

الجمهورية الجزائرية الديمقراطية الشعبية
République algérienne démocratique et populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique

جامعة عين تموشنت بلحاج بوشعيب
Université –Ain Temouchent- Belhadj Bouchaib

Faculté des Sciences et de Technologie
Département d'Électronique et Télécommunication



Projet de Fin d'Etudes

Pour l'obtention du diplôme de Master en : Réseaux et Télécommunications

Domaine : Sciences et Technologies

Filière : Télécommunications

Spécialité : Réseaux et Télécommunications

Thème

Détection d'anomalies à faible contraste par deep learning : Application à l'imagerie mammographique

Présentée Par : Remini kawther

Devant le jury composé de :

Mme SEKKAL Mansouria	MCA	UAT.B.B (Ain Temouchent)	Présidente
Mme MEKAMI Hayet	MCB	UAT.B.B (Ain Temouchent)	Examinatrice
Mr HACHEMI Belkacem	MCB	UAT.B.B (Ain Temouchent)	Encadrant

Année Universitaire 2025/2026

REMERCIEMENTS

Ce projet de fin d'étude a été réalisé au sein du Département de Génie Électrique et Télécommunication de la Faculté des Sciences et de la Technologie de l'Université Belhadj Bouchaib d'Aïn Témouchent.

Avant toute chose, je remercie ALLAH Tout-Puissant de m'avoir accordé la santé, la force, la patience et la persévérance nécessaires pour mener ce travail à son terme.

J'adresse mes plus sincères remerciements à mon encadreur, **Monsieur Hachemi Belkacem**, pour son accompagnement, sa disponibilité, ses précieux conseils et son soutien constant tout au long de la réalisation de ce projet. Son expertise, ses orientations et ses encouragements ont été d'une aide inestimable et ont grandement contribué à l'aboutissement de ce travail.

J'exprime également ma profonde gratitude aux membres du jury, **Madame Sekkal Mansouria** et **Madame Mekami Hayet**, qui m'ont fait l'honneur d'accepter d'évaluer ce projet de fin d'étude. Je les remercie sincèrement pour le temps consacré à son examen ainsi que pour leurs remarques et suggestions constructives, qui contribueront à son amélioration.

Je tiens également à adresser mes sincères remerciements aux professeurs de télécommunications de notre département, qui m'ont encadré, enseigné et transmis leurs connaissances tout au long de mon parcours universitaire. Leur disponibilité et la qualité de leur enseignement ont grandement contribué à ma formation et à la réussite de ce projet.

Enfin, je remercie mes camarades de promotion pour les moments partagés durant notre parcours universitaire.

Dédicace

Chère ma famille REMINI,

Je dédie ce travail à vous. Vous avez été mes plus grands soutiens durant mon parcours universitaire, et c'est grâce à vous que je suis là aujourd'hui.

À mon père, les mots ne suffisent pas pour exprimer mes sentiments. Tu es non seulement un père mais aussi mon héros et mon guide. Sans toi, tes encouragements, ton amour et ton soutien, je ne serais pas la personne que je suis aujourd'hui. Ma réussite est aussi la tienne et je suis très fière d'avoir un père comme toi. Que Dieu te protège et te garde toujours fier de moi.

Mille mercis mon cher papa.

À la personne la plus chère à mon cœur, ma mère, qui est mon âme, ma force et la lumière de ma vie. Tu as toujours été présente à mes côtés, dans les moments difficiles comme dans les moments de joie, en m'offrant ton amour, ton soutien, ta confiance et tes encouragements. Tu as consacré ta vie à notre bonheur et tu as tant sacrifié pour nous voir réussir. Si j'en suis arrivée là aujourd'hui, c'est grâce à toi. Cette réussite est autant la tienne que la mienne. Je te remercie du fond du cœur et je te dédie ce travail avec tout mon amour et toute ma gratitude, ma chère mère.

À ma chère sœur Rajaa, tu as été bien plus qu'une sœur tu as toujours été mon soutien, ma confidente et une source de force dans les moments les plus difficiles. Chacun de tes encouragements m'a donné le courage d'avancer et de croire en moi. Je suis infiniment reconnaissante de t'avoir dans ma vie.

À mon frère Abd El Rahmen, tu es ma fierté et mon soutien dans la vie. Je te souhaite beaucoup de réussite dans tes études et dans tous tes prochains pas. Je serai toujours à tes côtés pour t'encourager et te soutenir.

À ma chère tante Latifa, merci pour ton soutien constant et ta bienveillance. Dans les moments difficiles, tu as toujours su m'encourager et me donner la force de continuer. Ta présence a été très importante pour moi tout au long de ce parcours.

Enfin, à tous ceux qui me sont chers et qui m'ont soutenue de près ou de loin tout au long de ce parcours, votre aide et votre présence m'ont été précieuses.

Kawther

Résumé

Le cancer du sein est l'un des cancers les plus fréquents chez les femmes dans le monde. Son dépistage précoce joue un rôle essentiel dans l'amélioration des chances de traitement. Dans ce travail, nous proposons un système basé sur les techniques de Deep Learning pour la classification automatique des anomalies mammaires à partir d'images mammographiques. L'étude a été réalisée à l'aide de la base de données RSNA Screening Mammography Breast Cancer Detection, après une phase de prétraitement visant à améliorer la qualité des images. Deux architectures de réseaux de neurones convolutifs, resnet-50 et efficientnet-B4, ont été entraînées et évaluées à l'aide de plusieurs métriques de performance. Les résultats obtenus montrent que le modèle efficientnet-B4 présente des performances supérieures à celles de resnet-50. Cette étude met en évidence le potentiel du Deep Learning comme outil d'aide au diagnostic et au dépistage précoce du cancer du sein.

Mots clés: Cancer du sein, mammographie, Deep Learning, anomalies à faible contraste, classification d'images médicales, resnet50, efficientnet-B4

Abstract

Breast cancer is one of the most common cancers among women worldwide. Early detection plays an essential role in improving treatment outcomes. In this work, we propose a system based on Deep Learning techniques for the automatic classification of breast abnormalities from mammographic images. The study was conducted using the RSNA Screening Mammography Breast Cancer Detection dataset after a preprocessing phase aimed at improving image quality. Two convolutional neural network architectures, resnet-50 and efficientnet-B4, were trained and evaluated using several performance metrics. The obtained results show that the efficientnet-B4 model achieves better performance than resnet-50. This study highlights the potential of Deep Learning as a tool for assisting in the diagnosis and early detection of breast cancer.

Keywords: Breast cancer, mammography, Deep Learning, low-contrast abnormalities, medical image classification, resnet-50, efficientnet-B4

الملخص

يُعد سرطان الثدي من أكثر أنواع السرطانات شيوعًا لدى النساء في العالم. ويلعب الكشف المبكر عنه دورًا أساسيًا في تحسين فرص العلاج. في هذا العمل، نقترح نظامًا يعتمد على تقنيات التعلم العميق للتصنيف الآلي للشذوذات الثديية انطلاقًا من صور الماموغرافيا. أُجريت الدراسة باستخدام قاعدة بيانات RSNA Screening Mammography Breast Cancer Detection بعد مرحلة من المعالجة المسبقة الهادفة إلى تحسين جودة الصور. تم تدريب وتقييم بنيتين للشبكات العصبية الالتفافية، وهما resnet-50 وefficientnet-B4، بالاعتماد على عدة مقاييس لتقييم الأداء. وأظهرت النتائج المتحصل عليها أن نموذج efficientnet-B4 حقق أداءً أفضل مقارنةً بنموذج resnet-50. وتبرز هذه الدراسة الإمكانيات الواعدة لتقنيات التعلم العميق كأداة مساعدة في تشخيص سرطان الثدي والكشف المبكر عنه.

الكلمات المفتاحية: سرطان الثدي، الماموغرافيا، التعلم العميق، الشذوذات منخفضة التباين، تصنيف الصور الطبية، resnet-50، efficientnet-B4

Sommaire:

REMERCIEMENTS.....	I
<i>Dédicace</i>.....	II
Résumé.....	III
Abstract	IV
المخلص	V
Introduction générale.....	14
I. Contexte	2
II. Problématique	2
III. Objectif.....	2
Chapitre I : Le cancer du sein.....	3
I.1. Introduction.....	4
I.2. Le cancer du sein.....	4
I.2.1 Épidémiologie	4
I.2.2 Développement et évaluation	5
I.2.3 Les types et caractéristiques des tumeurs mammaires	6
I.2.3.1 Tumeurs bénignes	6
I.2.3.2 Tumeurs malignes.....	7
I.2.4 Facteurs de risque du cancer du sein	7
I.2.4.1 Facteurs liés au mode de vie	7
I.2.4.2 Facteurs génétiques et familiaux.....	8
I.2.4.3 Facteurs incontrôlables	8
I.2.5 les symptômes	8
I.2.6 Le dépistage.....	9
I.3. Anatomie du sein.....	9
I.3.1 Structure du sein.....	9
I.3.2 Vascularisation et réseau lymphatique	10
I. 3.2.1 Vascularisation artérielle du sein.....	10
I.3.2.2 Réseau lymphatique	10
I.4. L'imagerie médicale du cancer du sein.....	11
I.4.1 La mammographie.....	11

I.4.2 Historique	11
I.4.3 les types de mammographies.....	12
I.4.3.1 Mammographie analogique :	12
I.4.3.2 Mammographie numérique :	12
I.4.3.3 Tableau comparatif	12
I.4.4 Le mammographe.....	12
I.4.5 Procédé de la mammographie	13
I.5. Anomalies détectables en mammographie	14
I.6. Le système BI-RADS	15
I.7. Les fichiers DICOM	15
I.8. Avantages et limites de la mammographie	16
I.8.1 Avantages :	16
I.8.2 Limites :.....	17
I.9. Conclusion	17
Chapitre II :	18
Intelligence Artificiel et Deep Learning	18
II.1. Introduction	19
II.2. Intelligence Artificielle	19
II.2.1 Évolution de l'intelligence artificielle dans l'imagerie médicale	20
II.3. Machine Learning	21
II.3.1 l'utilisation de la machine learning	21
II.3.2 Types d'apprentissages	21
II.3.2.1 apprentissage supervisé	21
II.3.2.2 apprentissage non supervisé.....	22
II.3.2.3 apprentissages par renforcement	22
II.4. Deep Learning	23
II.5. La représentation des réseaux neurones artificiel	23
II.5.1 les réseaux neurones artificiel	24
II.5.1.1 Définition	24
II.5.1.2 Structure d'un réseau de neurones artificiels	24
II.5.1.3 Principe de fonctionnement d'un réseau de neurones artificiels	25
II.5.2 Les fonctions d'activation.....	26

II.5.2.1 Fonction de sigmoid	26
II.5.2.2 Fonction softmax	27
II.5.2.3 Fonction relu.....	27
II.5.2.4 Fonction Tanh	27
II.5.3 Fonction de la perte.....	28
II.5.3.1Entropie croisée (Cross-Entropy) :	28
II.5.3.2Entropie croisée binaire (Binary Cross-Entropy) :	29
II.5.3.3Entropie croisée catégorique (Categorical Cross-Entropy) :	29
II.5.4 la rétropropagation	30
II.5.5 Gradient évanescent	30
II.5.6 Réseau de neurones convolutionnel.....	31
II.5.6.1 Couche de convolution.....	32
II.5.6.2 Couche de pooling.....	32
II.5.6.3 Couche fully-connected	33
II.6. Modèles de deep learning en vision par ordinateur.....	33
II.7. L'architecture ResNet	33
II.8. L'architecture EfficientNet.....	35
II.9. Conclusion.....	36
Chapitre III :	37
Conception et implémentation du système	37
III.1. Introduction.....	38
III.2. Architecture du système CAD proposé	38
III. 3. Implémentation	39
III.3.1 Base de données utilisée	39
III.3.1.1 Organisations de data.....	40
III.3.2 Prétraitement des images	42
III.3.3 Transformation des images avant l'entraînement.....	45
III.3.4 Resnet-50	46
III.3.4.1 les hyperparamètres.....	47
III.3.4.2 Gestion du déséquilibre des classes	48
III.3.5 les métriques d'évaluation	48
III.3.7 Efficientnet-B4	50

III.4. Conclusion	52
Chapitre IV :	53
Analyse et discussion des résultats.....	53
IV.1. Introduction	54
IV.2. Les outils et environnement de travail	54
IV.2.1 Google Colab	54
IV.2.2 Python	54
IV.2.3 Les bibliothèques	55
IV.3. Architecture du modèle ResNet- 50 et paramètres d'entraînement....	57
IV.4. Analyse des performances du modèle resnet-50	58
IV.4.1 Évaluation des métriques de performance	58
IV.4.2 Analyse des courbes d'apprentissage du modèle resnet-50.....	60
IV.4.3 Discussion des résultats	61
IV.5. Architecture du modèle Efficientnet-B4 et paramètres d'entraînement	61
IV.6. Analyse des performances du modèle Efficientnet-B4.....	63
IV.6.1 Évaluation des métriques de performance	63
IV.6.2 Analyse des courbes d'apprentissage du modèle efficientnet-B4	64
IV.6.3 Discussion des résultats	66
IV.7. Comparaison des modèles resnet-50 et efficientnet-B4	67
IV.8. Conclusion	68
Conclusion générale	69
Références bibliographiques	71

Liste des figures :

Figure I. 1: Cellule cancéreuse [2].	4
Figure I. 2: Répartition des cas de cancers par type [3].	5
Figure I. 3: Anatomies du sein [9].	10
Figure I. 4: Représente le schéma des composants d'un mammographe [13].	13
Figure I. 5: Représente schéma de déroulement d'une mammographie et affichage de résultats [15].	14
Figure I. 6: Représentation des métadonnées et de la structure interne d'un fichier DICOM [17].	16
Figure II. 1: Les techniques fondamentaux de l'intelligence artificielle.	20
Figure II. 2: Schéma des types d'apprentissage en Machine Learning [25].	23
Figure II. 3: Neurone biologique [29].	24
Figure II. 4: Structure d'un réseau de neurones artificiels [30].	25
Figure II. 5: Modèle mathématique d'un neurone artificiel intégrant la fonction d'activation [31].	26
Figure II. 6: Fonction de sigmoid.	26
Figure II. 7: Fonction softmax	27
Figure II. 8: Fonction relu.	27
Figure II. 9: Fonction Tanh.	28
Figure II. 10: Schéma illustrant le processus de rétropropagation du gradient dans un réseau neuronal multi-couche [33].	30
Figure II. 11: Variation du Gradient par Couche durant la Rétropropagation dans un Réseau de Neurones Pro-fond [35].	31
Figure II. 12: Architecture de base d'un réseau de neurones convolutionnel (CNN) [37].	31
Figure II. 13: Exemple explicative sur l'opération de convolution [39].	32
Figure II. 14: Exemple explicative sur l'opération de Max Pooling et Average Pooling [40].	32
Figure II. 15: Couche fully-connected [42].	33
Figure II. 16: Architecture resnet « Bloc Résiduel, Bottleneck et Classification d'Images » [47].	35
Figure III. 1 : Architecture générale du système CAD proposé pour la classification des images mammographiques.	38
Figure III. 2: Étapes de l'implémentation de la méthodologie proposée	39
Figure III. 3: présente organisation des dossiers de la base de données.	40
Figure III. 4: Exploration initiale des données du fichier train.csv.	41
Figure III. 5 : Représente mammographie du patiente 1110981332de la base RSNA	41
Figure III. 6 : Représentation des mammographies des deux seins selon les incidences Cranio-caudale (CC) et médio-latérale oblique (MLO).	42
Figure III. 7: Image mammographique originale avant prétraitement(2776x2082) pixels.	43
Figure III. 8: Image après les étapes de prétraitement (CLAHE, windowing, correction photométrique, normalisation et segmentation).	44

Figure III. 9: Image finale après redimensionnement à (256×256) pixels.	44
Figure III. 10: Transformations appliquées aux images avant l’entraînement du modèle resnet-50.	45
Figure III. 11: Transformations appliquées aux images avant l’entraînement du modèle efficientnet-B4.	45
Figure III. 12: Architecture resnet50 pour la classification des images mammaires en classes Sain et présente une anomalie.	47
Figure III. 13: Structure de la matrice de confusion utilisée pour la classification binaire (Cancer /Not Cancer).	49
Figure III. 14 : Architecture du modèle efficientnet-B4 pour la classification des images mammographiques..	51
Figure IV. 1: Représentation de la couche de classification finale du modèle resnet-50.....	57
Figure IV. 2: Matrice de confusion du modèle resnet-50.....	59
Figure IV. 3: Graphes représentatifs des résultats obtenus avec l’architecture resnet-50.....	60
Figure IV. 4: Visualisation de la rétropropagation et du calcul des gradients dans le modèle efficientnet-B4.....	62
Figure IV. 5: Matrice de confusion du modèle efficientnet-B4.	64
Figure IV. 6: Graphes représentatifs des résultats obtenus avec l’architecture efficientnet-B4.	65

Liste des tableaux :

Tableau I. 1: La comparaison entre la mammographie analogique et numérique	12
Tableau I. 2: Classification BI-RADS et probabilité de malignité associée.	15
Tableau IV. 1: Hyperparamètres utilisés pour l'entraînement du modèle ResNet-50.	58
Tableau IV. 2: Évaluation des performances du modèle resnet-50.	59
Tableau IV. 3 : Hyperparamètres utilisés pour l'entraînement du modèle EfficientNet-B4.....	63
Tableau IV. 4: Résultats des métriques d'évaluation du modèle efficientnet-B4.	63
Tableau IV. 5: Comparaison des performances des modèles resnet-50 et efficientnet-B4	67

Liste des abréviations:

ACR: American College of Radiology.

