

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 سعد دحلب البلدية
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الإلكترونيك
Département d'Électronique



Mémoire de Master

Mention Électronique
Spécialité Instrumentation en électronique

Présenté par

MENOUER AYA

&

NECHAD MALAK

Analyse des images de cancer du sein par Deep Learning

Proposer par : Pr. CHERFA.Y et Pr CHERFA. A

Année Universitaire 2024-2025

ملخص: يعد سرطان الثدي أكثر أنواع السرطان شيوعاً لدى النساء في العالم. يهدف هذا المشروع إلى استخدام الشبكات لتحليل صور تصوير الثدي الشعاعي، من أجل الكشف المبكر عن المرض. تم تطوير نظام (CNN) العصبية الالتفافية للمساعدة في التشخيص بالاعتماد على التعلم العميق، يهدف إلى تحديد التكتلات الدقيقة، وهي من المؤشرات الأولية للإصابة بسرطان الثدي. على الرغم من بعض القيود، إلا أن النتائج مشجعة وتُظهر الدور المحتمل للذكاء الاصطناعي في دعم الأطباء في عملية التشخيص.

كلمات المفاتيح: سرطان الثدي، تصوير الثدي الشعاعي، التعلم العميق، الشبكات العصبية الالتفافية، التكتلات الدقيقة، المساعدة في التشخيص.

Résumé : Le cancer du sein est le cancer le plus fréquent chez les femmes dans le monde. Ce projet étudie l'utilisation des réseaux de neurones convolutionnels (CNN) pour l'analyse des images mammographiques dans le but de détecter précocement la maladie. Un système d'aide au diagnostic basé sur l'apprentissage profond a été développé pour repérer les microcalcifications, indicateurs précoces du cancer. Malgré certaines limites, les résultats obtenus sont prometteurs et montrent l'apport potentiel de l'IA pour assister les radiologues.

Mots clés : Cancer du sein, Mammographie, Apprentissage profond, Réseaux de neurones convolutionnels, Microcalcifications, Aide au diagnostic.

Abstract : Breast cancer is the most common cancer among women worldwide. This project explores the use of Convolutional Neural Networks (CNN) to analyze mammographic images for early detection. We developed and evaluated a deep learning-based system to detect microcalcifications, key indicators of early breast cancer. Despite some limitations, the results are encouraging and show the potential of AI to support radiologists in diagnosis.

Keywords : Breast cancer, Mammography, Deep Learning, CNN, Microcalcifications, CAD.

REMERCIEMENTS

Avant tout nous remercions "ALLAH" le tout puissant de nous avoir donnés le courage, la volonté, la patience et la santé durant toutes ces années et que grâce à lui ce travail a pu être réalisé.

On remercie nos très chers parents, qui ont toujours été là pour nous. On remercie nos sœurs, et nos frères, pour leurs encouragements.

Nos remerciements les plus vifs et chaleureux, vont à notre promoteur de mémoire Mme CHERFA Assiaw, pour son aide, son orientation judicieuse et sa disponibilité, aussi pour la confiance, la patience et la compréhension qu'elle nous a toujours manifesté.

Nous adressons nos sincères remerciements à tous les professeurs, intervenants et toutes les personnes qui par leurs paroles, leurs écrits, leurs conseils et leurs critiques ont guidé nos réflexions et ont accepté de nous rencontrer et de répondre à nos questions durant nos études.

Nos vifs remerciements vont également aux membres du jury d'avoir accepté de corriger et d'évaluer notre travail.

Enfin, on remercie nos amis qui ont toujours été là pour nous. Leur soutien inconditionnel et leurs encouragements ont été d'une grande aide.

DEDICACE

Aujourd'hui, je souhaite prendre un moment pour exprimer ma gratitude et ma reconnaissance envers vous tous.

Papa, tu as été toujours un modèle de persévérance et de détermination pour moi. Ton soutien inconditionnel et tes conseils précieux ont été la clé de ma réussite. Tu as été là à chaque étape de ce parcours, m'encourageant à donner le meilleur de moi-même et à poursuivre mes rêves.

Maman, ta tendresse et ton amour infini ont été ma source d'inspiration. Tu as sacrifié tant de choses pour me voir réussir, et je suis profondément reconnaissante pour tout ce que tu as fait pour moi. Tes encouragements et tes mots réconfortants ont été ma force lorsque les défis semblaient insurmontables.

À **mes frères, NAIM et CHAKIB** vous êtes mes compagnons de vie et mes meilleurs amis. Vos conseils de vie, votre soutien, vos encouragements et vos rires ont illuminé mon chemin tout au long de cette aventure.

À mon amie **ILHAM**, ton amour, ton soutien et ta compréhension inébranlables ont été une source d'inspiration pour moi. Ta présence dans ma vie a rendu ce voyage encore plus spécial, et je suis reconnaissante de t'avoir à mes côtés.

Enfin, à mon **binôme**, nous avons parcouru ce chemin ensemble, affrontant les défis et les succès. Je suis fier de ce que nous avons accompli ensemble.

Table des matières

Table des matières

LISTE DES ILLUSTRATION ET GRAPHIQUES

LISTE DES TABLEAUX

INTRODUCTION	1
1. CONTEXTE MÈDICAL	2
1.1 Introduction	2
1.2 Anatomie du sein : structure et fonction.....	2
1.2.1 Composition interne du sein	3
1.2.2 Structures visibles externes	3
1.2.3 Vascularisation et innervation	3
1.2.4 Système lymphatique.....	4
1.2.5 Rôle biologique.....	4
1.3 Pathologies mammaires.....	4
1.3.1 Tumeurs bénignes	5
1.3.2 Tumeurs malignes : le cancer du sein.....	6
1.3.3 Dépistage, Diagnostic et Traitement	8
1.4 Imagerie mammaire	9
1.4.1 La galactographie :	9
1.4.2 La pneumokystographie :.....	9
1.4.3 L'échographie :	10
1.4.4 l'IRM mammaire	11
1.4.5 Scintigraphie mammaire	11
1.4.6 PET SCAN ou TEP SCAN	12
1.4.7 Mammographie :	12
1.4.8 La mammographie analogique.....	12
1.4.9 Mammographie numérique.....	15
1.4.10 Les incidences en mammographie.....	16
1.4.11 Analyse des clichés mammographiques	17
1.5. D'autres techniques de diagnostic.....	21
1.5.1. La biopsie : quand une anomalie suspecte est identifiée dans un sein	
1.5.2. Tomosynthèse	27
1.5.3. Système CAD (Computer Aided Detection/Diagnosis) en mammographie.....	27

Conclusion	28
2. ETAT DE L'ART.....	29
2.1. Introduction	29
2.2. Etat de l'art des réseaux de neurones convolutionnels.....	29
2.3. Etat de l'art sur la classification des images histologiques du cancer de sein	33
2.4. Etat de l'art sue la détection des microcalcifications	34
2.5. Tableau récapitulatif	34
3.1. Introduction	40
3.2. Intelligence artificielle (IA).....	41
3.2.1. Sous-domaines de l'Intelligence Artificielle	41
3.2.2. Apprentissage profond (Deep Learning en anglais) :	42
3.3. Réseaux de neurones :	43
3.3.1. Qu'est-ce qu'un réseau de neurones ?.....	43
3.3.2. Des réseaux neuronaux aux réseaux neuronaux profonds :.....	43
3.3.3. Types des réseaux neuronaux profonds	44
3.4. Types de couches dans le réseau neuronal convolutif.....	48
3.4.1 Couche de convolution (CONV)	48
3.4.2 Couche de Pooling (Pool)	55
3.4.3 Couche de ReLU :.....	56
3.4.4 Couche Flatten :.....	57
3.4.5 Couche Entièrement Connectée (Fully Connected FC).....	58
3.5. Fonctions utilisées dans les réseaux CNN	61
3.5.1. Fonction de Perte/ Coût (LOSS).....	61
3.5.2. Surapprentissage (Overfitting) :.....	62
3.5.3 Descente du gradient (Vanishing gradient) :	64
3.6. Analyse des architectures CNN appliquées en traitement d'images.....	66
3.7. Conclusion.....	70
4.1 Introduction	71
4.2 Choix de l'architecture	71
4.3 Architectures proposées	72
4.3.1 Présentation des bases de données utilisées	73
4.3.2 Architecture du modèle 1	78
4.3.3 Architecture du model 2.....	80
4.3.4 Architecture du modèle 3 :.....	81

4.4 Conclusion :	83
Résultats et discussions	69
5.1 Introduction	84
5.2 Logiciels et bibliothèques de développement	84
5.2.1 Python	84
5.2.2 TensorFlow	84
5.2.3 Keras	85
5.2.4 OpenCV	85
5.2.5 Google Colab	86
5.3 Résultats obtenus et discussions :	90
5.3.1 Résultats obtenus pour le 1er Modèle :	90
5.3.2 Résultats obtenus pour le 2ème Modèle	93
5.3.3 Résultats obtenus pour le 3ème Modèle	97
5.4 Application:	100
5.4.1. Choix de l'image et du type de traitement	100
5.4.2 Résultats	101
5.5 Conclusion	103
CONCLUSION	104

LISTE DES ILLUSTRATION ET GRAPHIQUES

Chapitre 1

Figure 1.1 : Anatomie du sein chez la femme [1].

Figure 1.2 : Dystrophie fibro-kystique.

Figure 1.3 : Adénofibrome.

Figure 1.4 : Cancer Infiltrant et In Situ.

Figure 1.5 : Cliché de pneumokystographie et galactographie.

Figure 1.6 : Image échographique d'un sein [16].

Figure 1.7 : Tumeur détectée dans le sein droit sur une image IRM [16].

Figure 1.8 : Mammographie analogique.

Figure 1.9 : Mammographie numérique.

Figure 1.10 : Caractéristique des incidences en mammographie.

Figure 1.11: Radio anatomie d'un sein normal sur une incidence face/oblique.

Figure 1.12 : Différentes types de densité mammaire.

Figure 1.13 : Calcifications d'allures bénignes et malignes.

Figure 1.14 : Automate de fixation et d'imprégnation.

Figure 1.15 : Prélèvements mis dans la paraffine.

Figure 1.16 : Refroidissement de la paraffine.

Figure 1.17 : Illustration des coupes au microtome.

Figure 1.18 : Coupes après coloration.

Figure 1.19 : Tomosynthèse mammaire numérique 3D.

Chapitre 3

Figure 3.1 : La relation entre l'intelligence artificielle, le ML et le Deep Learning.

Figure 3.2 : Mécanismes techniques complexes du Deep Learning.

Figure 3.3 : Similitude entre un neurone biologique et artificiel.

Figure 3.5 : Les couches d'un perceptron multi-couches.

Figure 3.4 : Les couches d'un Réseau Feed Forward (FF).

Figure 3.6 : Structure générale d'un réseau de neurones convolutifs.

Figure 3.7 : Prélèvement de la couleur d'un même pixel sur une image en couleur.

Figure 3.8 : Exemple d'un filtre kernel.

Figure 3.9 : Exemple d'une opération de convolution.

Figure 3.10 : Convolution sur image d'entrée.

Figure 3.11 : Modèle du perceptron.

Figure 3.12 : Opération de remplissage par zéro.

Figure 3.13 : Cartes de caractéristiques formées de 32 filtres.

Figure 3.14 : Opération de max Pooling.

Figure 3.15 : Illustration du fonctionnement de la fonction ReLU.

Figure 3.16 : Fonction ReLU.

Figure 3.17 : Fonctionnement de la Couche Flatten.

Figure 3.18 : Couche entièrement connectée « fully connected ».

Figure 3.19 : Illustration du fonctionnement du fully connected.

Figure 3.20 : Exemple d'une prédiction à travers les couches (dense).

Figure 3.21 : Opération d'augmentation de données.

Figure 3.22 : Descente de gradient.

Figure 3.24 : Architecture standard d'un réseau CNN.

Chapitre 4

Figure 4.1 : dataset des images ultrasonores du model de classification

Figure 4.2 : dataset des images ultrasonores avec ses masques réelles du model de segmentation

Figure 4.3 : dataset des images histologiques du cancer du sein

Figure 4 .4 : structure du model 1

Figure 4.5 : Architecture du modèle CNN basé sur EfficientNetB3

Figure 4.6 : structure de model 3

Chapitre 5

Figure 5.1 : Google Colab

Figure 5.2 : choisir l'accélération matériel

Figure 5.3 : Importer les bibliothèques utilisées

Figure 5.4 : Importer les bibliothèques utilisées

Figure 5.5 : Code de Division des données apprentissage/testes

Figure 5.6 : Techniques d'augmentation des données

Figure 5.7 : Évolution de la précision d'apprentissage et de validation 1^{er} du modèle

Figure 5.8 : Évolution de la perte d'apprentissage et de validation du 1^{er} modèle

Figure 5.9 : les valeurs des Précisions et d'Erreur avec le nombre epochs du 1er modèle

Figure 5.10 : Évolution des métriques de performance au cours de l'entraînement du 2eme Modelé

Figure 5.11 : les valeurs des Précisions et d'Erreur avec le nombre epochs du 2eme modèle

Figure 5.12 : Évolution des métriques de performance au cours de l'entraînement du 3eme Modelé

Figure 5.13 : les valeurs des Précisions et d'Erreur avec le nombre epochs du 3eme modèle

Figure 5.14 : Interface d'application

Figure 5.16: Sélection du type de traitement d'image

Figure 5.17: Exemple de classification d'une image ultasonore

Figure 5.18: Exemple de classification d'une image histologique

LISTE DES TABLEAUX

Chapitre 1

Tableau 1.1 : Tableau récapitulatif des calcifications bénignes/ malignes [14]

Chapitre 2

Tableau 2.1 : Tableau récapitulatif

Chapitre 3

Tableau 3.1 : Résumé des tâches CNN appliquées à l'analyse d'images médicales

Tableau 3.2 : Résumé des tâches CNN appliquées à l'analyse d'images médicales

Tableau 3.3 : Tableau comparatif des principales architectures CNN

Liste des abréviations

CCD : Charge-Coupled Device.

QS : Quadrant Supérieur.

QSE : Quadrant Supéro-Externe.

QSI: Quadrant Supéro-interne.

BI-RADS: Breast Imaging Reporting and Data System.

Mcs : Microcalcifications.

RIS-PACS: Radiology Information Systeme-Picture Archiving and Communication System.

CAD : Systèmes d'aide au diagnostic.

IRM : Imageries par Résonance Magnétique.

TEP : tomographe par émission de positrons.

CNN : Convolutional Neural Network.

FCN : Fully Convolutional Network.

PCA : Principal Component Analysis.

MLP : Multi-Layer Perceptron.

VGG : Visual Geometry Group.

MCNN : Multi-Scale Convolutional Neural Network.

OCT : Optical Coherence Tomography.

DFT : Discrete Fourier Transform.

DCT : Discrete Cosine Transform

IDC : Invasive Ductal Carcinoma

IA : Intelligence artificielle

ML: Machine Learning

ANN : Artificial Neural Networks

RN : Réseaux Neuronaux

DNN: Deep Neural Networks

FF : Réseau Feed Forward

FC : Fully Connected

INTRODUCTION

Le cancer du sein constitue la forme de cancer la plus répandue chez les femmes et l'une des principales causes de mortalité à l'échelle mondiale. Sa détection précoce améliore considérablement le pronostic et les chances de survie. La mammographie est l'outil de dépistage le plus utilisé, mais elle repose encore fortement sur l'interprétation humaine, sujette à des erreurs, en particulier face à des images complexes ou de faible contraste.

Avec l'émergence de l'intelligence artificielle (IA) et du deep learning, de nouvelles solutions prometteuses voient le jour pour automatiser et fiabiliser l'analyse des images médicales. Les réseaux de neurones convolutionnels (CNN) se sont imposés comme l'une des méthodes les plus performantes dans le traitement et la classification d'images. L'objectif de ce travail est d'exploiter ces techniques pour améliorer l'analyse des mammographies, en particulier pour la détection des microcalcifications, qui sont des indicateurs précoces du cancer du sein.

Ce mémoire est structuré en cinq chapitres :

- Le premier chapitre, intitulé *Contexte médical*, expose en détail l'anatomie du sein, les pathologies mammaires, les méthodes de dépistage, ainsi que les différentes techniques d'imagerie, en mettant un accent particulier sur la mammographie.
- Le deuxième chapitre, *État de l'art*, présente les recherches récentes dans le domaine de l'apprentissage profond appliqué à l'analyse d'images médicales, notamment les méthodes CNN utilisées pour la classification d'images histopathologiques et la détection des microcalcifications.
- Le troisième chapitre, *Méthodes d'apprentissage en profondeur*, introduit les concepts fondamentaux du deep learning, en particulier les réseaux de neurones artificiels et convolutionnels, leurs composants, les fonctions d'activation, ainsi que les méthodes d'optimisation et de régularisation.
- Le quatrième chapitre, *Architectures proposées*, décrit les architectures CNN mises en œuvre pour la classification des images mammographiques. Nous y détaillons les choix techniques, les étapes de prétraitement, les paramètres d'apprentissage et la stratégie d'évaluation.
- Enfin, le cinquième chapitre est consacré à l'analyse des résultats obtenus. Il évalue les performances des modèles sur des bases de données spécifiques et discute les limites, les perspectives d'amélioration et les pistes futures pour l'intégration clinique.

À travers cette étude, nous visons à démontrer l'apport concret de l'intelligence artificielle dans l'amélioration du diagnostic précoce du cancer du sein, tout en mettant en lumière les défis encore à relever dans ce domaine.

CHAPITRE I

1. CONTEXTE MÈDICAL

1.1 Introduction

Le cancer du sein représente l'une des formes de cancer les plus récurrentes, chez les femmes à l'échelle mondiale. Heureusement, une détection précoce offre de bonnes perspectives de traitement, ce qui souligne l'importance cruciale du dépistage. La mammographie demeure le moyen privilégié pour repérer les indices précoces du cancer du sein. De nos jours, grâce aux progrès de l'intelligence artificielle (IA), des technologies, telles que les réseaux de neurones convolutionnels, peuvent assister les professionnels de la santé dans une analyse plus rapide et précise des images médicales. Avant d'aborder ce sujet plus en détail dans les prochains chapitres, il est primordial de bien saisir la complexité du sein, les pathologies qui peuvent le toucher et les méthodes diagnostiques utilisées.

1.2 Anatomie du sein : structure et fonction

Le sein, ou glande mammaire, est un organe pair et symétrique situé à l'avant du thorax, entre la troisième et la septième côte, reposant principalement sur le muscle grand pectoral [1] (**Fig1.1**). Bien qu'il soit présent chez les deux sexes, il se développe essentiellement chez la femme à la puberté sous l'influence des hormones.




FIGURE 1.1 : Anatomie du sein chez la femme [1]

1.2.1 Composition interne du sein

Le sein est une structure complexe formée de plusieurs types de tissus :

- **Tissu glandulaire** : il s'agit de la partie fonctionnelle du sein. Il est constitué de 15 à 25 lobes, chacun divisé en lobules, qui contiennent les acines. Ce sont ces derniers qui produisent le lait lors de l'allaitement [2].
- **Canaux galactophores** : ces conduits transportent le lait des lobules vers le mamelon. Ils convergent pour déboucher au centre de l'aréole [3].
- **Tissu conjonctif et graisseux** : ils remplissent l'espace entre les lobes, apportant soutien et forme au sein. Ce tissu détermine en grande partie le volume du sein [3].

1.2.2 Structures visibles externes

Il existe deux structures :

- **Aréole** : zone pigmentée entourant le mamelon. Elle contient des glandes de Montgomery qui sécrètent une substance lubrifiante et protectrice [3].
- **Mamelon** : relief central à travers lequel s'écoule le lait. Il est richement innervé et vascularisé [2].

1.2.3 Vascularisation et innervation

Le sein est irrigué par des **artères thoraciques internes et latérales**, et drainé par un réseau de veines superficielles. L'**innervation sensorielle** provient principalement des **nerfs intercostaux** [3].

1.2.4 Système lymphatique

Le sein possède un réseau lymphatique dense, essentiel pour le drainage immunitaire. Il se compose de **vaisseaux lymphatiques** et de **ganglions lymphatiques**, situés :

- Dans l'aisselle (**ganglions axillaires**),
- Sous et au-dessus de la clavicule,
- Autour du sternum (**ganglions mammaires internes**) [2].

Ce réseau est d'une importance majeure, car en cas de cancer du sein, les cellules cancéreuses peuvent se propager via la lymphe vers ces ganglions.

1.2.5 Rôle biologique

Le développement des seins constitue l'un des signes de la puberté chez la jeune fille. Il est contrôlé par plusieurs hormones [4], notamment les œstrogènes, la progestérone et les hormones produites par l'hypophyse. Au cours du cycle menstruel, la glande mammaire subit des modifications, notamment une augmentation de volume due à l'action des œstrogènes, environ deux semaines après la fin des règles. À la ménopause, la production d'hormones, en particulier d'œstrogènes, diminue, ce qui entraîne une réduction du volume des seins. Le rôle principal du sein est la production de lait. Pendant la grossesse, les œstrogènes et la progestérone (sécrétés par les ovaires et le placenta) préparent les seins à l'allaitement en stimulant le développement des glandes mammaires et en augmentant la taille des mamelons. Juste après la naissance, les seins produisent d'abord un liquide riche et jaunâtre appelé colostrum. Celui-ci est remplacé, après environ trois jours, par le lait maternel.

1.3 Pathologies mammaires

Les pathologies mammaires comprennent l'ensemble des affections bénignes ou malignes pouvant affecter la glande mammaire [5]. Elles nécessitent une attention particulière en raison de leur fréquence élevée et du risque de cancer du sein chez la femme.

Ces affections se manifestent le plus souvent par l'apparition de masses, de douleurs ou d'anomalies détectées à l'imagerie.

1.3.1 Tumeurs bénignes

Les tumeurs bénignes du sein ne sont pas cancéreuses. Elles présentent une croissance lente, sont composées de cellules bien organisées et différenciées, n'envahissent pas les tissus avoisinants et ne forment pas de métastases à distance [5].

Les principales tumeurs bénignes sont :

Dystrophie fibrokystique : la maladie se manifeste par les lésions élémentaires bénignes (Fig1.2) :

- **Fibrose** : épaissement du tissu conjonctif intra-lobulaire.
- **Adénose** : prolifération bénigne des structures canalaire.
- **Hyperplasie épithéliale** : augmentation du nombre de cellules dans les canaux.

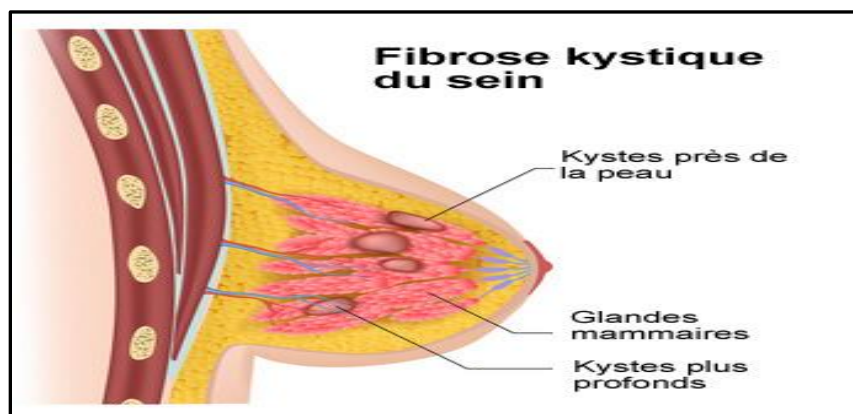


FIGURE 1.2 : Dystrophie fibro-kystique.

Adénofibrome : la tumeur bénigne la plus fréquente, surtout chez la femme jeune. Elle est mobile, ferme, bien circonscrite et souvent indolore (Fig1.3).




FIGURE 1.3 : Adénofibrome.

Bien que bénignes, ces tumeurs peuvent être confondues avec des lésions malignes lors de l'examen clinique ou radiologique, ce qui justifie leur surveillance ou exérèse.

1.3.2 Tumeurs malignes : le cancer du sein

Le cancer du sein est le cancer le plus fréquent chez la femme et constitue l'une des principales causes de mortalité par cancer dans le monde. Il se manifeste par une prolifération incontrôlée de cellules mammaires anormales, capables d'envahir les tissus voisins et de former des métastases via les systèmes lymphatique et sanguin.

Il y a différents types de cancer du sein :

- **Cancer non invasive**

Carcinome canalaire in situ : Il se développe au niveau des canaux, avec huit cas sur dix étant des cancers canaux in situ [6]. Il peut être détecté par une masse tactile, un flux ou par une lésion radiologique infra clinique, généralement un foyer de micro calcification, mais également une densité excessive ou une rupture dans l'architecture [7] (Fig1.4).

- **Cancers invasifs ou infiltrants**

Ces types de cancer se propagent dans les tissus autour des canaux lactifères, tout en restant à l'intérieur du sein. En revanche, sans traitement, la tumeur peut se propager à d'autres régions du corps (comme les os, les poumons ou le foie) en entraînant des métastases [12].

Carcinome canalaire : il se développe au sein des canaux lactifères [12]. Les cellules cancéreuses franchissent la barrière des canaux.

Carcinome lobulaire : les cellules malignes se manifestent dans les lobules qui sont rassemblés au sein des lobes.

Ensuite, elles passent à travers la paroi des lobules et se répandent dans les tissus voisins.

Carcinome inflammatoire : c'est un cancer peu fréquent qui se manifeste principalement par un sein susceptible de devenir rouge, gonflé et chaud. La peau du sein peut également présenter une texture similaire à celle de la peau d'orange. Cette forme de cancer évolue plus vite et est plus complexe à soigner.

Autres types de carcinomes : (médullaires, colloïdes ou muscineux, tubulaires, papillaires). On observe une rareté accrue pour ces formes de cancer du sein. Ces types de cancer se distinguent principalement par le type de cellules affectées.




Figure 1.4 : Cancer Infiltrant et In Situ

1.3.3 Dépistage, Diagnostic et Traitement

L'incidence du cancer du sein reste croissante. Différentes études ont confirmé que c'est la détection en stade précoce des cancers, qui peut en améliorer le pronostic vital. Tout changement de la taille ou de la forme du sein, des modifications de la peau et du mamelon, présence d'une masse dure et de contour irrégulier ainsi que la présence des ganglions durs et parfois douloureux au niveau de l'aisselle ; nécessite un examen médical approfondi du sein [6].

- **Le dépistage** précoce du cancer du sein est obligatoire pour les femmes de plus 40 ans, tous les deux ans. L'examen utilisé est la mammographie. Si une anomalie est découverte, le médecin demande des examens complémentaires (des incidences complémentaires, échographie, biopsie), afin de confirmer le diagnostic de cancer.
- **Le diagnostic** du cancer du sein repose sur le triplet diagnostique clinique, mammographie, anatomopathologique.
 - L'examen clinique : c'est un examen réalisé avant et après la mammographie, pour mettre en évidence d'éventuelles anomalies de certaines régions, et expliquer certains résultats, ainsi une corrélation entre clinique et imagerie est réalisée.
 - Mammographie : c'est l'examen incontournable de l'exploration de la glande mammaire. Il peut être complété par une échographie mammaire.
 - L'anatomopathologie : elle donne des informations précises sur le type de cancer du sein. Elle consiste à faire l'analyse au microscope des cellules et des tissus enlevés au niveau d'une anomalie du sein.
- **Les traitements** sont locaux et systémiques où : la chirurgie et la radiothérapie agissent localement sur les cellules cancéreuses situées dans le sein ou dans les ganglions : ce sont des traitements locaux du cancer [6].

