métriques. Cette étude a pour objectif de démontrer l'efficacité de l'apprentissage profond en tant que dispositif d'aide au diagnostic précoce du cancer du sein, dans le but de faciliter son intégration dans la pratique clinique.

III.2. Environnement de développement

La mise en œuvre d'une application dédiée au cancer du sein nécessite une phase d'analyse préalable. Cette phase est essentielle pour identifier les besoins, les contraintes et les objectifs du projet. Elle permet de concevoir une solution adaptée. Dans le cadre de cette

étude, nous avons pour objectif de mettre au point un système informatique capable de repérer et d'identifier automatiquement les lésions mammaires à l'aide d'images échographiques. Pour cela, nous comptons utiliser le langage Python et les bibliothèques qui y sont associées, spécialisées dans le traitement d'images, l'apprentissage profond et l'intelligence artificielle.

III.2.1. Outil de développement : Python

III.2.1.1. Définition et justification du choix

L'implémentation complète des algorithmes d'apprentissage et des pipelines de classification d'images a été réalisée en langage Python (version 3.13). Elle a été centralisée au sein de l'environnement de développement intégré (IDE) Spyder. Selon Gonzalez et Woods, Python s'est imposé comme la norme académique et industrielle pour le prototypage de systèmes de vision artificielle grâce à sa syntaxe épurée et à sa gestion optimisée des calculs matriciels complexes à haute dimension. L'utilisation de l'interface Spyder nous a permis d'assurer une traçabilité rigoureuse des variables d'état, des tenseurs de données et des graphiques d'exécution lors des phases d'entraînement de nos scripts [36], [37].

Pour manipuler les matrices d'images et construire des réseaux de neurones, nous avons utilisé un écosystème de bibliothèques logicielles spécialisées :

- **TensorFlow (version 2.x) et Keras** : Framework open source de haut niveau dédiés à l'apprentissage profond, utilisés pour instancier les couches de convolution, injecter les poids préentraînés issus de la base ImageNet et compiler les graphes informatiques via des optimiseurs adaptatifs.
- **OS** : bibliothèque native permettant d'interagir avec le système d'exploitation afin d'automatiser l'exploration des répertoires physiques, la création de chemins dynamiques et l'indexation synchrone des fichiers d'images.
- **NumPy** : module fondamental pour le calcul scientifique qui exploite des structures de tableaux multidimensionnels (ndarray) hautement optimisées en mémoire, indispensables pour représenter et manipuler les canaux de luminance des images échographiques.
- **Matplotlib.pyplot et Seaborn** : Ces outils d'ingénierie graphique sont indispensables pour l'extraction visuelle des courbes d'apprentissage (évolution de la perte et de l'exactitude).
- **Sklearn.metrics** : issue de la suite Scikit-Learn, cette bibliothèque fournit les outils statistiques permettant de calculer le rapport d'évaluation global, incluant la précision, le rappel et le score F1 [38].

III.2.2. Base de données

La robustesse statistique et la capacité de généralisation de tout modèle fondé sur des réseaux de neurones convolutifs dépendent directement de la structure et de la représentativité de sa base de données. Les expérimentations de ce projet ont été menées à partir de la base de données clinique de référence BUSI (Breast Ultrasound Dataset), initialement introduite et documentée par [39]. Les clichés échographiques, acquis chez des patientes âgées de 25 à 75 ans, sont répartis de manière catégorielle en trois sous-dossiers distincts, modélisant les variables cibles du diagnostic médical :

- **benign** : clichés illustrant des altérations tissulaires non cancéreuses, telles que des fibroadénomes ou des kystes complexes, caractérisés par des contours nets et réguliers ;
- **malignant** : images caractérisées par des masses tumorales invasives (carcinomes), présentant des spéculations architecturales, des ombres acoustiques postérieures prononcées et des contours fortement irréguliers.
- **normal** : clichés de contrôle montrant l'intégrité des structures glandulaires mammaires, sans aucune présence de masse ou de distorsion focalisée [40].

Afin de garantir une évaluation fiable des performances du modèle, le dataset est divisé en deux sous-ensembles : un ensemble d'entraînement pour l'apprentissage et un ensemble de test pour la validation des résultats.

III.3. Mise en place du système de la détection et de la classification

III.3.1. Objectif

L'implémentation de notre pipeline technologique répond à un objectif clinique et technique précis : développer une solution automatique capable de catégoriser une image d'échographique mammaire inconnue avec une grande sensibilité. En minimisant le taux d'erreur, notamment le taux de faux négatifs, le système vise à réduire la variabilité d'interprétation entre les observateurs, qui est liée à l'expérience du praticien, et à sécuriser ainsi la prise de décision thérapeutique précoce.

Sur le plan méthodologique, l'objectif est également de comparer l'efficacité de deux architectures de réseaux de neurones convolutifs, DenseNet121 et VGG16, afin d'identifier celle qui s'adapte le mieux à la nature des données étudiées. Cette comparaison permettra d'évaluer non seulement la précision de la détection et de la classification, aussi que la robustesse et la capacité de généralisation du système proposé.

III.3.2. Schéma général de conception

Le système conçu suit une chaîne de traitement structurée (cf. figure III.1). Dans un premier temps, les images sont collectées puis soumises à une phase de prétraitement visant à améliorer leur qualité visuelle et à réduire l'impact des éléments perturbateurs. Les images prétraitées sont ensuite préparées pour l'apprentissage par redimensionnement, normalisation et, le cas échéant, transfert d'apprentissage. Enfin, les modèles CNN sélectionnés extraient automatiquement les caractéristiques discriminantes et produisent la décision de classification.

III.3.2.1. Prétraitement des images

Le prétraitement des images représente une étape clé dans les systèmes de détection et de classification des images échographiques du sein, puisqu'il permet d'optimiser la qualité des données en amont de leur exploitation par les modèles de Deep Learning.

III.3.2.1.1. Importance du prétraitement

L'imagerie par ultrasons est intrinsèquement sujette à des dégradations d'origine physique causées par les interactions complexes de l'onde sonore avec les tissus biologiques traversés (réflexion, réfraction et atténuation). Selon [41], [42], l'absence de prétraitement sur des images échographiques brutes dégrade fortement la phase d'apprentissage des réseaux de neurones, qui risquent alors de se focaliser sur des variations de contraste globales ou des bruits parasites plutôt que sur la morphologie géométrique réelle de la tumeur. Le prétraitement s'avère donc impératif pour harmoniser et nettoyer les entrées.