ANN : Artificial Neural Network (Réseau de neurones artificiels).

AUC-ROC: Area Under the Receiver Operating Characteristic Curve.

BCE : Binary Cross-Entropy (Entropie croisée binaire).

BI-RADS: Breast Imaging-Reporting and Data System.

CAD : Computer Assisted Detection (Système d'aide à la détection).

CC : Crânion -caudale.

CCE : Categorical Cross-Entropy (Entropie croisée catégorique).

CCI : Carcinome canalaire infiltrant.

CCIS : Carcinome canalaire in situ.

CE : Cross-Entropy (Entropie croisée).

CLAHE: Contrast Limited Adaptive Histogram Equalization.

CLI : Carcinome lobulaire infiltrant.

CLIS : Carcinome lobulaire in situ.

CNN : Convolutional Neural Network (Réseau de neurones convolutionnel).

DICOM: Digital Imaging and Communications in Medicine.

DL: Deep learning.

IA: L'intelligence Artificielle.

MBConv: Mobile Inverted Bottleneck Convolution.

ML: Machine learning.

MLO : Médio-latérale oblique.

Relu : Rectified Linear Unit.

ResNet : Residual Network.

Introduction générale

I. Contexte

Le cancer du sein est l'une des pathologies les plus fréquentes chez la femme et constitue un défi majeur pour les systèmes de santé. Il résulte d'une prolifération anormale des cellules mammaires qui peut conduire à la formation d'une tumeur et, en l'absence d'un traitement précoce, évoluer vers des formes plus sévères. Pour cette raison, le dépistage précoce représente un élément essentiel dans l'amélioration de la prise en charge des patientes. La mammographie est l'examen le plus utilisé pour détecter les anomalies mammaires et identifier les premiers signes de la maladie.

II. Problématique

Anomalies, notamment les microcalcifications, sont caractérisées par une petite taille et un faible contraste. Ces caractéristiques rendent leur détection difficile et peuvent influencer la précision du diagnostic.

Les avancées de l'intelligence artificielle, et plus particulièrement du Deep Learning, offrent aujourd'hui de nouvelles possibilités pour l'analyse des images médicales. En exploitant les informations contenues dans les images, ces approches permettent d'améliorer la détection automatique des anomalies et de fournir une aide supplémentaire aux spécialistes lors du processus de diagnostic.

III. Objectif

L'objectif principal de ce travail est de développer un système automatisé de détection des anomalies mammaires à partir d'images mammographiques en s'appuyant sur des techniques de Deep Learning. Après une étape de prétraitement destinée à améliorer la qualité des images et à optimiser leur exploitation, deux architectures de réseaux de neurones convolutifs, resnet50 et efficientnet-B4, sont utilisées pour réaliser une classification binaire entre les cas normaux et les cas présentant une anomalie mammaire. Les performances des deux modèles sont évaluées à l'aide de métriques de performance standard, puis comparées afin d'identifier l'architecture la plus adaptée à cette tâche. Cette étude vise à contribuer au développement d'un outil d'aide au dépistage précoce du cancer du sein, capable d'assister les professionnels de santé dans l'amélioration de la précision et de la fiabilité du diagnostic.

Chapitre I : Le cancer du sein

I.1. Introduction

Le cancer du sein est considéré comme l'une des maladies les plus répandues chez les femmes dans le monde. Son diagnostic précoce joue un rôle très important dans l'augmentation des chances de guérison et la réduction du taux de mortalité. Parmi les moyens les plus utilisés pour le dépistage du cancer du sein, la mammographie occupe une place essentielle. Cependant, l'analyse des images mammographiques reste une tâche complexe, notamment à cause du faible contraste de certaines anomalies.

Dans ce chapitre nous présentons les notions générales liées à l'imagerie mammographique, les types d'anomalies mammaires et les principales difficultés rencontrées lors de leur détection.

I.2. Le cancer du sein

Le cancer du sein (Breast cancer) est une pathologie maligne qui apparaît à la suite de mutations génétiques perturbant le mécanisme normal de la division cellulaire. Cette prolifération anormale des cellules entraîne la formation d'une tumeur touchant principalement les canaux galactophores ou les lobules. En l'absence de traitement, la maladie peut se propager vers d'autres organes par voie lymphatiques ou sanguine, formant des métastases [1].




Figure I. 1:Cellule cancéreuse [2].

I.2.1 Épidémiologie

Le cancer du sein touche un nombre croissant des femmes à travers le monde et reste le cancer féminin le plus fréquent, avec environ 2,3 millions de nouveaux cas et 670 000 décès en 2022, selon l'OMS. L'incidence est particulièrement élevée en Europe et en Amérique du Nord, mais la mortalité y reste relativement faible grâce au dépistage précoce et aux traitements modernes.

À l'inverse, en Afrique et en Asie, la mortalité est proportionnellement plus élevée, souvent en raison d'un diagnostic tardif et d'un accès limité aux soins spécialisés [3].

En Algérie, on estime qu'en 2025 environ 15 000 nouveaux cas seront diagnostiqués, touchant principalement les femmes de plus de 40 ans. Cette situation est favorisée par des facteurs tels que le tard de diagnostic et le manque de dépistage systématique.

Le dépistage précoce en particulier par la mammographie joue un rôle essentiel dans la réduction de la mortalité et l'amélioration du pronostic.




Figure I. 2:Répartition des cas de cancers par type [3].

I.2.2 Développement et évaluation

Le cancer du sein se développe lorsque les cellules mammaires normales subissent des altérations génétiques et moléculaires. Cette prolifération anormale des cellules peut conduire à la formation de lésions précancéreuses, puis à un carcinome in situ. Si ce dernier progresse, il peut envahir les tissus voisins et se propager aux ganglions lymphatiques ou à d'autres organes. Le rythme de ce développement dépend de plusieurs facteurs, notamment génétiques et hormonaux [1].

- **Épithélium normal** : cellules saines suivent les règles du cycle cellulaire et assurent la stabilité du tissu mammaire.

- **Hyperplasie** : multiplication anormale mais encore bénigne des cellules, Car l'organisation et le comportement des cellules demeurent proches de la normale.
- **Hyperplasie atypique** : cellules qui commencent à être anormales dans leur forme et leur disposition. Cette étape est considérée comme une lésion précancéreuse, car elle augmente le risque de progression vers un cancer.
- **Cancer in situ** : cellules cancéreuses limitées au site d'origine, Elles n'ont pas encore franchi les tissus voisins, ce qui en fait une phase clé pour le dépistage et une prise en charge précoce.
- **Cancer invasif** : cellules cancéreuses qui se propagent dans le tissu mammaire ou au d'autres organes par les vaisseaux sanguins ou lymphatiques.
- **Métastases** : Dans les stades avancés, les cellules cancéreuses migrent vers des organes éloignés comme les os, les poumons, le foie ou le cerveau. Le cancer devient alors généralisé et plus complexe à traiter.

I.2.3 Les types et caractéristiques des tumeurs mammaires

Les tumeurs mammaires se répartissent en deux grandes catégories bénignes et malignes. Les tumeurs bénignes sont bien limitées, à croissance lente, restent localisées et ne donnent jamais de métastases (in situ), après une exérèse chirurgicale complète, elles ne récidivent généralement pas. À l'inverse, les tumeurs malignes présentent des contours irréguliers, envahissent les tissus voisins et peuvent se disséminer à distance sous forme de métastases (invasif). Le diagnostic repose sur des examens complémentaires, notamment la biopsie, afin de préciser la nature de la tumeur [4].

I.2.3.1 Tumeurs bénignes

Le fibroadénome : la tumeur bénigne la plus courante chez les femmes de 30 ans constitué de tissu glandulaire et fibreux.

Le lipome : c'est une petite masse ou nodule de graisse, molle et indolore, ne transforme presque jamais en cancer.

Phyllode : tumeur rare évoluant rapidement, pouvant parfois représente un potentiel malin.

Kystes : tumeur contenant sac liquide unique ou multiple.

Papillome intra canalaire : tumeur semblable à une verrue qui se forme dans les canaux mammaires.

I.2.3.2 Tumeurs malignes

Carcinome in situ :

Carcinome canalaire in situ (CCIS) : tumeur précoce limitée aux canaux lactifères qui transportent le lait de puis les glandes mammaires jusqu'au mamelon. Le traitement des cancers canalaire in situ est local tels que la chirurgie ou la radiothérapie.

Carcinome lobulaire in situ (CLIS) : des cellules anormales se développe dans les lobules qui produisent le lait. Sa présence augmente le risque futur de développer un cancer invasif du sein.

Carcinome invasif :

Carcinome canalaire infiltrant (CCI) : tout comme le (CCIS), ce type de tumeur touche les canaux lactifères, mais il est plus envahissant. Il a la capacité de se diffuser et de s'étendre aux tissus mammaires.

Carcinome lobulaire infiltrant (CLI) : ce type de cancer est moins courant, débute dans les glandes mammaires avant de se diffuser vers d'autres tissus de sein.

I.2.4 Facteurs de risque du cancer du sein

I.2.4.1 Facteurs liés au mode de vie

- **Consommation d'alcool :** l'alcool est proportionnellement associé à une augmentation du risque de cancer du sein. Il agit en perturbant le métabolisme des œstrogènes et en favorisant l'instabilité génétique des cellules mammaires.
- **Obésité et surpoids :** Après la ménopause, le tissu adipeux devient une source importante d'œstrogènes. L'excès de poids entraîne donc une stimulation prolongée des cellules mammaires, ce qui accroît le risque.
- **Sédentarité :** Le manque d'activité physique favorise l'accumulation de graisses et perturbe l'équilibre hormonal. À l'inverse, l'exercice régulier réduit le risque en régulant le poids et en améliorant le métabolisme.
- **Alimentation déséquilibrée :** Une alimentation riche en graisses saturées et pauvre en fibres est suspectée d'augmenter le risque, tandis qu'une alimentation équilibrée, riche en fruits et légumes, exerce un effet protecteur.
- **Absence d'allaitement :** l'allaitement maternel réduit le risque de cancer du sein, car il diminue la durée d'exposition aux œstrogènes et favorise la maturation des cellules mammaires. Les femmes n'ayant jamais allaité présentent donc un risque légèrement plus élevé.

- **Tabagisme** : Le tabac contient des substances cancérigènes qui favorisent l'apparition de mutations génétiques. Bien que son rôle soit moins marqué que l'alcool ou l'obésité, le tabagisme est reconnu comme un facteur de risque supplémentaire, surtout lorsqu'il est associé à d'autres comportements nocifs.

I.2.4.2 Facteurs génétiques et familiaux

- **Mutations héréditaires (BRCA1, BRCA2, TP53, PALB2)** : Ces anomalies génétiques altèrent les mécanismes de réparation de l'ADN, favorisant l'accumulation de mutations cancéreuses.
- **Antécédents familiaux** : Avoir une mère, une sœur ou une fille atteinte de cancer du sein ou de l'ovaire augmente considérablement le risque.
- **Antécédents personnels** : Une femme ayant déjà eu un cancer du sein ou certaines lésions mammaires prolifératives présente une probabilité plus élevée de récurrence ou de nouveau cancer.

I.2.4.3 Facteurs incontrôlables

- **Âge** : Le risque augmente avec l'âge, particulièrement après 50 ans, en raison de l'accumulation progressive de mutations au fil du temps.
- **Sexe féminin** : La grande majorité des cas concerne les femmes, car leur tissu mammaire est plus exposé aux hormones sexuelles.
- **Caractéristiques hormonales et reproductives** : Une puberté précoce, une ménopause tardive, l'absence de grossesse ou une première maternité tardive prolongent l'exposition aux œstrogènes, ce qui accroît le risque.
- **Densité mammaire élevée** : Les seins denses, visibles à la mammographie, augmentent le risque et compliquent le dépistage.
- **Exposition médicale aux radiations ionisantes** : Une radiothérapie thoracique reçue dans l'enfance ou l'adolescence accroît la probabilité de développer un cancer du sein [5].

I.2.5 les symptômes

Le cancer du sein se manifeste, avant tout dépistage systématique, par un ensemble de signes cliniques qui peuvent alerter la patiente ou le praticien. Les symptômes les plus fréquents incluent l'apparition d'une masse palpable au niveau du sein ou de l'aisselle, souvent indolore et de consistance dure. On observe également des modifications morphologiques du sein, telles

qu'une asymétrie nouvelle ou une déformation de la silhouette mammaire. Les altérations cutanées, comme l'épaississement, la rougeur ou l'aspect en « peau d'orange », constituent des indicateurs importants. Par ailleurs, des changements du mamelon (rétraction, écoulement anormal, démangeaisons persistantes) peuvent être révélateurs. Dans certains cas, la présence de ganglions axillaires palpables précède même la découverte d'une anomalie mammaire. Toutefois, il est essentiel de souligner que le cancer du sein peut rester asymptomatique aux stades précoces, ce qui justifie pleinement l'importance du dépistage par mammographie et autres examens complémentaires [6].

I.2.6 Le dépistage

Le dépistage du cancer du sein repose sur la mammographie, qui permet de repérer des anomalies avant l'apparition de signes cliniques. Il est recommandé aux femmes âgées de 50 à 74 ans de réaliser cet examen tous les deux ans dans le cadre du programme organisé. Ce dispositif vise à réduire la mortalité en favorisant une détection précoce et une prise en charge rapide, tout en garantissant une qualité homogène des examens sur l'ensemble du territoire. Pour les femmes présentant un risque élevé, un suivi spécifique est proposé, souvent plus précoce et rapproché. Ainsi, le dépistage constitue un outil essentiel de santé publique, combinant prévention et équité d'accès aux soins [7].

I.3. Anatomie du sein

Le sein est un organe glandulaire pair, situé dans la partie antérosupérieure du thorax, en avant les muscles pectoraux. Il produit le lait pour l'allaitement féminin. Chez être humain, il existe des différences morphologiques entre les sexes, le sein masculin reste à l'état rudimentaire [8].

I.3.1 Structure du sein

- **La peau** : elle forme la couche externe qui recouvre entièrement la glande mammaire.
- **Le mamelon** : petite saillie centrale de l'aréole, percée par les canaux galactophores qui permettent l'excrétion du lait.
- **L'aréole** : zone circulaire pigmentée autour du mamelon, contenant des glandes de Montgomery qui lubrifient
- **La glande mammaire** : composée de 15 à 20 lobes, chaque lobe étant subdivisé en 20 à 40 lobules reliés par des canaux lactifères, et spécialisée dans la production du lait.
- **Les canaux de lactation** : sont des conduits dans le sein qui servent à faire passer le lait jusqu'au mamelon.
- **Tissu graisseux** : donne la forme et le volume du sein.

- **Tissu conjonctif** : un tissu de soutien qui enveloppe et protège la structure mammaire, assurant la fermeté du sein.




Figure I. 3:Anatomies du sein [9].

I.3.2 Vascularisation et réseau lymphatique

I. 3.2.1 Vascularisation artérielle du sein

Le sein vascularisé principalement par trois artères :

- **L'artère thoracique interne** : branche de la subclavière, vascularise la partie supérieure du sein par ses collatérales destinées aux 2ème, 3ème et 4ème espaces intercostaux et à la face postérieure de la glande.
- **L'artère axillaire** : assure la vascularisation de la glande mammaire par l'artère thoracique latérale et ses collatérales. Elle pénètre la glande de puis le creux axillaire, irrigue surtout la partie externe et inférieure.
- **Les artères intercostales** : assurent l'irrigation de la paroi thoracique et de la région latérale et inférieure du sein, constituant un apport artériel secondaire.
- **Les Veines** : assurent le retour du sang depuis la glande mammaire vers le cœur, en reliant la glande aux veines axillaires, intercostales et thoraciques internes [8].