- La chirurgie consiste à enlever la tumeur et les éventuelles greffes cancéreuses. Il existe plusieurs interventions possibles : chirurgie conservatrice qui conserve le sein (seule la tumeur est enlevée) et la mastectomie totale : ablation du sein.
- La radiothérapie a pour but de dégager les cellules cancéreuses à l'aide d'appareils qui émettent des rayons. Ces rayons doivent éliminer toute trace de cancer qui pourrait rester après une chirurgie.
- La chimiothérapie est un traitement qui consiste à utiliser des médicaments qui se diffusent dans tout le corps. Ils ont pour but d'éliminer les cellules cancéreuses ou d'éviter leur accroissement.
- L'hormonothérapie est un traitement médicamenteux qui agit dans l'ensemble du corps. Elle a pour but de bloquer ou réduire l'action des hormones sur certains cancers sensible aux hormones.

1.4 Imagerie mammaire

Il existe plusieurs techniques de diagnostic tel que

1.4.1 La galactographie :

C'est un examen simple, par l'injection de produit de contraste, qui permet de mettre en évidence et de localiser des processus intra-canaux [15].

1.4.2 La pneumokystographie :

C'est une méthode diagnostic dans les cas de difficultés de différenciation d'échographie d'une tumeur solide ou d'un kyste, par l'injection d'air. Son utilisation thérapeutique est controversée [15] (Fig1.5).



Figure 1.5 Cliché de pneumocystographie et galactographie.

1.4.3 L'échographie :

Elle est d'une grande aide pour détecter les liquides, et examiner la structure des nodules palpables, ou repérés lors d'une mammographie (Fig1.6). Certaines mammographies complexes peuvent être remplacées par une échographie complète, cependant, cette dernière ne peut en aucun cas se substituer à la mammographie. En effet, l'échographie ne permet pas d'analyser certaines structures, sauf dans des situations spécifiques : femmes enceintes et adolescentes.




Figure 1.6 Image échographique d'un sein [16].

1.4.4 l'IRM mammaire

Occasionnellement, le médecin peut solliciter un examen par IRM (imagerie par résonance magnétique) (Fig 1.7). Bien qu'il ne soit pas infaillible, il peut également aider à distinguer une anomalie bénigne d'une anomalie maligne. Il peut également être utilisé pour déterminer si le cancer s'est étendu, ou s'il y a une réapparition locale, pour ceux qui ont déjà été soignés d'un cancer du sein. L'IRM est beaucoup plus performante pour la détection des carcinomes infiltrants (sensibilité allant de 94% à 100%) que pour celle des carcinomes intra-canaux (sensibilité variant de 77% à 94%) [2].




Figure 1.7 : Tumeur détectée dans le sein droit sur une image IRM [16].

1.4.5 Scintigraphie mammaire

Elle permet de détecter en phase préopératoire l'emplacement des ganglions sentinelles, premiers ganglions lymphatiques en partant du sein. Leur analyse préopératoire dira s'ils sont le siège d'un envahissement pouvant être à l'origine d'une dissémination métastatique.

1.4.6 PET SCAN ou TEP SCAN

C'est une méthode de médecine nucléaire, qui peut servir d'outil complémentaire aux autres techniques radiologiques comme la mammographie, l'échographie, la scintimammographie, le scanner et l'IRM.

Cependant, il ne peut pas les substituer. Il peut parfois être employé pour identifier les tumeurs chez les femmes possédant une densité mammaire élevée, des implants mammaires ou ayant subi une intervention chirurgicale du sein. Elle offre la possibilité d'évaluer de manière précise la dispersion d'un cancer, mais aussi de faire la différence entre une récurrence de cancer du sein et des modifications du sein dues à la chirurgie ou à la radiothérapie. Il ne permet cependant pas de détecter des tumeurs plus petites que 1 cm.

Dans ce mémoire en c'est intéressé a la mammographie car c'est la méthode a plus utilisée

1.4.7 Mammographie :

La Mammographie est un examen radiologique consacré à la détection des pathologies du sein, la plus performante en matière de surveillance et de dépistage précoce de cancer de sein. La qualité de l'image mammographique est caractérisée par trois paramètres physiques : la résolution, le contraste et le bruit [7]. Il existe deux types de mammographie : la mammographie conventionnelle (analogique, ou « classique ») qui produit une image imprimée sur un film argentique (cliché). La mammographie numérique construit l'image à partir de la valeur numérique de chacun des points.

1.4.8 La mammographie analogique

Elle utilise le même principe qu'une radiographie standard, la quantité

de rayon X produites dans le tube est de faible dose, elle dépendra de la quantité de tissu adipeux dans le sein (densité) et de nombre d'images prises (Fig1.8). Le sein radiographié étant positionné sur une porte cassette et comprimé par une plaque transparente. Cette compression est assurée par un système pneumatique avec une commande au pied, ce qui permet de libérer les mains du manipulateur, pour donner un positionnement correct de sein.

Le sein interposé entre un tube émetteur a rayon X et un couple « écran photo luminescent-film photosensible ». Les rayons X traversent le sein ou ils sont absorbés selon la densité des tissus rencontrés, et frappent l'écran ce qui entraîne la production d'une lumière qui impressionne le film argentique. L'image obtenue traduit la densité des tissus traversés, elle prend en continu, tous les niveaux de gris entre le blanc (absorption importante des tissus denses glandulaire, fibreux...) et noir (faible absorption des tissus gras). Une forte compression permet de :

- Immobiliser le sein, ce qui réduit le flou cinétique.
- Réduire la dose en diminuant l'épaisseur traversée pour améliorer le contraste et réduire la dose absorbée.
- Rendre l'épaisseur homogène sur la plus grande partie du sein, donc homogénéiser la densité.
- Etendre le tissu pour que les petites anomalies ne soient pas cachées par le tissu voisin.




Figure 1.8 : Mammographie analogique

1.4.9 Mammographie numérique

Il existe deux techniques pour obtenir une mammographie numérique. La première 1^{ère} ou la numérisation est indirecte consiste à transformer l'image du film argentique en image numérique par intermédiaire d'un scanner ou d'une caméra CCD qui affecte une valeur numérique déterminée à chaque NG [8]. La 2^{ème} ou la numérisation est direct, utilise des mammographie numérique « plein champ » ou la plaque et son film photographique sont remplacés par des détecteurs qui captent le rayonnement X en mode numérique et reconstruit l'image à partir d'un nombre fini de point dont chacun a une valeur [9].

La mammographie numérique est une technique plus récente en imagerie mammaire (Fig1.9). Cette technique permet, en association avec des technologies modernes RIS-PACS et par sa possibilité de travail en réseaux des avantages :

- Diminution de la dose de radiation.
- Accélère considérablement l'acquisition des images et élimine le temps sacré au développement de la pellicule.
- Manipulation des images sur des écrans d'ordinateur de haute résolution en fonctions des besoins (Zoom, inversion, contraste, fenêtrage)



Figure 1.9 : Mammographie numérique

1.4.10 Les incidences en mammographie

Il y a deux grandes catégories d'incidence :

Les incidences fondamentales

En fonction de la zone du sein examinée, diverses incidences sont employées. Les modalités d'incidence fondamentales sont : l'incidence oblique externe (également appelée médio-latérale-oblique), l'incidence de face et l'incidence de profil strict [10] (Fig. 1.10).

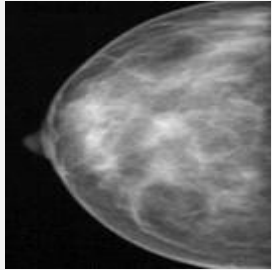
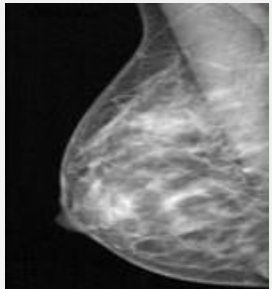
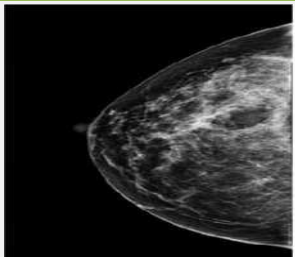
Types d'incidences	Critères de qualité	Régions aveugles	Mammographie correspondante
Incidence de face	<ul style="list-style-type: none"> *Mamelon situé au centre sans projection sur le sein. *Lame graisseuse rétro glandulaire bien dégagée. *Peau non visible (pas de pli cutané). 	<ul style="list-style-type: none"> *Partie hautes des QS. *Prolongement axillaire (QSE). 	
Incidence oblique externe	<ul style="list-style-type: none"> *Une exploration complète du sein est nécessaire. *Le sillon sous-mammaire doit être clairement visible. * 2/3 du grand pectoral sont visibles. *Le mamelon est projeté en dehors de la glande. *Une bande de graisse rétro glandulaire est observable. 	QSI	
Incidence de profil strict	<ul style="list-style-type: none"> *Pectoral en bordure de film. *Sillon sous pectoral dégagé. 	<ul style="list-style-type: none"> *Prolongement axillaire. *Partie profonde de la glande mammaire. 	

Figure1.10 : Caractéristique des incidences en mammographie

Incidences complémentaires :

- **Cliché agrandi** : s'applique lorsque l'on doit examiner une région spécifique du sein de manière plus détaillée (cas des microcalcifications, opacité nodulaire).
- **Cliché centrée** : grâce à une compression localisée (petite pelle) et sans agrandissement, cette méthode permet d'identifier une anomalie, d'éliminer les superpositions et de faire disparaître les images apparemment construites.
- **Cliché tangentiel** : son usage est rare, il revêt une importance pour les lésions superficielles et les structures qui se projettent dans les zones claires sous-cutanées.

1.4.11 Analyse des clichés mammographiques

L'image mammographique est obtenue en atténuant un faisceau de rayons X qui traverse divers tissus mammaires. Cette atténuation est principalement déterminée par la nature des tissus traversés (Fig1.11).

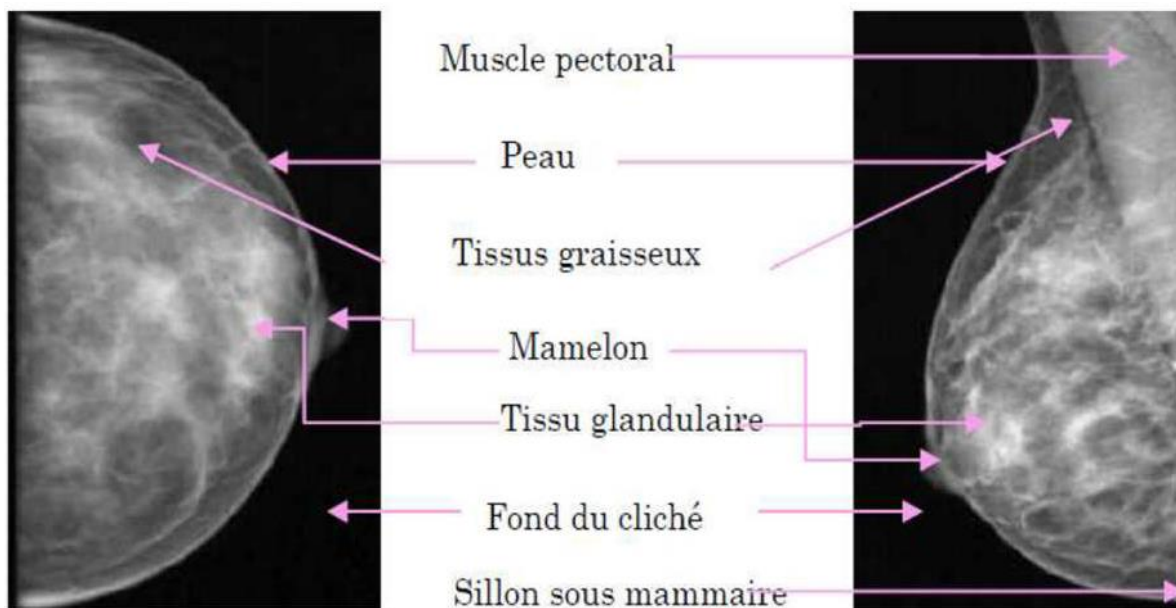


Figure 1.11: Radio anatomie d'un sein normal sur une incidence face/oblique

- **Densité mammaire**


La structure interne de la glande mammaire change avec l'âge des patientes. Chez les jeunes adultes, le sein est abondant en tissu glandulaire et conjonctif, apparaissant sur une mammographie comme une zone extrêmement dense remplissant presque entièrement le sein. À la ménopause, les seins sont souvent « déshabités » et donc totalement radio-transparents. Le système de classification BI-RADS de l'American College of Radiology divise les seins en quatre catégories, où le risque d'omission d'un cancer augmente en passant du type 1 au type 4 (Fig1.12) [8].

Type 1 : Les seins entièrement clairs, adipeux (graisseux).

Type 2 : structure fibro-glandulaires peu importante.

Type 3 : dense de façon hétérogène avec difficultés d'interprétation.

Type 4 : Sein uniformément dense avec difficultés d'interprétation.



Type 1

Type 2

Type 3

Type 4

Figure 1.12 Différentes types de densité mammaire

- **Anomalies mammaires radiologiques :**

La détection du cancer du sein révèle quatre types d'anomalies strictement radiologiques : les opacités, les microcalcifications, les asymétries de densité et les distorsions architecturales. Cette recherche se concentre spécifiquement sur l'examen des microcalcifications.

Les opacités mammaires : une anomalie du tissu conjonctif ou épithélial est indiquée par une opacité. Cela représente une plage de surdensité atypique, qui ne se différencie pas d'une surdensité standard par un critère spécifique, mais plutôt par une association de divers attributs : dimension, densité, ligne, configuration, texture... Elle sera donc facilement détectable dans une zone où la graisse est présente, et beaucoup plus difficile à identifier, dans une région ayant une densité élevée de tissu conjonctif [12]. C'est grâce à l'expérience que le radiologue est capable de repérer une opacité sur une mammographie. Une densité excessive observée sur plusieurs images, prises sous divers angles, suggère fortement une opacité.

Les calcifications mammaires : elles représentent de petites accumulations de calcium, non visibles par les rayons X et discernables par mammographie. Leur provenance n'est pas systématiquement déterminée, mais elles peuvent être associées à des sécrétions mobiles. Leur forme est définie par le lieu où elles se sont formées [13]. L'étude détaillée des calcifications nous permet de distinguer deux principales catégories :

1. Les macrocalcifications : ce sont des accumulations importantes de calcium dans le sein,

qui présentent une apparence très distinctive sur la mammographie. Elles sont systématiquement considérées comme des anomalies bénignes.

2. Les microcalcifications : il s'agit de dépôts de calcium de petite taille, variant entre 200 et 500 µm, à la limite de ce qui est visible. Elles peuvent être bénignes ou malignes (Fig1.13) : leur nature est déterminée par des micro ou macro-biopsies. Elles doivent être interprétées en fonction de plusieurs critères :

- La taille : on observe de grandes variations de taille entre les calcifications du cancer canalaire in situ. Pour l'évaluation des calcifications, il est nécessaire de considérer la différence de taille.
- Nombre de microcalcifications (Mcs) : en général, toute agrégation contenant plus de 4 calcifications doit être retirée, si ces calcifications sont associées à d'autres éléments, susceptibles d'évoquer une malignité [13].
- Localisation : elles sont soit éparpillées, touchant une large zone du sein, parfois même l'ensemble du système canalaire. Il arrive qu'elles soient plus localisées. Selon les recherches de Lanyi, les formes géométriques sont presque toujours indicatives d'un cancer, tandis que les formes plus diffuses tendent à avoir une signification bénigne [13].
- Forme : il s'agit sans doute du facteur crucial pour porter un jugement sur le degré de malignité. Il est probable que les calcifications de forme arrondie ou ovale soient bénignes. Au contraire, plus elles sont irrégulières, plus elles présentent un risque de malignité[13].
- Le polymorphisme de Mcs : c'est un paramètre crucial qui explique la divergence de taille et de densité entre les différentes Mcs au sein d'un même groupe. Le polymorphisme de Mcs est aussi un indicateur majeur de malignité : plus le nombre de Mcs s'accroît dans une lésion, plus le degré de polymorphisme tend à se renforcer [13].

- Le tableau 1.1 résume les arguments pour classer les microcalcifications :

Paramètres radiologiques	Critères de classification de calcifications	
	Calcifications négatives	Calcifications positives
Nombre	Quelques éléments calciques	Nombreuses calcifications unilatérales
Groupement	Dispersion dans tout le sein	Un ou deux foyers groupés, dans un seul sein

Morphologie	Rondes, régulières	Irrégulières, allongées, trop fines
Disposition	Amas arrondi, lobulaire	Amas linéaire, triangulaire, canalaire

Tableau 1.1 Tableau récapitulatif des calcifications bénignes/ malignes [14]




Figure 1.13 : Calcifications d'allures bénignes et malignes

1.5. D'autres techniques de diagnostic

Il existe un certain nombre de techniques de diagnostic de pathologies mammaires.

1.5.1. La biopsie : quand une anomalie suspecte est identifiée dans un sein suite à un test d'imagerie (mammographie, échographie ou IRM), des analyses supplémentaires sont requises pour établir si c'est un cancer. Pour cela, on effectue une biopsie, c'est-à-dire un échantillonnage de la lésion.

La biopsie implique l'extraction de morceaux de tissus mammaires, précisément à l'endroit de l'anomalie identifiée. Afin d'établir un diagnostic fiable, le médecin utilise l'une de ces deux techniques : la microbiopsie et la macrobiopsie. Le volume prélevé est bien plus important avec la macrobiopsie, indiquée en cas de microcalcifications. La microbiopsie est principalement employée pour le diagnostic des masses ou des nodules. Elle possède une efficacité remarquable, permettant de différencier les lésions bénignes et malignes dans plus de 98% des situations.

Micro-biopsie : cette procédure est réalisée après désinfection cutanée, sous anesthésie locale. Le praticien emploie un pistolet automatique équipé d'une aiguille permettant une collecte rapide [18].

Dans la plupart des cas, l'intervention se fait sous surveillance échographique pour cibler précisément l'anomalie avec l'aiguille. Il est possible de réaliser plusieurs prélèvements. L'examen ne provoque aucune douleur, et on perçoit juste le son du pistolet qui fait « bang » lors de la mise en place de l'aiguille.

Macro-biopsie : se fait également sous anesthésie locale. Pour repérer l'anomalie, on utilise une technique appelée stéréotaxie [18] : la patiente est assise devant le mammographe, torse nu. Plusieurs clichés sont réalisés et transmis à un ordinateur qui va guider l'aiguille jusqu'à la zone anormale. Le sein à biopsier est comprimé par un appareil de mammographie doté d'un système permettant de repérer les coordonnées de l'anomalie et de guider le médecin. Une quinzaine de prélèvements peuvent être effectués, avec une aiguille de plus gros calibre que celle utilisée pour la micro-biopsie. Celle-ci « aspire » le tissu prélevé. L'examen dure moins d'une demi-heure et n'est pas trop douloureux. L'incision est refermée par un pansement.

Ces prélèvements vont ensuite passer par l'examen anatomo-pathologique qui est détaillé par la suite.

- **Analyse anatomo-pathologique**

L'examen anatomopathologique, qui implique l'analyse microscopique de cellules ou tissus prélevés sur le sein [19], permet notamment d'identifier une inflammation ou une tumeur. On évoque également l'examen histopathologique ou examen histologique, crucial en oncologie pour différencier les tumeurs bénignes des tumeurs malignes et évaluer leur niveau de malignité. Les professionnels de santé se réfèrent souvent à cet examen sous le terme abrégé « examen Anapath ». C'est à travers l'examen anatomopathologique, que le diagnostic de cancer est établi de manière définitive. On évoque une preuve histologique.

- **Prise en charge d'un prélèvement**

Après le prélèvement des échantillons qui résultent de la micro ou macro-biopsie, ces échantillons vont être analysés visuellement par un

médecin spécialiste dans un premier temps (examen macroscopique), puis par un microscope (techniques microscopiques) selon des étapes techniques qui sont citées par la suite, dont le but est de comparer les cellules prélevées du patient avec les cellules normales. La comparaison se fait en fonction de :

- Lieu de prélèvement.
- Age.
- Type de lésion clinique.
- Histoire de la maladie.

La prochaine étape, c'est l'identification de la lésion, le médecin doit connaître la nature de lésion prélevée :

1. Si tumoral, il va déterminer si elle est bénigne ou maligne avec le nom de type de la tumeur de façon précise.
2. Si autres, il va déterminer si elle est inflammatoire, maladie congénitale ou bien subnormal.

- **Les phases techniques de l'examen anatomo-pathologique**

Le plus souvent, le prélèvement (matériel histologique) est fixé, inclus, coupé et coloré afin de pouvoir l'observer au microscope. On peut obtenir le matériel par biopsie ou par prélèvement opératoire ou d'autopsie, et les procédures techniques comprennent :

Fixation du tissu : Les objectifs de la fixation sont la préservation des structures et le renforcement des tissus. Elle doit être effectuée sans délai après le prélèvement, en immergeant le prélèvement dans un fixatif (Fig 1.14): une solution de formol 'CH₂O' ou une solution de formaldéhyde concentré. On fait usage de cette solution en la diluant dans de l'eau, ce qui nous amène à parler d'une solution de formol contenant en réalité 4% de formaldéhyde, une concentration parfaite pour la fixation.

Le formol est une substance hautement toxique, allergène et cancérigène. Il est employé pour la conservation des cellules constituant le tissu prélevé, afin de préserver sa forme originale et d'éviter sa lyse ou son délitage.

Le formol s'introduit graduellement dans les tissus (1mm/heure), donc la durée de fixation varie en fonction de la taille de l'échantillon à examiner. Cette étape est importante, en effet si le fixateur ne pénètre pas dans le tissu, celui-ci risque de se lyser.



Figure 1.14: Automate de fixation et d'imprégnation.

L'inclusion en paraffine : l'objectif de l'inclusion est de faciliter la production de sections minces et uniformes. Le milieu d'inclusion le plus utilisé est la paraffine (Fig1.15). Étant donné que la paraffine repousse l'eau, l'échantillon doit être préalablement déshydraté (en le plongeant dans des bains d'alcool à concentration croissante puis dans des bains de toluène), avant d'être versé dans un moule rempli de paraffine fondue par chauffage, jusqu'à devenir liquide, qui pénètre alors dans la totalité du spécimen. Après refroidissement (Fig 1.16), on se trouve en présence d'un bloc de paraffine, dur, à l'intérieur duquel la pièce prélevée est incluse.



Figure 1.15 : Prélèvements mis dans la paraffine.



Figure 1.16 : Refroidissement de la paraffine.

Coupes : les coupes du bloc de paraffine sont faites avec un microtome permettant de réaliser des tranches de section (coupes) de 2 à 5 micro mètres d'épaisseur. Les coupes sont recueillies sur des lames de verre et mises à sécher (sur toute la nuit à 40-45°C ou 1 heure à au maximum 60°C) (Fig1.17).



Figure 1.17 : Illustration des coupes au microtome.

Coloration : la plupart des tissus sont transparents, Les colorations réalisées sur lames, accentuent les contrastes pour pouvoir reconnaître différents éléments du tissu.

Elles permettent d'identifier l'architecture tissulaire (dans les tumeurs, l'architecture tissulaire est anormale).

Choix des colorations : au sein de l'hôpital, le pathologiste occupe une place cruciale, puisque c'est son diagnostic qui déterminera le traitement à mettre en place. L'examen histologique standard permet au pathologiste d'obtenir une compréhension de la pathologie présente et d'avoir une perspective générale sur la morphologie des tissus (noyau, cytoplasme et collagène).

Il peut par la suite solliciter une révision du même tissu, mais cette fois, en mettant l'accent sur un élément tissulaire spécifique, qui aurait été souligné de manière précise. On fait référence ici à des colorations particulières.

Colorations de routine : elle se réalise au moyen d'un automate. Après déshydratation puis réhydratation, les sections sont colorées par immersion dans divers produits chimiques pour distinguer les éléments du prélèvement (noyaux, cytoplasmes, etc.) par des couleurs distinctes.

L'éosine teinte les cytoplasmes en rose et les fibres dans une variété de nuances roses, plus ou moins intenses, en fonction de l'acidophilie des divers composants (Fig 1.18).

Colorants:

- Les colorants basiques produisent une coloration bleue dans les noyaux, un phénomène que l'on appelle basophilie.
- Les colorants acides ou anioniques teintent les cytoplasmes en rose : on parle d'acidophilie.
- En coloration standard, les noyaux tendent à être bleuâtres tandis que les cytoplasmes ont une teinte jaune-orangée.



Figure 1.18 : Coupes après coloration.

1.5.2. Tomosynthèse

C'est une méthode innovante et complémentaire à la mammographie numérique dans la lutte contre le cancer du sein. Son principe est de réaliser une série de clichés, millimètre par millimètre et selon un arc de cercle autour du sein (Fig1.19), de façon à obtenir, par extrapolation numérique, une vision du sein reconstituée en 3 dimensions [16].



Figure1.19 : Tomosynthèse mammaire numérique 3D

1.5.3. Système CAD (Computer Aided Detection/Diagnosis) en mammographie

Depuis plusieurs années, diverses équipes de recherche s'efforcent de concevoir des systèmes informatiques pour l'analyse des images de mammographie. On examine diverses approches, comme la classification

automatique des anomalies identifiées, la reconnaissance de formes et la détection. Des systèmes de détection assistée par ordinateur CAD sont actuellement sur le marché et leurs résultats sont largement publiés dans les revues scientifiques internationales.

Un CAD est un système combinant matériel et logiciel, conçu pour examiner des images médicales et soutenir le spécialiste dans son processus de détection. En termes pratiques, on parle généralement d'un détecteur accompagné d'un classificateur (intelligence artificielle). L'appareil identifie les microcalcifications et les masses, qu'elles soient de nature bénigne ou maligne, et donne donc une interprétation médicale à la détection. Le CAD ne formule évidemment pas de diagnostic. Il effectue une catégorisation en classes : bénin, malin, normal, indéterminé, entre autres. Certains systèmes excluent les éléments identifiés comme étant bénins ou normaux, par exemple. Le reste est souligné et laissé à l'appréciation du médecin, seul responsable de l'établissement du diagnostic.

Conclusion

Ce chapitre a mis en lumière l'importance de la mammographie et les informations cruciales qu'elle nous fournit pour le diagnostic du cancer du sein. Du fait de la gravité du cancer du sein, de nombreux groupes de recherche s'attaquent à la question de l'assistance au diagnostic. Les premières recherches remontent à 1967. Les travaux se caractérisent par les types de signes détectés (opacités, calcifications), l'objectif étant la détection et la classification. Dans le prochain chapitre, nous examinerons la question de la détection des Mcas. Nous énumérerons les diverses techniques employées ainsi que les instruments requis.

CHAPITRE

2. ETAT DE L'ART

2.1. Introduction

L'intelligence artificielle, et en particulier l'apprentissage profond (Deep Learning), est de plus en plus utilisée dans le domaine médical. Les réseaux de neurones convolutionnels (CNN) sont très efficaces pour analyser des images, car ils peuvent identifier automatiquement des formes et des motifs utiles à la classification. Les images histologiques, qui représentent des tissus humains observés au microscope, sont souvent utilisées pour détecter des maladies comme le cancer. Leur analyse reste toutefois difficile à cause de la complexité des tissus, des différences entre les patients et des erreurs possibles lors de la préparation.

Aujourd'hui, les CNN permettent d'automatiser cette analyse, en facilitant la détection de cellules cancéreuses ou la classification des images selon la gravité. Dans ce chapitre nous présentons un résumé des travaux de recherche, qui traitent les CNN, la classification des images histologiques du cancer de sein et la classification des microcalcifications mammaires. Ensuite nous donnerons un récapitulatif, des méthodes utilisées dans ces travaux.

2.2. Etat de l'art des réseaux de neurones convolutionnels

- ❖ Y.XU et ses collaborateurs [20] ont suggéré une approche pour segmenter les images IRM du cerveau des nouveau-nés en utilisant un réseau de neurones entièrement convolutif (FCN). Ils y ont intégré des informations pseudo-3D et le transfert d'apprentissage dans leur méthode. Cela permet d'évaluer le développement du cerveau et de diagnostiquer les troubles neurologiques. Cette technique a rendu possible la segmentation automatique d'un volume complet d'IRM 3D en quelques secondes, grâce à la méthode pseudo-3D. De plus, elle requiert un volume d'apprentissage minimal, grâce à l'application du transfert d'apprentissage. Ce dispositif segmente des images en couleur 2D qui sont générées à partir du volume en trois dimensions. L'image est introduite au niveau du réseau de base FCN, dont la sortie produit une image segmentée ; cette technique est détaillée dans [20]. Les résultats obtenus présentent une précision élevée et le délai d'exécution pour segmenter un volume IRM complet est de quelques secondes.