III.3.2.1.2. Correction des artefacts

En pratique, les appareils d'échographie mammaire intègrent automatiquement des informations techniques non médicales sur les images. Celles-ci comprennent la fréquence de la sonde (en MHz), l'échelle de profondeur, les repères temporels ainsi que les paramètres de l'équipement. La correction de ces artefacts est une étape essentielle du prétraitement des images échographiques du sein [43].

Cette correction de ces artefacts permet d'améliorer la qualité visuelle de l'image, de rendre la région d'intérêt plus clairement visible et de préserver les informations pertinentes relatives aux tissus mammaires et aux éventuelles lésions. Cette étape favorise donc une classification plus précise et facilite l'extraction des caractéristiques discriminantes utilisées pour la classification et le diagnostic assisté par ordinateur des anomalies mammaires [44].




Figure III.1 - Schéma général de conception.

III.3.2.1.3. Normalisation des intensités

La normalisation des intensités permet d'homogénéiser les niveaux de gris des images échographiques du sein afin de réduire les variations dues aux conditions d'acquisition. Dans les bases de données échographiques, certaines images peuvent présenter des différences de luminosité, de contraste ou de bruit, ce qui peut affecter l'analyse automatique. Sans normalisation, ces variations peuvent être interprétées à tort comme des caractéristiques pathologiques par le modèle. Cette étape améliore donc la cohérence globale du jeu de données et rend les images plus comparables entre elles [45].

Elle permet ainsi au réseau de se concentrer davantage sur les structures anatomiques et les anomalies mammaires réelles plutôt que sur les variations liées à l'acquisition. Dans les approches basées sur le transfert d'apprentissage, cette standardisation est particulièrement importante, car les modèles préentraînés exigent généralement des entrées normalisées selon un format spécifique.

III.3.2.1.4. Réduction du bruit

La réduction du bruit vise à atténuer les fluctuations indésirables présentes dans l'image, sans altérer l'information utile fournie par la lésion. Dans le cas des images médicales, le bruit peut provenir du capteur, de la compression ou de conditions d'acquisition imparfaites. Son traitement est important, car il peut altérer les contours, les détails fins et la texture, qui sont souvent des éléments discriminants dans l'analyse dermatologique.

L'enjeu de cette étape est de trouver un équilibre entre le nettoyage et la conservation de l'information. Un filtrage excessif peut lisser des détails importants, tandis qu'un filtrage insuffisant peut laisser persister des perturbations susceptibles d'affecter la qualité des prédictions. C'est la raison pour laquelle la réduction du bruit doit être intégrée dans une stratégie globale de prétraitement, évaluée quantitativement et visuellement [46].

IV.3.2.1.5. Évaluation de l'efficacité du processus de prétraitement

L'évaluation de l'efficacité du prétraitement des images échographiques mammaires est une étape importante. Elle permet de mesurer la qualité des transformations appliquées aux images. Cette étape est essentielle avant d'utiliser les images avec des modèles de Deep Learning. Elle permet également de vérifier l'impact des opérations de réduction du bruit, de normalisation et d'amélioration du contraste sur la qualité des données d'entrée. Pour ce faire, deux métriques quantitatives ont été utilisées : l'erreur quadratique moyenne, qui mesure

l'écart entre l'image originale et l'image traitée, et le rapport signal sur bruit de crête, qui permet d'évaluer la qualité de l'image reconstruite ou prétraitée. Ces indicateurs fournissent une mesure objective de l'efficacité des techniques de prétraitement utilisées.

a) Erreur quadratique moyenne (Mean Square Error (MSE))

L'erreur quadratique moyenne (MSE) est une métrique utilisée pour quantifier la différence entre une image originale et une image prétraitée, c'est-à-dire une image modifiée pour corriger certains défauts. Elle correspond à la moyenne des carrés des écarts entre les valeurs des pixels des deux images, ce qui implique de comparer chaque pixel de l'image initiale à celui de l'image transformée. Si la valeur de MSE est faible, alors les deux images sont très similaires. Cela indique qu'un prétraitement a été effectué avec succès. En revanche, si la valeur de MSE est élevée, alors les deux images sont très différentes. Cela indique qu'il y a eu une dégradation plus marquée [41].

Le MSE est défini par la formule suivante :

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (I(i, j) - K(i, j))^2 \quad \dots (III.1)$$

où $I(i, j)$ représente le pixel de l'image originale, $K(i, j)$ celui de l'image traitée, et m, n les dimensions de l'image.

b) Rapport crête signal sur bruit (Peak Signal to Noise Ratio (PSNR))

Le PSNR (Peak Signal-to-Noise Ratio), qui est une mesure dérivée du MSE, permet d'évaluer la qualité d'une image reconstruite par rapport à une image de référence. Exprimé en décibels (dB), il indique le rapport entre la puissance maximale du signal et la puissance du bruit introduit lors du traitement. Une valeur élevée du PSNR indique une meilleure qualité d'image, c'est-à-dire une image plus nette et une distorsion plus faible, et donc image plus fidèle à la réalité [43].

Le PSNR est défini par la formule suivante :

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

où MAX_I représente la valeur maximale des pixels de l'image (par exemple 255 pour une image en 8 bits).

Cette métrique permet d'évaluer la qualité des images après traitement. Elle permet également de vérifier que les opérations effectuées, comme l'ajustement du contraste ou de la luminosité, n'ont pas altéré de manière significative les informations visuelles. En pratique, une très bonne qualité d'image correspond à un PSNR supérieur à 40 dB, une bonne qualité par une valeur comprise entre 30 et 40 dB, une qualité moyenne par une valeur comprise entre 20 et 30 dB, et une faible qualité d'image est traduite par une valeur inférieure à 20 dB.

c) Résultats illustratifs

Les résultats du prétraitement peuvent également être évalués visuellement, en comparant les images avant et après traitement, ce qui permet de visualiser les modifications apportées. Cette comparaison permet d'observer à la fois la réduction du bruit, l'amélioration du contraste et la clarification des contours. En pratique, les résultats sont souvent présentés sous forme de figures et de tableaux. Ces observations qualitatives, qui offrent une évaluation plus complète de la qualité du processus de prétraitement (voir le tableau III.1) et viennent compléter les mesures quantitatives telles que le MSE et le PSNR.

Le tableau III.1 présente les valeurs de l'Erreur Quadratique Moyenne (MSE) et du Rapport Signal sur Bruit de Crête (PSNR) obtenues pour six images après l'étape de prétraitement. Les résultats montrent globalement des valeurs de MSE très faibles et des valeurs de PSNR élevées indiquant ainsi une bonne qualité des images traitées et une faible dégradation par rapport aux images d'origine (cf. figure III.2).