I.3.2.2 Réseau lymphatique

Le réseau lymphatique est un système de circulation complémentaire à la circulation sanguine, constitué de vaisseaux lymphatiques et ganglions lymphatiques. Il assure le transport de la

lymphe depuis les tissus vers la circulation veineuse. Il est crucial dans la propagation de certaines maladies, comme le cancer [10].

- **Lymphes** : fluide biologique transparent circulant dans le système lymphatique. Elle est composée essentiellement d'eau, de sels minéraux et de cellules immunitaires. Elle permet l'évacuation du surplus de liquide interstitiel, le transport de certaines molécules (notamment les lipides) et contribue aux défenses de l'organisme.
- **Vaisseaux lymphatiques** : ensemble de canaux assurant la circulation de la lymphe à travers l'organisme. Ils débutent par des capillaires dans les tissus, s'unissent en vaisseaux de plus grand calibre dotés de valvules, puis rejoignent la circulation sanguine.
- **Ganglions lymphatiques** : organes de petite taille disposés le long des vaisseaux lymphatiques. Ils jouent un rôle de filtration de la lymphe et participent à l'activation des cellules immunitaires lors des réponses de défense.

I.4. L'imagerie médicale du cancer du sein

L'imagerie médicale regroupe plusieurs techniques utilisées pour détecter, évaluer et suivre le cancer du sein. La mammographie, l'IRM mammaire, l'échographie et le TEP-scan sont employées de manière complémentaire afin d'aider au diagnostic, d'apprécier l'évolution de la maladie et d'orienter la prise en charge thérapeutique.

I.4.1 La mammographie

La mammographie s'impose aujourd'hui comme une méthode incontournable dans le domaine de l'imagerie médicale. D'un point de vue scientifique, elle se décrit comme une technique radiographique standardisée permettant l'exploration du tissu mammaire et la détection précoce d'anomalies, notamment celles liées au cancer du sein [11]

I.4.2 Historique

La mammographie a connu une évolution progressive depuis plus d'un siècle. En 1913, Albert Salomon réalisa les premières radiographies de seins opérés, démontrant que l'imagerie pouvait révéler différents types de cancers. Dans les années 1930, Stafford Warren poursuivit ces recherches sur patientes vivantes, ouvrant la voie à une pratique clinique. En 1949, Raúl Leborgne améliora la technique grâce à la compression et à des réglages spécifiques, tandis que Jacob Gershon-Cohen introduisit la mammographie préventive dans les années 1950. En 1965, Charles Gros inventa le premier appareil dédié, et peu après, les États-Unis lancèrent le premier dépistage de masse. Les décennies suivantes virent l'amélioration des films radiographiques et la détection des microcalcifications, jusqu'aux années 1990 où les études confirmèrent que la

mammographie réduisait la mortalité par cancer du sein. Depuis les années 2000, elle est devenue numérique, puis 3D avec la tomosynthèse, et aujourd'hui l'intelligence artificielle vient renforcer l'interprétation des images [12].

I.4.3 les types de mammographies

I.4.3.1 Mammographie analogique :

Technique traditionnelle qui utilise un film radiographique argentique. Les rayons X traversent le sein et impressionnent le film, lequel doit ensuite être développé chimiquement. L'image obtenue est fixe et ne peut pas être modifiée.

I.4.3.2 Mammographie numérique :

Méthode moderne où les rayons X sont captés par un détecteur électronique. L'image est transformée en données numériques, ce qui permet un traitement informatique.

I.4.3.3 Tableau comparatif

Critère d'analyse	Mammographie analogique	Mammographie numérique
Support de l'image	Film radiographique	Écran
Qualité de l'image	Moyenne résolution	Haute résolution
Manipulation	Image fixe non modifiable	Image ajustable
Archivage	Conservation physique des films	Stockage numérique PACS
Détection d'anomalies	Moins précise	Plus précise

Tableau I. 1:La comparaison entre la mammographie analogique et numérique

I.4.4 Le mammographe

Le mammographe est un dispositif médical spécialisé de radiologie, conçu pour l'imagerie du sein par rayons X. Il permet de détecter des anomalies telles que les microcalcifications, les masses ou les nodules [12].




Figure I. 4: Représente le schéma des composants d'un mammographe [13].

I.4.5 Procédé de la mammographie

La mammographie débute par le positionnement de la patiente devant l'appareil, debout ou allongée selon l'angle souhaité. Le sein est ensuite comprimé à l'aide d'un plaque compression, afin d'étaler le tissu mammaire pour obtenir une image de haute qualité tout en minimisant l'exposition aux rayons x.

Un faisceau de rayons x à faible énergie entre 25 et 32 KV, généré par un tube à foyer fin, traverse le sein et est capté par un détecteur, pouvant être un film radiographie, une plaque phosphore ou un capteur numérique plan. Chaque sein est examiné sous deux projections principales : crânio-caudale (CC) et médio-latérale oblique (MLO), permettant une analyse complète de la glande mammaire.

Les images obtenues lors de la mammographie sont automatiquement traitées par l'appareil et affichées sur écran noir et blanc de haute résolution, toute modification manuelle étant déconseillée afin de ne pas altérer des informations sensibles, en particulier les microcalcifications. Les clichés sont ensuite interprétés par un radiologue ou un oncologue, qui rédige un compte-rendu détaillé transmis au médecin prescripteur ou directement à la patiente, généralement dans un délai d'une semaine [14].



Figure I. 5:Représente schéma de déroulement d'une mammographie et affichage de résultats [15].

I.5. Anomalies détectables en mammographie

- **Masse :** Une masse est une opacité visible en mammographie, correspondant à une lésion solide ou liquidienne. Elle peut être bénigne (fibroadénome, kyste) ou maligne (cancer). Les masses bénignes ont des contours réguliers et bien limités, tandis que les masses suspectes présentent des contours spiculés ou irréguliers, traduisant une infiltration du tissu environnant [16]
- **Microcalcifications :** Les microcalcifications sont de minuscules dépôts de calcium visibles comme de petits points blancs très fins sur la mammographie. Elles sont importantes car elles peuvent être le premier signe d'un cancer du sein, notamment d'un carcinome canalaire in situ. Les microcalcifications bénignes sont souvent rondes, grossières et diffuses, liées à des séquelles ou à des lésions anciennes. En revanche, les microcalcifications suspectes sont fines, irrégulières, groupées et disposées en distribution segmentaire ou linéaire, ce qui traduit une prolifération cellulaire anormale. Leur analyse détaillée est donc essentielle pour différencier une lésion bénigne d'une lésion maligne [16].
- **Distorsion architecturale :** La distorsion architecturale correspond à une désorganisation du tissu mammaire sans masse individualisée. Elle se manifeste par des lignes convergentes ou des zones de traction. Ce signe peut être secondaire à une cicatrice post-chirurgicale ou indiquer une lésion infiltrante [16].

- **Asymétrie de densité** : l'asymétrie de densité est une différence radiologique entre deux zones du sein ou entre les deux seins. Elle peut être localisée ou diffuse. Certaines asymétries sont simplement des variantes anatomiques, mais une asymétrie nouvelle ou persistante peut révéler une tumeur [16].
- **Anomalies cutanées** : Les anomalies cutanées regroupent l'épaississement de la peau et la rétraction du mamelon ou de la peau. Elles peuvent être liées à une inflammation, un lymphœdème ou à une tumeur infiltrante [16].
- **Ganglions axillaires** : Les ganglions axillaires apparaissent parfois hypertrophiés ou irréguliers en mammographie. Une adénopathie se définit par une augmentation de taille ou une perte du hile graisseux. Elle peut traduire une réaction inflammatoire bénigne ou une atteinte métastatique dans le cadre d'un cancer du sein [16].

I.6. Le système BI-RADS

Le Breast Imaging-Reporting and Data System est un système de classification standardisée des anomalies observées en mammographie, développé par l'American College of Radiology (ACR) il sert de référence aux radiologues pour analyser les images mammaires, harmoniser l'interprétation des résultats et appuyer l'établissement ou diagnostic des examens de sein. Il permet de classer les anomalies détectées selon leur probabilité de malignité, à partir de critères radiologiques définis [16].

Catégorie BI-RADS	Imagerie	Probabilité de malignité
0	Examen incomplet	Non déterminé
1	Seins normaux	Très faible < 2%
2	Anomalie Bénin	Aucun 0%
3	Probablement bénin	Faible < 2%
4	Suspect mais incertain	Moyen à élevé 2 à 95%
5	Fortement suspect	Très élevé > ,= 95%
6	Cancer confirmé	Certain 100 %

Tableau I. 2:Classification BI-RADS et probabilité de malignité associée.

I.7. Les fichiers DICOM

La norme DICOM (Digital Imaging and Communications in Medicine) est un standard international dédié à la gestion, au stockage et à l'échange des images médicales, comme les radiographies, les IRM ou encore les mammographies. Elle a été conçue pour assurer la compatibilité

et l'interopérabilité entre les différents systèmes d'imagerie médicale, les logiciels et les établissements de santé, indépendamment des fabricants. Ce standard s'intègre également avec d'autres protocoles de santé tels que HIE (Health Information Exchange) pour le partage des données médicales entre institutions et HL7 pour la communication entre applications cliniques.

Un fichier DICOM, identifié par l'extension (.dcm), est structuré de manière spécifique. Il contient d'une part un en-tête composée de balises organisées, qui regroupe les métadonnées relatives au patient comme l'identité, âge, sexe, ainsi que les informations liées à l'examen comme type d'acquisition, paramètres techniques, date et conditions de réalisation. D'autre part, il comprend les données d'image proprement dites, représentées sous forme de matrice de pixels.

Cette organisation permet non seulement de conserver les images médicales avec un niveau de détail élevé, mais aussi d'assurer une traçabilité complète des informations associées. Grâce à cette structure normalisée, les fichiers DICOM jouent un rôle essentiel dans les systèmes d'archivage médical et dans les applications modernes d'analyse et d'aide au diagnostic

```
Dataset.file_meta -----
(0002, 0000) File Meta Information Group Length  UL: 174
(0002, 0001) File Meta Information Version       OB: b'\x00\x01'
(0002, 0002) Media Storage SOP Class UID        UI: CT Image Storage
(0002, 0003) Media Storage SOP Instance UID     UI: 1.2.840.113704.1.111.5044.1167842488.11984
(0002, 0010) Transfer Syntax UID                UI: Explicit VR Little Endian
(0002, 0012) Implementation Class UID          UI: 1.2.40.0.13.1.1.1
(0002, 0013) Implementation Version Name       SH: 'dcm4che-1.4.34'
-----
(0008, 0008) Image Type                        CS: ['ORIGINAL', 'PRIMARY', 'AXIAL', 'HELIX']
(0008, 0012) Instance Creation Date            DA: '20070103'
(0008, 0013) Instance Creation Time            TM: '104128'
(0008, 0016) SOP Class UID                     UI: CT Image Storage
```

Figure I. 6: Représentation des métadonnées et de la structure interne d'un fichier DICOM [17].

I.8. Avantages et limites de la mammographie

I.8.1 Avantages :

- **Outil de référence en dépistage :** la mammographie est la technique la plus utilisée pour détecter précocement le cancer du sein, avant l'apparition de symptômes cliniques.

- **Visualisation des microcalcifications** : elle permet d'identifier des anomalies très fines, souvent invisibles à l'échographie.
- **Suivi longitudinal** : les images peuvent être comparées dans le temps, ce qui facilite l'évaluation de l'évolution d'une lésion.
- **Accessibilité et rapidité** : examen relativement court, disponible dans la majorité des structures médicales.
- **Amélioration avec le numérique** : meilleure qualité d'image, possibilité de traitement informatique (zoom, contraste), réduction de la dose de rayons X et archivage électronique.

I.8.2 Limites :

- **Exposition aux rayonnements ionisants** : bien que faible, elle reste un facteur à considérer, surtout dans le cadre de dépistages répétés.
- **Inconfort de l'examen** : la compression mammaire nécessaire peut être douloureuse ou gênante.
- **Sensibilité variable** : la mammographie est moins performante chez les femmes ayant une forte densité mammaire, ce qui peut masquer certaines lésions.
- **Résultats imparfaits** : possibilité de faux positifs (entraînant anxiété et examens supplémentaires) et de faux négatifs (retardant le diagnostic).
- **Besoin de techniques complémentaires** : dans certains cas, une échographie ou une IRM est nécessaire pour compléter l'évaluation [18].

I.9. Conclusion

Ce premier chapitre a permis de situer le contexte médical du cancer du sein en abordant son anatomie, ses facteurs de risques, les modalités de dépistage ainsi que les différents types de tumeurs et anomalies. L'analyse des techniques d'imagerie, notamment la mammographie. Malgré son utilité dans la détection précoce de nombreuses anomalies, certains restent difficiles à identifier, notamment à cause du faible contraste ou de la densité du tissu mammaire. Ces limites mettent en évidence la nécessité de recourir à des méthodes plus avancées, telles que l'intelligence artificielle et en particulier les méthodes de Deep Learning, pour améliorer la détection des anomalies subtiles et optimiser la précision du diagnostic en imagerie mammographiques, sujet qui sera développé dans le chapitre suivant.

Chapitre II :
Intelligence Artificiel et Deep Learning

II.1. Introduction

L'intelligence artificielle (IA) connaît aujourd'hui un essor rapide et occupe une place centrale dans le domaine médical. Elle offre des outils puissants pour analyser les images médicales, permettant de détecter des anomalies qui pourraient passer inaperçues lors d'un examen traditionnel. Dans le contexte du cancer du sein, l'ia contribue à améliorer la précision du dépistage et à soutenir les professionnels de santé dans leurs décisions cliniques.

Parmi les approches les plus efficaces, les réseaux de neurones artificiels, notamment les réseaux convolutifs (CNN) et des architectures avancées telles que ResNet, permettent d'extraire et de reconnaître des motifs complexes dans les images mammaires. Ces technologies facilitent ainsi l'identification précoce des lésions et renforcent la fiabilité du diagnostic.

Ce chapitre présente les concepts essentiels de l'ia appliquée à l'imagerie mammaire, en mettant en lumière son intérêt pour le dépistage du cancer du sein et son rôle croissant dans l'accompagnement des praticiens.

II.2. Intelligence Artificielle

L'intelligence artificielle (IA) est une discipline de l'informatique consacrée au développement de systèmes capables de simuler certaines facultés cognitives humaines. Elle a pour objectif de concevoir des programmes et des machines aptes à accomplir des tâches qui nécessitent habituellement l'intelligence humaine, telles que la reconnaissance vocale et faciale, la compréhension du langage naturel, la prise de décision ainsi que la résolution de problèmes complexes.

Son fonctionnement repose sur l'exploitation d'algorithmes et de modèles mathématiques permettant aux systèmes d'analyser des données, d'en extraire des informations pertinentes et d'améliorer progressivement leurs performances grâce à l'expérience. Parmi les principales approches qui soutiennent le développement de l'ia figurent notamment le Machine Learning et le Deep Learning, qui permettent aux systèmes d'apprendre à partir des données et de traiter des informations de plus en plus complexes.

On distingue généralement l'IA dite « faible », spécialisée dans l'exécution d'une tâche spécifique, et l'IA dite « forte », qui vise à reproduire l'ensemble des capacités intellectuelles humaines, bien que cette dernière demeure encore théorique.

Aujourd'hui, l'intelligence artificielle est largement intégrée dans divers domaines tels que la santé, la finance, les transports, la sécurité et l'éducation. Elle contribue à améliorer la

Précision des analyses, l'efficacité des processus et la rapidité de la prise de décision. Toutefois, son expansion soulève également des questions importantes liées à l'éthique, à la protection des données personnelles et à son impact sur l'emploi et la société [19].




Figure II. 1: Les techniques fondamentales de l'intelligence artificielle.

II.2.1 Évolution de l'intelligence artificielle dans l'imagerie médicale

L'intelligence artificielle (IA) occupe une place croissante dans l'évolution des technologies d'imagerie médicale, en raison de sa capacité à améliorer l'exploitation et l'analyse des données médicales complexes. Les approches basées sur l'apprentissage automatique permettent de traiter de grands volumes d'images issues de différentes modalités telles que la radiographie, le scanner, l'IRM et la mammographie, avec une efficacité accrue.