- ❖ A.Sankari et S.Vigneshwari [21] ont proposé une méthode automatique de segmentation des tumeurs cérébrales basée sur les réseaux de neurones convolutionnels (Convolutional Neural Network (CNN)), en se servant de filtres petits (3x3), ce qui favorise une conception plus approfondie, dans le but d'améliorer la qualité de l'architecture du réseau. La méthode suggérée emploie une approche en domaine spatial pour offrir une image de haute qualité, et l'approche CNN détermine également la position et la zone de la tumeur dans le cerveau. La méthode suggérée [21] offre une segmentation automatique et exacte des tumeurs, en utilisant une approche de domaine spatial combinée à des réseaux neuronaux convolutifs (CNN). De plus, elle propose l'identification et l'étude de la tumeur lors de la phase précoce, et cette proposition joue un rôle très important dans l'augmentation des chances de traitement.

- ❖ S.E. Amin et M.A. Megeed [22] ont mis au point une méthode de segmentation destinée à l'identification et la classification automatique de divers types de tumeurs cérébrales visibles sur les images IRM, comme « le neurinome acoustique, les astrocytomes et le gliome optique ». Leur système repose sur des réseaux de neurones avancés et se divise en deux composantes majeures : un réseau neuronal PCA qui extrait les éléments principaux à partir des cas d'IRM, et un réseau MLP servant de système de classification, qui attribue les composants principaux aux cas semblables. L'objectif étant d'économiser du temps pour le radiologue, améliorer la précision des diagnostics et faciliter ainsi la tâche des médecins non spécialisés dans l'identification des tumeurs cérébrales.

- ❖ A.Q.Syed et K.Narayanan [23] ont mis en place une technique automatique pour identifier les tumeurs cérébrales et classer automatiquement les tissus cérébraux en catégories normales et anormales (malignes ou bénignes) à partir des images IRM. Cette technique [23] repose sur l'utilisation d'un réseau de neurones artificiels. Ils ont tenté de caractériser précisément les tissus cérébraux grâce au réseau de perceptrons multicouches, en utilisant l'énergie, l'entropie, le contraste et d'autres propriétés statistiques comme la moyenne, la médiane, la variance et la corrélation. Il s'appuie également sur une méthode de sélection des caractéristiques pour minimiser l'espace

des fonctionnalités. Le but est d'assister les radiologues pour améliorer la précision et, par conséquent, l'efficacité du diagnostic.

- ❖ A.R. Lopez et al [24] ont proposé une méthode basée sur l'apprentissage profond pour la classification des lésions cutanées, plus précisément pour distinguer les lésions cutanées comme étant malignes ou bénignes à partir d'une image dermatoscopique ; leur approche se base sur l'architecture du réseau neuronal convolutif VGGNet qui exploite le concept du transfert d'apprentissage [24]. Ils ont conçu un classificateur binaire qui prend en entrée des images de lésions cutanées étiquetées comme bénignes ou malignes, a élaboré un modèle en utilisant des réseaux neuronaux convolutifs profonds et utilise ce dernier pour la prédiction de l'état (bénin ou malin) [24]. Cette approche produit de bons résultats en matière de sensibilité et de précision comparativement à l'état antérieur de la méthode sur cet ensemble de données.

- ❖ S.Khan et S.Yong [25] ont visé à présenter une nouvelle structure de réseaux de neurones convolutionnels (CNN) pour la classification d'images comportant divers objets anatomiques. Ils ont également entrepris une étude comparative entre leur architecture et trois structures principales déjà établies dans le domaine de la classification d'images, à savoir LeNet, AlexNet et GoogLeNet. Cette étude a impliqué une évaluation exhaustive des trois architectures CNN mentionnées précédemment, dans le but d'examiner leur efficacité dans la classification de l'anatomie des images médicales. La technique suggérée [25] a prouvé son excellence en termes de performance pour la classification des images anatomiques, en effet, cette méthode implique une modification de l'architecture originale d'AlexNet, ce qui aboutit à la création d'une nouvelle architecture CNN. Les données recueillies indiquent que la récente proposition de CNN surpasse les trois autres structures CNN en matière d'exécution, de perte d'entraînement, de précision lors de la validation et de précision durant les tests.

- ❖ P.Buysens et A.Elmoataz [26] ont employé une méthode basée sur des réseaux de neurones convolutionnels multi-échelle (MCNN) pour la classification automatique des cellules pathologiques et saines. Cette démarche contribue à affiner le diagnostic pour les spécialistes en cytopathologie. La méthode employée pour la classification des cellules s'appuie sur l'extraction automatique de caractéristiques ainsi que leur catégorisation. En outre, une stratégie multi-échelle est suggérée, employant plusieurs réseaux profonds à divers niveaux d'échelle, dont les résultats sont combinés. Cette technique est détaillée dans [26]. Les résultats obtenus indiquent un meilleur taux de classification sur une base de données de cellules comparé aux méthodes traditionnelles.

- ❖ Une méthode de segmentation automatique de la valve mitrale a été suggérée par E.Costa et al [27]. Grâce à l'utilisation de réseaux de neurones convolutionnels, ils ont conçu une structure appelée UNet, qui contribue à assister les opérateurs dans la détermination précise de la morphologie des valves. Cette technique n'exige pas une grande quantité de données d'apprentissage, il suffit de fournir l'image à traiter comme entrée au réseau. Les conclusions tirées de l'évaluation clinique de la segmentation concordent avec les résultats quantitatifs.

- ❖ D.S.Kermany et al [28] ont suggéré une technique de classification des images rétiniennes en OCT (Tomographie par Cohérence Optique) dans le but de référencer les causes habituelles de déficience visuelle sévère (comme la dégénérescence maculaire et la rétinopathie diabétique). Cette recherche a permis de développer un algorithme de transfert d'apprentissage destiné à identifier des motifs spécifiques dans une catégorie d'images, et ce, en un temps réduit et avec moins de puissance informatique requise. La proposition de solution implique d'entraîner un réseau de neurones convolutif (CNN) sur ImageNet, qui comporte 1000 catégories, puis de l'adapter pour qu'il soit formé sur des images OCT. Des couches de convolution ont été fixées et transférées vers un nouveau réseau, tandis que les couches entièrement connectées (Fully Connected FC) sont recomposées et retransformées à partir d'une initialisation aléatoire au-dessus des couches transférées. L'analyse et la classification des images OCT ont montré une performance remarquable, sans

nécessiter une base de données avec des millions d'images ni un réseau d'apprentissage profond hautement spécialisé. Malgré le fait que le réseau ait été formé sur un nombre restreint d'images, il a maintenu ses performances en termes de précision, sensibilité et spécificité.

2.3. Etat de l'art sur la classification des images histologiques du cancer de sein

- ❖ Al-Nahid et Y. Kong [29] ont proposé une méthode de classification des images histopathologiques du sein en classes bénigne et maligne en utilisant un réseau de neurones convolutifs (CNN) avec des blocs résiduels, combiné à l'extraction de caractéristiques locales (Histogramme, Contourlet Transform, Local Binary Pattern) et de caractéristiques fréquentielles (DFT, DCT). Cinq variantes de modèles CNN ont été explorées : CNN-I (images brutes), CNN-CH (Histogramme + CT), CNN-CL (LBP + CT), CNN-DF (DFT) et CNN-DC (DCT). L'approche a été évaluée sur la base de données BreakHis, avec des images à quatre niveaux de grossissement (40×, 100×, 200×, 400×). La meilleure performance a été obtenue avec le modèle CNN-CH sur les images 200×, atteignant une précision de 97,19%, une sensibilité de 98,20% et une spécificité de 94,94%, montrant une capacité élevée à détecter correctement les tissus malins.

- ❖ La méthode de détection automatique du carcinome canalaire invasif (IDC) dans les images histologiques des diapositives intégrales du cancer du sein a été proposée par A.Cruz-Roaa et al [30]. Un réseau de neurones convolutif (CNN) a donc été créé [30] pour examiner les zones tumorales. L'approche a été examinée sur un corpus de données complet comprenant des diapositives de 162 patients atteints d'IDC. Pour l'apprentissage, 113 diapositives ont été choisies, tandis que 49 diapositives ont été utilisées pour le test. Le but de cette recherche est d'évaluer la justesse de la classification dans l'identification des zones de tissu IDC sur des diapositives intégrales. Les résultats obtenus offrent une détection automatique plus efficace des régions IDC en termes de F- mesuré et de l'accuracy (71,80 84,23).

- ❖ Dans [31], F. A. Spanhol et al. ont mis en évidence les performances de classification d'un réseau CNN, élaboré pour distinguer les tumeurs bénignes des tumeurs malignes. Ce réseau est appliqué à une base de données connue sous le nom de BreakHis, qui comprend 7909 images microscopiques de tissus tumoraux mammaires prises avec divers facteurs de grossissement : 40, 100, 200 et 400. Le système de catégorisation repose sur quatre modèles d'apprentissage automatique, formés à partir de diverses représentations texturales. Un éventail complet d'expériences démontre que les niveaux de précision avec ce système de base varient entre 80 et 85 pourcents, selon le facteur d'agrandissement de l'image.
- ❖ Dans [32], M. H. Motlagh et al introduisent une structure appelée ResNet, qui facilite la reconnaissance des images histologiques cancéreuses provenant du sein. En effet, ils ont prouvé que le réseau construit détecte et catégorise automatiquement la tumeur ainsi que ses sous-types. Ils ont également ajouté des méthodes complémentaires comme l'augmentation de données pour affiner la précision de prédiction. Cette recherche indique que la précision de classification des tumeurs bénignes et malignes est de 98,7%.

2.4. Etat de l'art sur la détection des microcalcifications

- ❖ **Zouari et al.** [33] proposent une méthode NLS (Non Linear Stretching) innovante, visant à rehausser le contraste des microcalcifications détectées dans la mammographie numérique. Ils utilisent une fonction exponentielle adaptative qui effectue une modification locale du niveau de gris afin de mieux faire ressortir les microcalcifications. Zouari et al utilisent deux fois le NLS : à l'échelle locale et globale. Les performances sont évaluées selon une mesure d'amélioration de type Seconde-Derivative like Measure of enhancement (SDME).
- ❖ L'étude de **Mustra et Grgic** [34] présente une technique pour détecter les microcalcifications, en renforçant le contraste entre ces dernières et le tissu environnant, grâce à l'application d'un filtrage par ondelettes combiné à la morphologie mathématique. Les résultats issus de l'identification automatique des zones suspectes de microcalcifications se sont révélés satisfaisants en comparaison à

d'autres techniques qui ne font pas appel à la sélection manuelle des zones suspectes. Ils ont constaté une nette amélioration de la détection des microcalcifications.

- ❖ **Intharasombat et Piamsa-nga.**[35] suggèrent une approche AWAT (An Adaptive Window and Adaptive Threshold), qui combine une fenêtre adaptable et un seuil évolutif, pour l'identification des microcalcifications. On détermine les maxima locaux en utilisant un seuil optimal spécifique à chaque fenêtre, où ce seuil est fixé à deux fois l'écart-type (2SD). Par la suite, les petits objets sont supprimés grâce à des opérations morphologiques. Les points culminants restants sont catégorisés en microcalcification ou tissu normal grâce à trois classificateurs : un Perceptron Multicouche, un Réseau de Neurones à Fonction de Base Radiale et un SVM. Les résultats d'expérimentation indiquent que la technique AWAT suggérée a mieux fonctionné que les techniques utilisant une taille de fenêtre fixe.

- ❖ **Chacon et al.** [36] suggèrent une approche pour diagnostiquer le cancer du sein, en se fondant sur l'état des tissus mammaires, grâce à une analyse d'asymétrie thermographique du sein qui compare les propriétés de la région du sein droit à celle du sein gauche. Le modèle suggéré repose sur un classificateur flou, faisant appel à des caractéristiques statistiques. Une comparaison a été faite entre les résultats du système CAD et l'état pathologique des tissus des patients, démontrant une efficacité notable à différencier les tissus cancéreux des tissus normaux, avec une sensibilité de 82,35% et une spécificité de 92,15%.

- ❖ **Esener et al.** [37] introduisent un système de diagnostic automatisé assisté par ordinateur (CAD) pour la détection du cancer du sein. Pour la mise en place du système CAD, chaque patch de mammographie est initialement soumis à un prétraitement via une égalisation d'histogramme, avant d'être filtré par des moyennes non locales (NLM). Par la suite, une extraction de caractéristiques est effectuée à l'aide de l'algorithme « Local Configuration Pattern (LCP) », associée à certaines caractéristiques statistiques basées sur la fréquence. Cela est suivi d'une classification réalisée grâce à l'analyse discriminante linéaire de Fisher (FLDA). L'approche innovante permet d'atteindre un taux de reconnaissance optimal de 94,67%.

- ❖ **Hai Su et al.** [38] élaborent une technique fondée sur le SVM (Machine à Vecteur de Support), en combinant l'analyse des caractéristiques morphologiques et les informations fonctionnelles du génome. La zone du sein a été identifiée et segmentée pour chaque patient afin de repérer les zones tumorales. L'approche suggérée a été évaluée sur un jeu de données regroupant 86 patients, grâce à la validation croisée, démontrant que les traits morphologiques et les données génomiques fonctionnelles contribuent à une performance supérieure en termes de classification, pour distinguer les patients au stade I des autres stades. L'union de l'image-omique et du caractère fonctionnel génomique pourrait augmenter la précision de la classification de 3%.

- ❖ **Tan et al.** [39] conçoivent une méthode innovante de détection assistée par ordinateur (CAD), fondée sur l'examen global des traits d'images, en se servant de la densité tissulaire mammographique. Des caractéristiques ont été dérivées à partir d'images bilatérales, craniocaudales et médio-latérales obliques, afin de constituer deux réseaux de neurones artificiels (ANNs). Par la suite, un troisième ANN a fusionné les résultats pour élaborer un classificateur prédictif du test de dépistage. La sensibilité mesurée est de 95% tandis que la spécificité atteint les 80%.

2.5. Tableau récapitulatif

Référence	Approche	Application	Validation	Base de données
Y. Xu et al. [20]	FCN + Pseudo-3D + Transfert d'apprentissage	Segmentation IRM cérébrale néonatale	Précision élevée, exécution en quelques secondes	—
A. Sankari & S. Vigneshwari [21]	CNN (filtres 3x3, domaine spatial)	Segmentation des tumeurs cérébrales	Segmentation automatique et exacte, détection précoce	—
S.E. Amin & M.A. Megeed [22]	PCA-NN + MLP	Classification automatique de tumeurs cérébrales	Gain de temps, amélioration du diagnostic	—
A.Q. Syed & K. Narayanan [23]	Perceptron multicouche + sélection de caractéristiques	Classification tissu cérébral (normal/anormal)	Aide au diagnostic, amélioration de la précision	—
A.R. Lopez et al. [24]	VGGNet + transfert d'apprentissage	Classification binaire des lésions cutanées	Haute sensibilité et précision	—
S. Khan & S. Yong [25]	Nouvelle architecture CNN (comparée à LeNet, AlexNet, GoogLeNet)	Classification d'objets anatomiques dans les images médicales	Meilleure précision, perte d'entraînement réduite, bons résultats aux tests	—
P. Buysens & A. Elmoataz [26]	CNN multi-échelle	Classification cellules saines/pathologiques	Amélioration du taux de classification	Base de cellules
E. Costa et al. [27]	UNet	Segmentation automatique de la valve mitrale	Résultats cliniques concordants avec évaluation quantitative	—

Référence	Approche	Application	Validation	Base de données
D.S. Kermany et al. [28]	CNN + transfert d'apprentissage (ImageNet vers OCT)	Classification des images OCT (rétine)	Bonne performance, pas besoin d'un grand volume de données	OCT (images rétinienne)
Al-Nahid & Y. Kong [29]	CNN résiduel + caractéristiques locales/fréquentielles	Classification histologique (sein bénin/malin)	Précision : 97.19 %, sensibilité : 98.20 %, spécificité : 94.94 %	BreakHis
A. Cruz-Roa et al. [30]	CNN	Détection automatique IDC (sein)	F-mesure : 71.80 %, Accuracy : 84.23 %	162 lames IDC (113 train/49 test)
F.A. Spanhol et al. [31]	CNN + représentations texturales	Classification bénin/malin (tissu mammaire)	Précision entre 80-85 % selon le grossissement	BreakHis
M.H. Motlagh et al. [32]	ResNet + augmentation de données	Classification histologique (sein, bénin/malin)	Précision : 98.7 %	—
Zouari et al. [33]	NLS (Non Linear Stretching)	Détection de microcalcifications	Mesure SDME pour évaluation du contraste	—
Musta & Grgic [34]	Filtrage par ondelettes + morphologie mathématique	Détection de microcalcifications	Résultats satisfaisants comparés à autres méthodes	—
Intharasombat & Piamsa-nga [35]	AWAT + SVM/MLP/RBFNN	Détection de microcalcifications	Meilleure performance que les approches à fenêtre fixe	—

Référence	Approche	Application	Validation	Base de données
Chacon et al. [36]	Analyse d'asymétrie thermographique + classificateur flou	Diagnostic du cancer du sein	Sensibilité : 82.35 %, spécificité : 92.15 %	—
Esener et al. [37]	LCP + caractéristiques statistiques + FLDA	Détection assistée du cancer du sein	Taux de reconnaissance : 94.67 %	—
Hai Su et al. [38]	SVM + morphologie + informations génomiques	Classification cancer du sein (stade I vs autres)	Amélioration de la précision de 3 % via image-omique + génome	86 patients
Tan et al. [39]	ANN bilatéral fusionné par un 3e ANN	CAD pour dépistage du cancer du sein	Sensibilité : 95 %, spécificité : 80 %	—

Tableau 2.1 : tableau récapitulatif des articles étudiés

CHAPITRE

3. METHODES D'APPRENTISSAGE EN PROFONDEUR POUR L'ANALYSE DES OBJETS

3.1. Introduction

Le cancer du sein est sans doute l'une des maladies les plus répandues et mortelles dans le monde actuel. La détection précoce est essentielle pour augmenter les chances de survie des patientes. Les méthodes diagnostiques actuelles, telles que la mammographie et la biopsie, offrent une détection satisfaisante, mais présentent des limites importantes comme les faux positifs, l'interprétation subjective et la dépendance aux compétences du radiologue. Cependant, les progrès réalisés dans le domaine de l'intelligence artificielle (IA) et de l'apprentissage automatique (machine Learning) ont révolutionné le diagnostic médical en apportant automatisation, précision et détection précoce, notamment dans le cadre du cancer du sein.

Cette étude examine l'utilisation des modèles d'apprentissage automatique basés sur l'IA pour le diagnostic du cancer du sein, principalement à partir de l'analyse d'images, en appliquant différentes techniques de Deep Learning. La recherche se concentre notamment sur les réseaux de neurones convolutionnels (CNN) dans la détection et la segmentation des tumeurs malignes et bénignes, en comparant leurs performances respectives.

Dans ce chapitre, nous commencerons par présenter une petite définition de l'intelligence artificielle, puis nous donnerons quelques notions sur les réseaux de neurones traditionnels, précisément l'élément central des réseaux de neurones profonds : réseaux convolutifs (CNN). Nous détaillerons ses principales architectures, les différents composants de ces réseaux, leurs paramètres clés, ainsi que les fonctions d'activation les plus couramment utilisées, telles que Relu, Sigmoid ou softmax. Par ailleurs, nous aborderons les méthodes d'optimisation et de régularisation indispensables pour améliorer l'apprentissage et éviter le surapprentissage. Enfin, nous présenterons les modèles CNN pour analyser les bases de données et réaliser la segmentation, afin de conclure ce chapitre.

3.2. Intelligence artificielle (IA)

L'intelligence artificielle est une discipline de l'informatique qui vise à concevoir des algorithmes et des systèmes capables d'accomplir des tâches généralement associées à l'intelligence humaine, telles que la reconnaissance vocale, la compréhension du langage naturel, la prise de décision ou encore la résolution de problèmes complexes.

Cette discipline repose sur le postulat que les machines peuvent être programmées pour imiter les capacités cognitives humaines. Pour cela, elle s'appuie sur plusieurs domaines scientifiques, notamment la théorie de l'information, la logique mathématique, la statistique, ainsi que les réseaux de neurones artificiels [40].

Aujourd'hui, l'IA est largement déployée dans diverses applications concrètes, incluant la reconnaissance vocale et visuelle, les systèmes de recommandation, les chatbots, la robotique industrielle et les systèmes de contrôle autonome, entre autres.

3.2.1. Sous-domaines de l'Intelligence Artificielle

L'intelligence artificielle (IA) est un domaine vaste et multidisciplinaire qui comprend plusieurs sous-domaines essentiels. Parmi eux, l'apprentissage automatique (machine Learning) occupe une place centrale, et le Deep Learning (apprentissage profond) en est une branche spécialisée, comme illustré dans la (Fig3.1).

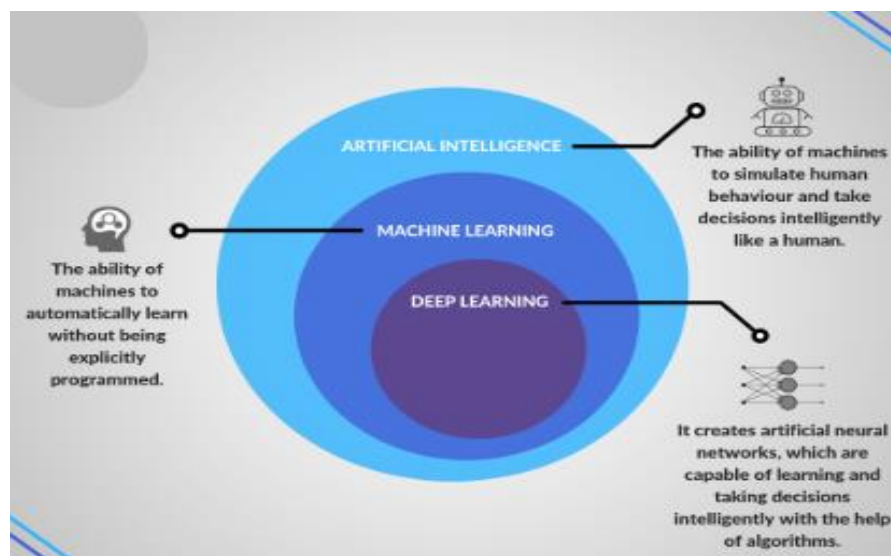


Figure 3.1: Relation entre l'intelligence artificielle, le ML et le Deep learning [40].

3.2.2. Apprentissage profond (Deep Learning en anglais) :

L'**apprentissage profond**, ou *Deep Learning (DL)* est une branche de l'apprentissage automatique qui se concentre sur l'utilisation de réseaux de neurones profonds pour résoudre des problèmes complexes. Il est notamment appliqué dans des domaines variés tels que la reconnaissance faciale, la détection d'objets — comme dans notre cas pour identifier les cellules cancéreuses —, la conduite autonome, la traduction automatique et la robotique industrielle.

Les avancées technologiques récentes, notamment dans le domaine de l'intelligence artificielle, ont considérablement facilité notre quotidien. Que ce soit à travers des appareils intelligents qui nous assistent dans nos tâches ou grâce à des dispositifs médicaux innovants capables de poser des diagnostics rapides et d'une précision remarquable — parfois même supérieure à celle des professionnels de santé —, ces progrès transforment nos vies.[42]

Cependant, derrière cette apparente simplicité, se cachent des mécanismes techniques complexes (Fig3.2). Ces modèles d'IA sont le fruit d'un apprentissage rigoureux, à partir d'immenses volumes de données étiquetées, et reposent sur des architectures de réseaux neuronaux profonds, composés de nombreuses couches. [43]




Figure 3.2 : Mécanismes techniques complexes du Deep Learning

3.3. Réseaux de neurones :

3.3.1. Qu'est-ce qu'un réseau de neurones ?

Le concept des réseaux de neurones artificiels (Artificiel Neural Networks – ANN) s'inspire directement du fonctionnement des neurones biologiques (fig3.3). Dans un réseau biologique, plusieurs neurones coopèrent en recevant des signaux d'entrée qu'ils analysent pour ensuite générer une réponse sous forme de signal de sortie [44].




Figure 3.3: Similitude entre un neurone biologique et artificiel

3.3.2. Des réseaux neuronaux aux réseaux neuronaux profonds :

Les réseaux neuronaux (RN) sont un type de modèle d'apprentissage automatique inspiré des mécanismes de traitement de l'information dans le cerveau. Ils sont couramment utilisés pour des tâches telles que la reconnaissance d'images, la classification de données et la prédiction de séquences.

Les réseaux neuronaux profonds, ou *Deep Neural Networks* (DNN), vont plus loin que les architectures classiques en intégrant plusieurs couches cachées de neurones. Cette profondeur supplémentaire leur permet de mieux comprendre et modéliser des structures complexes dans les données.

CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR L'ANALYSE DES OBJETS

Aujourd'hui, les DNN s'imposent comme une technologie incontournable dans plusieurs domaines, avec des résultats impressionnants notamment en reconnaissance vocale, en vision par ordinateur et en traduction automatique.

3.3.3. Types des réseaux neuronaux profonds

Les architectures des réseaux de neurones artificiels (ANN) étant très nombreuses, nous les présentons de manière concise [45].

- **Réseau Feedforward (FF) :**

Les réseaux de neurones de type *feedforward* (à propagation directe) représentent l'architecture de base sur laquelle reposent les autres types de réseaux de neurones, que nous aborderons par la suite.

Un réseau de neurone se compose :

- Une couche d'entrée ;
- Une ou plusieurs couches cachées ;
- Une couche de sortie (Fig3.4).

Les *feedforward neural networks* (FF) ne comportent aucune connexion de rétroaction. Ils constituent l'un des premiers développements majeurs dans le domaine des réseaux de neurones. Ils ont posé les bases des architectures plus complexes qui ont suivi [46].




Figure 3.4 : Couches d'un Réseau Feed Forward (FF)

- **Perceptron multi_couches (MLP)**

Il constitue une architecture fondamentale des réseaux de neurones supervisés, un type spécifique de **FF**. Il est largement utilisé grâce à son efficacité avec l'algorithme de rétropropagation.

Les connexions dans le réseau sont unidirectionnelles, allant toujours des couches situées à gauche vers celles situées à droite. Les neurones d'une même couche ne sont pas connectés entre eux. En revanche, chaque neurone est relié à l'ensemble des neurones de la couche suivante (Fig3.5), formant ainsi une architecture entièrement connectée (*fully connected*).

La définition de son architecture (nombre de couches, de neurones, et connexions) est essentielle : trop peu de paramètres peuvent rendre le modèle inefficace, tandis qu'un excès peut mener au surapprentissage. Utilisé surtout pour des **données tabulaires ou simples vecteurs** [45].

Un réseau MLP est un réseau FFNN avec plusieurs couches cachées




Figure 3.5 : Couches d'un perceptron multi-couche

- **Les réseaux de neurones convolutionnels CNN**

Les **CNN** basés aussi sur la structure **FF**, sont principalement utilisés pour l'analyse d'images. Chaque couche de ce type de réseau applique des filtres de convolution afin d'extraire automatiquement les caractéristiques pertinentes de l'image. Ils sont composés de deux parties :

- **La partie cachée de l'extraction des caractéristiques** : qui correspond aux couches cachées du réseau, où sont effectuées successivement des opérations de convolution et de pooling afin d'identifier et d'extraire les caractéristiques importantes de l'image.