Les résultats montrent une qualité de reconstruction des images très élevée, avec des valeurs de PSNR comprises entre 48 et 51 dB, ce qui indique un faible niveau de distorsion. De manière générale, les images présentant un MSE plus faible ont logiquement un PSNR plus élevé, ce qui confirme la cohérence entre ces deux métriques. L'image 5 obtient les meilleures performances, avec le MSE le plus faible (0,497) et le PSNR le plus élevé (51,16 dB), ce qui en fait la reconstruction la plus fidèle à l'image d'origine. À l'inverse, l'image 3 présente les résultats les moins bons, avec le MSE le plus élevé (1,018) et le PSNR le plus faible (48,05 dB), ce qui indique une dégradation plus importante. Les autres images se situent entre ces deux extrêmes, avec des performances globalement proches et satisfaisantes, ce qui confirme la stabilité et l'efficacité du système de prétraitement pour l'ensemble des cas testés.

Dans l'ensemble, ces résultats confirment l'efficacité des techniques de prétraitement employées. La faible erreur MSE et les valeurs élevées de PSNR indiquent que les opérations

réalisées ont permis d'améliorer la qualité des images tout en préservant leurs caractéristiques essentielles, ce qui favorise de meilleures performances des modèles de classification basés sur le Deep Learning.

Tableau III.1- Résultats MSE et PSNR après le prétraitement des images échographiques mammaires.

IMAGE	MSE	PSNR (dB)
IMAGE 1	0.7666414221938775	49.28488080068766 dB
IMAGE 2	0.9294284119897959	48.44864416437363 dB
IMAGE 3	1.0184550382653061	48.05138499907073 dB
IMAGE 4	0.9733537946428571	48.24809634542835 dB
IMAGE 5	0.4973891900510204	51.163840185190494 dB
IMAGE 6	0.7312460140306123	49.49016849079182 dB

III.3.2.2. Détection et classification des images mammaires

III.3.2.2.1. Les architectures du DenseNet121& VGG16 : Modèles (CNN)

Le cadre méthodologique de cette recherche s'appuie sur le paradigme de l'apprentissage par transfert (Transfer Learning). En raison de la taille limitée de notre base de données, l'entraînement d'un réseau de neurones convolutifs profonds à partir de zéro entraînerait probablement un phénomène de sur apprentissage précoce [40]. Pour surmonter cette contrainte, nous utilisons des architectures de pointe préalablement entraînées sur la base de données ImageNet, dont les connaissances acquises sont réutilisées et adaptées à notre tâche spécifique [38].

III.3.2.2.1.1. Le modèle VGG16

Conçue par le Visual Geometry Group de l'Université d'Oxford, l'architecture VGG16 marque une étape importante dans l'évolution des réseaux de neurones convolutifs profonds. Sa philosophie de conception repose sur les principes de rigueur et d'homogénéité structurelle.




Figure III.2 - Résultat de prétraitement des images échographiques mammaires:

(a) image originale, (b) image après le prétraitement.

Contrairement aux réseaux précédentes, tels qu'AlexNet qui utilisaient des filtres de grande taille (11×11 ou 7×7) appliqués avec des pas variables, VGG16 standardise son

extracteur de caractéristiques en utilisant exclusivement des noyaux de convolution de très petite taille, soit 3×3 , associés à un pas de déplacement fixe (Stride=1) et un rembourrage préservant les dimensions spatiales (Padding =1) [22].

Le choix mathématique consiste à empiler plusieurs filtres 3×3 pour un bloc convolutif comportant C canaux d'entrée et C canaux de sortie :

- **Augmentation de la non-linéarité du modèle** : L'empilement de deux couches convolutives 3×3 possède le même champ récepteur effectif (Receptive Field) qu'une unique couche 5×5 unique . De même, trois couches 3×3 équivalent à une couche 7×7 . Cependant, l'utilisation de trois couches distinctes permet d'insérer trois fonctions d'activation non linéaires (ReLU) de manière successive. Cela accroît mathématiquement la capacité du réseau à modéliser des frontières de décision hautement complexes, qui sont cruciales pour capturer la texture fine d'une masse tumorale.

- **Réduction significative du nombre de paramètres à optimiser** : l'utilisation de plusieurs petits filtres convolutionnels permet de diminuer considérablement la complexité du modèle. Adoptée par VGG16, cette stratégie permet d'augmenter la profondeur du réseau tout en réduisant le nombre total de paramètres d'environ 45%, ce qui limite le risque de sur apprentissage et améliore la capacité de généralisation du modèle.

Structurellement, VGG16 est constitué de 13 couches de convolution et de 3 couches entièrement connectées. Ces couches sont organisées en cinq blocs convolutionnels successifs. Chaque bloc se termine par une opération de sous-échantillonnage (Max-Pooling) utilisant une fenêtre de 2×2 avec un pas de 2 (voir la figure III.3). Cette architecture permet de réduire de moitié la résolution spatiale des cartes de caractéristiques à la fin de chaque bloc, tout en augmentant progressivement le nombre de filtres, qui passe de 64 dans le premier bloc à 512 dans les derniers. Cette stratégie favorise l'extraction de caractéristiques de plus en plus abstraites et discriminantes, tout en concentrant l'information visuelle essentielle et en réduisant la charge de calcul du réseau.

III.3.2.2.1.1. Le modèle DenseNet121

L'architecture DenseNet121 (Densely Connected Convolutional Networks) marque un changement de paradigme radical dans la topologie des réseaux profonds.




Figure III.3- Structure séquentielle du réseau VGG16.

Dans un réseau séquentiel classique, le flux d'information traverse les couches de manière strictement linéaire: la couche l ne reçoit que le signal émis par la couche $l - 1$. Lorsque la profondeur d'un réseau augmente massivement (comme c'est le cas ici avec 121 couches), deux obstacles majeurs se présentent : d'une part, l'évanouissement du gradient lors de la rétropropagation (Vanishing Gradient) et, d'autre part, la perte progressive de l'information géométrique initiale (les pixels de la tumeur) au fil des transformations mathématiques successives [35].

DenseNet121 résout élégamment ces limitations en implémentant un schéma de connectivité dense. Au sein d'un même module, appelé "Dense Block", chaque couche est connectée directement à toutes les couches qui la précèdent et à toutes celles qui la suivent. Ainsi, pour une couche donnée l , les entrées ne se limitent pas à l'activation de la couche immédiatement antérieure, mais intègrent les cartes de caractéristiques de l'ensemble des couches précédentes, combinées par une opération de concaténation.