Selon les études récentes, l'un des apports majeurs de l'ia réside dans l'amélioration de la performance diagnostique. En effet, les algorithmes sont capables d'identifier des structures et des anomalies difficiles à détecter par une analyse humaine classique, ce qui favorise une détection plus précoce des pathologies et une meilleure précision des résultats cliniques.

Par ailleurs, l'ia contribue à l'optimisation des processus en imagerie médicale en automatisant plusieurs étapes de traitement, notamment la classification des images, la segmentation des régions d'intérêt et l'assistance à l'interprétation radiologique. Cette automatisation permet de réduire le temps d'analyse et d'améliorer l'efficacité des services médicaux.

L'étude met également en évidence un impact organisationnel et économique important. L'intégration de l'ia permet une meilleure allocation des ressources, une réduction des coûts liés au diagnostic et une amélioration globale de la productivité dans les structures de santé [20].

II.3. Machine Learning

Machine Learning (l'apprentissage automatique) constitue un sous-domaine fondamental de l'intelligence artificielle. Il se concentre sur la conception de modèles computationnels capables d'acquérir des connaissances à partir des données, sans recourir à une programmation explicite pour chaque tâche. Son principe repose sur l'exploitation d'ensembles de données afin d'identifier des régularités, des corrélations et des structures sous-jacentes.

Sur le plan méthodologique, l'apprentissage automatique mobilise des outils issus des statistiques, de l'algèbre linéaire et de l'optimisation numérique pour construire une fonction mathématique reliant des variables d'entrée à une sortie prédictive. Le processus d'entraînement consiste à ajuster les paramètres internes du modèle en minimisant une fonction de coût, ce qui permet d'améliorer progressivement ses performances.

L'un des objectifs majeurs du machine learning est la capacité de généralisation, c'est-à-dire l'aptitude du modèle à produire des résultats pertinents sur de nouvelles données non observées lors de l'apprentissage. Ainsi, il représente un pilier essentiel de l'intelligence artificielle moderne, en permettant l'automatisation de tâches complexes telles que la classification, la prédiction ou l'aide à la décision, dans divers domaines scientifiques et industriels [21].

II.3.1 l'utilisation de la machine learning

L'apprentissage automatique occupe aujourd'hui une place centrale dans de nombreux domaines, tels que les services bancaires, le commerce électronique et les réseaux sociaux, en optimisant l'efficacité, la sécurité et la personnalisation des interactions utilisateur. Les algorithmes sous-jacents permettent, par exemple, la reconnaissance faciale pour l'identification automatique des individus sur des images, la reconnaissance optique de caractères pour la conversion de documents en formats exploitables, ainsi que le fonctionnement des moteurs de recommandation qui adaptent les contenus aux préférences individuelles. Ces applications illustrent l'intégration systématique de l'apprentissage automatique dans les technologies modernes, démontrant son rôle essentiel dans l'amélioration des systèmes intelligents [22].

II.3.2 Types d'apprentissages

II.3.2.1 apprentissage supervisé

L'apprentissage supervisé est une technique du machine learning basée sur l'utilisation de données d'entraînement étiquetées. Chaque donnée possède une entrée et une sortie connue, ce qui permet au modèle d'apprendre la relation entre les caractéristiques et les résultats attendus.

Pendant la phase d'apprentissage, l'algorithme compare ses prédictions aux valeurs réelles, calcule l'erreur, puis ajuste ses paramètres afin d'améliorer progressivement sa précision. Une fois entraîné, le modèle peut prédire les étiquettes de nouvelles données [23].

Cette méthode est principalement utilisée dans deux types de tâches :

- **La régression** : consiste à prédire une valeur numérique continue, comme un prix ou une consommation d'énergie.
- **La classification** : quant à elle, vise à attribuer une donnée à une catégorie précise, par exemple reconnaître un chiffre manuscrit ou déterminer si une tumeur bénigne ou maligne.

II.3.2.2 apprentissage non supervisé

L'apprentissage non supervisé est une méthode d'intelligence artificielle qui consiste à analyser des données non étiquetées afin d'identifier automatiquement des structures ou des regroupements basés sur leurs similarités.

Les algorithmes de clustering, tels que K-means, sont couramment utilisés pour partitionner les données en groupes homogènes selon leurs caractéristiques communes [24].

II.3.2.3 apprentissages par renforcement

L'apprentissage par renforcement est une approche de l'intelligence artificielle dans laquelle un agent apprend à optimiser ses décisions à travers des interactions continues avec un environnement. Chaque action entreprise génère un signal de récompense ou de pénalité, permettant à l'agent d'ajuster progressivement sa stratégie. L'objectif de ce processus est de déterminer une politique optimale visant à maximiser la récompense cumulative sur le long terme [23].




Figure II. 2: Schéma des types d'apprentissage en Machine Learning [25].

II.4. Deep Learning

Le deep learning ou apprentissage profond est un sous-domaine de l'apprentissage automatique qui repose sur des réseaux neuronaux artificiels profonds composés de plusieurs couches. Il permet au modèle d'apprendre automatiquement des représentations hiérarchiques complexes à partir de données brutes, ce qui rend possible la résolution de tâches difficiles comme la reconnaissance d'images, le traitement du langage naturel ou la synthèse vocale, sans qu'un humain ait à sélectionner manuellement les caractéristiques importantes des données [26].

II.5. La représentation des réseaux neurones artificiel

En apprentissage profond, l'objectif ne se limite pas à créer un modèle unique, mais consiste à concevoir des réseaux de neurones artificiels (ANN). Contrairement au machine learning traditionnel, où un modèle peut se réduire à une fonction simple, comme une régression linéaire ou logistique, un réseau de neurones est constitué de multiples fonctions interconnectées organisées en couches, formant ainsi une architecture complexe. La capacité des machines à accomplir des tâches sophistiquées dépend directement de la profondeur et de la complexité de ces réseaux. Ces tâches incluent, entre autres, la reconnaissance d'objets, l'identification de visages

sur des images, la conduite autonome ou encore le traitement du langage naturel. Pour comprendre le fonctionnement de ces réseaux, il est essentiel de revenir à leurs origines et d'analyser l'évolution de leur conception jusqu'aux architectures technologiques avancées que nous utilisons aujourd'hui [27].

II.5.1 les réseaux neurones artificiel

II.5.1.1 Définition

Un réseau de neurones artificiels, appelé également Artificial Neural Network (ANN), est un modèle informatique inspiré du fonctionnement du cerveau humain. Il vise à reproduire le mécanisme d'apprentissage à partir des données à l'aide de structures mathématiques et algorithmiques.

Ce réseau est constitué de plusieurs couches de neurones artificiels fortement interconnectés. Chaque neurone reçoit des informations en entrée, effectue un traitement mathématique, puis transmet le résultat aux neurones suivants. Cette organisation en couches permet de modéliser des relations complexes et d'améliorer les performances du système au cours de l'apprentissage [28].




Figure II. 3:Neurone biologique [29].

II.5.1.2 Structure d'un réseau de neurones artificiels

Un réseau de neurones artificiels est constitué de plusieurs couches de neurones interconnectées. Chaque neurone reçoit des informations numériques provenant des neurones de la couche précédente. Le réseau comprend une couche d'entrée, qui capte les données initiales, une ou plusieurs couches cachées, qui traitent et transfèrent l'information, et une couche de sortie, qui génère les résultats finaux du système [28].




Figure II. 4: Structure d'un réseau de neurones artificiels [30].

II.5.1.3 Principe de fonctionnement d'un réseau de neurones artificiels

Un réseau de neurones artificiels fonctionne en transmettant des données à travers plusieurs couches de neurones. Chaque neurone reçoit des entrées, les multiplie par des poids et additionne un biais, puis applique une fonction d'activation f pour produire sa sortie, représentée par la formule :

$$y = f(\sum w_i x_i + b). \quad (\text{II.1})$$

Les signaux circulent de la couche d'entrée vers les couches cachées, puis vers la couche de sortie. Le réseau apprend en ajustant les poids w_i et les biais b via la rétropropagation, afin de réduire l'écart entre la sortie prédite et la sortie réelle, permettant ainsi au modèle de généraliser à de nouvelles données et de résoudre des problèmes complexes [26] :

- x_i : entrée du neurone.
- w_i : poids associé à l'entrée.
- b : biais du neurone.
- f : fonction d'activation (sigmoïde, relu, tanh).
- y : sortie du neurone.




Figure II. 5:Modèle mathématique d'un neurone artificiel intégrant la fonction d'activation [31].

II.5.2 Les fonctions d'activation

Les fonctions d'activation déterminent si un neurone doit être activé en traitant la somme pondérée de ses entrées provenant de la couche précédente. Elles produisent ensuite une sortie, généralement non linéaire, qui est transmise à la couche suivante. Ces fonctions contribuent également à normaliser les sorties des neurones, en les maintenant dans une plage spécifique, typiquement comprise entre 0 et 1 ou entre -1 et 1 .ci-après nous présentons quelques exemples de fonctions d'activation couramment utilisées [32].

II.5.2.1 Fonction de sigmoid

Transforme la somme pondérée en une valeur comprise entre 0 et 1. Utile pour la probabilité en classification binaire.




Figure II. 6:Fonction de sigmoid.

II.5.2.2 Fonction softmax

Convertit un vecteur de valeurs en probabilités dont la somme est égale à 1. Utilisée pour la classification multi-classe.

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (\text{II.3})$$




Figure II. 7:Fonction softmax

II.5.2.3 Fonction relu

Renvoie 0 pour les valeurs négatives et x pour les positives. Très utilisée dans les réseaux profonds pour réduire le problème de vanishing gradient .

$$\text{ReLU}(x) = \max(0, x) \quad (\text{II.4})$$

$$\text{ReLU}(x) = \begin{cases} 0 & \text{pour } x < 0 \\ x & \text{pour } x \geq 0 \end{cases} \quad (\text{II.5})$$




Figure II. 8:Fonction relu.

II.5.2.4 Fonction Tanh

Convertit la somme pondérée en une valeur entre -1 et 1, centrée sur 0, ce qui facilite l'apprentissage.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (\text{II.6})$$




Figure II. 9:Fonction Tanh.

II.5.3 Fonction de la perte

La fonction de perte est une fonction mathématique utilisée en apprentissage automatique pour évaluer la qualité des prédictions d'un modèle. Elle mesure l'écart entre les valeurs prédites par le modèle et les valeurs réelles observées dans les données. Pendant l'entraînement du modèle, cette fonction sert d'indicateur pour ajuster les paramètres du réseau afin de réduire l'erreur et améliorer les performances du système [26].

Pour un ensemble de n échantillons d'entraînement, la fonction de perte est définie comme suit :

$$l = \frac{1}{n} \sum_{i=1}^n f(t_i, p_i) \quad (II.7)$$

- t_i : valeur réelle.
- p_i : valeur prédit.
- n : nombre d'échantillons d'entraînement.
- $f(t_i, p_i)$: fonction de perte calculée pour chaque échantillon i .

Il existe une grande variété de fonctions de perte, chacune adaptée à des objectifs, des types de données et des priorités spécifiques. Dans le cadre des problèmes de classification, les fonctions les plus utilisées sont :

II.5.3.1 Entropie croisée (Cross-Entropy) :


L'entropie croisée est une fonction de perte couramment utilisée dans les problèmes de classification. Elle permet d'évaluer l'écart entre les probabilités prédites par le modèle et les valeurs réelles associées aux différentes classes. Son objectif est de pénaliser les prédictions incorrectes et d'encourager le modèle à attribuer une probabilité élevée à la classe correcte.

$$\text{Valeur CE} = - \sum_{i=1}^c t_i \log(p_i) \quad (II.8)$$

- t_i : réelle (Ground-truth).
- c : nombre de classes.
- p_i : probabilité prédite pour la classe i

II.5.3.2 Entropie croisée binaire (Binary Cross-Entropy) :

L'entropie croisée binaire est une fonction de perte utilisée dans les tâches de classification binaire. Elle est souvent associée à la fonction d'activation sigmoïde, qui permet de convertir la sortie du modèle en une probabilité comprise entre 0 et 1.




$$\sigma(s_i) = \frac{1}{1+e^{-s_i}} \quad (\text{II.9})$$

$$BCE = -t \log(\sigma(s_i)) + (1 - t) \log(1 - \sigma(s_i)) \quad (\text{II.10})$$

- SI : les logits (scores).
- t : valeur réelle (0 ou 1).
- $\sigma(s_i)$: probabilité prédite par la sigmoid.

II.5.3.3 Entropie croisée catégorique (Categorical Cross-Entropy) :

L'entropie croisée catégorique est une fonction de perte utilisée dans les problèmes de classification multiclasse. Elle permet de mesurer l'écart entre les classes réelles et les probabilités prédites par le modèle. Plus cette valeur est faible, plus les prédictions du modèle sont proches des valeurs réelles. Elle est généralement associée à la fonction d'activation Softmax, qui convertit les sorties du réseau en probabilités.



$$\text{Softmax}(s)_i = \frac{e^{s_i}}{\sum_{j=1}^c e^{s_j}} \quad (\text{II.11})$$

$$CCE = - \sum_{i=1}^c t_i \log(\text{Softmax}(s)_i) \quad (\text{II.12})$$

- c : nombre de classes.
- t_i : valeur réelle (Ground-truth).
- $\text{Softmax}(s)_i$: vecteur de probabilités prédites.
- S : vecteur de logits.

II.5.4 la rétropropagation

La rétropropagation du gradient (Backpropagation) est un algorithme d'apprentissage supervisé utilisé pour entraîner les réseaux de neurones. Après le calcul de l'erreur entre la prédiction du modèle et la valeur réelle, cette erreur est propagée de la couche de sortie vers les couches précédentes afin de calculer les gradients. Ces gradients servent ensuite à ajuster les poids et les biais du réseau à l'aide d'un algorithme d'optimisation, tel que la descente de gradient, dans le but de minimiser la fonction de perte et d'améliorer les performances du modèle (figure 2.10) [26].




Figure II. 10:Schéma illustrant le processus de rétropropagation du gradient dans un réseau neuronal multi-couche [33].

II.5.5 Gradient évanescent

Dans les réseaux de neurones convolutifs (CNN) profonds, le problème du gradient évanescent (Vanishing Gradient) apparaît lors de la rétropropagation du signal d'erreur. En effet, le gradient de la fonction de perte est propagé de la couche de sortie vers les couches initiales à travers la règle de la chaîne. À chaque étape, ce gradient est multiplié par les dérivées locales des fonctions d'activation et des poids du réseau.

Lorsque ces dérivées prennent des valeurs inférieures à 1, leur multiplication successive à travers un grand nombre de couches entraîne une décroissance exponentielle du gradient. Ainsi, plus le réseau est profond, plus l'amplitude du gradient diminue en se rapprochant des premières couches. Cela conduit à une mise à jour très faible, voire négligeable, des paramètres des couches initiales.

Ce phénomène pose une limitation importante dans l'apprentissage des CNN profonds, car les premières couches sont responsables de l'extraction des caractéristiques fondamentales (con-

tours, textures, motifs de base). Une faible mise à jour de leurs poids réduit la capacité du modèle à construire des représentations hiérarchiques efficaces, ce qui impacte directement les performances globales du réseau [34].




Figure II. 11: Variation du Gradient par Couche durant la Rétropropagation dans un Réseau de Neurones Profond [35].

II.5.6 Réseau de neurones convolutionnel

Un réseau de neurones convolutionnel (Convolutional Neural Network – CNN ou ConvNet) est un algorithme d'apprentissage profond conçu principalement pour traitement et l'analyse des images. Il prend une image comme entrée et apprend automatiquement à identifier ses caractéristiques importantes en attribuant des poids et des biais aux différentes parties de l'image, ce qui lui permet de distinguer les objets présents.

L'architecture des CNN s'inspire du fonctionnement du cortex visuel humain, chaque neurone répond uniquement aux stimuli situés dans une zone restreinte du champ visuel, appelée champ récepteur. L'ensemble de ces champs se chevauchent pour couvrir toute la zone visuelle, permettant au réseau de détecter efficacement les différentes structures présentes dans l'image [36].




Figure II. 12: Architecture de base d'un réseau de neurones convolutionnel (CNN) [37].

II.5.6.1 Couche de convolution

Une couche convolutionnel se compose de filtres (noyaux ou kernels) qui parcourent l'image pour en extraire des caractéristiques importantes. Chaque filtre calcule un produit scalaire entre ses poids et les pixels de la région analysées, produisant une carte de caractéristiques (feature map). Ces cartes permettent au réseau de détecter progressivement des motifs tels que les contours, les textures ou les formes de l'image [38].