- **La partie classification** : dans laquelle, les couches entièrement connectées (fully connected) interviennent pour analyser les caractéristiques extraites et attribuer à l'image une probabilité d'appartenance à une classe spécifique.

Contrairement aux réseaux de neurones traditionnels, les CNN sont dotés de couches spécialisées (Fig3.6), qui leur permettent d'apprendre efficacement des représentations hiérarchiques des données visuelles [46].

Un réseau CNN est un réseau MLP, avec des couches de convolution pour les images.

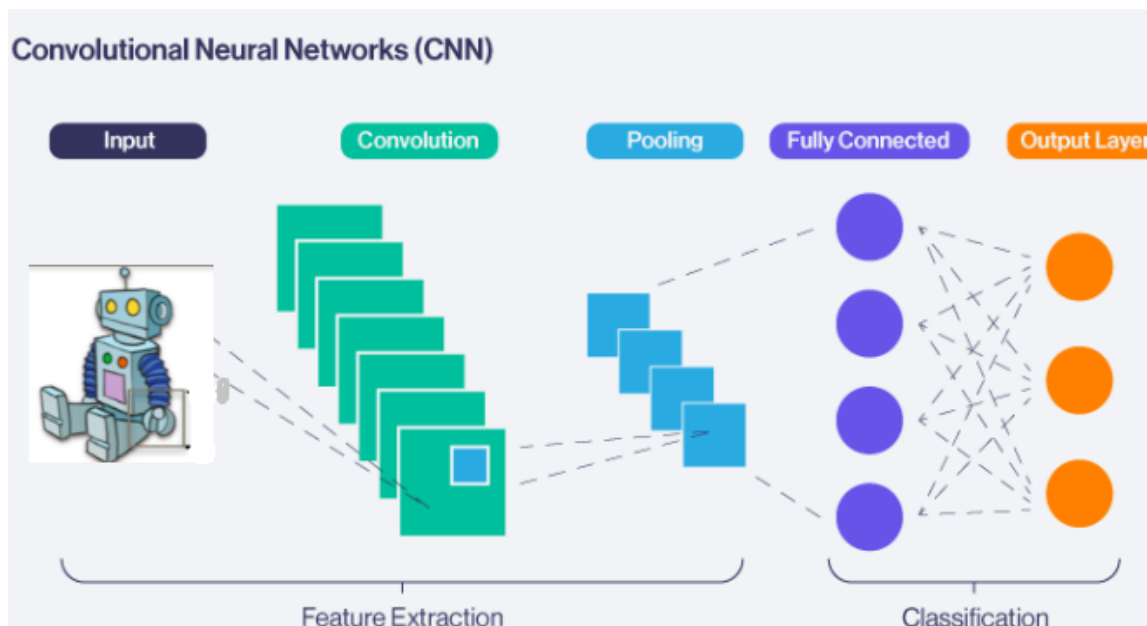


Figure 3.6 : Structure générale d'un réseau de neurones convolutifs

CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR L'ANALYSE DES OBJETS

Nous présenterons dans ce qui suit les autres types de réseaux neuronaux de manière concise et structurée (Tableau 3.1).

Type	Structure principale	Domaine d'application	Relation
RNN	Réseau avec connexions récurrentes	Données séquentielles (texte, séries temporelles)	Architecture différente de FF
LSTM	Type de RNN avec mémoire à long terme	Traduction automatique, reconnaissance vocale	Sous-type avancé de RNN
GRU	Variante simplifiée de LSTM	Analyse de séries temporelles, traitement du langage naturel (NLP)	Sous-type de RNN
GAN	Deux réseaux (générateur et discriminateur)	Génération d'images, synthèse de données	Architecture spécialisée
Autoencoder	Réseau pour encoder/décoder les données	Réduction de dimension, débruitage d'image	Architecture non supervisée
Transformer	Basé sur l'attention, sans récurrence	Traitement du langage naturel (NLP), vision	Successeur de RNN/LSTM en NLP

Tableau 3.1 : Résumé le reste des types de réseaux neuronaux dans un tableau

Après avoir posé les bases théoriques de l'intelligence artificielle et de l'apprentissage profond, cette seconde partie de notre mémoire se concentre spécifiquement sur **les réseaux de neurones convolutionnels (CNN)** qui sont liées à notre travail.

3.4. Types de couches dans le réseau neuronal convolutif

Une architecture CNN repose sur l'enchaînement structuré de plusieurs couches de traitement autonomes [47].

À la base, le fonctionnement est simple : l'utilisateur fournit une image, qui est représentée en interne comme une matrice de pixels. Si l'image est en niveaux de gris, cette matrice possède deux dimensions. Cependant, pour une image couleur, une troisième dimension est incluse, avec une profondeur de 3, pour encoder les intensités individuelles du **Rouge, du Vert et du Bleu**. (Fig3.7) [48]



Figure 3.7 : Prélevé la couleur d'un même pixel sur une image en couleur

3.4.1 Couche de convolution (CONV)

La partie initiale d'un CNN est la **couche de convolution**, dont la fonction principale est d'**extraire automatiquement les caractéristiques** des images. Elle détecte des motifs visuels comme les **contours, les lignes ou les couleurs**. L'intérêt majeur est que le réseau, une fois qu'il a appris une caractéristique, peut la reconnaître là où elle se trouve dans l'image.

Ainsi, l'image est **soumise à une série de filtres**, aussi appelés **noyaux de convolution**. Chaque filtre opère une transformation sur l'image, aboutissant à une **carte de convolution** qui fait ressortir des caractéristiques spécifiques

Mais qu'est-ce qu'un filtre? (Fig3.8) Pour une image couleur (profondeur 3), un filtre (kernel) est un bloc plus petit, mais de même profondeur, qui glisse sur l'image d'entrée et

effectue une opération de convolution (produit scalaire + somme) [48].




Figure 3.8 : Exemple d'un filtre kernel

- Les opérations de convolution :

La convolution est une opération mathématique qui effectue une "somme pondérée" entre deux entités. En imagerie, pour calculer le résultat à un emplacement (x,y), on prélève un bloc de taille k×k de l'image, centré sur ce point. On multiplie ensuite chaque valeur de ce bloc, élément par élément, avec le **filtre de convolution** (également de taille k×k), puis on additionne tous les résultats pour obtenir une sortie unique. Le "k" est la **taille du noyau**. La figure 3.9 présente un exemple de convolution sur une matrice 5×5 utilisant un **noyau de taille 3×3** [49].

Le **noyau de convolution glisse sur toute la matrice** afin de produire une **carte d'activation**.

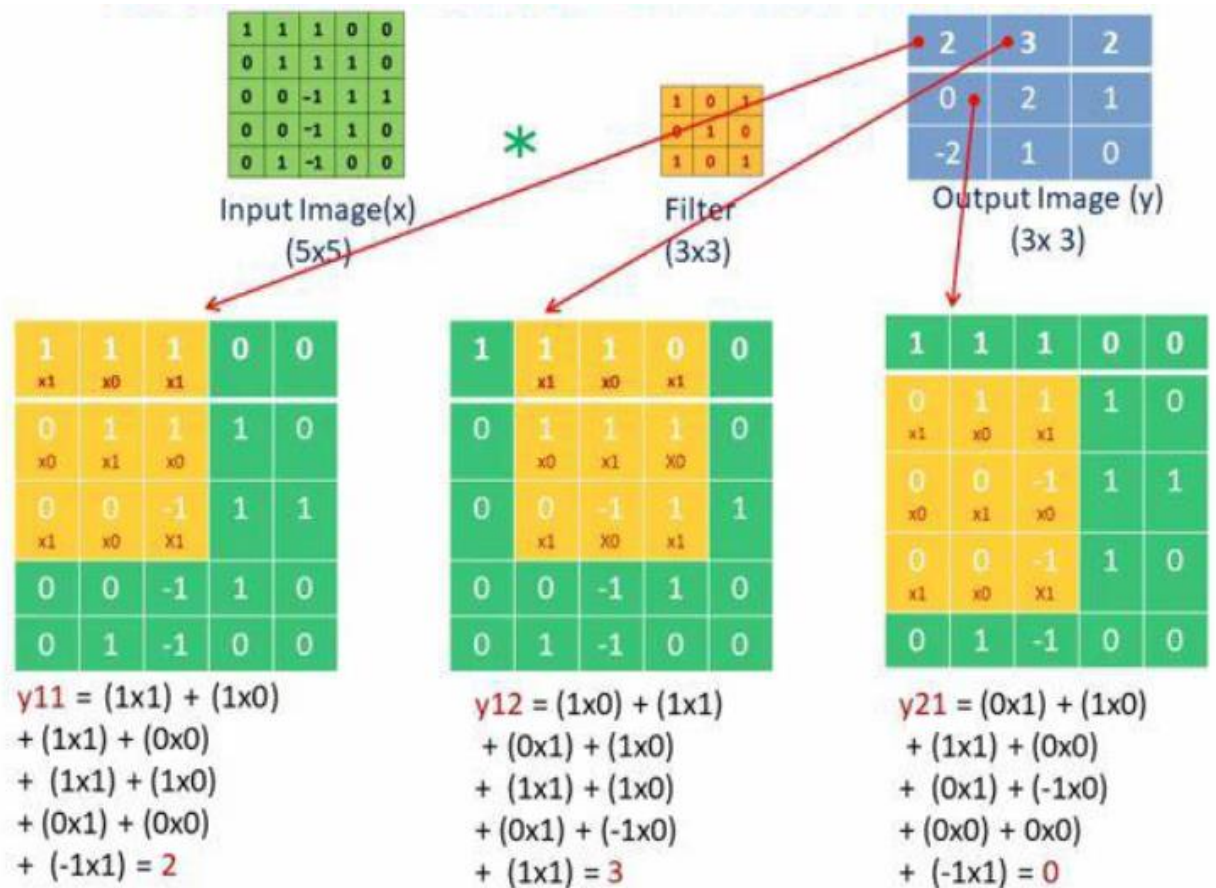


Figure 3.9 : Exemple d'une opération de convolution

Prenons un exemple concret pour mieux comprendre les différents termes. Supposons que l'image d'entrée ait des dimensions (32x32x3), ce qui correspond à un tableau tridimensionnel avec une profondeur de 3 (souvent liée aux canaux RVB). Tout filtre de convolution appliquée à cette couche doit impérativement avoir la même profondeur que l'image d'entrée. Ainsi, on peut utiliser des filtres de convolution de dimensions (3x3x3, 5x5x3, 7x7x3,...). Pour illustrer cette notion, considérons un filtre de taille 3x3x3. Dans ce cas, comme le montre la figure 3.10, le noyau de convolution prend la forme d'un cube plutôt que d'un simple carré




Figure 3.10 : Convolution sur image d'entrée

Si nous effectuons une opération de convolution d'un filtre $3 \times 3 \times 3$ sur une image $32 \times 32 \times 3$ génère une image de sortie de $30 \times 30 \times 1$. La raison en est que le filtre doit toujours être entièrement contenu dans l'image. Cela signifie que la convolution ne peut pas s'effectuer sur une bande de 2 pixels de largeur autour de l'image, ce qui équivaut à retirer un pixel de chaque côté (gauche, droite, haut et bas).

Notes Importantes :

-Les **mêmes filtres** sont utilisés de manière répétée sur l'ensemble de l'image. Leur but est de repérer des caractéristiques spécifiques et des motifs récurrents.

-Concernant le balayage, nous partons du principe que la fenêtre avance d'un pixel à chaque pas, horizontalement et verticalement. Ainsi, elle chevauche toujours avec la fenêtre précédente, sauf au début d'une nouvelle ligne. Il est bon de noter que le "**Pas de Progression**" (ou "**Stride**") peut être ajusté. De plus, les CNN peuvent utiliser une technique de "**Remplissage des Zéros**" (appelée "**Padding**") pour mieux gérer les bords de l'image lors du balayage.

- **Poids et Biais partagés (Weights and Biases)**

L'un des éléments clés des réseaux de neurones convolutifs (CNN) réside dans l'utilisation d'un même filtre sur l'ensemble de l'image. Autrement dit, tous les neurones d'une même couche convolutive partagent les mêmes poids **W** (paramètres du filtre) et le même biais **B** [50] (valeur ajoutée après l'opération de convolution) (Fig3.11)

CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR L'ANALYSE DES OBJETS

Dans l'exemple présenté, on obtient $30 \times 30 = 900$ neurones, correspondant au nombre de positions possibles pour appliquer un filtre de taille $3 \times 3 \times 3$. Contrairement aux réseaux de neurones classiques, où chaque neurone possède ses propres poids et biais, les CNN utilisent un mécanisme de partage des paramètres au sein d'un même filtre. Ce principe permet de réduire considérablement le nombre de paramètres du modèle tout en favorisant la détection de motifs répétitifs dans l'image.

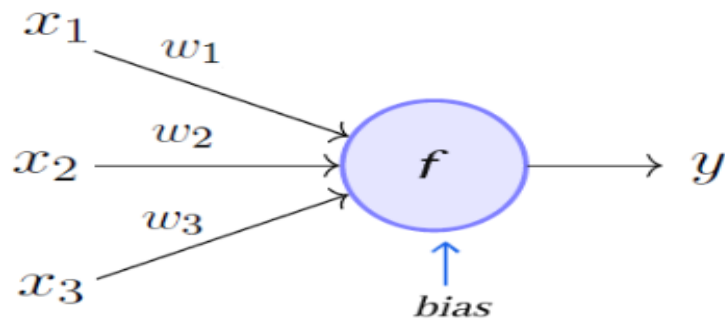


Figure 3.11 : Modèle du perceptron

- **Pas de progression (Stride)**

Le pas de glissement (ou stride) indique de combien de pixels la fenêtre (le filtre) avance à chaque étape. Ce déplacement peut être d'un seul pixel ou de plusieurs

- **Remplissage par Zéro (Padding)**

Il est évident que la convolution réduit la dimension de l'image résultante (la figure 3.12 montre un passage de 32×32 à 30×30). Pour pallier cette diminution et obtenir une image de sortie de taille équivalente à l'entrée, une pratique courante consiste à appliquer un remplissage de zéros (padding) sur les bords de l'image d'entrée. En ajoutant un pixel de remplissage de chaque côté dans cet exemple, nous obtenons une couche de sortie de 32×32 , simplifiant ainsi le processus.

Pour une image **d'entrée** $N \times N$, un filtre **F**, un pas **S** et un remplissage **P**, la taille de la sortie **M** \times **M** est donnée par la formule :

$$M = \frac{N - F + 2P}{S} + 1$$

0	0	0	0	0	0
0	35	19	25	6	0
0	13	22	16	53	0
0	4	3	7	10	0
0	9	8	1	3	0
0	0	0	0	0	0

Figure 3.12 Opération de remplissage par zéro

- **Cartes de caractéristiques (Feature Map)**

Les cartes de caractéristiques (ou *feature maps*) sont les sorties obtenues après une convolution. Pour une image $32 \times 32 \times 3$ traitée par un filtre $3 \times 3 \times 3$, on génère $30 \times 30 \times 1$ activations. Chacune de ces activations correspond à un neurone, et l'ensemble forme une carte de caractéristiques, qui alimentera la couche suivante.

- **Filtres multiples**

Au sein d'une couche de convolution, nous avons souvent recours à l'utilisation de plusieurs filtres. Par exemple, si nous utilisons 32 filtres, cela générera une **carte d'activation** dont les dimensions seront de $30 \times 30 \times 32$ (figure 3.13).

Un point fondamental est que tous les neurones qui sont rattachés au **même filtre** partagent un ensemble identique de poids et de biais. Ainsi, pour 32 filtres, le calcul des poids est de $3 \times 3 \times 3 \times 32 = 288$, tandis que le nombre de biais correspondra simplement au nombre de filtres, soit 32 [51].




Figure 3.13 : Cartes de caractéristiques formées de 32 filtres

Résumé de la Couche de Convolution

Une couche de convolution reçoit un **volume d'entrée** (représentant une image) avec des dimensions **Largeur (L1) × Hauteur (H1) × Profondeur (P1)**.

➤ **Hyperparamètres essentiels :**

Elle nécessite la définition de quatre hyperparamètres clés :

1. **Nombre de filtres (K)** : par exemple, 32, 64, 128, etc. Plus il y a, plus le nombre de caractéristiques pouvant être détectées augmente.
2. **Taille du filtre (F)** : elle est souvent égale à 3, 5 ou 7 pixels. C'est la dimension de la fenêtre de détection.
3. **Pas de progression (Stride) (S)** : il peut être égal à 1, 2, 3, etc. C'est le nombre de pixels dont le filtre se déplace à chaque étape.
4. **Quantité de remplissage (Padding) (P)** : on peut prendre par exemple, 1, 2, etc. Il s'agit du nombre de zéros ajoutés autour de l'image d'entrée pour contrôler la taille de la sortie.

Volume de Sortie (Carte de Caractéristiques)

La couche de convolution produit un **volume de sortie** appelé **carte de caractéristiques** (ou carte d'activation) avec des dimensions ($L2 \times H2 \times P2$), calculées comme suit :

- $L2 = (L1 - F + 2P) / S + 1$
- $H2 = (H1 - F + 2P) / S + 1$
- $P2 = K$

➤ **Partage des Paramètres :**

Grâce au **partage de paramètres**, chaque filtre introduit un nombre de poids égal à $F \times F \times P1$.

Le nombre total de paramètres pour la couche est donc de :

- **Poids** : $(F \times F \times P1) \times K$
- **Biais** : K (un par filtre)

Chaque **carte d'activation** est le résultat d'une opération de convolution entre **un seul filtre** et l'image d'entrée. Utiliser plusieurs filtres produit donc un nombre égal de cartes d'activations.

3.4.2 Couche de Pooling (Pool)

Pour optimiser les réseaux de neurones, la couche de Pooling est souvent insérée après la convolution. Elle a pour mission de réduire la taille de l'image (largeur et hauteur uniquement), ce qui a pour effet de diminuer significativement le nombre de paramètres et la complexité des calculs [50]. L'intégration régulière de couches de Pooling entre les couches convolutives, est une stratégie clé pour éviter le surajustement du modèle.

La méthode de pooling la plus fréquente est le "**maximum pooling**". Elle fonctionne en déplaçant un filtre de taille P sur l'image et en extrayant, à chaque étape, **la valeur maximale** de la zone couverte par le filtre (Fig3.14).

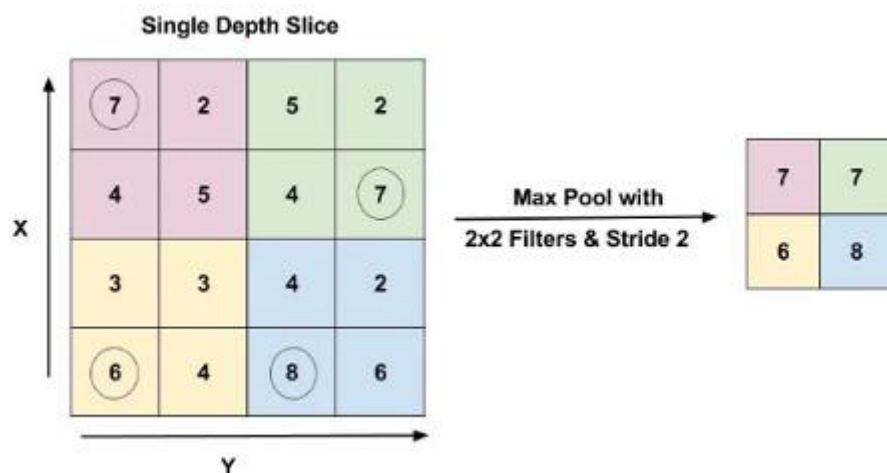


Figure 3.14 : Opération de max Pooling

L'**average-pooling (regroupement moyen)** est une alternative au max-pooling. Au lieu de retenir la valeur maximale d'un groupe de points, il en calcule la moyenne. Néanmoins, le max-pooling s'avère souvent plus efficace

Sum_pooling est un autre type où l'on somme toutes les valeurs d'une région (fenêtre) de la carte de caractéristiques

3.4.3 Couche de ReLU :

Il est souvent possible d'optimiser l'efficacité du traitement en intercalant une couche qui applique une fonction mathématique (fonction d'activation) aux signaux de sortie. Parmi celles-ci, on retrouve notamment :

- **La ReLU (Rectified Linear Unit)**

C'est une fonction d'activation simple : elle renvoie la valeur d'entrée si elle est positive, et zéro sinon (Fig3.15). On l'exprime mathématiquement par $y=\max(0,x)$, et sa représentation visuelle se trouve à la (fig3.16).



Figure 3.15 : Illustration du fonctionnement de la fonction ReLU




Figure 3.16 : Fonction ReLU

➤ **Tangente hyperbolique (tanh)**

Cette fonction, représentée par $f(x)=\tanh(x)$, convertit les valeurs d'entrée en une plage comprise entre -1 et 1. Elle est similaire à la sigmoïde mais centrée autour de zéro, ce qui peut parfois faciliter l'entraînement du réseau.

➤ **Tangente hyperbolique saturante**

Elle est définie comme $f(x)=|\tanh(x)|$, il s'agit d'une variante de la tangente hyperbolique où toutes les sorties sont positives, généralement dans la plage de 0 à 1. Elle peut être utile dans des scénarios spécifiques où seules des activations positives sont souhaitées.

➤ **Fonction sigmoïde** : La fonction sigmoïde, souvent exprimée comme

$$f(x)=\frac{1}{1+e^{-x}}$$

➤ Comprime les valeurs d'entrée dans une plage entre 0 et 1. Historiquement populaire, elle est utilisée pour introduire de la non-linéarité et peut être interprétée comme une probabilité.

Souvent, la correction **Relu** est **préférable**, principalement parce qu'elle offre des bénéfices significatifs pour l'entraînement :

- **Efficacité des calculs** : Elle est peu coûteuse à évaluer, ce qui réduit considérablement le temps d'entraînement du modèle.
- **Rapidité de convergence** : Sa linéarité évite les problèmes de "saturation" de la pente pour les grandes valeurs, permettant au réseau de converger plus vite.

Elle **renforce les propriétés non linéaires** du processus de décision et de l'intégralité du réseau, **sans perturber les champs récepteurs** de la couche de convolution [47]

3.4.4 Couche Flatten :

La **couche Flatten** est un élément crucial des réseaux de neurones convolutifs (CNN). Elle a pour mission de convertir les sorties multidimensionnelles (comme celles des couches de convolution ou de pooling) en un **vecteur unidimensionnel**.

Cette transformation est indispensable car les couches entièrement connectées (denses), qui suivent généralement les couches de convolution, exigent des entrées sous forme de vecteurs plats.

CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR L'ANALYSE DES OBJETS

Par exemple, une sortie de dimensions (2,2,2) sera transformée en un seul vecteur de taille 8 (soit $2 \times 2 \times 2$) (Fig3.17). Cette opération permet de conserver toutes les informations extraites par les couches précédentes tout en les rendant compatibles avec les couches finales de classification ou de régression [53].

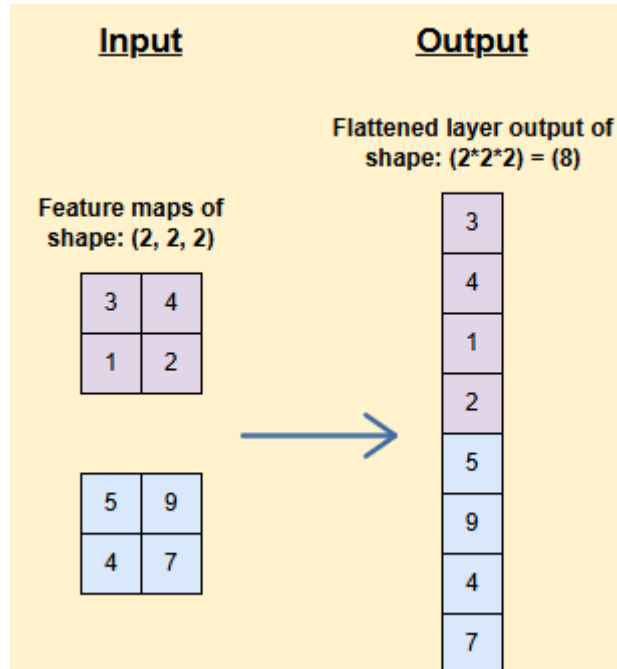


Figure 3.17 : Fonctionnement de la Couche Flatten

3.4.5 Couche Entièrement Connectée (Fully Connected FC)

Les couches entièrement connectées (souvent appelées "FC" pour *fully-connected*) se trouvent à la fin de l'architecture d'un CNN. Elles sont, comme leur nom l'indique, connectées à tous les neurones de la couche précédente (Fig3.18).

Après avoir reçu un vecteur en entrée, une couche FC applique une **combinaison linéaire** suivie d'une **fonction d'activation**. Son objectif final est de **classifier l'image d'entrée** (Fig3.18).

En sortie, elle produit un **vecteur de taille d** , où d correspond au nombre de classes. Chaque composante de ce vecteur représente la probabilité que l'image d'entrée appartienne à une classe spécifique [48].

CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR L'ANALYSE DES OBJETS

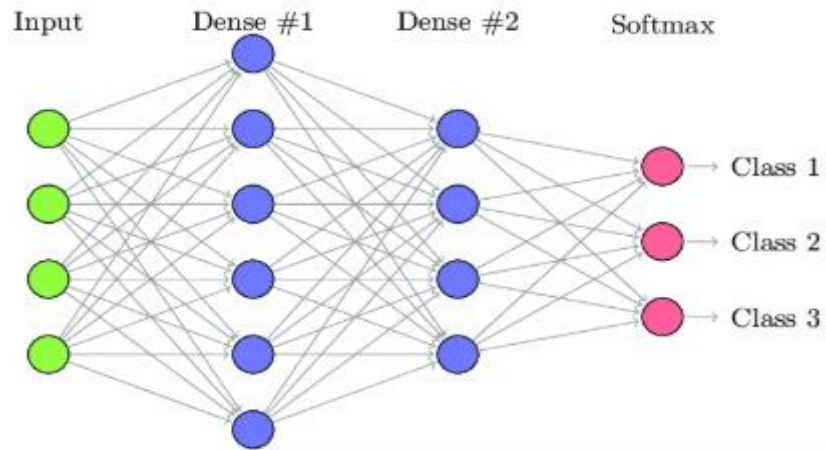


Figure 3.18: Couche entièrement connectée « fully connected »

La figure 3.20, illustre le processus de fonctionnement de la couche FC, dans le cas d'une sortie à deux classes.