Cette connectivité exclusive confère à DenseNet121 des propriétés hautement avantageuses pour notre étude oncologique [35] :

- **Amélioration du flux de gradient :** Les gradients d'erreur calculés en sortie peuvent se propager directement vers les toutes premières couches du réseau sans subir d'atténuation au niveau des connexions directes, ce qui rend l'entraînement des 121 couches extrêmement stable.
- **Réutilisation systématique des caractéristiques:** Les couches les plus profondes du réseau ont un accès direct aux caractéristiques géométriques de bas niveau (contours nets, spicules, micro textures de l'échographie). Le modèle préserve ainsi l'intégrité visuelle de la lésion tout au long du traitement.

• **Efficacité des paramètres et compacité** : comme chaque couche réutilise les cartes des couches précédentes, elle n'a pas besoin de recalculer des informations redondantes. Le nombre de nouveaux canaux générés à chaque couche, défini par le taux de croissance (Growth Rate), peut ainsi être maintenu très faible (généralement $k = 32$), ce qui rend DenseNet121 beaucoup plus léger en termes de paramètres que d'autres architectures de profondeur équivalente.

Le modèle DenseNet121 est structuré autour de quatre Dense Blocs distincts (voir la figure III.4). Entre chaque bloc est intercalée une couche de transition (Transition Layer), composée d'une convolution 1×1 (visant à réduire le nombre de canaux) et d'un Average Pooling 2×2 , ce qui garantit une réduction progressive de la taille des tenseurs.




Figure III.4- Structure séquentielle du réseau denseNet121.

III.3.2.2.2. Les métriques d'évaluation de la classification

L'évaluation d'un système de classification ne saurait se limiter à une seule mesure. Dans le cas des bases de données médicales, il est essentiel d'utiliser plusieurs indicateurs pour évaluer les performances sous différents angles. En effet, un modèle peut afficher une bonne exactitude globale tout en étant peu efficace pour détecter une classe minoritaire ou cliniquement sensible. C'est la raison pour laquelle les métriques de robustesse, d'exactitude, de sensibilité, de spécificité, de précision et de FPR sont utilisées dans cette étude [37].

III.3.2.2.2.1. Évaluation de la robustesse

La robustesse d'un modèle correspond à sa capacité à maintenir des performances satisfaisantes en présence de variations des données d'entrée, comme des changements d'éclairage, de petites perturbations visuelles ou des différences de distribution entre les ensembles d'apprentissage et de test. Dans le domaine médical, cette qualité est essentielle, car les images réelles peuvent différer de celles utilisées pour l'entraînement. Un modèle robuste inspire davantage confiance pour une utilisation pratique.

III.3.2.2.2.2. Évaluation de la précision globale (Accuracy)

L'Accuracy représente la proportion de prédictions correctement réalisées par le modèle. Elle offre une vue d'ensemble du comportement du classificateur et constitue un premier indicateur de performance utile. Toutefois, dans un contexte de déséquilibre des classes, cette métrique peut s'avérer insuffisante, car un modèle peut obtenir une précision élevée tout en échouant à détecter correctement certaines catégories moins représentées [43].

La formule de l'Accuracy est la suivante :

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad \dots \text{ (III.3)}$$

Notre problème de classification comprend trois catégories : la première, « Normal », la deuxième, « Bénin », et la troisième, « Malin ». Pour déterminer les valeurs de TP, TN, FP et FN pour une classe spécifique (par exemple, la classe « Malin »), nous utilisons une approche de type « one-vs-rest » (une classe contre toutes les autres).

- TP (vrais positifs) : nombre d'images malignes correctement identifiées comme telles ;
- FN (False Negatives): nombre d'images malignes incorrectement classées comme normales ou bénignes ;
- FP (False Positives) : nombre d'images normales ou bénignes classées à tort comme malignes ;
- TN (True Negatives) : nombre d'images non malignes (normales ou bénignes) correctement reconnues comme telles.

III.3.2.2.2.3. Sensibilité (ou Recall)

La sensibilité, également appelée « Recall » ou « taux de vrais positifs (VP) », correspond à la capacité du modèle à identifier correctement les cas positifs. Dans le domaine médical, cette métrique est cruciale, car elle reflète la probabilité de détecter effectivement une lésion appartenant à une classe donnée. Une faible sensibilité signifie que le système laisse échapper un grand nombre de cas positifs, ce qui peut poser problème dans un contexte diagnostique [43].

La formule du Recall est donnée par :

$$\text{Recall} = \frac{\text{TP}}{(\text{TP} + \text{FN})} \quad \dots \text{ (III.4)}$$

où :

- TP: nombre de vrais positifs (True Positives),
- FN: nombre de faux négatifs (False Négatives).

III.3.2.2.2.4. Spécificité

La spécificité traduit la capacité du modèle à reconnaître correctement les cas négatifs. Autrement dit, elle évalue le pourcentage d'éléments sains ou non concernés qui ne sont pas classés à tort comme positifs. Dans les systèmes d'aide au diagnostic, une bonne spécificité permet de réduire les fausses alertes. Elle permet également d'éviter des examens complémentaires inutiles [43].

La formule de la spécificité est la suivante :

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad \dots \text{ (III.5)}$$

où:

- TN: vrais négatifs (True Négatives),
- FP: faux positifs (False Positives).

III.3.2.2.2.5. Précision

La précision correspond à la proportion de prédictions positives correctes. Elle permet donc de répondre à la question suivante : parmi l'ensemble des cas déclarés positifs par le modèle, combien le sont-ils effectivement. Cette métrique est importante lorsque le coût des faux positifs est élevé ou lorsque l'on cherche à garantir la fiabilité des alertes produites par le système [43].

La formule de la précision est donnée par :

$$\text{Precision} = \frac{TP}{TP+FP} \quad \dots \text{ (III.6)}$$

où :

- TP: nombre de vrais positifs (True Positives),
- FP: nombre de faux positifs (False Positives).

Une valeur élevée de la précision indique que la plupart des zones suspectes de cancer du sein identifiées sur les images d'échographie correspondent effectivement à des lésions cancéreuses, ce qui réduit le nombre de faux positifs.