Figure II. 13:Exemple explicative sur l'opération de convolution [39].

II.5.6.2 Couche de pooling

La couche de pooling est un processus de discrétisation à base d'échantillon, généralement placée entre deux couches de convolution dans un réseau de neurones convolutionnel. Elle a pour rôle de réduire les dimensions des cartes de caractéristiques en appliquant une opération de résumé sur de petites régions, ce qui permet de diminuer la quantité de données tout en conservant les informations importantes. Les méthodes les plus courantes sont le **Max Pooling** qui sélectionne le pixel qui a la valeur maximale entre tous les pixels de la sélection et **Average Pooling** qui calcule la moyenne de tous les pixels de la sélection [26].




Figure II. 14:Exemple explicative sur l'opération de Max Pooling et Average Pooling [40].

II.5.6.3 Couche fully-connected

La couche entièrement connectée est une couche placée en fin d'architecture de CNN dans laquelle chaque neurone est relié à tous ceux de la couche précédente et de la couche suivante. Elle transforme le vecteur d'entrée via une combinaison linéaire suivie d'une fonction d'activation, produisant un vecteur de sortie qui alimente la couche suivante. Cette couche permet de combiner les caractéristiques extraites pour réaliser la classification finale [41].




Figure II. 15: Couche fully-connected [42].

II.6. Modèles de deep learning en vision par ordinateur

Les modèles de deep learning appliqués à la vision par ordinateur ont fortement évolué ces dernières années, permettant des avancées significatives dans l'analyse et l'interprétation des données visuelles. Ces architectures peuvent être regroupées en plusieurs familles selon les tâches qu'elles permettent d'accomplir, notamment la classification d'images, la détection d'objets, la segmentation sémantique, ainsi que les approches récentes basées sur les Transformers. Chaque catégorie de modèles présente des propriétés spécifiques et est conçue pour répondre à des problématiques distinctes liées à la compréhension et à l'exploitation des images numériques dans divers contextes applicatifs [43].

II.7. L'architecture ResNet

ResNet (Residual Network) est une architecture de réseaux de neurones convolutifs introduite afin d'améliorer la reconnaissance et la classification d'images complexes.

La principale particularité de ResNet est qu'elle constitue une solution au problème du gradient évanescent. Elle repose sur l'utilisation de blocs résiduels, qui facilitent l'entraînement de ré-

seaux très profonds. Cette approche consiste à introduire des connexions de saut (skip connections) reliant directement l'entrée d'un bloc à sa sortie. Ainsi, l'information peut contourner certaines couches au lieu de traverser obligatoirement toutes les couches de manière séquentielle, ce qui facilite la propagation du signal et stabilise l'apprentissage [45].

L'architecture de ResNet est construite à partir d'une succession de blocs résiduels, chacun contenant une organisation interne basée sur des opérations de convolution. À l'intérieur de chaque bloc, on trouve principalement des couches de convolution 3×3 et parfois 1×1 dans les blocs bottleneck, suivies de Batch Normalization et de la fonction d'activation relu. Ces opérations permettent d'extraire progressivement les caractéristiques de l'image tout en stabilisant l'apprentissage.

Le point clé de cette architecture est la connexion résiduelle, qui ajoute directement l'entrée du bloc à sa sortie après les opérations de convolution. Cette addition permet de conserver l'information initiale et d'éviter la dégradation des performances dans les réseaux profonds. L'ensemble du réseau est donc une répétition de ces blocs, suivie d'un Global Average Pooling et d'une couche Fully Connected pour produire la classification finale. Selon la profondeur du réseau, plusieurs variantes de ResNet ont été développées, parmi lesquelles **resnet-18**, **resnet-34**, **resnet-50**, **resnet-101** et **resnet-152**, qui se distinguent principalement par le nombre de couches et de blocs résiduels utilisés [45].




Figure II. 16 : Architecture ResNet « Bloc Résiduel, Bottleneck et Classification d’Images » [46].

II.8. L’architecture EfficientNet

EfficientNet est une architecture de réseau de neurones convolutif (CNN) développée pour obtenir de hautes performances en classification d’images tout en maintenant une efficacité computationnelle élevée. Contrairement aux approches traditionnelles qui augmentent séparément la profondeur ou la largeur du réseau, EfficientNet adopte une stratégie de mise à l’échelle uniforme permettant d’améliorer simultanément plusieurs dimensions du modèle de manière équilibrée.

Cette famille de modèles comprend plusieurs variantes, allant de **EfficientNet-B0** à **EfficientNet-B7**. Le modèle **B0** constitue l’architecture de référence, tandis que les versions suivantes sont obtenues par une augmentation progressive de la capacité du réseau. Cette évolution permet d’améliorer les performances de classification, au prix d’une augmentation des besoins en mémoire et en puissance de calcul. Grâce à son efficacité et à sa robustesse, EfficientNet est

largement utilisé dans les applications de vision par ordinateur, notamment dans le domaine de l'imagerie médicale.

II.9. Conclusion

Dans ce chapitre, nous avons présenté les concepts fondamentaux de l'intelligence artificielle, du Machine Learning et du Deep Learning. Nous avons également étudié les réseaux de neurones artificiels, les réseaux de neurones convolutionnels (CNN) ainsi que les mécanismes d'apprentissage qui leur permettent d'extraire automatiquement des caractéristiques à partir des images. Enfin, l'architecture ResNet a été introduite comme une solution efficace au problème du gradient évanescent, offrant de meilleures performances pour les tâches de classification d'images. Ces notions constituent le socle théorique nécessaire à la compréhension de la méthodologie adoptée dans la suite de ce travail.

Chapitre III :
Conception et implémentation du système

III.1. Introduction

Dans ce chapitre, nous présentons la démarche adoptée pour la conception de notre système de détection des anomalies mammaires basé sur les techniques de deep learning, ainsi que les principales étapes de son développement.

Notre travail s'appuie sur la base de données RSNA Screening Mammography Breast Cancer Detection, qui contient des images mammographiques annotées représentant différents cas cliniques. Cette base de données est adaptée à l'apprentissage profond grâce à la diversité des images qu'elle propose, ce qui permet d'entraîner et d'évaluer efficacement les modèles.

La méthodologie mise en œuvre repose sur un processus global comprenant principalement les étapes de prétraitement des images, de transformation des données et de classification. Dans ce travail, nous avons utilisé deux modèles de réseaux de neurones convolutifs, à savoir resnet-50 et efficientnet-B4 pré-entraîné, afin de comparer leurs performances dans la tâche de classification des images mammographiques.

L'objectif de ce système est de distinguer automatiquement les mammographies saines de celles présentant des anomalies liées au cancer du sein, afin d'améliorer la détection précoce et d'assister le radiologue dans son diagnostic.

III.2. Architecture du système CAD proposé

Le système CAD développé dans ce travail vise à automatiser la détection des anomalies mammaires à partir des images de mammographie. L'architecture proposée est organisée en plusieurs étapes successives, allant de l'acquisition des données jusqu'à la phase de décision. Dans un premier temps, les images sont extraites à partir de la base de données RSNA Screening Mammography Breast Cancer Detection. Elles subissent ensuite une étape de prétraitement, destinée à améliorer leur qualité, à normaliser leur représentation et à rendre les données plus homogènes pour l'apprentissage. Par la suite, les images préparées sont introduites dans la phase de classification, réalisée à l'aide de deux modèles de réseaux de neurones convolutifs, à savoir resnet-50 et efficientnet-B4 pré-entraîné. Ces modèles permettent d'extraire automatiquement les caractéristiques discriminantes et d'effectuer la classification des mammographies. À l'issue du processus, le système fournit une prédiction finale indiquant si l'image correspond à un sein sain ou présentant une anomalie mammaire, contribuant ainsi à l'amélioration de l'aide au diagnostic et à la réduction de la charge d'interprétation des spécialistes (Figure III. 1).




Figure III. 1: Architecture générale du système CAD proposé pour la classification des images mammographiques.

III. 3. Implémentation




Figure III. 2: Étapes de l'implémentation de la méthodologie proposée

III.3.1 Base de données utilisée

Dans le cadre de ce travail, nous avons utilisé la base de données **RSNA Screening Mammography Breast Cancer Detection**, une base de données de référence [47] dans le domaine de

l'imagerie médicale dédiée à la détection du cancer du sein à partir de mammographies. Cette base est largement exploitée dans les travaux de recherche en intelligence artificielle et en apprentissage profond pour le développement de modèles de diagnostic assisté par ordinateur.

La base de données a été téléchargée depuis la plateforme Kaggle sous forme d'archives compressées (format ZIP) et représente un volume d'environ 300 Go après extraction. Les images sont stockées au format DICOM (.dcm), un standard en imagerie médicale permettant de conserver les images radiologiques ainsi que l'ensemble des métadonnées associées à chaque examen.

Elle contient environ 8000 patientes, chacune disposant d'un examen mammographique complet composé de quatre images, correspondant aux deux seins (gauche et droit) et aux deux incidences radiologiques standard CC (Cranio-Caudale) et MLO (Médio-Latérale Oblique). Cette configuration permet une analyse complète des tissus mammaires sous différentes perspectives, ce qui améliore la performance des modèles de classification et de détection.

Les images sont organisées de manière structurée, où chaque examen est associé à un identifiant unique de patiente. Cette organisation garantit une bonne traçabilité des données et facilite leur exploitation dans les différentes étapes du pipeline de traitement, notamment le prétraitement, l'entraînement et l'évaluation des modèles de deep learning.

III.3.1.1 Organisations de data

La base de données est accompagnée de plusieurs fichiers essentiels permettant la gestion et l'exploitation des données :




Figure III. 3:présente organisation des dossiers de la base de données.

- **Train.csv** : ce fichier contient les informations associées aux données d'entraînement. Il regroupe les identifiants des images ainsi que les annotations et labels utilisés durant la phase d'apprentissage du modèle.
- **Test.csv** : correspond aux données de test utilisées pour évaluer les performances du modèle après l'entraînement. Il permet de vérifier la capacité du modèle à effectuer des prédictions sur de nouvelles données non utilisées durant l'apprentissage.

- **Train images** : ce dossier contient l'ensemble des images mammographiques utilisées pendant la phase d'entraînement. Chaque image est liée aux informations présentes dans le fichier train.csv.
- **Sample_submission.csv** : représente un modèle de soumission des résultats. Il définit la structure et le format attendus pour l'enregistrement des prédictions générées par le modèle.

site_id	patient_id	image_id	laterality	view	age	cancer	biopsy	invasive	BIRADS	implant	density	machine_id	difficult_negative_case	
0	2	10006	462822612	L	CC	61.0	0	0	0	NaN	0	NaN	29	False
1	2	10006	1459541791	L	MLO	61.0	0	0	0	NaN	0	NaN	29	False
2	2	10006	1864590858	R	MLO	61.0	0	0	0	NaN	0	NaN	29	False
3	2	10006	1874946579	R	CC	61.0	0	0	0	NaN	0	NaN	29	False
4	2	10011	220375232	L	CC	55.0	0	0	0	0.0	0	NaN	21	True

Figure III. 4:Exploration initiale des données du fichier train.csv.

Le dossier **train- images** contient des images mammographiques au format DICOM (.dcm). Chaque fichier DICOM est associé à un identifiant de patient, facilitant ainsi l'organisation des données et leur exploitation. À titre d'exemple le fichier 1110981332.dcm correspond à une image mammographique individuelle issue de la base de données (Figure III. 5).




Figure III. 5 : Représente mammographie du patiente 1110981332de la base RSNA

Chaque patiente possède quatre images couvrant les deux seins (gauche et droit) et les deux incidences standards (CC et MLO). Les vues CC offre une projection frontale du sein permettant l'observation globale des tissus mammaires, tandis que les vues MLO fournissent une vue oblique permettant une meilleure visualisation des structures internes du sein (Figure III. 6).




Figure III. 6: Représentation des mammographies des deux seins selon les incidences Cranio-caudale (CC) et médio-latérale oblique (MLO).

III.3.2 Prétraitement des images

Une chaîne de prétraitement a été conçue afin de préparer les images mammographiques issues de la base de données pour leur exploitation par un modèle de deep learning. Les données, initialement fournies au format DICOM et associées à des métadonnées structurées sous forme de fichier CSV, sont d'abord chargées et organisées en fonction des identifiants des patientes ainsi que des examens correspondants.

Le processus de prétraitement repose sur une succession d'opérations visant à améliorer la qualité des images et à les rendre exploitables par le modèle de classification. Dans un premier temps, les images sont extraites à partir des fichiers DICOM à l'aide de la fonction **dicomsgl.Open ()**.




Figure III. 7:Image mammographique originale avant prétraitement(2776x2082) pixels.

Une amélioration du contraste est ensuite effectuée par la méthode CLAHE (Contrast Limited Adaptive Histogram Equalization), implémentée dans la fonction `_clahe ()`, permettant de renforcer les structures locales et d'améliorer la visibilité des tissus mammaires.

Par la suite, une opération de windowing, basée sur les paramètres radiologiques des fichiers DICOM (WindowCenter, WindowWidth, BitsStored et VOILUTFunction), est appliquée à travers la fonction `_windowing ()`, afin d'ajuster dynamiquement l'intensité des pixels et de mieux représenter les variations des tissus internes.

Les images sont ensuite harmonisées selon leur interprétation photométrique via la fonction `_fix_photometric_interpretation ()`, garantissant une cohérence des niveaux de gris indépendamment des modalités d'acquisition (MONOCHROME1 ou MONOCHROME2).

Afin d'uniformiser les données, une normalisation des intensités est réalisée sur une échelle allant de 0 à 255 à l'aide de la fonction `_normalize_to_255()`, ce qui permet de stabiliser la distribution des valeurs et de faciliter l'apprentissage du modèle.

Une étape de correction de la latéralité est ensuite appliquée par la fonction `_flip_breast_side ()`, appuyée sur `_determine_breast_side ()`, afin d'assurer une orientation homogène des images (sein gauche ou droit) selon le protocole défini.

Par ailleurs, une opération de segmentation est effectuée afin d'isoler la région d'intérêt en supprimant les zones de fond non pertinentes. Cette étape repose sur les fonctions `_crop ()`, `_binarize ()`, `_extract_contour ()` et `_erase_background ()`, permettant d'extraire uniquement la région mammaire utile à l'analyse.




Figure III. 8:Image après les étapes de prétraitement (CLAHE, windowing, correction photométrique, normalisation et segmentation).

Enfin, les images sont redimensionnées à une taille fixe compatible avec l'architecture du modèle resnet-50 via la fonction `_resize ()`, garantissant une homogénéité des entrées pour le réseau de neurones.




Figure III. 9:Image finale après redimensionnement à (256×256) pixels.

Afin de faciliter l'analyse visuelle des variations d'intensité, les images ont été affichées à l'aide de la palette de couleurs Jet. Cette représentation pseudo-colorée est utilisée exclusivement à des fins de visualisation et ne modifie en aucun cas la nature des données. Les images restent des données en niveaux de gris tout au long du processus de prétraitement [48].

III.3.3 Transformation des images avant l'entraînement

Après les différentes étapes de prétraitement, une phase de transformation des données a été réalisée avant l'entraînement du modèle. Cette étape vise à adapter les images au format d'entrée requis par l'architecture resnet-50 et à garantir une préparation adéquate des données pour l'apprentissage.

Dans ce cadre, les images ont été redimensionnées à une résolution de 224×224 pixels à l'aide de la fonction **Resize()**. Elles ont ensuite été converties en tenseurs numériques grâce à la fonction **totensor()**, permettant leur traitement par le réseau de neurones. Enfin, une opération de normalisation a été appliquée à l'aide de la fonction **Normalize()** afin d'uniformiser les valeurs des pixels et de favoriser la stabilité du processus d'apprentissage. Les images ainsi transformées constituent les données d'entrée utilisées pour les phases d'entraînement et de validation du modèle.

```
transformations = transforms.Compose([
    transforms.Resize((224, 224)), # Sécurité pour garantir la taille
    transforms.ToTensor(),
    transforms.Normalize(mean=[0.485, 0.456, 0.406], std=[0.229, 0.224, 0.225])
])
```

Figure III. 10: Transformations appliquées aux images avant l'entraînement du modèle resnet-50.