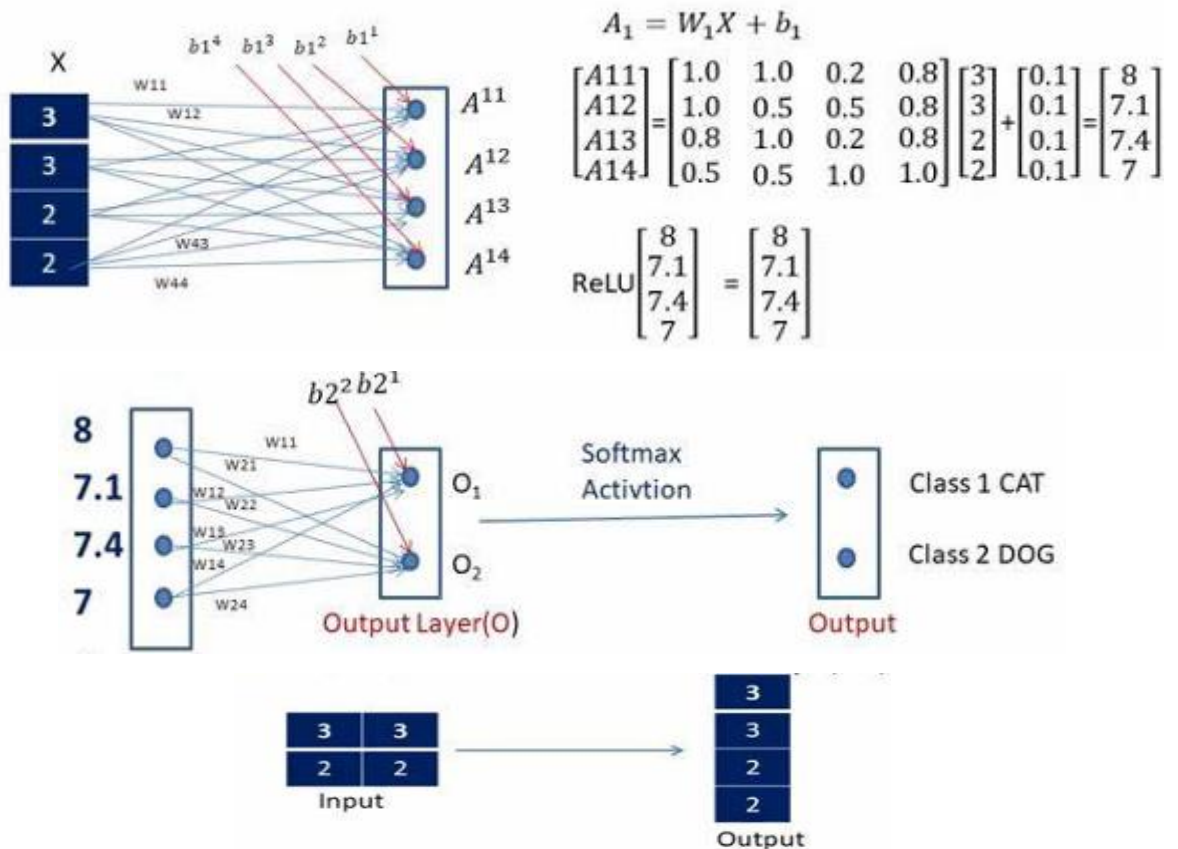


Figure 3.19 : Illustration du fonctionnement de la couche fully connected

CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR L'ANALYSE DES OBJETS

- **Principe de fonctionnement :**

Pour comprendre le processus de classification, il est essentiel d'examiner les **ponds** attribués à chaque connexion (synapse) menant aux différentes classes. C'est en analysant ces poids que nous pouvons identifier les **caractéristiques les plus pertinentes** pour chaque catégorie.

Voici comment les **couches entièrement connectées (FC)** opèrent concrètement :

- Un neurone situé dans la couche FC **détecte une caractéristique spécifique**, comme un nez par exemple.
- Il **enregistre la "force"** de cette détection.
- Ensuite, il **communique cette valeur** aux classes concernées, telles que "chien" et "chat".
- Chacune de ces classes **évalue la pertinence** de cette caractéristique par rapport à sa propre définition.

Par exemple, si le poids de la connexion entre le neurone détectant un "nez" et la classe "chien" est élevé (disons 1,0), cela signifie que le réseau est très confiant que la caractéristique identifiée correspond bien au nez d'un chien (Fig3.20).




Figure 3.20 : Exemple d'une prédiction à travers les couches (dense)

La couche de sortie d'un réseau de neurones utilise souvent la fonction d'activation **Softmax** afin de transformer les scores bruts (logits) issus de la dernière couche entièrement connectée, en **probabilités normalisées**.

CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR L'ANALYSE DES OBJETS

Cette fonction convertit un vecteur de valeurs réelles en un vecteur dont les composantes sont **comprises entre 0 et 1 et dont la somme est égale à 1**, ce qui permet d'interpréter ces valeurs comme des probabilités d'appartenance à chaque classe (Fig3.20).

Ainsi, grâce à l'utilisation de **Softmax** en sortie, le modèle peut attribuer une **probabilité de classification** à chaque classe cible, tout en garantissant que la somme totale des probabilités reste égale à 1.

3.5. Fonctions utilisées dans les réseaux CNN

3.5.1. Fonction de Perte/ Coût (LOSS)

La **fonction de perte** (ou loss function en anglais) est un élément fondamental de l'apprentissage automatique, en particulier dans les réseaux de neurones.

Elle permet de **mesurer l'écart** entre la **prédiction du modèle** et la **valeur réelle** durant et après un entraînement [51]

En d'autres termes, elle quantifie **l'erreur du modèle** : plus la valeur de la perte est élevée, plus la prédiction du modèle est éloignée de la réalité. L'objectif de l'apprentissage est donc de **minimiser cette perte** grâce à l'optimisation (comme la descente de gradient). La fonction de perte qui est couramment utilisée est l'erreur quadratique moyenne :

$$EQM = \left(\frac{1}{n}\right) \sum_{t=1}^n e^2$$

Avec : **n** le nombre de classes, **e** la différence entre la valeur vérité terrain et le résultat prédit

Supposons un problème de classification avec **trois classes**. Si une image appartient à la **classe 3**, sa vérité terrain (ou *ground truth*) est représentée par le vecteur **0,0,1**, imaginons que le réseau de neurones produise la prédiction suivante : **0.1,0.3,0.60**. L'**erreur quadratique moyenne (EQM / MSE)** peut alors être calculée comme suit :

$$EQM = \frac{(0.1-0)^2+(0.3-0)^2+(0.6-0)^2}{3} = \frac{0.001+0.09+0.16}{3} = 0.0867$$

Cela permet de quantifier l'**erreur moyenne au carré** entre les **prédictions** et les **valeurs attendues**, ce qui aide à évaluer la performance du modèle.

3.5.2. Surapprentissage (Overfitting) :

Les réseaux de neurones profonds comportent généralement des dizaines de milliers, voire des millions de paramètres. Cette abondance de paramètres confère au réseau une grande flexibilité, lui permettant de s'adapter à une large variété de jeux de données complexes. Cependant, cette même flexibilité expose le modèle au risque de surapprentissage.

Le surapprentissage se produit lorsque le modèle excelle à classer et prédire les données présentes dans l'ensemble d'entraînement, mais peine à généraliser sur des données nouvelles, non vues auparavant. En d'autres termes, le modèle est trop spécifiquement ajusté aux particularités des données d'entraînement.

Dans cette section, nous allons présenter plusieurs techniques efficaces pour limiter ce phénomène de surapprentissage.

- **Augmentation des données (data augmentation)**

L'une des principales causes du **surapprentissage** est le manque de données d'entraînement. Pour y remédier, une technique très efficace consiste à recourir à l'**augmentation des données**. Ce processus consiste à générer artificiellement de nouvelles images à partir de celles que l'on possède déjà, en y apportant de légères modifications.

Ces modifications mineures peuvent inclure des **retournements** (flips), des **translations** ou des **rotations** (Fig3.21). En enrichissant ainsi le jeu de données existant, on offre au réseau de neurones une plus grande diversité d'exemples, ce qui l'aide à mieux généraliser et à moins surapprendre les spécificités d'un ensemble limité de données [54].




Figure 3.21 : Opération d'augmentation de données

Les réseaux de neurones convolutionnels (CNN) sont largement utilisés en traitement d'images pour leur capacité à reconnaître des objets malgré des variations telles que la position, la taille ou l'éclairage. Cette propriété, appelée **invariance**, permet au modèle de rester performant face à des modifications visuelles. Pour développer cette robustesse, on utilise l'**augmentation des données**, qui consiste à générer des versions modifiées des images d'entraînement, améliorant ainsi la généralisation du modèle et limitant le surapprentissage.

- **Dropout**

Le **dropout** est une technique très efficace pour lutter contre le **surapprentissage** (ou *overfitting*) dans les réseaux de neurones.

Son fonctionnement est assez simple : pendant l'entraînement du modèle, à **chaque étape, chaque neurone** du réseau (sauf ceux de la couche de sortie) a une **probabilité P d'être désactivé temporairement**. Cela signifie que ce neurone sera **ignoré complètement** pour cette étape : il ne fera ni de calcul ni de transmission d'information. Cependant, il pourra à nouveau fonctionner normalement à l'étape suivante.

Autrement dit, le réseau est **légèrement modifié à chaque itération** pendant l'apprentissage. Cela empêche les neurones de trop "s'habituer" à travailler ensemble et force le modèle à apprendre des représentations plus **générales et robustes**, ce qui réduit le risque de surapprentissage.

La figure 3.22 illustre probablement comment certains neurones sont "éteints" de manière aléatoire à chaque cycle d'entraînement [55].




Figure 3.22 : Régularisation par Dropout

L'hyperparamètre **P**, appelé **taux de dropout**, correspond à la probabilité pour qu'un neurone soit désactivé lors d'une étape d'entraînement. Ce taux est généralement fixé à **50 %**. Une fois l'entraînement terminé, tous les neurones restent activés lors de l'inférence (prédiction).

Pour bien saisir la puissance du **dropout**, il est important de comprendre que chaque étape d'entraînement produit en réalité une **architecture de réseau légèrement différente**, du fait de la désactivation aléatoire de certains neurones. Étant donné que chaque neurone peut être soit actif soit désactivé, il existe (2^N) **configurations possibles** (où N représente le nombre total de neurones susceptibles d'être désactivés). Ce nombre est si élevé qu'il devient pratiquement impossible de générer deux fois exactement le même réseau au cours de l'entraînement.

Ainsi, après **10 000 itérations**, on peut considérer que l'on a entraîné **10 000 versions différentes du réseau**, chacune sur une instance légèrement modifiée. Bien que ces réseaux partagent une grande partie de leurs poids, ils sont néanmoins distincts. Le modèle final peut alors être vu comme une **moyenne ou une combinaison de ces multiples réseaux**, ce qui renforce sa capacité de généralisation et réduit le risque de surapprentissage.

3.5.3 Descente du gradient (Vanishing gradient) :

La descente de gradient est une méthode utilisée pour **entraîner les réseaux de neurones**. Elle consiste à ajuster les poids du réseau en **minimisant une fonction de perte**, grâce à des petites mises à jour faites en suivant la pente (le **gradient**) de cette fonction (Fig3.23)




Figure 3.23 : Descente du gradient

Cependant, lorsque le réseau comporte un grand nombre de couches, un problème peut apparaître : **le gradient devient de plus en plus petit au fur et à mesure qu'il est propagé vers les premières couches**. Ce phénomène est appelé «**vanishing gradient**», ou **disparition du gradient**.

Concrètement, cela signifie que les **poils des premières couches** ne sont **presque plus mis à jour** durant l'apprentissage, car les signaux (les gradients) qui leur parviennent sont **trop faibles**. Il en résulte que ces couches n'apprennent pas efficacement, ce qui nuit à la performance globale du réseau [56].

Ce problème est particulièrement fréquent avec certaines **fonctions d'activation** comme **sigmoïde** ou **tanh**, qui «**écrasent**» les valeurs extrêmes et produisent de petites dérivées, amplifiant ainsi la disparition du gradient.

Les solutions que l'on peut apporter à la disparition du gradient sont :

1. **Utiliser des fonctions d'activation adaptées**, comme **ReLU** au lieu de sigmoid ou tanh.
2. **Initialisation des poids intelligents**, comme l'initialisation de *Xavier*.
3. **Utiliser des architectures comme les réseaux résiduels (ResNet)** qui permettent de faire passer l'information plus efficacement.
4. Faire une normalisation par (**Batch Normalization**), qui stabilise les distributions des activations à chaque couche.

3.6. Analyse des architectures CNN appliquées en traitement d'images

Tout d'abord, il est important de noter que les réseaux de neurones convolutifs (CNN) suivent généralement une architecture standard, (Fig3.24). Cette architecture commence par une **image en entrée**, suivie d'une **succession de couches convolutives (CONV)** et de **couches de sous-échantillonnage (POOL)**, généralement associées à la **fonction d'activation ReLU**. Enfin, le réseau se termine par une ou plusieurs **couches entièrement connectées (Fully Connected)**, qui permettent de prédire les **classes des images** lors de la phase de sortie.

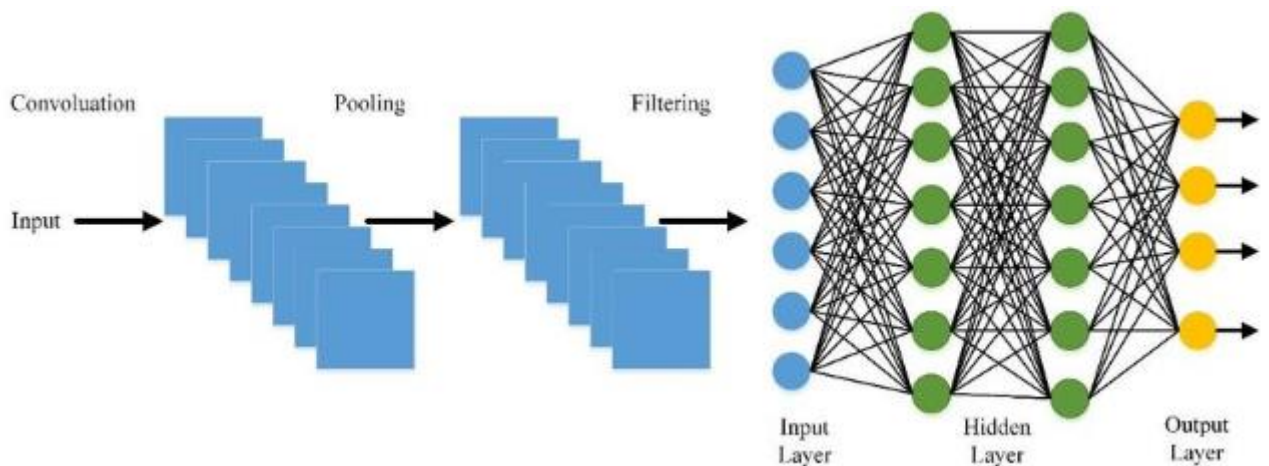


Figure 3.24 : Architecture standard d'un réseau CNN

Dans cette section, nous allons analyser les architectures CNN connus qui existent, en nous basant sur les concepts abordés dans la section précédente. Mais avant tout il est essentiel de bien comprendre les différentes tâches que peut accomplir un modèle d'apprentissage profond. Parmi les plus courantes, on retrouve la **classification**, la **détection** et la **segmentation**.

CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR L'ANALYSE DES OBJETS

Ces tâches, bien qu'elles partagent un objectif commun qui consiste à analyser le contenu d'une image – diffèrent par leur niveau de précision et leur finalité. Par exemple, classer une image revient à répondre à la question "Qu'est-ce que cette image représente ?", tandis que détecter consiste à dire "Où se trouve cet objet dans l'image ?", et segmenter va encore plus loin en précisant "Quelle est la forme exacte de cet objet ?".

Pour mieux illustrer ces différences et comprendre leur utilité dans l'analyse des images médicales, en particulier pour le **diagnostic du cancer du sein**, il est important de les étudier séparément tout en soulignant leurs complémentarités . Ces différences seront présentées de manière synthétique dans le tableau 3.2 qui suit.

Critères	Classification	Détection	Segmentation
Définition	Prédire une étiquette pour l'image entière.	Localiser et identifier les objets d'intérêt via des boîtes englobantes.	Identifier précisément les régions d'intérêt pixel par pixel.
Type de sortie	Une seule classe (label).	Donner les coordonnées des boîtes + classe pour chaque objet.	Fournir le masque d'image où chaque pixel est classé.
Précision spatiale	Faible	Moyenne	Très élevée
Complexité	Faible à modérée	Moyenne à élevée	Élevée
Exemple (cancer du sein)	Prédire si la tumeur est bénigne ou maligne.	Détecter une lésion suspecte et l'entourer dans une mammographie.	Segmenter précisément la tumeur dans une image histologique ou échographique.
Utilité en imagerie médicale	Première étape pour le diagnostic automatique.	Aide à repérer et classer les anomalies visibles.	Permet une analyse fine des tissus affectés (forme, surface, marges, etc.).

Tableau 3.2 : Résumé des tâches CNN appliquées à l'analyse d'images médicales

CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR L'ANALYSE DES OBJETS

- **Architectures CNN : caractéristiques, fonctions et applications :**

Avec l'évolution rapide du deep learning, de nombreuses architectures de réseaux de neurones convolutionnels (CNN) ont été développées pour répondre à des besoins variés en vision par ordinateur. Chaque architecture possède ses propres spécificités en termes de profondeur, de types de couches, de stratégie d'apprentissage ou de performance.

Dans le contexte de l'imagerie médicale, notamment pour le diagnostic du cancer du sein, à partir d'images histologiques ou échographiques, le choix de l'architecture CNN est un facteur déterminant. Certaines architectures sont mieux adaptées à la classification, d'autres à la segmentation ou à la détection des régions suspectes.[58]

Le tableau 3.3 présente un résumé comparatif des architectures CNN les plus connues, en indiquant leurs caractéristiques principales, ainsi que quelques exemples d'application dans le domaine médical (cancer du sein)

**CHAPITRE III : METHODES D'APPRENTISSAGE E PROFONDEUR POUR
L'ANALYSE DES OBJETS**

di	Définition courte	Utilisation typique	Exemple en imagerie du cancer du sein
AlexNet	Réseau CNN profond avec 5 couches convolutives et 3 couches entièrement connectées, introduit en 2012	Classification	Classification des tumeurs bénignes vs malignes à partir d'images histologiques.
VGG16/ VGG19	Réseaux profonds avec uniquement des petites convolutions (3x3), très utilisés pour l'extraction de caractéristiques.	Classification	Utilisé pour classifier des images échographiques ou histologiques ; souvent affinés(Fine-tuning) sur des jeux de données de mammographie.
ResNet	Réseau à connexions résiduelles (skip connections), très profond, évitant le problème du vanishing de la disparition du gradient.	Classification / Détection	Résultats excellents en classification de masses mammaires ; utilisé pour détecter des anomalies dans des échographies.
U-Net	Architecture en forme de U, conçue pour la segmentation d'images médicales, avec des connexions entre les couches d'encodage et de décodage.	Segmentation	Très utilisé pour segmenter des tumeurs dans des images histopathologiques ou IRM mammaires.
DenseNet	Chaque couche est connectée à toutes les couches précédentes, favorisant la réutilisation des caractéristiques.	Classification, segmentation	Bons résultats sur petits jeux de données médicales ; employé pour la segmentation fine de zones tumorales.
MobileNet	Architecture légère optimisée pour les appareils mobiles ou embarqués.	Classification	Utilisé dans des applications mobiles pour prédire le type de lésion mammaire à partir d'images
EfficientNet	développée par Google en 2019, conçue pour offrir une excellente précision tout en restant légère et efficace en calcul . Elle se distingue par une méthode innovante appelée Compound Scaling , qui ajuste simultanément la profondeur (nombre de couches), la largeur (nombre de filtres) et la résolution d'entrée des images. Cette approche permet d'optimiser les performances sans augmenter excessivement la complexité du modèle. Il existe plusieurs versions, de EfficientNetB0 (le plus petit) à EfficientNetB7 (le plus grand et le plus performant)	Classification \ détection\ segmentation	Détection et classification des masses mammaires sur mammographies ou échographies pour différencier lésions bénignes et malignes, segmentation des zones suspectes

Tableau 3.3 : Tableau comparatif des principales architectures CNN

3.7. Conclusion

Maintenant que ce chapitre est achevé, récapitulons brièvement les notions essentielles que nous avons abordées concernant les réseaux de neurones convolutionnels (CNN). Les points suivants résument les étapes clés du processus de construction et d'optimisation d'un réseau CNN tel que présenté précédemment :

- Le processus débute par l'entrée d'une image.
- Des filtres sont appliqués à cette image pour générer des cartes de caractéristiques (*feature maps*), qui extraient les informations visuelles les plus importantes.
- La fonction d'activation ReLU est ensuite appliquée pour introduire de la non-linéarité et accélérer l'apprentissage.
- Vient ensuite la phase de *pooling*, qui a pour but de réduire la dimension des données, de conserver les caractéristiques les plus pertinentes et de limiter le nombre de paramètres à apprendre.
- À l'issue du *pooling*, les cartes de caractéristiques sont aplaties (*flattening*) et transmises aux couches entièrement connectées (*fully connected layers*) pour finaliser la prédiction ou la classification.

Tout au long de ce flux, les éléments constitutifs du réseau, tels que les poids et les cartes de caractéristiques,

sont ajustés de manière itérative pour améliorer les performances du modèle. L'objectif final est d'obtenir un réseau capable de reconnaître et de classer des objets ou des images avec une précision optimale.

À présent, nous disposons des fondements théoriques nécessaires pour aborder les applications concrètes des CNN, notamment dans le domaine de l'imagerie médicale.

CHAPITRE 4

Architectures proposées

4.1 Introduction

Pour l'**analyse des images**, les réseaux de neurones convolutionnels (CNN) sont les plus utilisés en raison de leur grande efficacité. Contrairement aux méthodes classiques, où l'image passe par plusieurs étapes — prétraitement, segmentation, extraction manuelle des caractéristiques, puis classification — les CNN simplifient considérablement ce processus. Ils réduisent ce cheminement à deux phases principales : l'extraction automatique des caractéristiques via des filtres convolutifs, puis la classification de l'image. Ces deux étapes sont entièrement automatisées, ce qui représente un gain de temps et de précision.

Dans notre projet, deux modèles CNN ont été développés de manière indépendante :

Un modèle de classification, chargé de déterminer automatiquement le type de tumeur à partir des images d'entrée.

Un modèle de segmentation, dédié à l'identification précise de la zone tumorale sur les images médicales.

Cette séparation des tâches permet d'optimiser les performances de chaque modèle selon son objectif spécifique, tout en garantissant une approche complète du traitement des images du cancer du sein.

4.2 Choix de l'architecture

L'un des principaux défis dans l'utilisation des réseaux de neurones convolutionnels (CNN) réside dans le choix d'une architecture adaptée à la base de données, afin d'atteindre un taux de précision élevé en sortie. Ce processus implique une sélection rigoureuse des hyperparamètres qui définissent la structure du réseau, notamment :

- Le nombre et la taille des couches de convolution, ainsi que les paramètres associés comme le **stride** (pas de convolution) et le **padding** (remplissage par zéro) ;
- La taille des couches de **pooling** ;
- Le nombre de couches entièrement connectées (**fully connected**) et de neurones par couche ;
- Le taux de **dropout** appliqué pour éviter le surapprentissage, et le choix de la fonction d'activation (ReLU, Softmax, etc.).

Information complémentaire : Il est important de noter que la taille de la base de données d'images joue un rôle crucial dans l'entraînement du réseau. En effet, plus le nombre d'images est élevé, meilleures seront les performances obtenues après l'apprentissage, notamment la précision. Dans le cas où la base de données contient un nombre limité d'images, il devient nécessaire d'utiliser des techniques d'augmentation de données pour augmenter artificiellement le nombre d'images présentées en entrée du réseau. Ce procédé a été détaillé dans le chapitre précédent.

Tous les paramètres mentionnés requièrent une bonne connaissance des réseaux de neurones convolutifs (CNN) afin, de pouvoir les appliquer correctement et choisir leurs valeurs de manière à optimiser la précision finale du réseau entraîné. Il est rare d'atteindre la précision maximale dès le premier entraînement, d'où l'importance d'ajuster ces paramètres au fur et à mesure. C'est cette capacité à modifier et affiner les paramètres qui différencie une architecture d'une autre.

4.3 Architectures proposées

Dans ce chapitre, nous présentons en détail les différentes architectures de réseaux de neurones que nous avons utilisées pour nos tâches d'analyse d'images médicales. Nous aborderons tout d'abord les modèles dédiés à la classification, conçus pour distinguer les images selon leurs caractéristiques spécifiques. Ensuite, nous décrirons l'architecture de segmentation, qui permettent de localiser précisément les régions d'intérêt au sein des images.

Chaque modèle est adapté aux particularités des données sur lesquelles il est entraîné, qu'il s'agisse d'images échographiques mammaires ou d'images histologiques. Cette diversité d'architectures vise à exploiter au mieux les informations contenues dans chaque type de données, en tenant compte des exigences propres à chaque tâche.

4.3.1 Présentation des bases de données utilisées

Dans cette étude, nous avons utilisé deux jeux de données : les images échographiques et les images histologiques.

- **Description du jeu de données échographiques**

Nous avons utilisé des données échographiques pour la classification, et des données pour la segmentation.

- **Données échographiques pour la classification binaire**

Le jeu de données intitulé "**Ultrasound Breast Images for Breast Cancer**", disponible sur la plateforme Kaggle, constitue une ressource essentielle pour la recherche sur le dépistage du cancer du sein à partir d'images médicales. Il regroupe un ensemble d'images échographiques mammaires réparties en deux classes principales : **bénigne** et **maligne**. Ce type d'imagerie est largement utilisé dans le diagnostic non invasif des pathologies mammaires, en complément des mammographies (Fig4.1).

Le jeu de données comprend environ **9 248 images** au format **PNG**, avec une résolution standardisée de **224 × 224 pixels**. Les images ont été soumises à des techniques d'**augmentation de données** (notamment des rotations et des ajustements d'intensité) afin d'enrichir la diversité des exemples et améliorer la robustesse des modèles entraînés.

La base de données est structurée selon trois sous-ensembles :

- **Jeu d'entraînement** : 6 311 images
- **Jeu de validation** : 1 353 images
- **Jeu de test** : 1 352 images

Cette organisation permet un entraînement rigoureux des modèles d'apprentissage automatique tout en évitant le surapprentissage. Le jeu de données est couramment utilisé pour la **classification binaire** (lésion bénigne vs. maligne) et convient parfaitement à des architectures de réseaux de neurones convolutionnels telles qu'EfficientNet ou U-Net, notamment dans le cadre d'approches basées sur le **transfert d'apprentissage** [59].




Figure 4.1 : Dataset des images ultrasonores du modèle de classification

➤ **Données échographiques pour la segmentation**

Le jeu de données "**Breast Ultrasound Images Dataset** «, aussi disponible sur Kaggle, constitue une ressource précieuse pour la recherche en détection et classification du cancer du sein à partir d'images échographiques. Il comprend **780 images échographiques** collectées en 2018 auprès de **600 patientes âgées de 25 à 75 ans**.