III.3.2.2.6. False Positive Rate (FPR)

Le taux de faux positifs, ou FPR, exprime la proportion de cas négatifs classés à tort comme positifs. Il complète utilement la spécificité, dont il constitue en quelque sorte le pendant. Lors de l'évaluation d'un système médical, un FPR élevé signifie que le modèle génère trop d'alarmes incorrectes sont générées par le modèle, ce qui peut diminuer sa pertinence pratique malgré une bonne sensibilité [43].

La formule est :

$$\text{FPR} = \frac{FP}{FP + TN} \quad \dots \text{ (III.7)}$$

où :

- FP: nombre de faux positifs (False Positives),
- TN: vrais négatifs (True Négatives).

III.4. Résultats expérimentaux

Nous avons exploré différentes approches de classification basées sur l'apprentissage profond. Ces méthodes ont été appliquées à un ensemble d'images échographiques mammaires réelles pour d'identifier et de classer différents types de lésions.

Les images analysées sont en niveaux de gris et présentent des résolutions variables. Par exemple, une image peut avoir une résolution de 558×471 pixels, ce qui signifie qu'elle est composée de 558 pixels de large et de 471 pixels de haut. Bien que les images échographiques soient généralement codées en niveaux de gris avec une profondeur de couleur de 24 bits, Cette caractéristique, redondante pour les images médicales en niveaux de gris, facilite leur compatibilité avec certains algorithmes de traitement d'images. Elle permet

de conserver une bonne qualité d'image lors des étapes de prétraitement, d'extraction de caractéristiques et d'analyse automatique dans les systèmes de diagnostic assisté par ordinateur des lésions mammaires.

III.4.1. Présentation des résultats

Les données traitées correspondent à des images échographiques mammaires en niveaux de gris, généralement redimensionnées à des tailles uniformes afin de faciliter leur traitement par les modèles d'apprentissage profond. Cette série d'expérimentations porte sur des images médicales réelles, réparties en trois catégories : « normal », « bénin » et « malin ».

L'objectif est de permettre une classification automatique des images échographiques afin d'identifier les tissus sains et de distinguer les lésions bénignes des lésions malignes. Cette approche vise à améliorer la précision du diagnostic précoce et à orienter les patientes vers une prise en charge médicale adaptée.

Les objectifs de ces exemples sont les suivants :

- Une analyse détaillée des résultats expérimentaux obtenus dans le cadre de la tâche de classification ; Cette analyse s'appuie sur deux modèles de Deep Learning : DenseNet121 et VGG16. Elle prendra en compte l'impact de deux techniques de prétraitement appliquées aux images : l'amélioration du contraste et la détection des artefacts. Son but est d'évaluer leur contribution aux performances des modèles.
- Identifier le modèle le plus performant : Cette étape consiste à comparer les performances des différentes architectures de Deep Learning utilisées, comme DenseNet121 et VGG16, à l'aide de plusieurs métriques d'évaluation telles que l'exactitude (Accuracy), la précision (Precision), le rappel (Recall) et la Spécificité. L'objectif est de déterminer le modèle qui offre le meilleur compromis entre capacité de généralisation, robustesse et efficacité de classification.
- L'ambition de cette analyse est d'évaluer l'impact de la strate de transition employée entre l'extracteur de caractéristiques et les strates de classification. Pour ce faire, nous étudierons l'impact des couches Flatten et Global Average Pooling (GAP), ainsi que de leurs différentes architectures. La couche Flatten convertit les cartes de caractéristiques en un vecteur unidimensionnel, augmentant ainsi considérablement le nombre de paramètres entraînaables. En revanche, la couche Global Average Pooling (GAP) réduit chaque carte de caractéristiques à une seule valeur représentative, ce qui limite la complexité du modèle. L'étude comparera les performances, la capacité de généralisation, le risque de

sur apprentissage et le coût computationnel de ces deux approches, tout en analysant leur comportement au sein des architectures DenseNet121 et VGG16.

III.4.2. Analyse et discussion

Les résultats expérimentaux obtenus à l'aide des modèles DenseNet121 et VGG16 sont présentés de manière comparative. Cette comparaison met en évidence les différences entre les deux méthodes. Les performances de chaque modèle sont détaillées en termes de précision, ce qui permet de les comparer et de choisir celui qui correspond le mieux à ses besoins.

L'efficacité des techniques de prétraitement appliquées est mise en évidence par les résultats obtenus dans l'ensemble des images traitées (voir le Tableau III-1). Ces résultats montrent notamment que le contraste est amélioré et que les artefacts sont détectés. Ils permettent également d'évaluer l'impact de ces techniques sur les performances des modèles. Les faibles valeurs de l'erreur quadratique moyenne (MSE) et les valeurs élevées du rapport signal sur bruit de crête (PSNR) indiquent que les opérations effectuées ont permis d'améliorer la qualité des images tout en préservant leurs caractéristiques essentielles. Cette amélioration permet d'extraire plus les caractéristiques pertinentes, ce qui accroît de manière significative les performances des modèles de classification basés sur l'apprentissage profond.

Le tableau III.2 compare les performances de deux architectures de réseaux de neurones convolutifs, VGG16 et DenseNet121, avec deux types de couches finales : Flatten et Global Average Pooling (GAP). Les résultats montrent que l'impact de la couche finale varie en fonction de l'architecture considérée. Pour VGG16, l'utilisation de GAP améliore les performances globales du modèle, avec une précision de test de 93,48 %, contre 91,30 % pour la version utilisant Flatten. En revanche, pour DenseNet121, la meilleure précision est obtenue avec Flatten (91,30 %), tandis que l'utilisation de GAP entraîne une légère diminution de l'Accuracy à 89,13 %. Les valeurs de précision et de rappel confirment cette tendance : VGG16 avec GAP affiche les meilleures performances parmi les configurations évaluées, avec respectivement 93,96 % et 93,48 %.

Concernant la perte de test (Test Loss), le modèle DenseNet121 avec GAP affiche la valeur la plus faible (0,2055), contre 0,2533 pour DenseNet121 avec Flatten, 0,2300 pour VGG16 avec Flatten et 0,2521 pour VGG16 avec GAP. Cette faible valeur de perte indique que le modèle est capable de produire des prédictions plus stables et mieux calibrées. Bien que son taux de classification soit légèrement inférieur, cette performance suggère que

l'intégration de GAP améliore la capacité de généralisation de DenseNet121 et réduit le risque de sur apprentissage.