De manière similaire, pour le modèle efficientnet-B4, les mêmes principes de transformation ont été appliqués afin d'assurer une cohérence dans le traitement des données avant leur passage au modèle. Les images ont ainsi été redimensionnées à une résolution de 380×380 pixels à l'aide de la fonction **Resize()**, conformément aux exigences de l'architecture efficientnet-B4, puis soumises aux mêmes opérations de transformation et de normalisation.

```
mu, std = [0.485, 0.456, 0.406], [0.229, 0.224, 0.225]
tr_tf = T.Compose([T.Resize((380, 380)), T.RandomHorizontalFlip(), T.RandomVerticalFlip(),
    T.RandomRotation(10), T.ColorJitter(0.2, 0.2), T.ToTensor(), T.Normalize(mu, std)])
te_tf = T.Compose([T.Resize((380, 380)), T.ToTensor(), T.Normalize(mu, std)])
```

Figure III. 11: Transformations appliquées aux images avant l'entraînement du modèle efficientnet-B4.

III.3.4 Resnet-50

Resnet-50 est une architecture de réseau de neurones convolutifs (CNN) composée de 50 couches profondes. Elle repose sur le principe des connexions résiduelles (skip connections), qui permettent de transmettre directement les informations d'une couche à une autre afin de faciliter l'apprentissage, d'éviter le problème de disparition du gradient et d'améliorer les performances du modèle.

L'architecture utilisée dans ce travail est illustrée à la (figure 3.10). Après l'étape de prétraitement, les images mammographiques sont normalisées et redimensionnées au format $224 \times 224 \times 3$ (RGB), puis introduites dans le modèle. Elles traversent d'abord une première couche de convolution Conv1 (7×7 , 64 filtres), dont le rôle est d'extraire les caractéristiques de bas niveau, telles que les contours, les lignes et les variations d'intensité présentes dans l'image.

Les feature maps obtenues passent ensuite par une couche de Batch Normalization (BN), qui normalise les activations afin de stabiliser et d'accélérer l'apprentissage, puis par la fonction d'activation relu, qui introduit une non-linéarité permettant au réseau d'apprendre des représentations plus complexes. Une opération de Max Pooling est ensuite appliquée afin de réduire les dimensions des feature maps tout en conservant les informations les plus pertinentes.

L'extraction des caractéristiques est ensuite assurée par quatre stages résiduels successifs : Conv2_x $\times 3$, Conv3_x $\times 4$, Conv4_x $\times 6$ et Conv5_x $\times 3$. Au fur et à mesure de la propagation des données à travers ces blocs, le modèle apprend une représentation hiérarchique des images : les premières couches détectent des caractéristiques simples, tandis que les couches profondes identifient progressivement des structures plus complexes et des motifs associés aux anomalies mammaires. Les connexions résiduelles présentes entre les blocs permettent d'ajouter directement les informations d'entrée à la sortie, facilitant ainsi la propagation du gradient et améliorant la convergence du réseau.

À la sortie du dernier bloc résiduel, une couche de Global Average Pooling transforme les feature maps en un vecteur de 2048 dimensions, réduisant ainsi le nombre de paramètres tout en conservant les informations essentielles. Une couche de Dropout ($p = 0,5$) est ensuite appliquée ; elle désactive aléatoirement 50 % des neurones pendant l'entraînement afin de limiter le surapprentissage (overfitting) et d'améliorer la capacité de généralisation du modèle.

Le vecteur obtenu est ensuite transmis à une couche Fully Connected (FC 512 + relu), chargée de combiner les caractéristiques extraites pour produire une représentation finale de l'image. Enfin, une couche Softmax réalise une classification binaire en attribuant à chaque image une probabilité d'appartenance à l'une des deux classes considérées : sein sain ou sein présentant

une anomalie. Le modèle fournit ainsi une prédiction finale indiquant la présence ou l'absence d'une anomalie sur l'image mammographique.




Figure III. 12: Architecture resnet50 pour la classification des images mammaires en classes Sain et présente une anomalie.

III.3.4.1 les hyperparamètres

Pour entraîner le modèle, une sélection rigoureuse des hyperparamètres a été effectuée afin d'optimiser les performances du réseau dans la tâche de détection des anomalies mammaires sur les images mammographiques.

- **Époque (Epoch) :** Les époques représentent le nombre de passages complets des données d'entraînement à travers le modèle, permettant l'ajustement progressif de ses paramètres [26].
- **Taille du batch (Batch size) :** La taille du batch correspond au nombre d'échantillons traités avant chaque mise à jour des poids, influençant la stabilité et la vitesse d'apprentissage [49].
- **Taux d'apprentissage (Learning rate)** Le taux d'apprentissage contrôle l'amplitude des mises à jour des poids et conditionne la convergence du modèle [49].

- **Optimiseur** : l'optimiseur est l'algorithme responsable de la mise à jour des poids du réseau afin de minimiser la fonction de perte. Dans les réseaux profonds comme resnet-50, des méthodes telles que SGD ou Adam sont couramment utilisées. Adam est souvent privilégié pour sa capacité à accélérer la convergence et à adapter automatiquement les mises à jour des paramètres [49].
- **Taille d'entrée (Input size)** : La taille d'entrée définit les dimensions des images fournies au modèle, généralement redimensionnées à 224×224 pour resnet-50. Selon le type d'image, elles peuvent être représentées en trois canaux (RGB) ou en niveau de gris (1 canal), comme c'est généralement le cas pour les mammographies [26].

III.3.4.2 Gestion du déséquilibre des classes

La base de données utilisée dans cette étude est de grande taille et contient un nombre important d'images mammographiques. Toutefois, elle présente un déséquilibre significatif entre les classes, le nombre d'images correspondant à des seins sains étant largement supérieur à celui des images présentant une anomalie. Cette répartition peut orienter l'apprentissage du modèle vers la classe majoritaire et réduire sa capacité à identifier correctement les cas minoritaires. Afin de réduire l'impact du déséquilibre entre les classes, la fonction de perte **Focal Loss**, dérivée de la Cross-Entropy Loss, a été adoptée. Elle attribue un poids plus important aux exemples difficiles à classer tout en réduisant l'influence des exemples correctement prédits, ce qui améliore l'apprentissage de la classe minoritaire[50]. La Focal Loss est définie par l'expression suivante :

$$FL(pt) = -\alpha(1 - pt)^\gamma \text{Log}(pt) \quad (\text{III.1})$$

- pt : la probabilité prédite pour la classe correcte.
- α : le coefficient d'équilibrage des classes.
- γ : le paramètre de focalisation.

III.3.5 les métriques d'évaluation

Dans cette section, nous présentons les principales métriques permettant d'évaluer les performances du modèle resnet-50 appliqué à la classification des anomalies mammaires.

- **Matrice de confusion** : La matrice de confusion est un outil d'évaluation largement utilisé pour analyser les performances d'un modèle de classification. Elle se présente sous la forme d'un tableau de dimension $N \times N$, où N représente le nombre de classes à prédire. Les lignes correspondent généralement aux classes réelles, tandis que les colonnes représentent les classes prédites par le modèle. Dans le cas d'une classification binaire, la matrice comporte deux classes ($N = 2$) [51].

Chaque cellule de cette matrice fournit des informations sur les prédictions correctes et incorrectes du modèle. Les principaux éléments qui la composent sont les suivants :

True Positive (TP) : nombre d'instances positives correctement identifiées comme positives par le modèle.

True Negative (TN) : nombre d'instances négatives correctement identifiées comme négatives.

False Positive (FP) : nombre d'instances négatives classées à tort comme positives.

False Negative (FN) : nombre d'instances positives classées à tort comme négatives.

Ces quatre indicateurs constituent la base du calcul de plusieurs métriques d'évaluation, telles que l'accuracy, la précision, la sensibilité (recall) et le F1-score.

		True label	
		Positive (D+) Cancer	Negative (D-) Not Cancer
Predicted label	Positive (T+) Cancer predicted	TP <i>True Positive</i>	FP <i>False Positive</i>
	Negative (T-) Not Cancer predicted	FN <i>False Negative</i>	TN <i>True Negative</i>

D : Disease (ground truth) · T : Test (model prediction)
TP/TN : correct classifications · FP/FN : error classifications

Figure III. 13: Structure de la matrice de confusion utilisée pour la classification binaire (Cancer /Not Cancer).

- **Accuracy** : représente la proportion de prédictions correctement classées par rapport à l'ensemble des prédictions effectuées par le modèle de classification [51].

Elle est définie mathématiquement comme suit :

$$\text{Accuracy} = \frac{\text{nombre de prédictions correctes}}{\text{nombre total de prédictions}} \quad (\text{III.2})$$

Dans le cas d'une classification binaire, cette métrique peut également être exprimée en fonction des vrais positifs (TP), vrais négatifs (TN), faux positifs (FP) et faux négatifs (FN) :

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

- **Precision** : est une métrique qui mesure la part des prédictions positives correctes parmi toutes les prédictions positives effectuées par le modèle [51].

$$\text{Precision} = \frac{TP}{TP + FP} \quad (\text{III.4})$$

- **Sensitivity (Recall)** : il représente la proportion des instances positives correctement détectées parmi l'ensemble des instances effectivement positives dans les données [51].

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (\text{III.5})$$

- **F1-score** : le F1-score est une métrique d'évaluation utilisée en classification pour mesurer la performance d'un modèle en combinant à la fois la précision et le Sensitivity. Il permet de tenir compte simultanément des faux positifs et des faux négatifs, offrant ainsi une vision plus équilibrée de la qualité du modèle. Cette mesure est fréquemment utilisée pour comparer différents modèles sur une même tâche de classification. En règle générale, un F1-score élevé indique une meilleure performance globale du modèle [51].

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (\text{III.6})$$

- **AUC-ROC** : L'Area Under the Receiver Operating Characteristic Curve est une métrique d'évaluation utilisée pour mesurer la capacité d'un modèle de classification binaire à distinguer les classes positives des classes négatives. La courbe ROC représente le taux de vrais positifs (True Positive Rate ou sensibilité) en fonction du taux de faux positifs (False Positive Rate) pour différents seuils de décision. L'AUC correspond à l'aire située sous cette courbe et fournit une mesure globale des performances du classificateur, indépendante du seuil de classification. Une valeur d'AUC proche de 1 indique une excellente capacité de discrimination, tandis qu'une valeur de 0,5 correspond à une performance équivalente à une classification aléatoire [52].

$$\text{AUC} = \int_0^1 \text{TPR}(\text{FPR}) d(\text{FPR}) \quad (\text{III.7})$$

III.3.7 Efficientnet-B4

Efficientnet-B4 est une architecture de réseaux de neurones convolutifs utilisée pour la classification d'images. Elle appartient à la famille EfficientNet, qui repose sur une méthode d'optimisation appelée « Compound Scaling ». Cette stratégie consiste à ajuster simultanément et de manière équilibrée la profondeur du réseau, sa largeur ainsi que la résolution des images d'entrée, afin d'améliorer les performances tout en maintenant une complexité computationnelle maîtrisée.

Dans ce travail, nous avons utilisé un modèle efficientnet-B4 pré-entraîné sur une base de données d'images radiologiques dans un cadre de transfert d'apprentissage. Cette initialisation permet au modèle de bénéficier de connaissances visuelles déjà acquises à partir de données médicales, ce qui facilite son adaptation à la tâche de classification des images mammographiques. Comme illustré dans la (Figure III. 14), le réseau reçoit en entrée une image de dimension $380 \times 380 \times 3$. Celle-ci est d'abord traitée par une couche convolutionnelle initiale, dont le rôle est d'extraire des caractéristiques simples telles que les contours, les textures et les variations d'intensité. Les informations obtenues sont ensuite transmises à une succession de blocs MBConv (Mobile Inverted Bottleneck Convolution), qui constituent le cœur de l'architecture.

Ces blocs assurent une extraction progressive et hiérarchique des caractéristiques. Les premières couches du réseau apprennent des éléments locaux simples, tandis que les couches profondes permettent de capturer des représentations plus abstraites et plus complexes. Au fur et à mesure de la propagation des données, la réduction de la taille spatiale des cartes de caractéristiques s'accompagne d'une augmentation du nombre de canaux, ce qui permet de préserver et d'enrichir l'information représentée.

Les blocs MBConv combinent plusieurs opérations efficaces, notamment les convolutions depthwise separable, les convolutions ponctuelles 1×1 ainsi que des connexions résiduelles. Ces mécanismes contribuent à réduire la charge computationnelle tout en facilitant la circulation du gradient et la stabilité de l'apprentissage.

À la fin de l'étape d'extraction des caractéristiques, les cartes obtenues sont agrégées à l'aide d'une opération de Global Average Pooling, ce qui permet de produire un vecteur compact représentant les informations les plus importantes de l'image. Ce vecteur est ensuite introduit dans une couche entièrement connectée, précédée d'un mécanisme de Dropout afin de limiter le surapprentissage et d'améliorer la capacité de généralisation du modèle.

Enfin, la sortie du réseau est assurée par un neurone unique utilisant une fonction d'activation Sigmoid, qui produit une probabilité comprise entre 0 et 1. Cette valeur indique la présence ou l'absence d'une anomalie dans l'image mammographique.

Grâce à sa capacité à apprendre des représentations hiérarchiques riches et à son efficacité renforcée par le transfert d'apprentissage, efficientnet-B4 constitue une architecture particulièrement adaptée à la classification des images médicales.




Figure III. 14: Architecture du modèle efficientnet-B4 pour la classification des images mam-mographiques.

III.4. Conclusion

Dans ce chapitre, nous avons présenté la conception et l'implémentation du système proposé pour la classification des images mammographiques. Nous avons décrit la base de données RSNA utilisée ainsi que les différentes étapes de prétraitement et de transformation appliquées aux images avant leur exploitation par les modèles de deep learning. Nous avons ensuite détaillé les architectures resnet-50 et efficientnet-B4 ainsi que les métriques retenues pour l'évaluation des performances. Les résultats obtenus montrent que le modèle efficientnet-B4 présente de meilleures performances que resnet-50 pour la tâche de classification des mammographies. Le chapitre suivant sera consacré à l'analyse et à la discussion des résultats obtenus.

Chapitre IV :

Analyse et discussion des résultats

IV.1. Introduction

Ce chapitre présente l'analyse et la discussion des résultats obtenus dans le cadre de notre approche basée sur les réseaux de neurones convolutifs resnet-50 et efficientnet-B4 pour la classification des anomalies mammaires. L'évaluation des performances des modèles repose sur plusieurs métriques, notamment l'accuracy, la précision, le rappel, le score F1 ainsi que l'auc-ROC. Les résultats obtenus permettent d'évaluer la capacité des modèles à distinguer entre les cas normaux et pathologiques, ainsi que de comparer leurs performances afin d'identifier l'architecture la plus performante pour cette tâche de classification.

IV.2. Les outils et environnement de travail

Cette partie est consacrée à la présentation des outils de développement utilisés pour la réalisation de notre système d'aide au diagnostic, notamment l'environnement de développement, les langages de programmation ainsi que les bibliothèques exploitées dans ce travail.

IV.2.1 Google Colab



Google Colab « Colaboratory » est un environnement de développement en ligne basé sur Jupyter Notebook, destiné principalement aux applications de machine learning et de deep learning. Il permet l'exécution de code Python directement sur le cloud et offre un accès à des ressources de calcul accélérées telles que les GPU.

Dans notre travail, nous avons utilisé la version payante **Colab Pro**, afin de bénéficier d'un accès plus fiable et plus performant aux GPU, ce qui a permis d'améliorer la rapidité d'entraînement des modèles [53].

IV.2.2 Python



Python est un langage de programmation moderne conçu pour offrir une programmation simple, efficace et adaptée à différents domaines informatiques. Il se caractérise par une syntaxe claire et facile à comprendre, permettant de développer des applications de manière rapide et organisée. Grâce à cette simplicité, Python est largement adopté

aussi bien dans le milieu académique que dans le secteur professionnel. Ce langage est particulièrement apprécié pour sa polyvalence. Il est utilisé dans plusieurs domaines tels que le développement web, l'automatisation, l'analyse de données, la

Cybersécurité ainsi que l'intelligence artificielle. Python permet également de gérer des traitements complexes tout en conservant un code lisible et structuré.

L'un des principaux avantages de Python réside dans la richesse de son écosystème. Il possède un grand nombre de bibliothèques spécialisées facilitant la réalisation de tâches scientifiques et techniques, notamment dans le traitement d'images et l'apprentissage profond. Cette diversité d'outils permet de réduire le temps de développement et d'améliorer l'efficacité des applications développées [54].

IV.2.3 Les bibliothèques



Pandas : est une bibliothèque utilisée pour la gestion et l'analyse des données structurées. Elle facilite le traitement des datasets sous forme de tableaux (DataFrame), ainsi que le nettoyage et préparation des données [55].



NumPy : bibliothèque fondamentale pour le calcul scientifique en python. Elle permet la manipulation efficace des tableaux multidimensionnels ainsi que la réalisation d'opérations mathématiques rapides sur les données [55].