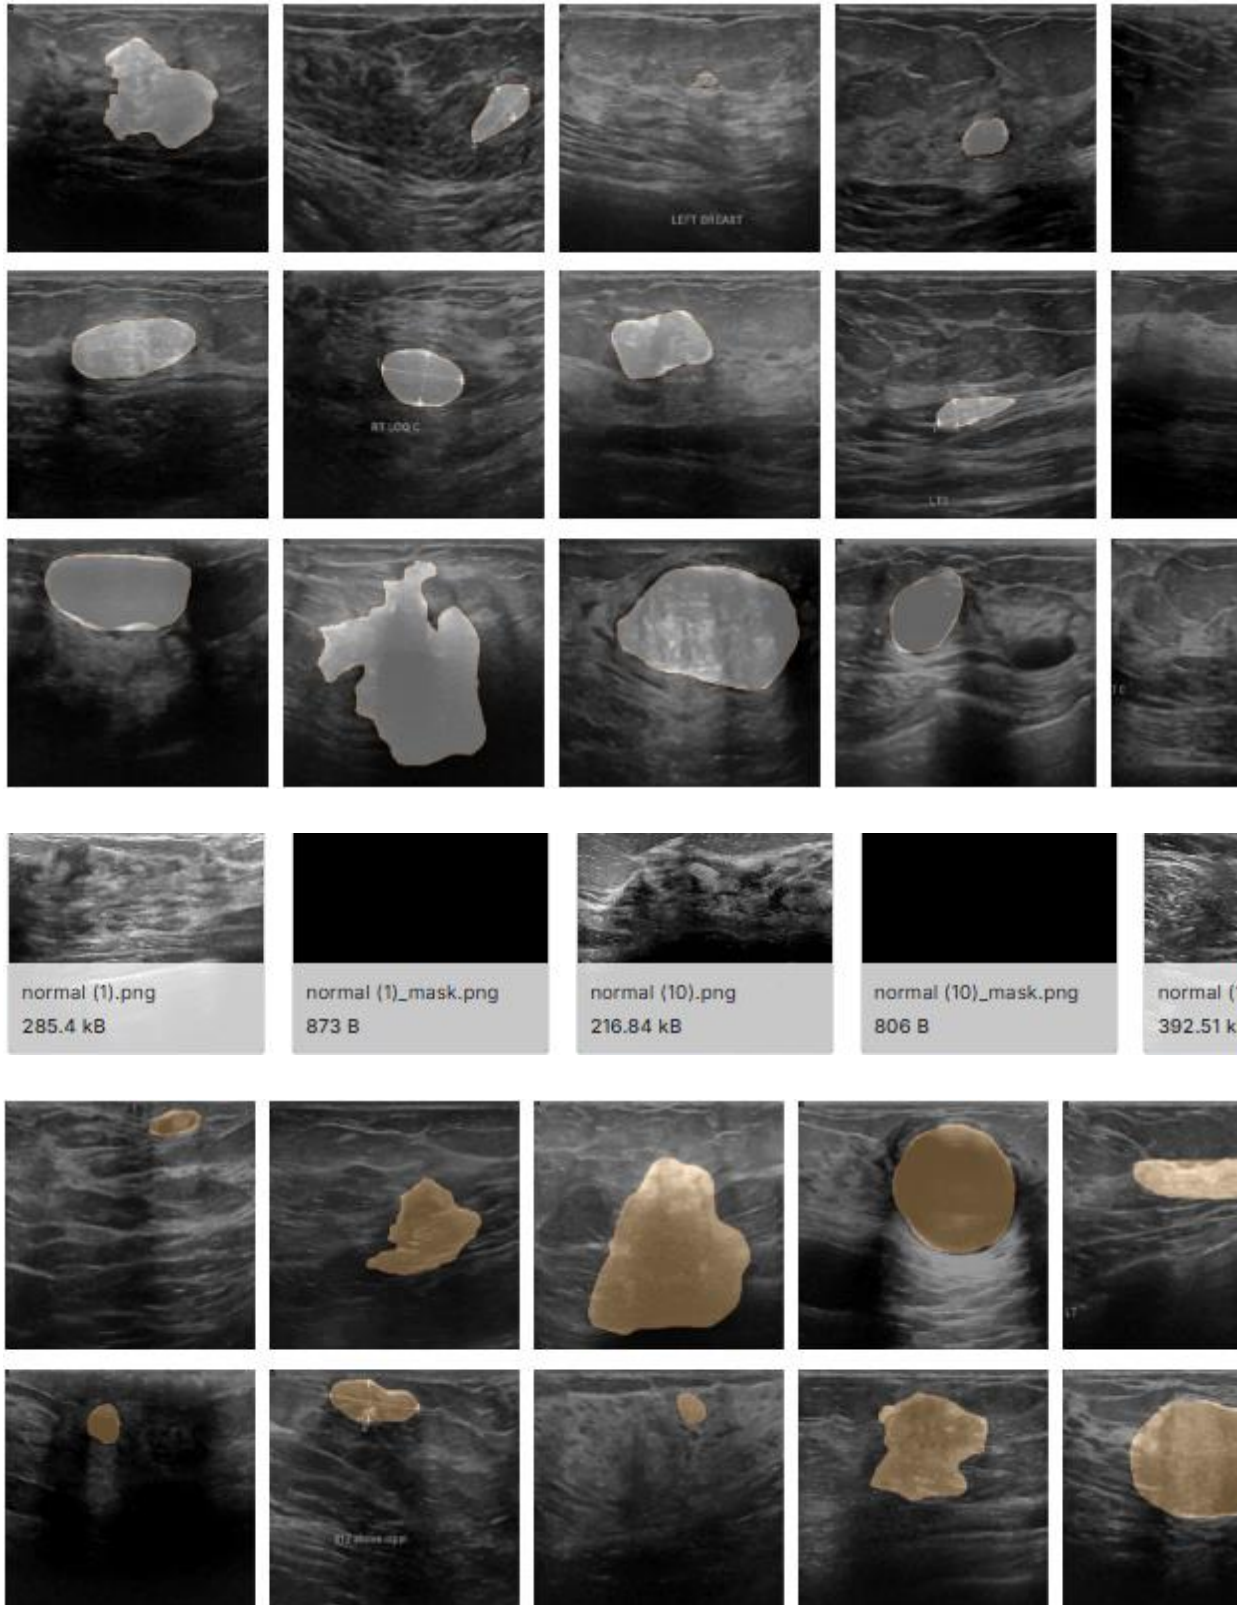
Chaque image, au format **PNG** avec une résolution moyenne de **500 × 500 pixels**, est classée en trois catégories : **normale**, **bénigne** ou **maligne**. Cette classification permet d'entraîner des modèles d'apprentissage profond pour distinguer les tissus sains des lésions tumorales. (Fig 4.2)

Le jeu de données est structuré en trois classes :

- **Normale** : 133 images représentant des tissus mammaires sains.
- **Bénigne** : 487 images montrant des lésions non cancéreuses.
- **Maligne** : 210 images illustrant des tumeurs cancéreuses.

Des techniques d'**augmentation de données** telles que la rotation, le redimensionnement, le zoom et le retournement horizontal, ont été appliquées pour équilibrer les classes, et améliorer la robustesse des modèles. Ce jeu de données est

couramment utilisé pour entraîner des architectures de réseaux de neurones convolutionnels (CNN), comme **ResNet**, **VGG**, **MobileNet** ou **U-Net**, dans des tâches de classification et de segmentation des images échographiques mammaires [60].






Figure 4.2 : Dataset des images ultrasonores avec ses masques réelles du model de segmentation

- **Description du jeu de données histologique**

Le jeu de données "**Histopathologic Cancer Detection**", proposé dans le cadre d'une compétition Kaggle, est une ressource précieuse pour la détection du cancer métastatique à partir d'images histopathologiques. Il est dérivé du benchmark **PatchCamelyon (PCam)**, conçu pour évaluer les performances des modèles d'apprentissage automatique, dans des tâches de classification binaire d'images médicales (Fig4.3).

Caractéristiques du jeu de données

Les images de ce jeu de données ont les caractéristiques suivantes :

- **Nombre total d'images** : 220 025 images couleur de taille **96 × 96 pixels**.
- **Format des images** : TIFF.
- **Annotations** : Chaque image est associée à une étiquette binaire indiquant la présence (1) ou l'absence (0), de tissu tumoral dans la région centrale de **32 × 32 pixels**.

Structure des données :

- **Entraînement** : 165 018 images.
- **Test** : 55 007 images.

Répartition des classes :

- **Images positives** (présence de tissu tumoral) : 89 117 images.
- **Images négatives** (absence de tissu tumoral) : 130 908 images.

Utilisation dans le diagnostic du cancer

Ce jeu de données est largement utilisé pour entraîner et évaluer des modèles d'apprentissage profond, notamment des réseaux de neurones convolutionnels (CNN), dans la tâche de classification binaire, visant à détecter la présence de tissu tumoral dans des images histopathologiques.

Des architectures telles que **ResNet50**, **InceptionNet** et **DenseNet** ont été appliquées avec succès, atteignant des performances élevées en termes de précision et de rappel.

L'utilisation de ce jeu de données permet de développer des systèmes de diagnostic assisté par ordinateur, contribuant ainsi à une détection plus rapide et précise du cancer métastatique dans les tissus lymphatiques [61].




Figure 4.3 : Dataset des images histologiques du cancer du sein

4.3.2 Architecture du modèle 1

Le modèle de classification prend en entrée des images histologiques de taille 96x96x3. Il est structuré en plusieurs blocs de couches, chacun suivi d'une couche de MaxPool et de Dropout (Fig4.4).

- **Bloc de Convolution Initial**

Le premier bloc débute avec trois couches de convolution successives, chacune utilisant 32 filtres de taille 3x3 et une fonction d'activation ReLU. Après ces convolutions, une couche de MaxPool de taille 2x2 réduit la dimensionnalité, suivie d'une couche de Dropout avec un taux de 0.3 pour prévenir le surapprentissage.

La taille de sortie après ce bloc est de (44, 44, 32) du fait que les convolutions réduisent les images de la taille (96x96) à la taille (92x92) et le maxpooling réduit l'image à (44x44).

- **Bloc de Convolution Intermédiaire**

Le deuxième bloc reproduit la même structure : trois couches de convolution avec 64 filtres de taille 3x3 et activation ReLU. Il est également suivi d'une couche de MaxPool de taille 2x2 et d'une couche de Dropout de 0.3 (Fig4.4).

La taille de sortie après ce bloc est de (19, 19, 64). Les convolutions réduisent l'images de la taille (44x44) à la taille (38x38), le maxpooling réduit l'image à (19x19).

- **Bloc de Convolution Final**

Le troisième bloc maintient la séquence avec trois couches de convolution utilisant cette fois 128 filtres de taille 3x3 et activation ReLU. Comme les précédents, il est suivi d'une couche de MaxPool de taille 2x2 et d'une couche de Dropout de 0.3.

La taille de sortie après ce bloc est de (7, 7, 128). Les convolutions réduisent l'images de la taille (19x19) à la taille (13x13), et le maxpooling réduit l'image à (7x 7).

• **Couches Entièrement Connectées (Classification)**

Après les étapes de convolution et de pooling, les données sont aplaties (Flatten()) en un vecteur unidimensionnel. Ce vecteur est ensuite alimenté dans un réseau de neurones entièrement connecté :

- Une première couche Dense de 256 neurones avec une fonction d'activation ReLU, suivie d'une couche de Dropout de 0.3.
- Une dernière couche Dense de 2 neurones avec une fonction d'activation Softmax, permettant la classification en deux classes.

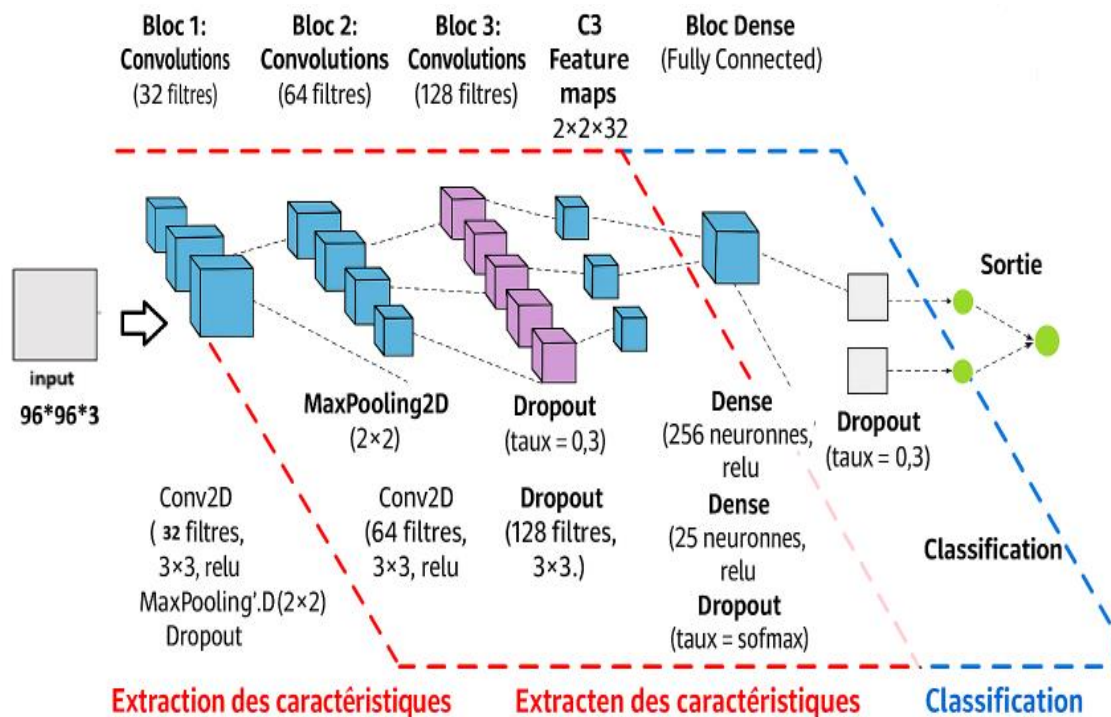


Figure 4.4 : Structure du modèle 1

4.3.3 Architecture du model 2

Le modèle de classification présenté dans la figure suivante repose sur l'architecture **EfficientNetB3**, préentraînée sur le dataset **ImageNet**, utilisée comme extracteur de caractéristiques. L'image ultrasonore en entrée est de taille **224×224×3**. Elle est d'abord traitée par le modèle EfficientNetB3 sans sa couche de classification finale, ce qui permet de conserver uniquement les couches de convolution apprises sur ImageNet. Ces couches sont **gelées** afin de ne pas modifier les poids lors de l'entraînement. (Fig4.5)

À la sortie de ce bloc d'extraction, une couche de **GlobalAveragePooling2D** est utilisée pour transformer les cartes de caractéristiques en un vecteur unidimensionnel. Avant cette étape, une couche de **bruit gaussien (GaussianNoise)** est ajoutée afin d'introduire une régularisation supplémentaire et éviter le surapprentissage.

Le vecteur obtenu est ensuite envoyé vers une **couche entièrement connectée de 256 neurones**, avec la fonction d'activation **ReLU**. Une **normalisation par lot (BatchNormalization)** est appliquée après cette couche pour améliorer la stabilité de l'apprentissage. Un second bruit gaussien ainsi qu'un **Dropout de 25%** sont également appliqués pour renforcer la régularisation du modèle.

Enfin, la sortie du réseau est obtenue à travers une **couche dense composée d'un seul neurone**, avec une **fonction d'activation sigmoïde**, adaptée à une tâche de **classification binaire** (par exemple : bénin ou malin). Ce modèle permet ainsi de tirer profit d'un puissant extracteur de caractéristiques, tout en adaptant la prédiction à un domaine spécifique, via un classifieur léger en tête.

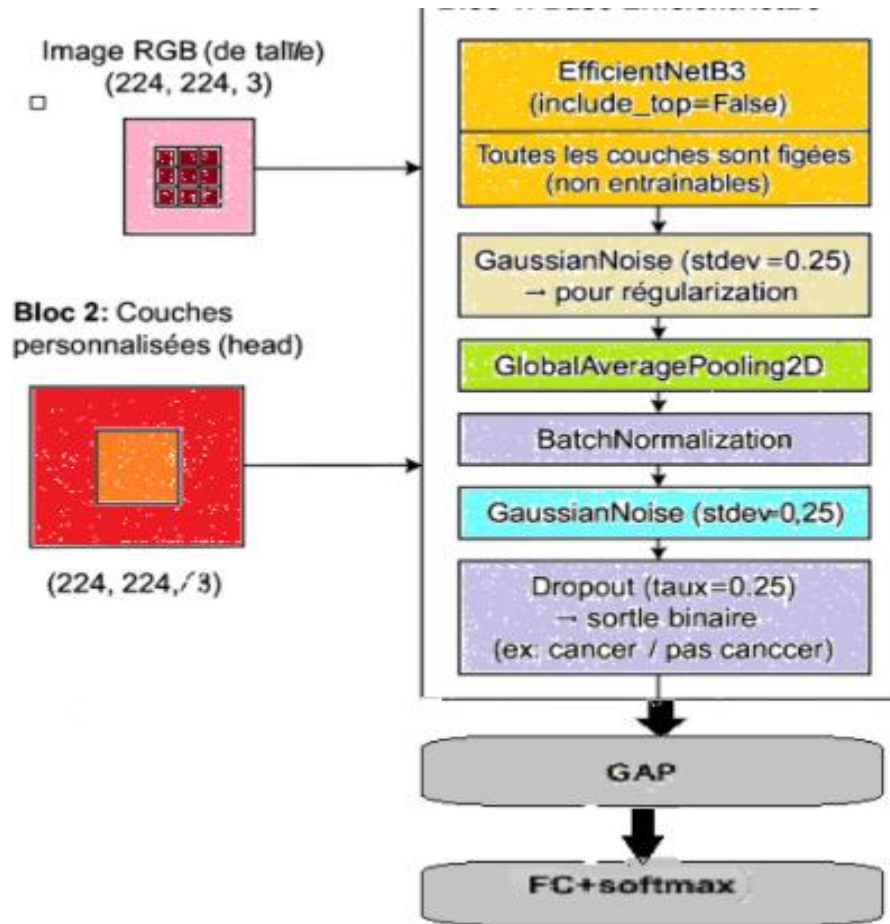


Figure 4.5 : Architecture du modèle CNN basé sur EfficientNetB3

4.3.4 Architecture du modèle 3 :

Le modèle présenté dans la figure 4.6 ci-dessous est un **réseau de type Attention U-Net** conçu pour la **segmentation d'images échographiques du sein**. Il est composé de **4 blocs d'encodage (EncoderBlock)**, d'un **bloc d'encodage profond (bottleneck)**, de **4 blocs de décodage (DecoderBlock)**, et de **modules d'attention (AttentionGate)** insérés entre les connexions d'encodage et de décodage.

L'image en entrée est de taille 256x256x1. Elle est d'abord traitée par le **premier bloc d'encodage**, constitué de deux couches de convolution de taille 3x3, avec 32 filtres, suivies d'une couche de **dropout** et d'un **MaxPooling 2x2**. Ce processus est répété à travers les trois blocs d'encodage, suivants avec un nombre croissant de filtres (64, 128, 256). À chaque niveau, la taille des cartes de caractéristiques est réduite de moitié tandis que leur profondeur augmente, permettant l'extraction progressive de caractéristiques de haut niveau.

Le **bloc d'encodage central** (ou bottleneck) contient également deux couches de convolution avec 512 filtres, mais ne contient pas de MaxPooling, ce qui préserve la résolution minimale avant reconstruction.

La phase de **décodage** consiste à appliquer une **UpSampling2D**, puis à concaténer les cartes de caractéristiques issues de l'encodeur (via skip connections). Ces connexions sont **filtrées par des modules d'attention** qui apprennent à pondérer les informations importantes, améliorant la précision de la segmentation, notamment dans les zones tumorales.

Chaque bloc de décodage applique un EncoderBlock sans pooling, permettant d'affiner progressivement la reconstruction spatiale. Le dernier bloc produit une **carte de segmentation binaire** de même taille que l'entrée, via une couche Conv2D (1) avec une fonction d'activation sigmoïde, qui permet de différencier la tumeur du tissu sain.

Ce modèle permet donc une **segmentation fine et contextuelle** des masses suspectes, tout en réduisant les erreurs, grâce à l'intégration de l'attention.

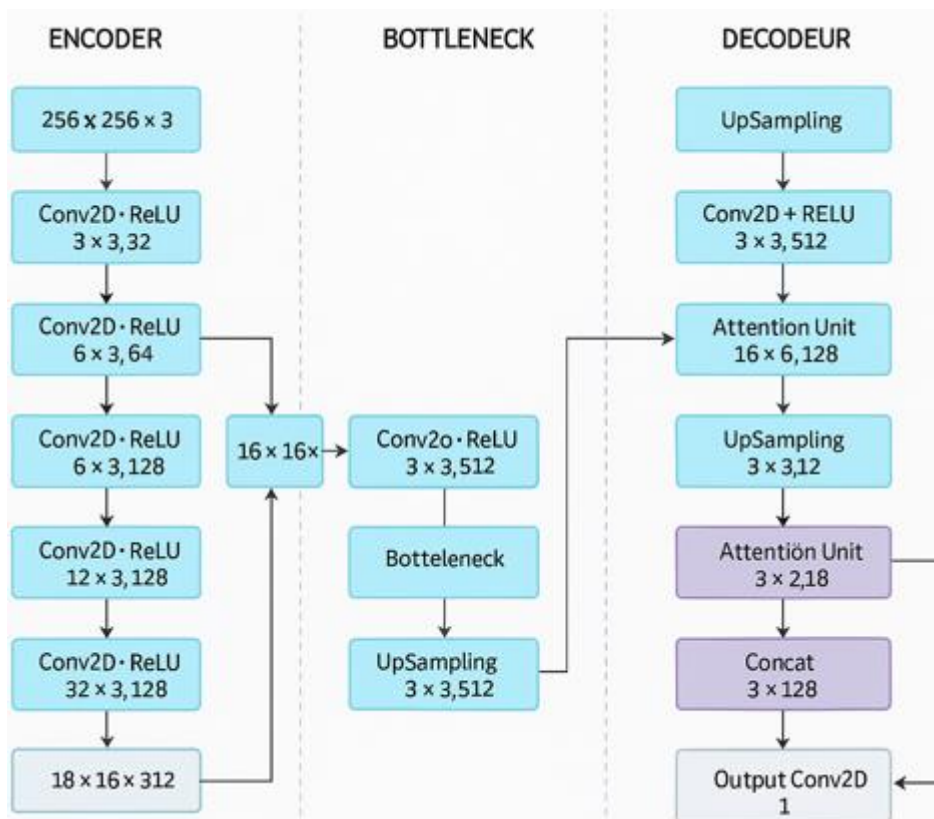


Figure 4.2 : Structure de modèle 3

4.4 Conclusion :

Dans ce chapitre, nous avons mis en œuvre et comparé trois modèles de deep learning appliqués à des tâches de classification et de segmentation, dans le contexte du diagnostic médical assisté par images.

Deux modèles ont été dédiés à la classification et un modèle à la segmentation :

Le premier est un réseau CNN très basique, appliqué à une base de données histologique, permettant de tester les performances d'une architecture simple.

Le second est basé sur EfficientNet B3, un modèle plus avancé, appliqué cette fois à des images ultrasonores, afin d'évaluer l'impact des architectures profondes et optimisées sur la classification d'images complexes. Le troisième modèle, dédié à la segmentation sémantique, a été appliqué également à des images ultrasonores, à travers une architecture de type Attention U-Net, permettant de localiser plus précisément les régions d'intérêt.

Ce chapitre a donc pour objectif principal de poser les bases des expériences à venir, en décrivant les architectures utilisées et les données traitées. L'analyse des performances, les résultats quantitatifs et qualitatifs obtenus, ainsi que leur interprétation, seront développés dans le chapitre suivant.

5. Chapitre

Résultats et discussions

5.1 Introduction

Après avoir exécuté l'ensemble des architectures proposées dans le chapitre précédent, ce chapitre est consacré à l'analyse des résultats obtenus. Nous commencerons par présenter les outils logiciels et les bibliothèques utilisés pour l'implémentation. Ensuite, nous procéderons à la discussion des résultats.

Pour rendre ces modèles facilement accessibles, nous avons conçu une interface utilisateur intuitive. Cette interface propose plusieurs options via des boutons, permettant à l'utilisateur de sélectionner la tâche souhaitée (classification ou segmentation) ainsi que la base de données correspondante (échographie ou histologie). Par exemple, lors d'une classification, l'utilisateur choisit la source de l'image — échographique ou histologique — ce qui dirige vers le modèle adapté.

Cette architecture modulaire confère une grande flexibilité, en intégrant plusieurs approches dans un même outil tout en optimisant les performances selon les spécificités propres à chaque jeu de données.

5.2 Logiciels et bibliothèques de développement

5.2.1 Python



Python est aujourd'hui le langage de programmation open source le plus utilisé dans le domaine de l'intelligence artificielle, en particulier pour le Deep Learning. Il se distingue par la richesse de ses bibliothèques, spécialement conçues pour la vision par ordinateur et l'exploitation des réseaux de neurones. Sa syntaxe simple et ses outils de haut niveau en font un langage axé sur la productivité des développeurs. Dans le cadre de ce projet, Python a été utilisé via une plateforme cloud, ce qui dispense de toute installation locale de logiciel ou d'environnement de développement (IDE) [62].


5.2.2 TensorFlow



C'est une bibliothèque logicielle libre et open source conçue pour le traitement des flux de données et la programmation différentiable, utilisée dans diverses tâches computationnelles. Il s'agit d'une bibliothèque mathématique symbolique largement exploitée dans le domaine de l'apprentissage automatique, en particulier pour la mise en œuvre de réseaux de neurones.

Développée par **Google**, **TensorFlow** est utilisée à la fois pour la recherche et la production. Son nom fait référence à l'utilisation de structures de données multidimensionnelles appelées *tensors* (ou tenseurs), qui constituent le cœur des opérations effectuées dans les réseaux neuronaux. Par exemple, un tenseur à deux dimensions correspond à une matrice. De nombreux produits phares de Google, tels que Gmail, Google Photos ou encore les systèmes de reconnaissance vocale, reposent aujourd'hui sur cette technologie.

5.2.3 Keras



C'est une bibliothèque open source de réseaux de neurones, développée en Python. Elle est compatible avec plusieurs moteurs de calcul tels que TensorFlow, Theano, Microsoft Cognitive Toolkit (CNTK) et PlaidML. Keras a été conçue pour faciliter l'expérimentation rapide de modèles d'apprentissage profond grâce à une interface conviviale, modulaire et extensible.

Cette bibliothèque a vu le jour dans le cadre du projet de recherche ONEIROS (*Open-ended Neuro-Electronic Intelligent Robot Operating System*) et a été initiée par François Chollet, ingénieur chez Google. En 2017, l'équipe TensorFlow a officiellement intégré Keras comme interface de haut niveau dans sa bibliothèque principale. L'objectif de Keras est de fournir un ensemble d'abstractions intuitives et de haut niveau, simplifiant ainsi la création, l'entraînement et le déploiement de modèles de Deep Learning, indépendamment du moteur de calcul sous-jacent.

5.2.4 OpenCV



C'est une bibliothèque open-source largement utilisée en vision par ordinateur. Elle permet de réaliser de nombreuses opérations sur les images et vidéos, telles que la lecture, l'écriture, le traitement (filtrage, détection de contours, etc.) et l'analyse. Dans ce travail,

OpenCV a été utilisée principalement pour **charger et afficher des images** au format .tif lors de l'exploration des données.

5.2.5 Google Colab



Google Colaboratory, ou "Colab», (*figure 5.1*) est un service proposé par Google Research qui permet d'écrire et d'exécuter du code Python directement depuis un navigateur web. Principalement utilisé dans les domaines de l'apprentissage automatique, de l'analyse de données et de l'enseignement, Colab offre un environnement de développement interactif basé sur les notebooks Jupyter.

Ce service ne nécessite aucune configuration locale et fournit un accès gratuit à des ressources matérielles avancées, telles que les GPU, ce qui en fait un outil particulièrement adapté aux projets de Deep Learning. Pour l'utiliser, il suffit de se rendre à l'adresse suivante : <https://colab.research.google.com> et de se connecter à l'aide d'un compte Google.

En plus de sa simplicité d'utilisation, Google Colab offre une grande flexibilité de configuration et automatise de nombreuses tâches pour l'utilisateur. Parmi ses principales fonctionnalités, on peut citer :

- La compatibilité avec Python 2.7 et Python 3.6 ;
- L'accès gratuit à des accélérateurs matériels, notamment des GPU ;
- La disponibilité immédiate des principales bibliothèques Python, telles que TensorFlow, Scikit-learn et bien d'autres, préinstallées dans l'environnement ;
- La prise en charge des commandes Bash directement dans les cellules du notebook.