L'analyse du nombre de paramètres met également en évidence l'intérêt de la couche GAP. Pour VGG16, le nombre de paramètres passe de 21,17 millions avec Flatten à 14,88 millions avec GAP, soit une réduction d'environ 30 %. Cette diminution est encore plus marquée pour DenseNet121, avec une réduction de 19,92 millions à 7,33 millions de paramètres, soit environ 63%. Cette réduction significative de la complexité du modèle permet de diminuer la mémoire nécessaire au stockage des poids, d'accélérer l'entraînement et l'inférence, tout en limitant le risque de sur apprentissage.

Concernant les mesures diagnostiques, les modèles présentent des sensibilités comprises entre 89,13% et 93,48%, reflétant une bonne capacité à détecter les cas positifs. Le modèle VGG16 avec GAP obtient la sensibilité la plus élevée (93,48%), suivi des modèles VGG16 avec Flatten et DenseNet121 avec Flatten, qui atteignent chacun 91,30 %. Le modèle DenseNet121 avec GAP enregistre une sensibilité de 89,13%. En ce qui concerne la spécificité, le modèle VGG16 avec GAP atteint une valeur de 96.12 %, démontrant ainsi sa capacité à identifier correctement la majorité des cas négatifs. Le modèle DenseNet121 avec Flatten obtient une spécificité de 94,12%, tandis que les modèles VGG16 avec Flatten et DenseNet121 avec GAP affichent chacun une spécificité de 88,24%. Dans l'ensemble, ces résultats montrent que les quatre modèles offrent de bonnes performances diagnostiques pour la classification des images échographiques du cancer du sein, avec un avantage pour VGG16 utilisant la couche GAP.

Tableau III.2 – Comparaison des performances des modèles VGG16 et DenseNet121 utilisant les couches Flatten et Global Average Pooling (GAP).

Model	VGG 16		DenseNet121	
	Flatten	GAP	Flatten	GAP
Total params:	21, 170,755 (80.76 MB)	14, 879,299 (56.76 MB)	19, 916,099 (75.97 MB)	7, 333,187 (27.97 MB)
Test Accuracy	91.30 %	93.48%	91.30%	89.13%
Test Loss	0.2300	0.2521	0.2533	0.2055
Precision	91.37 %	93.96 %	91.30 %	89.29 %
Sensibilité (Recall)	91.30 %	93.48 %	91.30 %	89.13 %
Spécificité	88.24 %	96.12 %	94.12 %	88.24 %

Dans l'ensemble, ces résultats montrent que l'efficacité de la couche Global Average Pooling dépend de l'architecture utilisée. Pour VGG16, la couche GAP permet d'améliorer les performances de classification tout en réduisant le nombre de paramètres, ce qui en fait une solution particulièrement avantageuse. En revanche, pour DenseNet121, la couche GAP permet de réduire considérablement la complexité du modèle et d'améliorer la perte de test, mais au prix d'une légère diminution de la précision. Parmi toutes les configurations étudiées, VGG16 avec GAP semble être le meilleur compromis entre performance et efficacité. Il affiche en effet la meilleure précision de test (93,48 %), les meilleures valeurs de précision et de rappel, ainsi qu'une spécificité (96.12 %), tout en réduisant de manière significative le nombre de paramètres par rapport à la version utilisant Flatten. Ces caractéristiques font de ce modèle le candidat le plus approprié pour une application pratique de la classification automatique d'images médicales.

Ces résultats sont représentés sur les figures ci-dessous : La figure III.5 présente l'évolution des performances du modèle au cours des 50 époques d'entraînement. La courbe de gauche montre que les pertes d'entraînement et de validation diminuent progressivement au fil des époques, ce qui indique que le modèle apprend efficacement les caractéristiques des images. La courbe de droite montre une augmentation continue de la précision d'entraînement et de validation, traduisant une amélioration progressive des performances de classification.




Figure III.5 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de la validation du modèle VGG16 (GAP).

On remarque que les courbes d'entraînement et de validation suivent globalement la même tendance, ce qui démontre une bonne capacité de généralisation du modèle. Malgré

quelques fluctuations de la précision et de la perte de validation, les performances restent stables en fin d'apprentissage. La précision de validation atteint plus de 93,48 %, tandis que la perte de validation reste faible, confirmant ainsi l'efficacité du modèle pour la tâche de classification étudiée. Globalement, ces courbes indiquent une bonne convergence du modèle avec un sur apprentissage limité.




Figure III.6 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de la validation du modèle DenseNet121(Flatten).

La figure III.6 illustre l'évolution de la perte (Loss) et de la précision (Accuracy) du modèle pendant les phases d'entraînement et de validation. On observe que la perte d'entraînement diminue très rapidement au cours des premières époques puis se stabilise à une valeur très faible. La perte de validation suit quand à elle une tendance décroissante avec quelques légères fluctuations. Cette évolution indique que le modèle apprend efficacement les caractéristiques des données et parvient à réduire progressivement ses erreurs de prédiction.

Concernant la précision globale (Accuracy), les courbes montrent une augmentation rapide dès les premières époques. La précision globale d'entraînement atteint presque 100 %, tandis que la précision de validation se stabilise entre 90 et 94 %. L'écart observé entre les performances d'entraînement et de validation suggère un léger phénomène de sur apprentissage, mais celui-ci reste limité, la précision de validation demeurant élevée et relativement stable. Ces résultats témoignent globalement d'une bonne convergence du modèle et d'une capacité satisfaisante à généraliser sur des données non utilisées lors de l'entraînement.

IV.5. Conclusion

Dans ce chapitre, nous avons étudié les performances des architectures VGG16 et DenseNet121 pour la classification automatique d'images échographiques mammaires en trois catégories : normales, bénignes ou malignes, afin de déterminer leur capacité à fournir des résultats précis et rapides pour la détection précoce des cancers du sein. Une fois les images traitées et améliorées, les modèles ont été entraînés et évalués. Cela a permis de déterminer la configuration la plus performante.

Les résultats obtenus montrent que les deux architectures sont capables de distinguer efficacement les différentes classes mammaires, ce qui est un premier pas prometteur vers la détection précoce du cancer du sein. La réduction significative du nombre de paramètres a été rendue possible par l'utilisation de la couche Global Average Pooling (GAP), tout en maintenant de bonnes performances de classification. Les courbes d'apprentissage ont par ailleurs révélé une bonne convergence des modèles, avec une diminution progressive de la perte et une amélioration de la précision au fil de l'entraînement, ce qui est un signe positif pour la fiabilité du modèle.