Matplotlib : est une bibliothèque de visualisation de données permettant de générer des graphiques, des courbes et des histogrammes afin d'analyser les résultats obtenus [55].



OpenCV : est une bibliothèque open-source de traitement d'images et de vision par ordinateur utilisée pour manipuler, transformer et analyser les images [56].



Pydicom : bibliothèque spécialisée dans la lecture et manipulation des images médicales au format DICOM. Elle est largement utilisée dans le domaine de l'imagerie médicale pour extraire et traiter les données des examens [57].



Tqdm : utilisée pour afficher des barres de progression lors de l'exécution des boucles ou des traitements longs. Ce qui permet de suivre l'avancement des opérations [58].



Scikit-Learn : est une bibliothèque Python open source dédiée à l'apprentissage automatique. Elle fournit des outils efficaces pour construire, entraîner et évaluer des modèles de machine learning, aussi bien en apprentissage supervisé qu'en non supervisé, et est largement utilisée dans les projets de data science et d'analyse prédictive [55].



PyTorch : est une bibliothèque Python dédiée au deep learning. Elle sert à créer et entraîner des modèles basés sur les réseaux de neurones pour analyser des données et faire des prédictions. Elle est connue pour sa simplicité d'utilisation et sa grande flexibilité lors du développement des modèles [55].



TensorFlow : est un Framework open source d'apprentissage automatique développé par Google Brain. Il est utilisé pour construire et entraîner des modèles de machine learning et de deep learning destinés à l'analyse de données et à la réalisation de prédictions, notamment en classification et en reconnaissance d'images.

Il repose sur un système de calculs sous forme de graphes, ce qui permet d'exécuter efficacement les opérations sur de grandes quantités de données. TensorFlow est largement adopté en intelligence artificielle grâce à sa puissance, sa flexibilité et sa compatibilité avec plusieurs langages comme Python et C++ [55].

IV.3. Architecture du modèle ResNet- 50 et paramètres d'entraînement

Nous avons choisi le modèle resnet-50, une architecture de réseau de neurones convolutif profond reconnue pour ses performances dans les tâches de classification d'images médicales.




Figure IV. 1: Représentation de la couche de classification finale du modèle resnet-50.

Cette couche reçoit un vecteur de caractéristiques de dimension 2048 extrait par les couches convolutives de resnet-50. Les paramètres « fc.weight » et « fc.bias » correspondent respectivement aux poids et aux biais utilisés pour calculer la sortie finale. Lors de la phase de rétropropagation, **Addmmbackward0** calcule les gradients associés à l'opération de multiplication matricielle de la couche de classification, **Tbackward0** effectue la transposition des matrices nécessaire au calcul de ces gradients, tandis que **AccumulateGrad** accumule les gradients obtenus afin de mettre à jour les paramètres du modèle. Cette couche permet finalement de produire la prédiction correspondant aux classes « Normal » et « Cancer ».

Nous avons réalisé l'entraînement du modèle sur Google Colab Pro en utilisant un GPU NVIDIA Tesla T4, permettant d'accélérer les calculs et de réduire le temps d'exécution. Afin d'optimiser les performances du modèle **ResNet-50**, plusieurs hyperparamètres ont été définis en fonction des caractéristiques du modèle et des ressources matérielles utilisées. Le tableau suivant présente les paramètres retenus pour l'entraînement.

Hyperparamètre	Valeur	Justification
Taille d'entrée des images	224×224 pixels	Correspond au format d'entrée standard du modèle ResNet-50.
Nombre d'époques	10	Permet d'obtenir une convergence satisfaisante tout en limitant le risque de surapprentissage.
Learning rate	1×10^{-4}	Permet une mise à jour efficace des poids et favorise une convergence stable.
Optimiseur	Adam	Choisi pour sa capacité à assurer une convergence stable et efficace du modèle.
Fonction de perte	Focal Loss	Réduit l'impact du déséquilibre des classes et améliore l'apprentissage des exemples difficiles.

Tableau IV. 1: Hyperparamètres utilisés pour l'entraînement du modèle ResNet-50.

IV.4. Analyse des performances du modèle resnet-50

IV.4.1 Évaluation des métriques de performance

Les performances du modèle resnet-50 ont été évaluées à l'aide de la matrice de confusion et de plusieurs métriques de classification. L'analyse de la matrice de confusion montre que le modèle a correctement identifié 230 cas de cancer sur les 232 cas réellement positifs, tandis que Seulement 2 cas ont été classés à tort comme normaux. En revanche, parmi les 10 709 cas réellement normaux, seuls 145 ont été correctement reconnus, alors que 10 564 ont été incorrectement classés comme cancéreux. Ces résultats mettent en évidence une forte capacité du

modèle à détecter les cas de cancer, mais également une difficulté importante à distinguer correctement les cas normaux. 3.2 Analyse des courbes d'apprentissage du modèle resnet-50.




Figure IV. 2:Matrice de confusion du modèle resnet-50.

Afin de compléter cette analyse, les principales métriques d'évaluation obtenues sur l'ensemble de test sont présentées dans le tableau suivant.

Métrique	Valeur
AUC-ROC	0,6386
F1-Score	0,0415
Recall	1
Precision	0,0212
Accuracy	0,0214

Tableau IV. 2:Évaluation des performances du modèle resnet-50.

Les métriques obtenues mettent en évidence des performances contrastées du modèle resnet-50. Le Recall de 1,0000 montre que le modèle détecte l'ensemble des cas de cancer présents dans les données. Cependant, la Precision de 0,0212 reste très faible, indiquant qu'une grande partie des prédictions positives correspond en réalité à des cas normaux. Cette situation se reflète dans le F1-score de 0,0415, qui traduit un déséquilibre important entre la précision et le

rappel. Par ailleurs, l'AUC-ROC de 0,6386 indique une capacité de discrimination limitée entre les classes « Normal » et « Cancer ». Enfin, malgré sa forte sensibilité à la détection des cas positifs, le modèle présente une faible performance globale, comme en témoigne l'Accuracy de 0,0214.

IV.4.2 Analyse des courbes d'apprentissage du modèle resnet-50.

Les courbes d'apprentissage permettent d'évaluer le comportement du modèle resnet-50 au cours de l'entraînement et d'analyser sa capacité de généralisation.




Figure IV. 3:Graphes représentatifs des résultats obtenus avec l'architecture resnet-50.

La courbe de la Focal Loss montre une diminution rapide de la perte durant les premières époques, passant d'une valeur proche de 0,002 à environ 0,0013. Par la suite, les courbes d'entraînement et de validation se stabilisent autour de valeurs similaires. Cette convergence indique que le modèle apprend correctement les caractéristiques présentes dans les données sans présenter de signe important de surapprentissage (overfitting). La proximité entre les pertes d'entraînement et de validation suggère également une bonne stabilité du processus d'apprentissage. Concernant la courbe AUC-ROC, on observe des fluctuations modérées au fil des époques avec des valeurs comprises entre 0,59 et 0,69. Une légère amélioration est constatée vers les dernières époques, où l'AUC-ROC atteint sa valeur maximale d'environ 0,69. Cependant, cette performance reste inférieure au seuil de référence fixé à 0,80, ce qui indique que le modèle possède une capacité de discrimination limitée entre les classes « Normal » et « Cancer ».

La courbe située à droite, représentant le F1-Score et le Recall, montre que ces deux métriques restent nulles durant l'ensemble des 10 époques d'entraînement. Un Recall égal à zéro indique que le modèle ne parvient à détecter aucun vrai positif ($TP = 0$) parmi les cas cancéreux, ces

derniers étant systématiquement classés comme des cas normaux, ce qui entraîne un nombre élevé de faux négatifs. Cette situation est principalement due au fort déséquilibre de la base de données, qui pousse le modèle à privilégier la classe majoritaire au détriment de la classe minoritaire. Par ailleurs, le F1-Score est également nul, car il dépend directement du Recall et de la précision, et s'annule automatiquement lorsque le Recall est égal à zéro.

IV.4.3 Discussion des résultats

Nous avons observé que les résultats du modèle resnet-50 sont globalement limités et fortement influencés par le déséquilibre de la base de données. Bien que le modèle présente une convergence stable durant l'entraînement, les métriques de classification mettent en évidence des difficultés importantes dans la détection de la classe minoritaire (cas cancéreux). En effet, le Recall peut atteindre une valeur de 1,0000 lorsqu'il est calculé sur la classe majoritaire (cas normaux), ce qui indique que le modèle identifie correctement cette classe. Cependant, l'analyse des courbes montre que le Recall associé à la classe cancéreuse reste nul sur l'ensemble des époques (Recall = 0), ce qui signifie que le modèle ne parvient à détecter aucun cas positif. Dans ce cas, tous les cas cancéreux sont systématiquement classés comme normaux, correspondant à un nombre de vrais positifs nul ($TP = 0$) et un nombre élevé de faux négatifs (FN). Ce comportement s'explique principalement par le fort déséquilibre des données, où la classe normale représente environ 98% des échantillons contre seulement 2% pour la classe cancéreuse. Ainsi, le modèle développe un biais en faveur de la classe majoritaire afin de minimiser l'erreur globale, au détriment de la classe minoritaire. Afin de réduire cet effet, nous avons utilisé une Focal Loss dans le but de compenser le déséquilibre des classes et de renforcer l'apprentissage des exemples difficiles, notamment ceux de la classe minoritaire. Toutefois, cette méthode n'a pas permis d'améliorer significativement la détection des cas cancéreux. Par conséquent, malgré une convergence stable des pertes durant l'entraînement, les performances globales du modèle restent insuffisantes pour une application fiable en contexte médical. Les faibles valeurs de l'AUC-ROC, du F1-Score ainsi que le Recall nul pour la classe cancéreuse confirment une capacité de généralisation limitée et un biais marqué vers la classe majoritaire, ce qui empêche une séparation efficace entre les deux classes.

IV.5. Architecture du modèle Efficientnet-B4 et paramètres d'entraînement

La figure (Figure IV. 4) illustre une partie du processus d'apprentissage d'**efficientnet-B4**. Les blocs **convolutionbackward0** correspondent au calcul des gradients des couches de convolu-

tion, responsables de l'extraction des caractéristiques. Les nœuds **cudnnbatchnormbackward0** représentent la rétropropagation à travers les couches de normalisation, utilisées pour stabiliser l'apprentissage. Les blocs **silubackward0** sont associés à la fonction d'activation Silu, qui améliore la capacité du modèle à apprendre des représentations complexes. Enfin, les nœuds **AccumulateGrad** assurent l'accumulation des gradients nécessaires à la mise à jour des paramètres **weight** et **bias** lors de l'optimisation du réseau.




Figure IV. 5: Visualisation de la rétropropagation et du calcul des gradients dans le modèle efficientnet-B4

Afin d'optimiser les performances du modèle **EfficientNet-B4**, plusieurs expérimentations ont été réalisées pour déterminer les hyperparamètres les plus appropriés. Les paramètres retenus pour l'entraînement sont présentés dans le tableau suivant :

Hyperparamètre	Valeur	Justification
Taille d'entrée des images	380 × 380 pixels	Correspond aux dimensions requises par EfficientNet-B4 et permet de préserver les informations pertinentes des mammographies.
Nombre d'époques	20	Après plusieurs expérimentations, 20 époques ont permis

		un apprentissage plus approfondi que 10 époques.
Learning rate	1×10^{-5}	Assure une mise à jour progressive et stable des poids, tout en limitant les fluctuations durant l'apprentissage.
Optimiseur	Adam	Choisi pour son efficacité et sa rapidité de convergence.
Fonction de perte	Binary Cross-Entropy (BCE)	Adaptée à la classification binaire des anomalies mammaires.

Tableau IV. 3 :Hyperparamètres utilisés pour l'entraînement du modèle EfficientNet-B4

IV.6. Analyse des performances du modèle Efficientnet-B4

IV.6.1 Évaluation des métriques de performance

Les principales métriques obtenues sont résumées dans le tableau suivant :

Métrique	Valeur
AUC-ROC	0,74
F1-Score	0,1488
Recall	0,2414
Precision	0,1075
Accuracy	0,9414

Tableau IV. 4:Résultats des métriques d'évaluation du modèle efficientnet-B4.

Les résultats obtenus par le modèle efficientnet-B4 montrent des performances globalement influencées par le déséquilibre des données. Selon la matrice de confusion, le modèle a correctement identifié 56 cas de cancer sur 232 cas réels, soit environ 24 % des cas positifs, tandis que 176 cas cancéreux ont été classés comme normaux. En parallèle, sur les 10 709 cas normaux, 10 244 ont été correctement classés.




Figure IV. 6:Matrice de confusion du modèle efficientnet-B4.

Cette répartition se traduit par un Recall de 0,2414, indiquant que le modèle détecte près d'un quart des cas de cancer présents dans les données. La Precision obtenue est de 0,1075, ce qui signifie qu'une proportion relativement faible des échantillons prédits comme cancéreux correspond effectivement à des cas de cancer. Le F1-score de 0,1488 reflète cet équilibre entre la précision et le rappel. Par ailleurs, l'AUC-ROC atteint 0,74, ce qui traduit une capacité de discrimination acceptable entre les classes « Normal » et « Cancer ». Enfin, l'accuracy de 0,9414 apparaît élevée, mais elle doit être interprétée en tenant compte du déséquilibre de la base de données, caractérisée par une prédominance de la classe « Normal ». Ainsi, l'analyse conjointe de l'AUC -ROC, du Recall, de la Precision et du F1-score permet d'obtenir une évaluation plus représentative des performances du modèle pour la détection des cas de cancer.

IV.6.2 Analyse des courbes d'apprentissage du modèle efficientnet-B4

L'analyse des courbes d'apprentissage du modèle efficientnet-B4 pré-entraîné sur RadImageNet met en évidence un comportement globalement cohérent au début de l'entraînement, mais limité en fin de processus.




Figure IV. 7: Graphes représentatifs des résultats obtenus avec l'architecture efficientnet-B4.

La BCE Loss d'entraînement et de validation diminue de manière similaire au départ, passant d'une valeur proche de 1,35 jusqu'à environ 1,21 (minimum de validation observé vers l'epoch 11). Cette évolution montre que le modèle parvient à apprendre correctement les caractéristiques des données durant la première phase de l'entraînement. Cependant, à partir de l'epoch 10–11, la loss de validation commence à augmenter progressivement jusqu'à environ 1,47 en fin d'entraînement (epoch 20), tandis que la loss d'entraînement continue de diminuer jusqu'à 0,71. Cette divergence entre les deux courbes traduit clairement l'apparition d'un phénomène de surapprentissage (overfitting), où le modèle s'adapte excessivement aux données d'entraînement au détriment de sa capacité de généralisation.

Concernant l'AUC -ROC, on observe une progression régulière au début de l'entraînement, passant d'environ 0,59 (epoch 1) à environ 0,74 à partir de l'epoch 14, puis une stabilisation jusqu'à la fin de l'entraînement (epoch 20). Cette évolution indique que la capacité du modèle à discriminer entre les classes « Normal » et « Cancer » s'améliore au début, avant d'atteindre un plateau sans amélioration significative par la suite.

Enfin, les métriques de classification (Recall, Precision et F1-score) restent globalement faibles et instables. Le Recall varie entre 0,40 et 0,77, traduisant une capacité irrégulière à détecter les cas cancéreux. La Precision demeure très faible, entre 0,03 et 0,06, ce qui indique un nombre

important de faux positifs, les cas normaux étant souvent classés à tort comme cancer. En conséquence, le F1-score reste bas, compris entre 0,05 et 0,10, reflétant un mauvais équilibre entre la sensibilité et la précision du modèle.

IV.6.3 Discussion des résultats

Les résultats obtenus avec le modèle efficientnet-B4 montrent clairement que ses performances sont fortement influencées par le déséquilibre des données, avec une prédominance marquée de la classe « Normal ». Bien que l'accuracy soit élevée (0,9414), cette valeur reste trompeuse car elle est principalement due à la bonne classification de la classe majoritaire, sans refléter correctement les performances du modèle sur la classe « Cancer ». En effet, l'analyse de la matrice de confusion montre que le modèle ne détecte que 56 cas de cancer sur 232 cas réels, ce qui correspond à un Recall faible (0,2414). Cela signifie qu'une grande partie des cas pathologiques est non détectée et classée comme normale, ce qui constitue une limite importante dans un contexte médical où la sensibilité est primordiale.