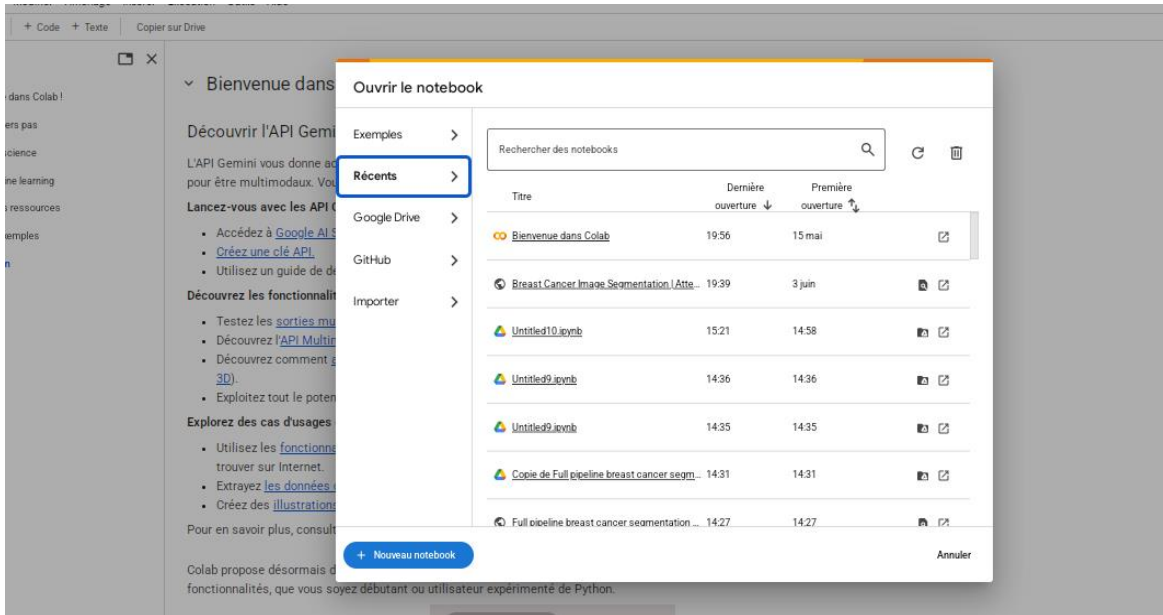


Figure 5.1 : Fenêtre de Google Colab

- **Choix l'accélérateur matériel**

Dans la barre de menu, cliquez sur « **Exécution** » (*Runtime*), puis sélectionnez « **Modifier le type d'exécution** » (*Change runtime type*). Dans la fenêtre qui s'ouvre, définissez l'option « **Accélérateur matériel** » (*Hardware Accelerator*) sur **GPU** ou **TPU** (*Tensor Processing Unit*), selon les besoins du projet. Cette configuration permet d'accélérer considérablement l'exécution des calculs. Les étapes sont illustrées en détail dans les figures ci-après (Fig5.2).

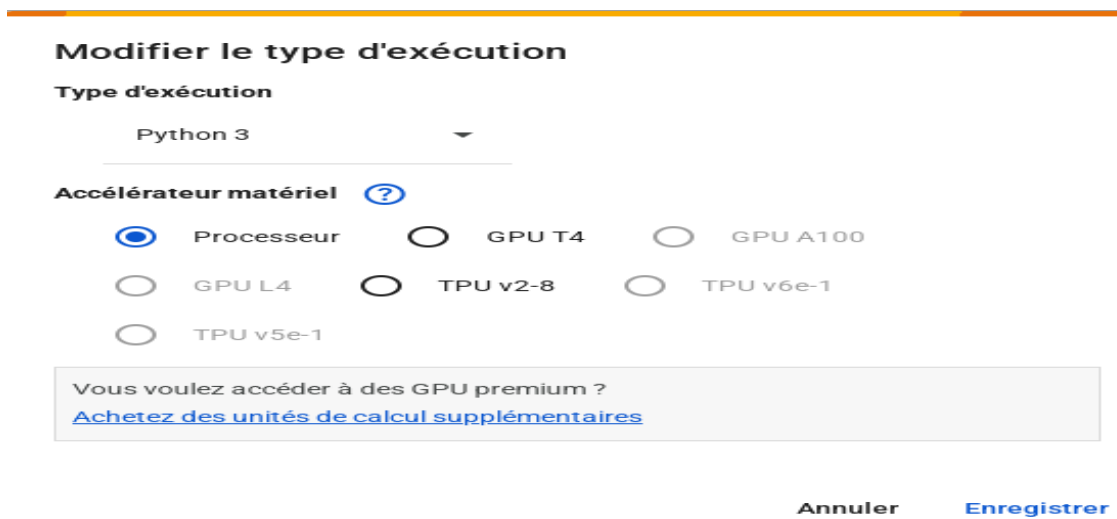


Figure 5.2 : choix l'accélération matériel

- **Importation des bibliothèques Python :**

L'importation des bibliothèques en python se fait grâce à l'instruction import (Fig5.3).

```
import os
import sys
# path manipulation
from pathlib import Path
# regex
import re
# plotting
import matplotlib.pyplot as plt
import matplotlib.image as mpimg
from matplotlib.patches import Circle
# data manipulation / preparation
import numpy as np
import pandas as pd
import h5py
from sklearn.model_selection import train_test_split
from tensorflow.keras.preprocessing.image import ImageDataGenerator
# image manipulation
from PIL import Image
from IPython.display import Image
from sklearn.metrics import confusion_matrix, classification_report
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, Dense, Flatten, MaxPool2D, Dropout
from tensorflow.keras.utils import plot_model
```

Figure 5.3 : Exemple d'importation des bibliothèques utilisées

- **Importer la base de données**

Voir la figure 5.4.

```
] # IMPORTANT: RUN THIS CELL IN ORDER TO IMPORT YOUR KAGGLE DATA SOURCES,
# THEN FEEL FREE TO DELETE THIS CELL.
# NOTE: THIS NOTEBOOK ENVIRONMENT DIFFERS FROM KAGGLE'S PYTHON
# ENVIRONMENT SO THERE MAY BE MISSING LIBRARIES USED BY YOUR
# NOTEBOOK.
import kagglehub
vuppalaadithyasairam_ultrasound_breast_images_for_breast_cancer_path = kagglehub.dataset_download('vuppalaadithyasairam/ultrasound-breast-images-for-breast-cancer')

print('Data source import complete.')
```

Downloading from <https://www.kaggle.com/api/v1/datasets/download/vuppalaadithyasairam/ultrasound-breast-images-for-breast-cancer> 100%|██████████| 564M/564M [00:10<00:00, 54.1MB/s]Extracting files...

Data source import complete.

Figure 5.4 : Importation des bibliothèques utilisées

- **Diviser les données en données d'apprentissage et de tests**

La base de données est divisée en deux classes, une classe pour l'entraînement et une classe pour le test (Fig5.5).

```
train_path= '../input/ultrasound-breast-images-for-breast-cancer/ultrasound breast classification/train'
test_path= '../input/ultrasound-breast-images-for-breast-cancer/ultrasound breast classification/val'
```

Figure 5.5 : Code de Division des données apprentissage/test

- **Augmentation d'images (Data Augmentation)**

L'augmentation des données constitue une stratégie couramment utilisée pour enrichir artificiellement un ensemble d'entraînement à partir de données existantes. Elle vise à introduire des transformations contrôlées telles que des rotations, translations, mises à l'échelle ou inversions, afin de générer des variations pertinentes des images d'origine. Cette démarche permet d'améliorer la robustesse et la capacité de généralisation du modèle, notamment lorsqu'il est confronté à de nouvelles instances appartenant à la même classe que celle observée durant l'entraînement.

Plusieurs techniques d'augmentation sont disponibles ; un aperçu de certaines d'entre elles est présenté dans la figure suivante (Fig5.6).

Dans le cadre de ce travail, l'**augmentation par rotation** a été mise en œuvre de manière automatisée à l'aide de la classe **ImageDataGenerator**, fournie par la bibliothèque **Keras**, dans le contexte d'un apprentissage supervisé, basé sur des réseaux de neurones convolutifs.

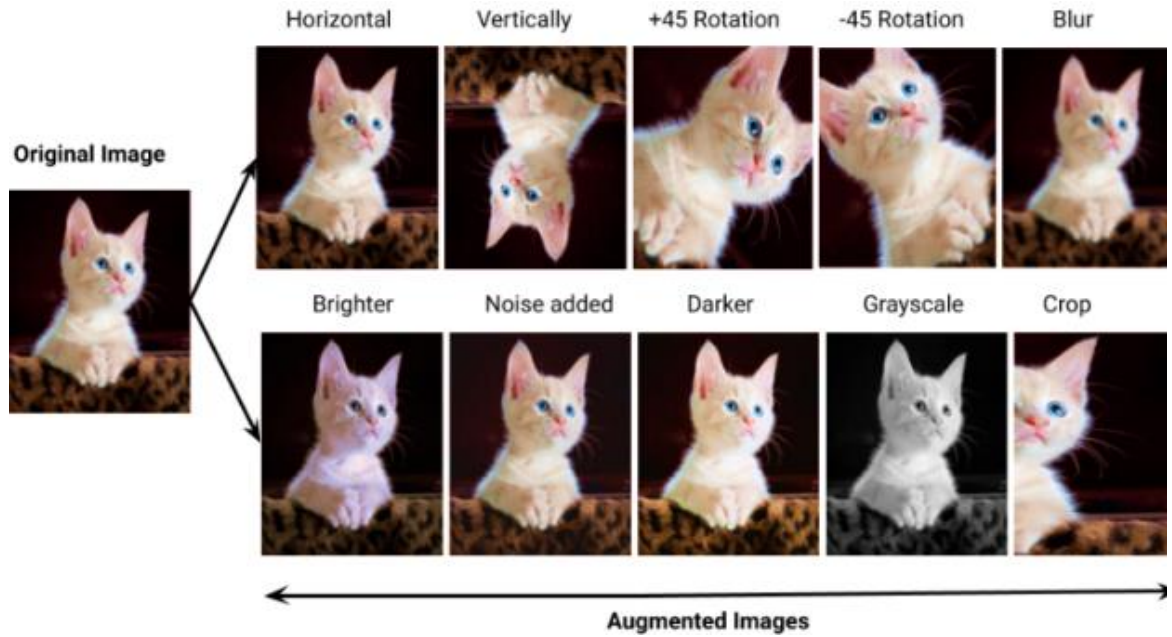


Figure 5.6 : Techniques d’augmentation des données

5.3 Résultats obtenus et discussions :

Après avoir présenté les architectures des différents modèles dans le chapitre précédent, nous allons à présent analyser les résultats obtenus pendant et après la phase d'entraînement, en examinant les graphes des métriques de performance de chaque modèle.

5.3.1 Résultats obtenus pour le 1er Modèle :

Les figures ci-dessous présentent les courbes d'évolution de la précision (*accuracy*) (Fig5.7) et de la perte (*loss*) (Fig5.8) du modèle EfficientNetB3, pour la classification des images histologiques du cancer du sein lors de l'entraînement, sur une durée de 5 époques.

- **Courbes de précision**




Figure 5.7 : Évolution de la précision d'apprentissage et de validation du 1^{er} modèle

La courbe de la précision d'apprentissage (*Training Accuracy*) montre une amélioration continue au fil des époques. Elle débute à environ **83 %**, puis progresse rapidement pour atteindre **88 %** à la troisième époque, et finit à à peu près de **90 %** à la cinquième époque. Cette progression indique que le modèle parvient progressivement à mieux extraire et apprendre les caractéristiques discriminantes des tissus histologiques.

En parallèle, la précision de validation (*Validation Accuracy*) suit une trajectoire similaire. Elle commence à **74 %**, témoignant d'un réseau encore peu entraîné sur des données qu'il n'a jamais vu. Toutefois, cette précision s'améliore sensiblement jusqu'à **près de 90 %** à la fin de l'entraînement. Le fait que la précision de validation atteigne des valeurs proches de la précision d'apprentissage, sans chute significative, montre que le modèle **généralise bien** sur des données inédites, et **ne présente pas de signe évident de sur-apprentissage** (*overfitting*) dans cette phase.

- **Courbes de perte**

Les courbes de perte (*loss*) confirment cette bonne dynamique d'apprentissage. La perte d'entraînement (*Training Loss*) diminue progressivement, passant de **0.41** à **0.25** à la cinquième époque, indiquant que le modèle réduit efficacement l'erreur de prédiction sur les données d'apprentissage.




Figure 5.8 : Évolution de la perte d'apprentissage et de validation du 1^{er} modèle

Quant à la perte de validation (*Validation Loss*), elle suit également une tendance décroissante, chutant de **0.55** à **0.26** à la cinquième époque. L'absence d'augmentation significative dans cette courbe suggère, une fois encore, que le modèle **ne sur-apprend pas** et maintient une bonne capacité de généralisation.

La figure 5.9 présente l'ensemble des valeurs de précision et de perte évoquées précédemment, représentées sous forme de courbes

```

Epoch 1/5
14400/14400 [=====] - 6247s 434ms/step - loss: 0.4136 - accuracy: 0.814
7 - val_loss: 0.5715 - val_accuracy: 0.7412
Epoch 2/5
14400/14400 [=====] - 6273s 436ms/step - loss: 0.3420 - accuracy: 0.851
4 - val_loss: 0.4953 - val_accuracy: 0.7838
Epoch 3/5
14400/14400 [=====] - 6233s 433ms/step - loss: 0.2981 - accuracy: 0.874
5 - val_loss: 0.2963 - val_accuracy: 0.8769
Epoch 4/5
14400/14400 [=====] - 6183s 429ms/step - loss: 0.2718 - accuracy: 0.887
5 - val_loss: 0.2814 - val_accuracy: 0.8874
Epoch 5/5
14400/14400 [=====] - 6146s 427ms/step - loss: 0.2509 - accuracy: 0.897
9 - val_loss: 0.2549 - val_accuracy: 0.8991

```

Figure 5.9 : Valeurs des Précisions et d’Erreur avec le nombre d’époques du 1er modèle

Dans l’ensemble, l’analyse de ces courbes démontre que le modèle offre de bonnes performances de classification sur les images histologiques du cancer du sein. L’entraînement est efficace, avec une montée rapide en précision et une perte en diminution constante sur les données d’apprentissage comme sur les données de validation. Aucun signe clair de sur-apprentissage, n’est observé à ce stade, ce qui traduit une **convergence stable et un apprentissage pertinent**.

5.3.2 Résultats obtenus pour le 2ème Modèle

La figure 5.10 ci-dessous présente les courbes d’évolution des différentes métriques du 2ième modèle, utilisé pour la classification binaire des images échographiques du cancer du sein. Ces métriques incluent la précision (Precision), le rappel (Recall), l’exactitude (Accuracy) ainsi que la fonction de perte (Loss), aussi bien en phase d’apprentissage qu’en phase de validation.

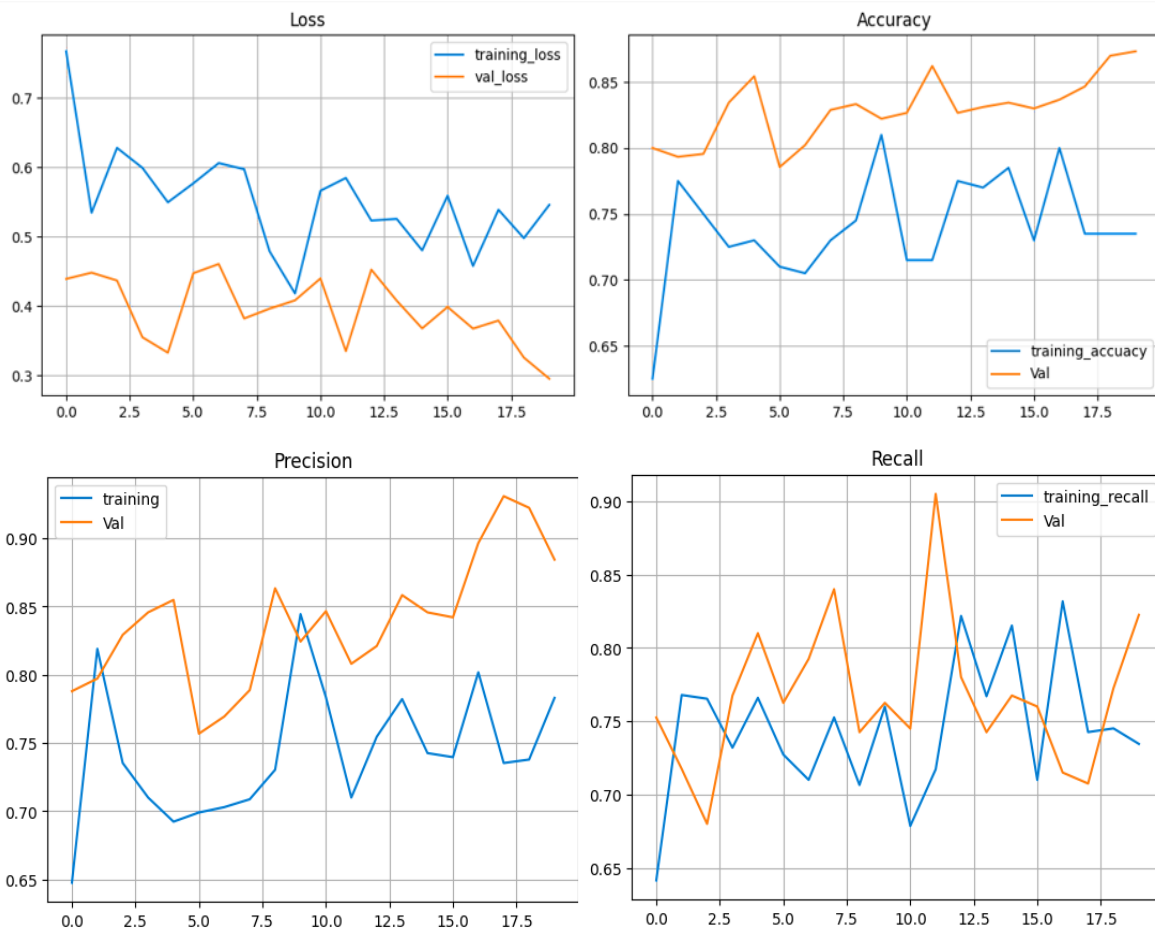


Figure 5.10 : Évolution des métriques de performance au cours de l'entraînement du 2ième Modelé

- **Précision**

L'évolution de la précision en phase d'apprentissage montre une progression notable durant les premiers époques, passant d'environ 65 % à plus de 84 % à la 9^e époque, traduisant une phase active d'apprentissage des caractéristiques discriminantes par le modèle. Cependant, à partir de cette étape, la courbe devient plus instable, ce qui peut indiquer une difficulté à consolider l'apprentissage ou à généraliser sur l'ensemble des données d'entraînement.

La précision en validation, quant à elle, débute à un niveau relativement élevé (environ 78 %), et progresse de manière régulière jusqu'à atteindre plus de 90 %, avant de légèrement chuter vers 89 %. Cette évolution suggère une bonne capacité du modèle à généraliser sur des données non vues. Toutefois, la baisse observée en fin d'entraînement peut être interprétée comme un début de sur-apprentissage (*overfitting*).

- **Rappel**

La courbe du rappel en apprentissage oscille entre 65 % et 83 %, ce qui traduit une variabilité dans la capacité du modèle à identifier correctement les exemples positifs. La courbe de validation, en revanche, présente une amélioration continue, culminant à plus de 91 %, ce qui témoigne d'un bon apprentissage des représentations discriminantes nécessaires à la tâche de classification.

- **Exactitude (Accuracy)**

L'accuracy en phase d'apprentissage débute autour de 63 % et augmente de manière graduelle jusqu'à environ 81 %. Ce comportement indique une assimilation progressive des motifs caractéristiques présents dans les images. L'accuracy de validation reste supérieure tout au long de l'entraînement, dépassant les 89 % vers la fin, ce qui démontre la capacité généralisante du modèle. Toutefois, l'écart croissant entre les courbes d'apprentissage et de validation à la fin de l'entraînement suggère un sur-apprentissage.

- **Fonction de perte (Loss)**

La fonction de perte durant l'entraînement décroît initialement de 0.75 à environ 0.5, bien que l'on observe quelques fluctuations indiquant une convergence partiellement instable. En revanche, la perte en validation diminue plus régulièrement (de 0.45 à 0.3), témoignant d'un apprentissage cohérent sur les données non vues, sauf une légère remontée en fin d'entraînement, ce qui renforce l'hypothèse d'un sur-apprentissage.

La figure 5.11 présente l'ensemble des valeurs de précision et de perte évoquées précédemment, représentées sous forme de courbes

```

50/50 ----- 141s 3s/step - AUC: 0.8808 - Precision: 0.8411 - Recall: 0.7217 - accuracy: 0.7851 - loss: 0.4707
Epoch 11/20
50/50 ----- 0s 542ms/step - AUC: 0.8373 - Precision: 0.8207 - Recall: 0.6954 - accuracy: 0.7326 - loss: 0.542
Epoch 11: val_accuracy did not improve from 0.85444
50/50 ----- 145s 3s/step - AUC: 0.8371 - Precision: 0.8200 - Recall: 0.6951 - accuracy: 0.7323 - loss: 0.5425
Epoch 12/20
50/50 ----- 0s 536ms/step - AUC: 0.8195 - Precision: 0.7354 - Recall: 0.7348 - accuracy: 0.7352 - loss: 0.541
Epoch 12: val_accuracy improved from 0.85444 to 0.86222, saving model to best_model.h5
WARNING:absl:You are saving your model as an HDF5 file via `model.save()` or `keras.saving.save_model(model)`. This file format is considered
50/50 ----- 170s 3s/step - AUC: 0.8192 - Precision: 0.7349 - Recall: 0.7345 - accuracy: 0.7348 - loss: 0.5422
Epoch 13/20
50/50 ----- 0s 537ms/step - AUC: 0.8742 - Precision: 0.8337 - Recall: 0.8806 - accuracy: 0.8402 - loss: 0.427
Epoch 13: val_accuracy did not improve from 0.86222
50/50 ----- 142s 3s/step - AUC: 0.8732 - Precision: 0.8321 - Recall: 0.8795 - accuracy: 0.8389 - loss: 0.4297
Epoch 14/20
50/50 ----- 0s 537ms/step - AUC: 0.8275 - Precision: 0.8007 - Recall: 0.7622 - accuracy: 0.7751 - loss: 0.540
Epoch 14: val_accuracy did not improve from 0.86222
50/50 ----- 169s 3s/step - AUC: 0.8275 - Precision: 0.8003 - Recall: 0.7623 - accuracy: 0.7750 - loss: 0.5402
Epoch 15/20
50/50 ----- 0s 546ms/step - AUC: 0.8643 - Precision: 0.7987 - Recall: 0.8377 - accuracy: 0.8185 - loss: 0.501
Epoch 15: val_accuracy did not improve from 0.86222
50/50 ----- 144s 3s/step - AUC: 0.8643 - Precision: 0.7976 - Recall: 0.8373 - accuracy: 0.8179 - loss: 0.5014
Epoch 16/20
50/50 ----- 0s 548ms/step - AUC: 0.8292 - Precision: 0.7821 - Recall: 0.7077 - accuracy: 0.7541 - loss: 0.525
Epoch 16: val_accuracy did not improve from 0.86222
50/50 ----- 145s 3s/step - AUC: 0.8287 - Precision: 0.7813 - Recall: 0.7078 - accuracy: 0.7536 - loss: 0.5257
Epoch 17/20
50/50 ----- 0s 546ms/step - AUC: 0.8730 - Precision: 0.8304 - Recall: 0.8185 - accuracy: 0.7972 - loss: 0.454
Epoch 17: val_accuracy did not improve from 0.86222
50/50 ----- 144s 3s/step - AUC: 0.8729 - Precision: 0.8298 - Recall: 0.8187 - accuracy: 0.7972 - loss: 0.4547
Epoch 18/20
50/50 ----- 0s 554ms/step - AUC: 0.8208 - Precision: 0.7177 - Recall: 0.7355 - accuracy: 0.7191 - loss: 0.547
Epoch 18: val_accuracy did not improve from 0.86222
50/50 ----- 170s 3s/step - AUC: 0.8207 - Precision: 0.7180 - Recall: 0.7357 - accuracy: 0.7194 - loss: 0.5473
Epoch 19/20
50/50 ----- 0s 544ms/step - AUC: 0.8373 - Precision: 0.8387 - Recall: 0.7319 - accuracy: 0.7767 - loss: 0.487
Epoch 19: val_accuracy improved from 0.86222 to 0.87000, saving model to best_model.h5
WARNING:absl:You are saving your model as an HDF5 file via `model.save()` or `keras.saving.save_model(model)`. This file format is considered
50/50 ----- 170s 3s/step - AUC: 0.8373 - Precision: 0.8367 - Recall: 0.7322 - accuracy: 0.7759 - loss: 0.4876
Epoch 20/20
50/50 ----- 0s 554ms/step - AUC: 0.8202 - Precision: 0.8002 - Recall: 0.7266 - accuracy: 0.7609 - loss: 0.531
Epoch 20: val_accuracy improved from 0.87000 to 0.87333, saving model to best_model.h5
WARNING:absl:You are saving your model as an HDF5 file via `model.save()` or `keras.saving.save_model(model)`. This file format is considered
50/50 ----- 146s 3s/step - AUC: 0.8200 - Precision: 0.7999 - Recall: 0.7268 - accuracy: 0.7604 - loss: 0.5321

```

Figure 5.11 : Valeurs des Précisions et d'Erreur selon le nombre d'époques du 2ième modèle

Discussion :

Au vu des résultats obtenus, le modèle a démontré une bonne capacité à apprendre et généraliser les caractéristiques des images échographiques. Cependant, des signes évidents de sur-apprentissage apparaissent vers la fin de l'entraînement, comme en témoignent l'écart entre les courbes d'apprentissage et de validation, ainsi que les fluctuations de la fonction de perte. Afin d'y remédier, il est recommandé de recourir à des techniques telles que

l'augmentation des données (*Data Augmentation*), l'ajout de couches de **Dropout**, ou encore l'utilisation d'un arrêt prématuré (**early stopping**), afin de stopper l'entraînement avant la dégradation des performances de validation

5.3.3 Résultats obtenus pour le 3ème Modèle

La *figure 5.12* montre les courbes de **précision** et d'**erreur**, générées lors de la phase d'apprentissage du modèle U-Net, pour la segmentation des tumeurs, à partir d'images échographiques du sein.



Figure 5.12 : Évolution des métriques de performance au cours de l'entraînement du 3ème Modèle

- **Accuracy (Précision)**

On constate tout d'abord que la courbe de **précision d'apprentissage** (Training Accuracy) connaît une progression constante dès les premières époques. Elle démarre à environ **90 %** pour atteindre progressivement **94.3 %** à la 19e époque. Cela traduit une bonne capacité du réseau à apprendre les caractéristiques spatiales et texturales des structures tumorales. La **précision de validation** (Validation Accuracy), quant à elle, reste relativement proche de celle de l'entraînement, bien qu'avec quelques variations. Elle commence à **92 %**, atteint un pic à **94.2 %** vers l'époque 15, mais chute brutalement à l'époque 17, avant de remonter en fin d'apprentissage. Cette chute suggère un épisode de **sur-apprentissage ponctuel**, où le modèle s'adapte trop aux données d'apprentissage au détriment de sa capacité de généralisation.

- **Loss (Erreur)**

La **perte d'apprentissage** (Training Loss) suit une courbe décroissante régulière, passant d'une valeur initiale de **1.1** à environ **0.6**. Cela confirme que le modèle converge bien vers un minimum d'erreur. La **perte de validation** (Validation Loss) est plus instable. On note plusieurs pics, notamment à l'époque 2 et à l'époque 15, où la valeur remonte temporairement. Ces fluctuations peuvent être dues à une variabilité importante dans les images de validation, ou à un manque de régularisation dans le modèle. Ces hausses ponctuelles renforcent l'hypothèse d'un **sur-apprentissage localisé**.

- **Dice Coefficient**

Concernant la **courbe du coefficient Dice**, elle montre une croissance significative dès les premières époques pour l'ensemble d'apprentissage, atteignant plus de **62 %** à la fin. Ce score indique que le modèle apprend efficacement à détecter les contours des régions tumorales.

La courbe de validation progresse globalement, mais reste moins régulière avec des pics et des baisses, oscillant entre **45 % et 58 %**, ce qui démontre une performance modérée mais instable sur les images non vues.

- **IoU (Intersection over Union)**

La courbe de l’**IoU d’entraînement**, reste stable autour de **46 %**, indiquant une constance dans la qualité des prédictions segmentées. En revanche, la **courbe d’IoU de validation** reste nulle durant les premières époques, puis évolue de manière abrupte après l’époque 12. Cette évolution tardive suggère que le modèle a mis du temps à extraire des représentations suffisamment générales pour obtenir une bonne segmentation sur les données de test. Le pic vers la fin montre toutefois une amélioration tardive de la performance.