L'étude comparative a révélé que la combinaison de VGG16 et de la couche GAP constituait la configuration la plus performante parmi celles évaluées. Ce modèle a obtenu les meilleures performances globales. Celles-ci concernent la précision, le rappel, la sensibilité et la spécificité. Le modèle reste d'une complexité raisonnable. Ces résultats démontrent ainsi la capacité des modèles d'apprentissage profond à différencier efficacement les cas normaux des lésions bénignes et malignes à partir d'images échographiques mammaires.

Pour finir, cette étude montre que l'apprentissage profond peut aider à poser un diagnostic de cancer du sein, ce qui ouvre la voie à de nouvelles possibilités de traitement et de détection précoce de la maladie. Un tel système pourrait non seulement permettre d'améliorer la détection précoce des anomalies mammaires, mais aussi de faciliter la distinction entre les cas normaux, bénins et malins, et enfin d'assister les radiologues dans leur prise de décision clinique.

IV.1. Récapitulatif

Ce mémoire s'est articulé autour de plusieurs volets complémentaires portant sur l'analyse des images échographiques du sein et sur l'exploitation des techniques d'intelligence artificielle pour la détection et la classification du cancer du sein. Les principaux axes de recherche et de développement menés dans ce travail concernent le prétraitement des images, l'extraction des caractéristiques pertinentes ainsi que la conception et l'évaluation de modèles de classification performants. Ces différents axes sont présentés de manière synthétique ci-dessous et font l'objet d'une description détaillée dans les sections suivantes.

- Dans le cadre de cette étude, nous avons choisi d'explorer le domaine du traitement des images médicales. À cet effet, nous avons entrepris les démarches suivantes :
 - i) Nous avons analysé les caractéristiques et les particularités des images. Ces images sont issues de l'imagerie médicale. Nous avons mis en évidence l'importance de leur qualité et de leur précision. Cela permet de garantir un diagnostic fiable et pertinent.
 - ii) Nous avons également étudié les différentes techniques de traitement des images médicales, en particulier les méthodes d'acquisition, de prétraitement et de classification. Cette étude nous a permis d'acquérir les connaissances nécessaires à leur mise en œuvre dans notre travail. Ces techniques jouent un rôle essentiel dans l'amélioration de la qualité des images et l'optimisation de leur analyse, favorisant ainsi une interprétation clinique plus précise et plus fiable.
- Les avancées récentes de l'intelligence artificielle, et plus particulièrement de l'apprentissage profond, ont considérablement favorisé son intégration dans le domaine médical. Ces progrès ont permis le développement d'outils performants d'analyse d'images médicales ainsi que de systèmes d'aide au diagnostic. Parmi les techniques les plus utilisées, les réseaux de neurones convolutifs (CNN) se distinguent par leur capacité à extraire automatiquement des caractéristiques pertinentes à partir des images échographiques. Cette aptitude en fait des outils

particulièrement efficaces pour la détection précoce, la classification des lésions mammaires, contribuant ainsi à améliorer la précision du diagnostic du cancer du sein.

Pour aboutir à cela nous avons fait les étapes suivantes :

- La première partie de ce mémoire a été consacrée à une étude bibliographique portant sur le cancer du sein et les techniques d'analyse des images échographiques mammaires. Elle a également abordé les principales méthodes de traitement numérique des images ainsi que les modèles de classification les plus utilisés en imagerie médicale. Cette étude a permis de mettre en évidence les avancées récentes dans ce domaine et de souligner l'efficacité des approches fondées sur l'apprentissage automatique et l'apprentissage profond. Ces méthodes ont démontré des performances remarquables dans la détection et la classification des lésions mammaires, contribuant ainsi à l'amélioration du diagnostic précoce du cancer du sein.
- La deuxième partie de ce travail a été consacrée à l'étude et à l'application des réseaux de neurones convolutifs (CNN) pour la classification des images échographiques mammaires. Les expérimentations réalisées sous Python ont permis de confirmer l'efficacité et la robustesse de ces modèles. Les CNN se sont révélés particulièrement performants pour la classification des lésions mammaires, même en présence d'un volume de données limité, ce qui souligne leur intérêt dans le cadre de l'aide au diagnostic du cancer du sein.
- La troisième et dernière partie de ce mémoire a été consacrée à la mise en œuvre du modèle de réseau de neurones convolutifs (CNN) précédemment étudié, clôturant ainsi ce travail de recherche. Nous avons procédé à son implémentation ainsi qu'à son évaluation sur une base d'images échographiques mammaires afin d'analyser ses performances en matière de la détection et de la classification des lésions du sein. Les résultats obtenus se sont révélés prometteurs.
- L'évaluation a mis en évidence l'efficacité et la robustesse du modèle VGG16, qui a démontré une capacité remarquable à distinguer les lésions bénignes et malignes, ainsi que les cas normaux. Cette performance souligne l'intérêt de ce modèle dans le domaine de l'aide au diagnostic du cancer du sein. Cette étude confirme ainsi la pertinence des architectures CNN, et en particulier de VGG16, pour l'analyse des images médicales, ouvrant la voie à de nouvelles perspectives en recherche médicale.

Plusieurs améliorations peuvent néanmoins être envisagées afin d'optimiser la performance du modèle dans la classification des images échographiques mammaires.

IV.2. Perspectives

Ce travail ouvre plusieurs perspectives d'amélioration dans le domaine de l'imagerie médicale et de l'intelligence artificielle appliquées au diagnostic du cancer du sein. Il serait intéressant de comparer différentes architectures de réseaux de neurones profonds afin d'identifier les modèles les plus performants pour la classification des lésions mammaires. Il conviendrait également d'explorer des architectures hybrides combinant plusieurs approches d'apprentissage profond, dans le but d'améliorer la précision, la robustesse et la généralisation du modèle.

Le développement d'une application web ou mobile pourrait permettre une utilisation en temps réel et faciliter l'accès aux outils d'aide au dépistage. Par ailleurs, l'intégration de techniques d'intelligence artificielle explicable (XAI) améliorerait l'interprétabilité des résultats et renforcerait la confiance dans les prédictions du modèle. Enfin, la robustesse, la précision et la capacité de généralisation du système pourraient être renforcées par l'ajout de données cliniques complémentaires ainsi que par une validation sur des bases de données issues de plusieurs centres hospitaliers.