Par ailleurs, la Precision (0,1075) reste également faible, indiquant que la majorité des prédictions positives sont incorrectes, ce qui réduit la fiabilité des résultats du modèle. Le F1-score (0,1488), qui combine la précision et le rappel, confirme ce déséquilibre et met en évidence une performance globale insuffisante pour la classe minoritaire. Concernant la capacité de discrimination, l'AUC -ROC (0,74) indique une performance moyenne dans la distinction entre les classes « Normal » et « Cancer », mais reste insuffisante pour une utilisation fiable en pratique clinique.

L'analyse des courbes d'apprentissage vient renforcer ces observations, en montrant un phénomène de surapprentissage à partir de l'époque 10–11, caractérisé par une divergence entre les pertes d'entraînement et de validation. Malgré une bonne convergence initiale, le modèle perd progressivement sa capacité de généralisation sur les données non vues. En résumé, bien que le modèle efficientnet-B4 présente une certaine capacité d'apprentissage et une AUC acceptable, ses performances restent limitées pour la détection du cancer, principalement en raison du déséquilibre des données et du surapprentissage, ce qui nécessite des améliorations futures telles que le rééquilibrage des classes, l'ajustement du seuil de décision ou l'utilisation de techniques de régularisation plus avancées.

IV.7. Comparaison des modèles resnet-50 et efficientnet-B4

Métrique	Resnet-50	Efficientnet-B4
AUC-ROC	0,6386	0,74
F1-Score	0,0415	0,1488
Recall	1	0,2414
Precision	0.0212	0,1075
Accuracy	0.0214	0,9414

Tableau IV. 5: Comparaison des performances des modèles resnet-50 et efficientnet-B4

La comparaison entre les résultats des modèles **resnet-50** et **efficientnet-B4** met clairement en évidence des différences importantes en termes de performance globale. Le modèle resnet-50 présente une accuracy très faible de 0,0214, malgré un Recall égal à 1,0. Cependant, ce résultat doit être interprété avec prudence, car la base de données est biaisée et déséquilibrée, avec une proportion de cas « Normal » largement supérieure aux cas « Cancer ». Par conséquent, le modèle tend à apprendre principalement la classe majoritaire, ce qui rend l'interprétation du Recall trompeuse. Bien que ce dernier soit égal à 1, l'analyse des courbes et du comportement du modèle montre qu'il ne parvient pas réellement à détecter les cas de cancer, mais qu'il classe principalement les observations comme « Normal ». Cela est également confirmé par les représentations graphiques, où la détection des cas positifs apparaît quasi inexistante, ce qui indique une mauvaise discrimination entre les deux classes. Ainsi, la valeur du Recall ne reflète pas fidèlement les performances réelles du modèle. De plus, la très faible Precision de 0,0212 et le F1-score de 0,0415 confirment un grand nombre d'erreurs et un manque de fiabilité des prédictions.

En revanche, efficientnet-B4 obtient de meilleures performances globales, avec une accuracy élevée de 0,9414 et un AUC-ROC supérieur de 0,74, ce qui traduit une meilleure capacité de discrimination entre les classes « Normal » et « Cancer ». Bien que son Recall soit plus faible de 0,2414, il présente une meilleure Precision de 0,1075 ainsi qu'un F1-score plus élevé de 0,1488, indiquant un meilleur équilibre entre la détection des cas positifs et la fiabilité des prédictions.

En conclusion, efficientnet-B4 est globalement meilleur que resnet-50, car il offre des performances plus stables et plus équilibrées, malgré les limites imposées par le déséquilibre des données.

IV.8. Conclusion

Dans ce chapitre, nous avons présenté une analyse comparative des performances des deux modèles étudiés, à savoir resnet-50 et efficientnet-B4, pour la classification des anomalies mammaires. L'évaluation a été effectuée à l'aide de plusieurs métriques de performance, notamment l'accuracy, la précision, le rappel, le F1-score et l'auc-ROC, ainsi que par l'analyse des matrices de confusion et des courbes d'apprentissage. Les résultats obtenus montrent que les performances des deux modèles sont fortement influencées par le déséquilibre des classes ainsi que par la nature biaisée du dataset, caractérisé par une forte dominance de la classe « Normal ». L'analyse détaillée a permis de mettre en évidence les limites du modèle resnet-50, notamment sa faible capacité de détection des cas de cancer, tandis que le modèle efficientnet-B4 présente des performances globalement plus stables et mieux équilibrées. En conclusion, efficientnet-B4 s'avère être le modèle le plus performant dans ce travail, bien que les deux approches restent limitées par la qualité et la distribution des données, ce qui impacte la fiabilité globale du système de classification.

Conclusion générale

Conclusion générale

Ce mémoire a été consacré à l'étude et à la mise en œuvre d'un système basé sur le Deep Learning pour la détection automatique des anomalies mammaires à faible contraste à partir d'images mammographiques. Notre objectif principal était d'évaluer la capacité de deux architectures de réseaux de neurones convolutifs, resnet-50 et efficientnet-B4, à distinguer les cas normaux des cas présentant une anomalie.

Au cours de ce travail, nous avons développé et évalué les deux modèles en nous appuyant sur la base de données RSNA Screening Mammography Breast Cancer Detection. Les résultats obtenus ont montré que les performances des modèles sont influencées par la taille de la base de données ainsi que par le déséquilibre important entre les classes. Malgré ces contraintes, nous avons constaté qu'efficientnet-B4 présente des performances plus satisfaisantes que resnet-50, avec une meilleure capacité de classification des images mammographiques. Nous avons également mis en évidence l'importance des étapes de prétraitement et du choix de l'architecture dans l'amélioration des performances des systèmes de détection assistée par ordinateur.

Les résultats obtenus confirment l'intérêt du Deep Learning dans le domaine de l'imagerie médicale et son potentiel pour contribuer au dépistage précoce du cancer du sein. Bien que certaines améliorations restent nécessaires pour renforcer la robustesse du système proposé, ce travail constitue une contribution intéressante au développement de solutions d'aide au diagnostic plus performantes et plus fiable.

Références bibliographiques

- [1] V. Kumar, A. K. Abbas et J. C. Aster, Robbins and Cotran Pathologic Basis of Disease, 10, Éd., Elsevier, 2021.
- [2] Pasakorn, «Cancer development: Normal cells are transformed into cancer,» n.d. [En ligne]. Available: <https://stock.adobe.com/image/1365395412>.
- [3] H. Sung, J. Ferlay, R. L. Siegel, M. Laversanne, I. Soerjomataram, A. Jemal et F. Bray, «Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide,» *CA: A Cancer Journal for Clinicians*, 2021.
- [4] A. Sapino et J. Kulka, Breast Pathology, Springer Nature, 2019.
- [5] A. Nkondjock et P. Ghadirian, «Facteurs de risque du cancer du sein,» *Médecine/Sciences*, vol. 21, n° 12, p. 175–180, 2005.
- [6] National Cancer Institute, «Breast Cancer Treatment (PDQ®) – Health Professional Version,» National Cancer Institute, 2023.
- [7] World Health Organization (WHO), «Breast cancer: early diagnosis and screening,» World Health Organization, Geneva, 2023.
- [8] Comité éditorial pédagogique de l'umvf, «Anatomie de la glande mammaire,» Université Médicale Virtuelle Francophone (UMVF), 2011.
- [9] H. Rouvière et A. Delmas, Anatomie humaine : descriptive, topographique et fonctionnelle., 15 éd., Paris: Masson, 2002.
- [10] T. Tammela et K. Alitalo, «The lymphatic system in disease processes and cancer progression,» *Nature Reviews Cancer*, vol. 10, p. 459–471, 2010.
- [11] D. B. Kopans, Breast Imaging, 2 éd., Philadelphia, PA: Lippincott Williams & Wilkins, 2007.
- [12] Institut Arthur Vernes, «Mammographie et sénologie – Historique,» 2024. [En ligne]. Available: <https://www.institut-vernes.org/histoire-de-la-mammographie>. [Accès le 2026].
- [13] Radiology Key, «Breast imaging: Mammography,» 18 avril 2023. [En ligne]. Available: <https://radiologykey.com/breast-imaging-mammography/>.
- [14] American College of Radiology, «ACR Practice Parameter for the Performance of Screening and Diagnostic Mammography,» American College of Radiology, Reston, Virginia, USA, 2018.

- [15] Ruban Rose , «Mammographie : pour qui, pour quoi et comment ?», 2023. [En ligne]. Available: <https://rubanrose.org/blogue/mammographie-pour-qui-pour-quoi-et-comment/>. [Accès le 9 juin 2026].
- [16] American College of Radiology (ACR), Breast Imaging Reporting and Data System (BI-RADS®) Atlas, 5th edition, Reston, VA: American College of Radiology, 2013.
- [17] National Electrical Manufacturers Association, «Digital Imaging and Communications in Medicine (DICOM) Standard: PS3.1–PS3.22,» 2026.
- [18] M. G. Marmot, D. G. Altman, D. A. Cameron, J. A. Dewar, S. G. Thompson et Independent UK Panel on Breast Cancer Screening, «The benefits and harms of breast cancer screening: An independent review,» *The Lancet*, vol. 380, n° 9855, p. 1778–1786, 2012.
- [19] S. Russell et P. Norvig, Artificial Intelligence: A Modern Approach, 4 éd., Pearson, 2021.
- [20] A. Hosny, C. Parmar, J. Quackenbush, L. H. Schwartz et H. J. W. L. Aerts, «Artificial intelligence in radiology,» *Nature Reviews Cancer*, vol. 18, n° 18, p. 500–510, 2018.
- [21] K. P. Murphy, Machine Learning: A Probabilistic Perspective, Cambridge, MA: MIT Press, 2012.
- [22] Oracle, (corporate author);, «Qu’est-ce que l’apprentissage automatique ?», [En ligne]. Available: <https://www.oracle.com/ca-fr/artificial-intelligence/what-is-machine-learning.html>.
- [23] A. Géron, Hands-On Machine Learning with Scikit-Learn, Keras, and tensorflow, 2 éd., O’Reilly Media, 2019.
- [24] V. Mathivet, Machine Learning : Implémentation en Python avec Scikit Learn, 2 éd., Éditions ENI, 2024.
- [25] D. Coleman, « Introduction à l'apprentissage automatique : ce que vous devez savoir, »Serverspace, 20 juin 2023. [En ligne]. Disponible : <https://serverspace.io/fr/about/blog/introduction-to-machine-learning/>.
- [26] L. Goodfellow, . Y. Bengio et A. Courville, Deep Learning, MIT Press, 2016.
- [27] K. Lounis et D. Moussi, «La classification d’images d’insectes ravageurs en utilisant le deep learning,» 2020.
- [28] S. M. Korti et M. N. E. Mediani, «Intrusion Detection System Using Machine Learning Techniques,» 2022.

- [29] I. Talbi., «Comprendre les réseaux de neurones,» 11 juin 2020. [En ligne]. Available: <https://larevueia.fr/comprendre-les-reseaux-de-neurones/>.
- [30] T. Keldenich, «Deep Learning – Comprendre facilement les réseaux de neurones,» 28 December 2020. [En ligne]. Available: <https://inside-machinelearning.com/le-deep-learning-cest-quoi/>.
- [31] Blent.ai, «Réseaux de neurones : tout comprendre – Machine Learning,» 27 January 2022. [En ligne]. Available: <https://blent.ai/blog/a/reseaux-de-neurones-tout-comprendre>. [Accès le 27 février 2026].
- [32] L. Makhlof, «l'apprentissage profond appliqué à la reconnaissance des anomalies mammaires,» 2022.
- [33] Hardware &Co, «IA : mais qui es-tu donc ?,» [En ligne]. Available: <https://hardwareand.co/dossiers/logiciel-jeu/analyse-ia-ia-mais-qui-es-tu-donc?Start=5>. [Accès le 4 juin 2026].
- [34] X. Glorot et Y. Bengio, «Understanding the Difficulty of Training Deep Feedforward Neural Networks,» *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics (AISTATS)*, p. 249–256, 2010.
- [35] Botpenguin, «Vanishing Gradient Problem,» [En ligne]. Available: <https://botpenguin.com/glossary/vanishing-gradient-problem>. [Accès le 27 mai 2026].
- [36] Techtalks, «How do cnns work?,» 6 January 2020. [En ligne]. Available: <https://bdtechtalks.com/2020/01/06/convolutional-neural-networks-cnn-convnets/>.
- [37] L. Alzubaidi, J. Zhang, A. J. Humaidi, Y. Duan, O. Al-Shamma et L. Farhan, «Review of deep learning: concepts, CNN architectures, challenges, applications, future directions,» *Neural Computing and Applications*, vol. 34, 2022.
- [38] O. Colliot, Éd., «Deep learning: Basics and convolutional neural networks (cnns),» chez *Machine learning for brain disorders*, Springer, 2023, p. 45–72.
- [39] Neurones Biokore, «Intelligence artificielle : réseaux de convolution,» 27 March 2018. [En ligne]. Available: <https://neuronesbiokore.fr/intelligence-artificielle-reseaux-de-convolution/>.
- [40] D. Donoho, V. Pappayan et Y. Zhong, «Analyses of Deep Learning (STATS 385),» 2019.
- [41] Geeksforgeeks, «What is Fully Connected Layer in Deep Learning?,» 2025. [En ligne]. Available: <https://www.geeksforgeeks.org/deep-learning/what-is-fully-connected-layer-in-deep-learning/>. [Accès le 10 mars 2026].

- [42] Superdatascience, «Réseaux de neurones convolutifs (CNN) : Étape 4 – Connexion complète,» 18 August 2018. [En ligne]. Available: <https://www.superdatascience.com/blogs/convolutional-neural-networks-cnn-step-4-full-connection>.
- [43] R. Szeliski, *Computer Vision: Algorithms and Applications* (2nd ed.), Springer, 2022.
- [44] A. Esteva, A. Robicquet, B. Ramsundar, V. Kuleshov, M. Depristo, K. Chou et J. Dean, «A guide to deep learning in healthcare,» *Nature Medicine*, vol. 25, n° %11, p. 24–29, 2019.
- [45] K. He, X. Zhang, S. Ren et J. Sun, «Deep residual learning for image recognition,» chez *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [46] K. Okokpujie, S. Apeh, C. Ndujiuba et I. P. Okokpujie, «resnet architectures (right) and residual block (top left), bottleneck layer (bottom left),» *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, n° %15, p. 9215–9220, 2020.
- [47] Radiological Society of North America (RSNA), «RSNA Breast Cancer Detection,» 2023. [En ligne]. Available: <https://www.kaggle.com/competitions/rsna-breast-cancer-detection>. [Accès le 12 juin 2026].
- [48] P. Bacher, «Custom Preprocessor – RSNA Breast Cancer,» [En ligne]. Available: <https://www.kaggle.com/code/paulbacher/custom-preprocessor-rsna-breast-cancer/notebook>. [Accès le 18 mars 2026].
- [49] Y. Bengio, «Practical recommendations for gradient-based training of deep architectures,» chez *Neural Networks: Tricks of the Trade*, G. Montavon, G. B. Orr et K. Müller, Éd., Springer, 2012, p. 437–478.
- [50] P. G. R. G. K. H. P. D. Tsung-Yi Lin, «Focal Loss for Dense Object Detection,» chez *International Conference on Computer Vision (ICCV)*, Venice, Italy, 2017.
- [51] M. Sokolova et G. Lapalme, «A systematic analysis of performance measures for classification tasks,» *Information Processing & Management*, vol. 45, n° %14, p. 427–437, 2009.
- [52] T. Fawcett, «An introduction to ROC analysis,» *Pattern Recognition Letters*, vol. 27, n° %18, p. 861–874, 2006.
- [53] Google Colaboratory, «Colaboratory(Google Colab),» n.d. [En ligne]. Available: <https://colab.research.google.com>.

- [54] P. S. Foundation, «About Python,» [En ligne]. Available: <https://www.python.org/about/>.
- [55] Data Bird, «Bibliothèque Python : comment importer une bibliothèque sur Python,» [En ligne]. Available: <https://www.data-bird.co/blog/bibliotheque-python#comment-importer-une-bibliotheque-sur-python>. [Accès le 21 mai 2026].
- [56] Opencv, «Read, display and write an image using opencv,» [En ligne]. Available: <https://opencv.org/read-display-and-write-an-image-using-opencv>. [Accès le 21 mai 2026].
- [57] Python Software Foundation,, «pydicom,» [En ligne]. Available: <https://pypi.org/project/pydicom/>. [Accès le 21 mai 2026].
- [58] C. Da Costa-Luis, «tqdm: A Fast, Extensible Progress Meter for Python and CLI,» *Journal of Open Source Software*, vol. 4, n° 137, p. 1277, 2019.