La figure 5.13 présente l’ensemble des valeurs de précision et de perte évoquées précédemment, représentées sous forme de courbes

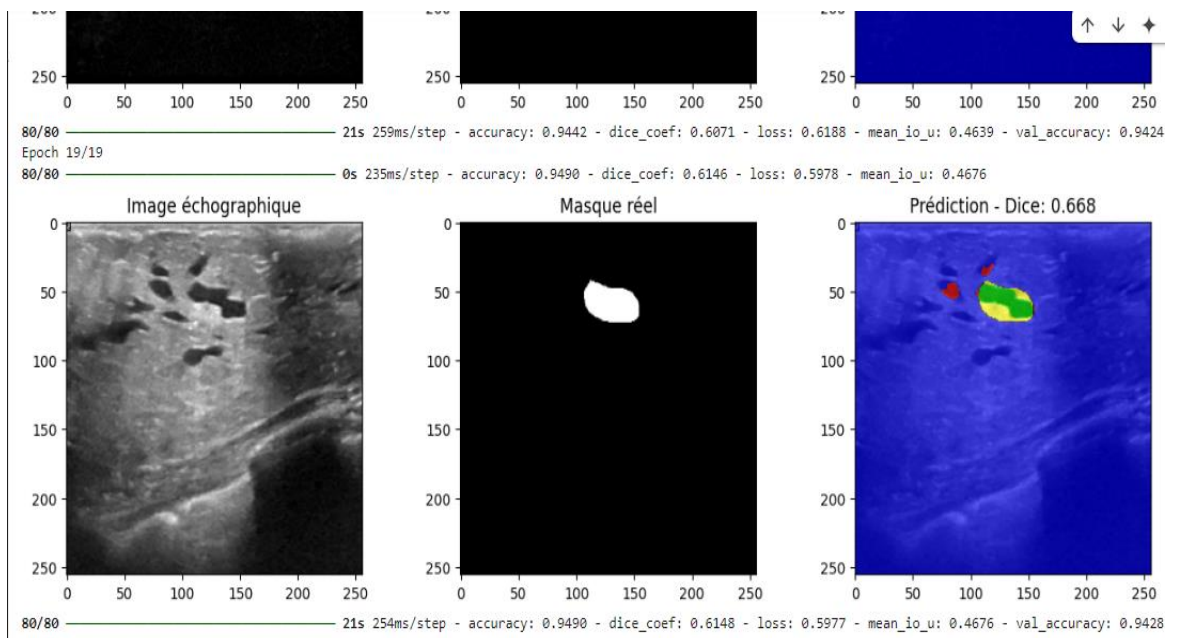


Figure 5.13 : Valeurs des Précisions et d’Erreur d’après le nombre d’époques, du 3ième modèle

5.4 Application:

La fenêtre principale de notre application est donnée par la figure 5.14.

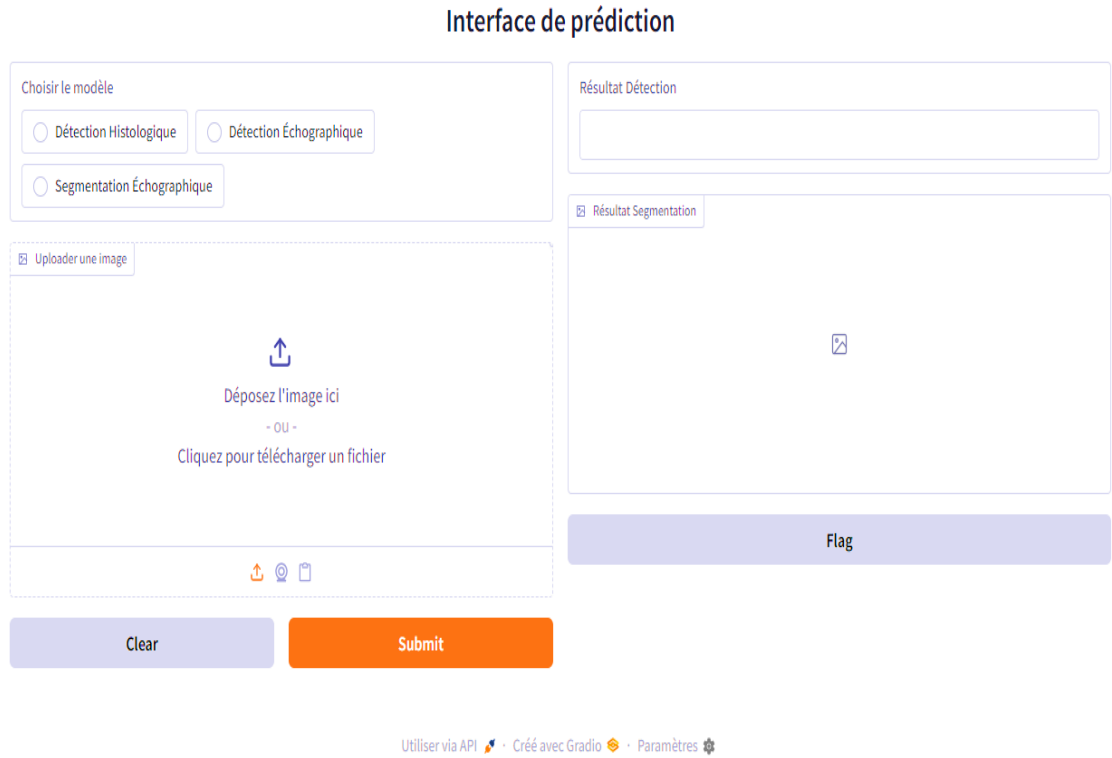


Figure 5.14 : Interface d’application

5.4.1. Choix de l’image et du type de traitement

- Sélection de l’image à partir de l’interface

Pour cela, il faut cliquer sur le bouton "télécharger un fichier" comme suit (Fig5.15) :

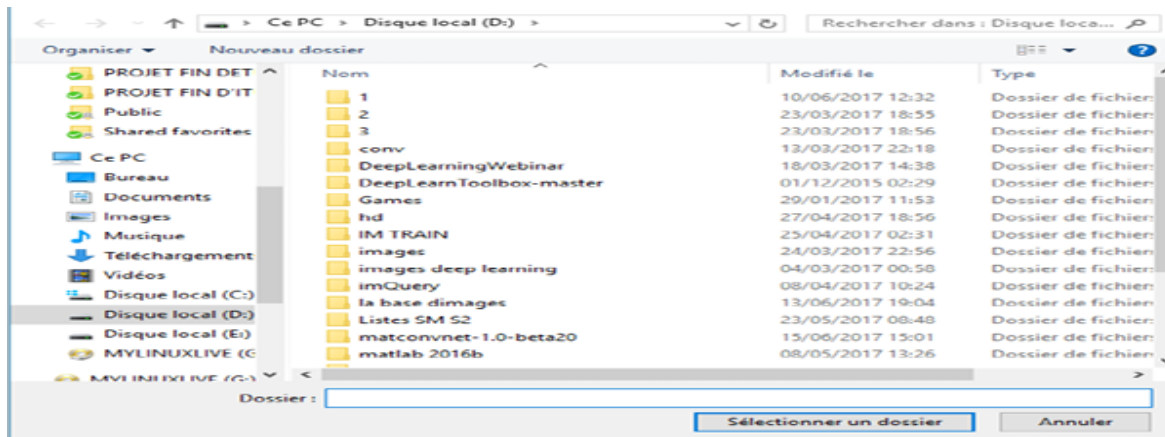
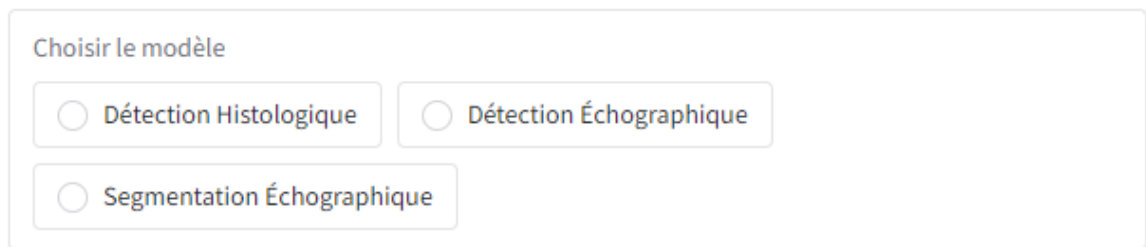


Figure 5.15= Sélection d’un fichier

- **La Classification et recherche :**

Lors de l'utilisation de l'interface, la première étape consiste à choisir le type d'analyse souhaitée. L'utilisateur peut sélectionner le type de traitement à appliquer aux images, à savoir soit une classification (par exemple, distinguer entre tissus malins et bénins), soit une segmentation (délimiter précisément la zone tumorale). Ce choix oriente le fonctionnement de l'application selon le type d'images fournies (histologiques ou échographiques) et la nature de la tâche à effectuer (Fig5.16).



The image shows a user interface titled "Choisir le modèle" (Choose the model). It contains three radio button options for selecting the type of image processing:

- Détection Histologique
- Détection Échographique
- Segmentation Échographique

Figure 5.16 : Sélection du type de traitement d'image

5.4.2 Résultats

Dans un second temps, une fois le type d'analyse sélectionné et l'image chargée, le **résultat s'affiche automatiquement dans la deuxième colonne** de l'interface. Pour une classification, le système indique la probabilité d'appartenance à chaque classe (maligne ou bénigne). Pour une segmentation, il affiche l'image annotée, avec la région détectée en surbrillance, permettant une visualisation claire de la zone tumorale identifiée par le modèle. (Fig5.17 et Fig5.18).



Figure 5.17 : Exemple de classification d’une image ultrasonore

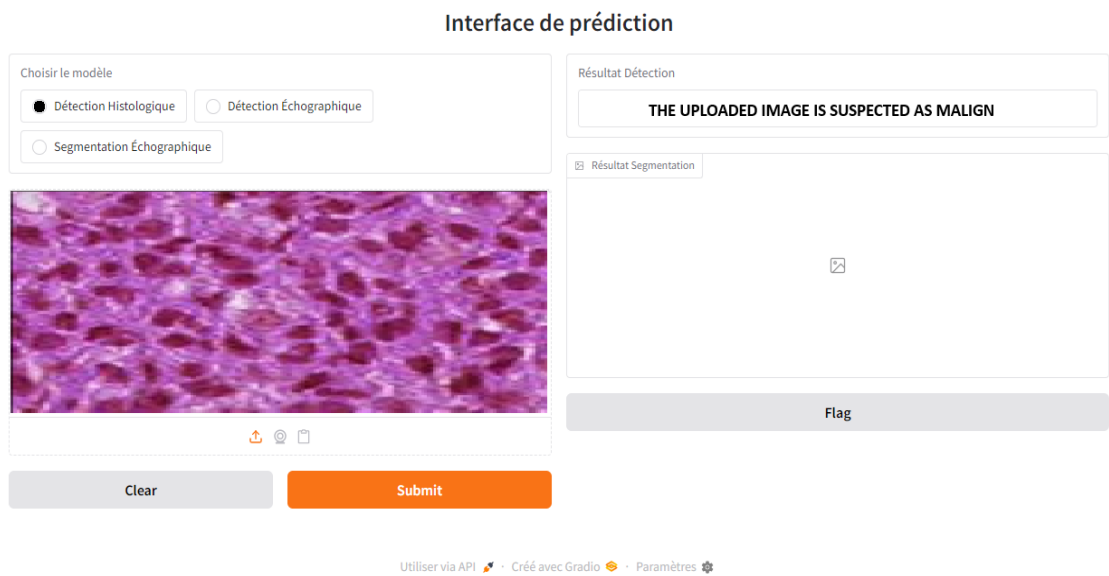


Figure 5.18 : Exemple de classification d’une image histologique

5.5 Conclusion

Après avoir finalisé la conception de notre projet, nous avons mis en place l'ensemble des outils nécessaires à sa réalisation. Nous avons également présenté l'environnement de développement utilisé, ainsi que les résultats obtenus en termes de précision et de taux d'erreur.

Enfin, nous avons introduit notre application à travers plusieurs captures d'écran illustrant son fonctionnement, les différentes étapes du processus, ainsi que les résultats générés. Un exemple concret de classification d'une image a été présenté pour illustrer l'efficacité de l'outil développé.

CONCLUSION

Dans ce travail de projet de fin d'études, nous avons tenté d'apporter une contribution à l'analyse assistée des images mammographiques, dans le but de favoriser un diagnostic plus rapide et plus fiable du cancer du sein. Malgré les avancées technologiques dans le domaine médical, le dépistage précoce du cancer du sein demeure un enjeu de santé publique majeur, complexe et toujours au cœur des recherches scientifiques actuelles.

Notre objectif principal était de concevoir une approche basée sur les réseaux de neurones convolutionnels (CNN), capable d'aider les radiologues à détecter les signes précoces du cancer, tels que les microcalcifications ou les masses suspectes, en analysant les images issues de mammographies.

Pour ce faire, nous avons commencé par présenter dans le premier chapitre le contexte médical, incluant l'anatomie du sein, les pathologies mammaires, les techniques d'imagerie et les critères de détection des anomalies. Le deuxième chapitre a été consacré à un état de l'art approfondi sur les approches CNN appliquées à l'imagerie médicale, la classification des lésions et la détection des microcalcifications. Ensuite, dans le troisième chapitre, nous avons détaillé les principes fondamentaux de l'apprentissage profond, en mettant l'accent sur les architectures CNN, leurs composants (convolutions, pooling, fonctions d'activation), et les techniques d'optimisation.

Le quatrième chapitre a été dédié aux architectures proposées, où nous avons implémenté et testé un modèle CNN pour classifier les images mammographiques. L'architecture choisie s'inspire des modèles standards comme VGG ou ResNet, mais adaptée à notre jeu de données. En raison de la complexité des textures et de la faible visibilité des microcalcifications, les résultats initiaux n'ont pas atteint le niveau de performance escompté. Cela nous a conduit à considérer des techniques de prétraitement spécifiques, comme l'augmentation de données et la normalisation, pour améliorer la qualité d'apprentissage.

Dans le cinquième chapitre, nous avons analysé et évalué les performances du modèle. La classification automatique a permis une bonne identification globale des anomalies, mais a souffert d'un certain taux de faux positifs, notamment dans les cas de densité mammaire élevée. Néanmoins, les résultats obtenus restent encourageants et montrent que les CNN peuvent apporter un soutien précieux dans le cadre du dépistage automatisé.

Perspectives

Ce projet constitue une première étape vers l'automatisation fiable du dépistage du cancer du sein. Pour améliorer notre système, plusieurs pistes peuvent être envisagées. Il serait tout d'abord pertinent d'intégrer une segmentation précise des régions d'intérêt avant la classification, afin d'extraire plus efficacement les zones contenant des anomalies. L'utilisation de modèles plus récents comme EfficientNet ou des architectures hybrides (CNN + Transformer) pourrait également améliorer les performances.

Par ailleurs, une extension naturelle de notre travail serait de caractériser les anomalies détectées pour évaluer leur bénignité ou malignité, en se basant sur des critères morphologiques, texturaux ou encore génétiques. Enfin, une validation clinique en collaboration avec des professionnels de santé, sur des bases de données plus variées et annotées, serait indispensable pour évaluer l'applicabilité réelle de notre système en environnement hospitalier.

REFERENCES

- [1] Haehnel, P. Mammographie – 83 exercices de radiodiagnostic pour étudiants et praticiens. Paris : Vigot, 1996. ISBN : 2-7114-1049.
- [2] Brettes J., Mathelin C., Gairard B., Bellocq J. Cancer du sein. Paris : Elsevier Masson, 2007. ISBN : 978-2-294-01813-8.
- [3] Kobrunner S.H., Schreer I., Bassler R., Dickhaut M. Imagerie diagnostique du sein. 2e éd. Paris: Elsevier Masson, 2007. ISBN: 978-2-294-01790-2.
- [4] Carol DerSarkissian, “The breast (human anatomy),” shorturl.at/gvQX0.
- [5] Friedman PD, et al. Imagerie du sein : Pathologie bénigne et maligne. Elsevier Masson, 2015.
- [6] l'article de comprendre le cancer du sein : l'INSTITUT NATIONAL DU CANCER, Disponible sur le net : www.e-cancer.fr, ISBN : 978-2-913 495-30-2, Validation : janvier 2007.
- [7] Hadjidj, Approche Morphologique pour la Segmentation d'Images Médicales, Mémoire présenté à l'Université de Tlemcen pour l'obtention de Diplôme de Magister en Électronique Biomédicale, 2011.
- [8] S. H. Kobrunner, I. Schreer, R. Bassler, M. Dickhaut. Imagerie diagnostique du sein Mammographie, échographie, IRM, techniques interventionnelles. 2^{ème} édition. Paris : Elsevier Masson, 2007. 513 p. Imagerie Médicale Précis. ISBN : 9782294017902.
- [9] Malhaire J-P, Saidi R, Maccia C, Gibon D. Technologies en mammographie numérique. Journal de Radiologie Diagnostique et Interventionnelle. 2023 ;104 (2) :100–105.
- [10] J. Stines, « Les cancers du sein : les images visibles sur une seule incidence », Journal de Radiologie, vol. 85, n° 12, Part 2, p. 2083-2094, déc. 2004, doi: 10.1016/S0221-0363(04)97786-4.
- [11] A. LE TREUT, M.H. DILHUYDY “Mammographie, guide d'interprétation”. Arnette (1989).
- [12] H. Chekkaf, I. Touil, Segmentation des masses dans les images mammographiques, Mémoire de fin d'études pour l'obtention du diplôme de Master en Informatique, 2012.
- [13] P. Haehnel. Mammographie- 83 exercices de radiodiagnostic pour étudiants et praticiens. Paris : Vigot, 1996. 137p. Exercices de radiodiagnostic. ISBN : 2-7114- 1049.

- [14] <https://www.e-cancer.fr> Institut National du Cancer (INCa) Visité 01/02/2025
- [15] Burstein HJ, et al. Estrogen Receptor–Positive Breast Cancer: Systemic Therapies and Clinical Issues. *New England Journal of Medicine*, 2023 ; 388 :1352-1366.
- [16] Info radiographie.ch, “Roles de l echographie dans le depistage du cancer du sein,” <https://www.info-radiologie.ch/echographie-cancer-sein.php>.
- [17] Formation gyneco-obstetrique <http://www.fmcdinan.org/article-communique-de-l-imagerie-du-pays-de-rance-tomosynthese-100039739.html>.
- [18] Centers for Disease Control, Agency for Healthcare Research Prevention, and Quality, “Biopsy,” <https://www.nationalbreastcancer.org/breast-cancer-biopsy/> visité 05/04/2025
- [19] « Examen anatomopathologique », <https://www.cancer.fr/Patients-et-proches/%20Les-cancers/Cancer-du-sein/Diagnostic/Examen-anatomopathologique/> visité 24/04/2025
- [20] Yongchao XU, Thierry Geraud, and Isabelle BLOCH, “Segmentation d'IRM de cerveaux de nouveau-nés en quelques secondes à l'aide d'un réseau de neurones convolutif pseudo-3D et de transfert d'apprentissage,” in *Actes du 26e Colloque GRETSI*, Juan-les-Pins, France, 2017.
- [21] A Sankari and S Vigneshwari, “Automatic tumor segmentation using convolutional neural networks,” in *2017 Third International Conference on Science Technology Engineering & Management (ICONSTEM)*. IEEE, 2017, pp. 268–272.
- [22] Safaa E Amin and MA Megeed, “Brain tumor diagnosis systems based on artificial neural networks and segmentation using MRI,” in *2012 8th International Conference on Informatics and Systems (INFOS)*. IEEE, 2012, pp. MM–119.
- [23] Aqhsa Q Syed and K Narayanan, “Detection of tumor in MRI images using artificial neural networks,” *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, vol. 3, no. 9, pp. 11749–11754, 2014.
- [24] Adria Romero Lopez, Xavier Giro-i Nieto, Jack Burdick, and Oge Marques, “Skin lesion classification from dermoscopic images using deep learning techniques,” in *2017 13th IASTED International Conference on Biomedical Engineering (BioMed)*. IEEE, 2017, pp. 49–54.
- [25] Sameer Khan and Suet-Peng Yong, “A deep learning architecture for classifying medical images of anatomy object,” in *2017 Asia-Pacific Signal and Information Processing*

- Association Annual Summit and Conference (APSIPA ASC). IEEE, 2017, pp. 1661–1668.
- [26] Pierre Buysens and Abderrahim Elmoataz, “Réseaux de neurones convolutionnels multi-échelle pour la classification cellulaire,” 2016.
- [27] Eva Costa, Nelson Martins, Malik Saad Sultan, Diana Veiga, Manuel Ferreira, Sandra Mattos, and Miguel Coimbra, “Mitral valve leaflets segmentation in echocardiography using convolutional neural networks,” in 2019 IEEE 6th Portuguese Meeting on Bioengineering (ENBENG). IEEE, 2019, pp. 1–4.
- [28] Daniel S Kermany, Michael Goldbaum, Wenjia Cai, Carolina CS Valentim, Huiying Liang, Sally L Baxter, Alex McKeown, Ge Yang, Xiaokang Wu, Fangbing Yan, et al., “Identifying medical diagnoses and treatable diseases by image-based deep learning,” *Cell*, vol. 172, no. 5, pp. 1122–1131, 2018.
- [29] Al Nahid, A., & Kong, Y. (2018). Histopathological Breast-Image Classification Using Local and Frequency Domains by Convolutional Neural Network. *Information*, 9(1), 19.
- [30] Angel Cruz-Roa, Ajay Basavanhally, Fabio González, Hannah Gilmore, Michael Feldman, Shridar Ganesan, Natalie Shih, John Tomaszewski, and Anant Madabhushi, “Automatic detection of invasive ductal carcinoma in whole slide images with convolutional neural networks,” in *Medical Imaging 2014 : Digital Pathology*. International Society for Optics and Photonics, 2014, vol. 9041, p. 904103.
- [31] Fabio A Spanhol, Luiz S Oliveira, Caroline Petitjean, and Laurent Heutte, “A dataset for breast cancer histopathological image classification,” *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 7, pp. 1455–1462, 2015.
- [32] Nima Habibzadeh Motlagh, Mahboobeh Jannesary, HamidReza Aboulkheyr, Pegah Khosravi, Olivier Elemento, Mehdi Totonchi, and Iman Hajirasouliha, “Breast cancer histopathological image classification : A deep learning approach,” *bioRxiv*, p. 242818, 2018.
- [33] M. Zouari, A. Dammak Masmoudi, et D. S. Masmoudi, « A non linear stretching image enhancement technique for microcalcification detection », in 2014 1st International Conference on Advanced Technologies for Signal and Image Processing (ATSIP), mars 2014, p. 193-197. doi: 10.1109/ATSIP.2014.6834605.

- [34] M. Mustra et M. Grgic, « Detection of areas containing microcalcifications in digital mammograms », in IWSSIP 2014 Proceedings, mai 2014, p. 51-54.
- [35] O. Intharasombat et P. Piamsa-nga, « Adaptive window and adaptive threshold method for microcalcification detection », in 2014 International Computer Science and Engineering Conference (ICSEC), Khon Kaen, Thailand, juill. 2014, p. 446-451. doi: 10.1109/ICSEC.2014.6978238.
- [36] M. I. Chacon-Murguia et A. J. Villalobos-Montiel, « A fuzzy computer aided diagnosis system using breast thermography », in 2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI), Brooklyn, NY, USA, avr. 2015, p. 105-108. doi: 10.1109/ISBI.2015.7163827.
- [37] I. I. Esener, S. Ergin, et T. Yuksel, « A new ensemble of features for breast cancer diagnosis », in 2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), Opatija, Croatia, mai 2015, p. 1168-1173. doi: 10.1109/MIPRO.2015.7160452.
- [38] Hai Su et al., « Robust automatic breast cancer staging using a combination of functional genomics and image-omics », in 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Milan, août 2015, p. 7226-7229. doi: 10.1109/EMBC.2015.7320059.
- [39] M. Tan, W. Qian, J. Pu, H. Liu, et B. Zheng, « A new approach to develop computer-aided detection schemes of digital mammograms », *Phys Med Biol*, vol. 60, n° 11, p. 4413-4427, juin 2015, doi: 10.1088/0031-9155/60/11/4413.
- [40] LeCun, Y. (2017). Qu'est-ce que l'intelligence artificielle. chaire Recherches sur l'intelligence artificielle, informatique et sciences numériques (2015-2016), Collège de France, https://www.college-de-france.fr/media/yannlecun/UPL4485925235409209505_Intelligence_Artificielle____Y._LeCun.pdf. Visité 5/02/2025
- [41] Reese, H. (2017). Understanding the differences between AI, machine learning, and deep learning. URL: <https://www.techrepublic.com/article/understanding-the-differences-between-ai-machine-learning-and-deeplearning>. Visité 11/02/2025

- [42] Maaref, A. (2019). Prediction of Chemotherapy Response of Liver Metastases from Baseline CT-Images Using Deep Neural Networks (Doctoral dissertation, Ecole Polytechnique, Montreal (Canada)).
- [43] « Deep Learning : définition, applications, avantages et inconvénients », Retengr, 22 janvier 2021. <https://www.retengr.com/2021/01/22/deep-learning-definitions-applications-avantages-inconvenients/> Visité 28/01/2025
- [44] Inaam, d. systeme de reconnaissance d'iris par reseaux de neurones convolutionnels (doctoral dissertation, university of kasdi merbah ouargla).
- [45] Gauthier, E. (1999). Utilisation des réseaux de neurones artificiels pour la commande d'un véhicule autonome (Doctoral dissertation, Institut National Polytechnique de Grenoble INPG).
- [46] SabrePC. (2024, 22 novembre). Six Types of Neural Networks You Need to Know About. SabrePC Blog.
Visité 26-03-2025
- [47] SEKKIL, H. M., & MEBROUKI, M. (2021). Etude comparative entre les différentes architectures des réseaux de neurones convolutifs (CNNs) pour la détection de la fatigue du conducteur (Doctoral dissertation, Directeur: Melle. Imane NEDAJR/Co-Directeur: M. MEGNAFI Hichem).25/02/2023
- [48] DataScientest. (s.d.). Convolutional Neural Network: Everything You Need to Know. Visité 27-03-2025
- [49] T. rédac, « Convolutional neural network-Deep Learning - DataScientest », Formation Data Science | DataScientest.com, 25 juin 2020. <https://datascientest.com/convolutional-neural-network>. Visité 14/02/2025
- [50] Aaron Courville Ian Goodfellow, Yoshua Bengio, Deep Learning, MIT Press, 2016.
- [51] Aurelien Geron, Hands-On Machine Learning with Scikit-Learn and TensorFlow : Concepts, Tools, and Techniques to Build Intelligent Systems, OReilly Media, 2017.
- [52] Vikas Gupta, "Convolutional layer," <https://www.learnopencv.com/image-classification-using-convolutional-neural-networks-in-keras/>, date NOVEMBER29,2017, visité 28-03-2025

- [53] (s.d.). What is a neural network flatten layer?. visité 29-03-2025
- [54] Dhillon, A. (2020, March 9). Five Simple Image Data Augmentation Techniques to Mitigate Overfitting In Computer Vision. Towards Data Science.
- [55] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929– 1958.
- [56] DataCorner. (s.d.). Gradient descent : la méthode d'apprentissage des réseaux de neurones. Visité 29/05/2025
- [57] Khan, S. A., Khan, M. Y., Khan, M. A., & al. (2024). A Review of Machine Learning and Deep Learning for Object Detection, Semantic Segmentation, and Human Action Recognition in Machine and Robotic Vision. *Technologies*, 12(2), 15
- [58] Das, S. (2017, novembre 16). CNN Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more.... *Analytics Vidhya*. Visité 29/03/2025
- [59] Vuppala, A. S. (2022). *Ultrasound Breast Images for Breast Cancer* [Dataset]. Kaggle
- [60] Shah, A. (2021). Breast Ultrasound Images Dataset. Kaggle.
- [61] Kaggle. (n.d.). Histopathologic Cancer Detection
- [62] —The Python Tutorial — Python 3.8.6rc1 documentation