BIBLIOGRAPHIE

- [1] <http://www.depistagesein.ca/anatomie-du-sein/>
- [2] American Cancer Society. What is Breast Cancer. Consulté le 31 juillet 2011.
- [3] National Cancer Institute. Understanding Cancer Series. Accessed May 29, 2014
- [4] Mehidi aicha; thèse de doctorat en sciences; Détection des microcalcifications par les modèles Markoviens pour des tissus mammaires; Université de Mostaganem; 2019.
- [5] Centre international de recherche sur le cancer: 2018, titre de communiqué de presse N°263.
- [6] Nabil ZERIGUI, Lounes MEZAGUER ; « Rôle de l'éducation thérapeutique dans l'amélioration de la qualité de vie chez les personnes atteintes de maladies chroniques « cas de cancer du sein unité de BELLOUA, CHU Tizi-Ouzou » » ; Master en Sciences Economiques ; 2019-2020.
- [7] Wild .C centre international de recherche sur le cancer (CIRC) « incidence et mortalité du cancer du sein dans le monde ».
- [8] Service d'épidémiologie du CHU de Tizi-Ouzou, Algérie. avril 2019.
- [9] World Health Organization (WHO), « Breast cancer – Fact sheet », 2023. <https://www.who.int/news-room/fact-sheets/detail/breast-cancer>
- [10] Sung H., Ferlay J., Siegel R.L. et al., « Global Cancer Statistics 2020 », 2021. <https://doi.org/10.3322/caac.21660>
- [11] Institut National du Cancer (INC), « Cancer du sein : diagnostic et prise en charge », 2023. <https://www.e-cancer.fr>
- [12] Kopans D.B.; *Breast Imaging*, 4th ed., 2019. <https://www.worldcat.org/title/breast-imaging>.
- [13] Berg W.A. et al., *Diagnostic Imaging: Breast*, Elsevier, 2012. <https://www.elsevier.com/books/diagnostic-imaging-breast>.
- [14] American Cancer Society, « Breast Cancer Facts & Figures », 2024. <https://www.cancer.org/cancer/types/breast-cancer.htm>
- [15] www.cse-radiologie.com/accueil/irm/irm-mammaire-ou-irm-du-sein
- [16] Haute Autorité de Santé (HAS) – Cancer du sein <https://www.has-sante.fr>
- [17] Institut National du Cancer (INCa) ; <https://www.e-cancer.fr>

- [18] Mitchell T. M. (1997). *Machine Learning*. McGraw-Hill; Science/Engineering/Math.
- [19] McCarthy J. (2007); from here to human-level AI. *Artificial Intelligence*, 171(18), 1174-1182.
- [20] Bishop C. M. & Nasrabadi N. M. (2006); *Pattern recognition and machine learning*; New York: Springer.
- [21] LeCun Y., Bengio Y. & Hinton G. (2015). Deep learning; *Nature*, 521(7553), 436-444
- [22] Krizhevsky A., Sutskever I. & Hinton, G. E. (2012); ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems (NeurIPS)*, 25, 1097-1105.
- [23] LeCun Y., Bottou L., Bengio, Y. & Haffner P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [24] McCulloch W. S. & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity; *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- [25] Rosenblatt F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386.
- [26] Stéphane Meurisse; Dans *Articles*, Deep Learning, Des neurones et de l'IA; 5 janvier 2025. <https://www.codeandcortex.fr/modelisation-et-fonctionnement-dun-neurone-artificiel/>
- [27] Les réseaux de neurones et l'apprentissage profond ;
<https://www.mccours.net/cours/pdf/yass2/yass2cllic1943.pdf>
- [28] Bengio Y. (2009). Learning deep architectures for AI; *Foundations and Trends in Machine Learning*, 2(1), 1-127
- [29] Glorot X., Bordes A. & Bengio Y. (2011). Deep sparse rectifier networks; *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics*, 315-323
- [30] Good fellow I., Bengio Y. & Courville A. (2016). *Deep Learning*; MIT Press
- [31] Byra M., Styczynski G., Szawan, C., Michałowski, K. & Nowicki A. (2018). Breast mass classification in ultrasound with transfer learning and assessment of protocol-specific features; *IEEE Journal of Biomedical and Health Informatics*, 23(3), 1195-1203
- [32] Shen L. et al. (2019); Deep learning to improve breast cancer detection on screening mammography. *Scientific Reports*, 9(1), 1-12.

- [33] Litjens G. et al. (2017); A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- [34] Ker J. et al. (2017). Deep learning applications in medical image analysis; *IEEE Access*, 5, 9375-9389
- [35] Huang G., Liu Z., Van Der Maaten L. & Weinberger K. Q. (2017). Densely connected convolutional networks; *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4700-4708.
- [36] Al-Dhabyani W., Gomaa M., Khaled H., & Fahmy A. (2020). Dataset of breast ultrasound images; *Data in Brief*, 28, 104863
- [37] Faris H., Al-Zoubi A. M. & Al-Madi, N. (2023). Computer-Aided Diagnosis System for Breast Cancer in Ultrasound Images Using Deep Transfer Learning Architectures; *Jordan Journal of Computer and Information Technology (JJCIT)*, 9(2), 155-172
- [38] Huang G., Liu Z., Van Der Maaten L. & Weinberger K. Q. (2017). Densely connected convolutional networks; In *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)* (pp. 2261-2269).
- [39] Boudefa S. (2022). Classification des images médicales par les réseaux de neurones convolutifs (CNN). Mémoire de Master en Automatique et Informatique Industrielle (AII), Département de Génie Électrique, Mostaganem, Algérie
- [40] Beldjilali F. Z. (2021). Apprentissage profond pour la classification automatique des lésions du sein en imagerie par ultrasons. Thèse de Doctorat en Électronique, Faculté des Sciences de l'Ingénieur, Sidi Bel Abbès, Algérie
- [41] Cherifi H. (2019). Filtrage du bruit de chatoiement (Speckle) et amélioration du contraste en imagerie médicale échographique. Thèse de Doctorat en Sciences, Faculté des Sciences, Université d'Alger 1, Algérie
- [42] Simonyan K. & Zisserman A. (2014). Very deep convolutional networks for large-scale image recognition; *arXiv preprint arXiv: 1409.1556*
- [43] Classification: Accuracy, recall, precision, and related metrics. <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall>
- [44] Kalloum K. (2023). Optimisation des hyper paramètres des réseaux convolutifs pour le diagnostic assisté par ordinateur. *Journal de l'Innovation Médicale Arabe*, 7(3), 89-101

- [45] Bouzenada S. & Mokrani A. (2023). Classification automatisée des pathologies tumorales via l'apprentissage par transfert profond. *Revue Algérienne des Sciences et Technologies*, 11(2), 142-155.
- [46] Joseph S., Olugbara O. (2022). Pre-processing Effects on Performance of Skin Lesion Saliency Segmentation; *Diagnostics*, 12(2), 344.