

Faculté des Sciences Exactes et d'Informatique
Département de Mathématiques et informatique
Filière : Informatique

MEMOIRE DE FIN D'ETUDES

Pour l'Obtention du Diplôme de Master en Informatique

Option : **Intelligence Artificielle pour l'internet des objets**
(IA4IoT)

Présenté par :

LAHRECHE Mansour

THEME :

Apprentissage profond pour la détection de cancer de sein

Soutenu le : 23/06/2025

Devant le jury composé de :

DJEBARA M ^{ed} Réda	MCA	Université de Mostaganem	Président
ABDALLAH BENSELOUA Charef	MCA	Université de Mostaganem	Examineur
BOUATTOU Zina	MCB	Université de Mostaganem	Encadreur

Année Universitaire 2024-2025

Résumé

Les systèmes de détection automatisée du cancer du sein jouent un rôle essentiel dans le diagnostic précoce et la prise en charge efficace de cette maladie. De nombreux travaux de recherche ont été menés pour concevoir des solutions performantes exploitant les réseaux de neurones convolutifs (CNN) dans le domaine médical. Les performances de ces systèmes dépendent de plusieurs facteurs, notamment la qualité et la représentativité des données utilisées.

Ce mémoire propose une solution de détection du cancer du sein fondée sur les réseaux de neurones convolutifs. L'objectif est d'améliorer la précision du diagnostic et de limiter les faux négatifs en tirant parti des capacités des CNN à extraire des caractéristiques pertinentes des images médicales. Les données sont préalablement prétraitées puis introduites dans le réseau CNN afin d'identifier les anomalies caractéristiques du cancer du sein.

Pour mettre en œuvre cette solution, nous abordons les principales étapes de conception d'un modèle de CNN : la collecte et la préparation des données, la conception et l'entraînement du réseau CNN, ainsi que la validation et le test du modèle. Les images médicales sont collectées et prétraitées pour constituer un ensemble de données représentatif. Un réseau CNN est ensuite conçu et entraîné sur cet ensemble afin d'apprendre à reconnaître les motifs associés aux lésions mammaires.

Mots-clés : Apprentissage profond, Réseaux de Neurones Convolutifs, Cancer de sein, Classification d'images

Abstract

Automated breast cancer detection systems have become crucial for early diagnosis and effective management of the disease. Significant research efforts have been devoted to developing efficient solutions based on convolutional neural networks (CNNs) in the medical field. The performance of such systems depends on various factors, particularly the quality and representativeness of the data.

This thesis presents a breast cancer detection solution based on convolutional neural networks. The goal is to improve diagnostic accuracy and reduce false negatives by leveraging the feature extraction capabilities of CNNs. Data is pre-processed and then fed into the CNN to identify characteristic anomalies associated with breast cancer.

To implement this solution, we address the main steps of CNN model design: data collection and preparation, CNN network design and training, as well as model validation and testing. Medical images are collected and pre-processed to form a representative dataset. A CNN is then designed and trained on this dataset to learn how to recognize patterns indicative of breast lesions.

Keywords : Deep Learning, Convolutional Neural Networks, Breast Cancer, Image classifications

Dédicaces

Je dédie ce mémoire :

À Dieu Tout-Puissant, pour la force, la patience et la clarté d'esprit qu'Il m'a accordé chaque jour, durant ces cinq années d'études et tout au long de la rédaction de ce travail.

À mon père, Monsieur Lahreche Ahmed, et à ma mère, Madame Benguireche Fatima, pour leur amour indéfectible, leurs encouragements constants et leur soutien, malgré la distance qui nous sépare.

À mes petites sœurs, qui m'inspirent chaque jour et me donnent de nombreuses raisons de persévérer.

À mes grands-parents, pour leurs appels et leurs messages empreints de sagesse et d'affection.

À toute ma grande famille, toujours présente dans les moments importants.

À mes amis proches Abderrachid, Ali, Boutheina et Amel et tous m'ont supporté, pour leur soutien sincère, leur écoute bienveillante et leurs encouragements tout au long de cette aventure.

Remerciements

Au terme de ce travail, je tiens à exprimer ma profonde gratitude et ma sincère Reconnaissance à toutes les personnes qui ont contribué, de près ou de loin à l'élaboration de ce mémoire.

En tout premier lieu, j'adresse mes remerciements à mon encadrante, Mme ZINA BOUATTOU, pour son aide, sa disponibilité, son suivi permanent et ses nombreux conseils qui nous ont permis de mener à bien ce travail.

Je tiens également à remercier l'ensemble du personnel du département informatique, en particulier **Monsieur Djebbara**, **Madame Benkerdagh**, chef du département, **Monsieur Zahmani**, ainsi que tous les enseignants qui m'ont accompagné tout au long de mon parcours universitaire.

Liste des figures

Figure N°	Titre de la figure	Page
Figure 1	Machine Learning vs Deep Learning	13
Figure 2	Exemple de processeus du Max Pooling	22
Figure 3	Exemple de processeus du Average Pooling	23
Figure 4	Architecture d'un Réseau de Neurones Convolutif (CNN) pour la Classification d'images	25
Figure 5	Application de l'apprentissage par transfert (Transfer Learning)	26
Figure 6	Types de cancer de sein	30
Figure 7	Statistiques de cancer de sein dans le monde depuis 2022.	31
Figure 8	Logo de la plateforme utilisée dans le cadre de notre travail	38
Figure 9	Logos des différentes ressources logiciels	41
Figure 10	Diagramme de cas d'utilisation	42
Figure 11	Diagramme de séquence	43
Figure 12	Diagramme de classe	44
Figure 13	Exemples d'images de la base de données Breast Histopathology images	45
Figure 14	Exemples d'images de la bdd Breast Ultrasound Images Dataset	46
Figure 15	Fonction d'activation Softmax	49
Figure 16	Principe de la fonction de perte	51
Figure 17	Architecture de notre modèle	52

Figure 18	Progression de l'entraînement lors des 10 premières époques avec des informations sur la précision (Accuracy) et la perte (Loss) à l'entraînement et la validation	53
Figure 19	Progression de l'entraînement lors des 10 dernières époques avec des informations sur la précision (Accuracy) et la perte (Loss) à l'entraînement et la validation	53
Figure 20	Implémentation de la validation	54
Figure 21	Code décrivant la partie de test du modèle	54
Figure 22	Graphique pour Accuracy et Loss	56
Figure 23	Matrice de confusion après la validation	56
Figure 24	Compilation de modèle	59
Figure 25	Architecture de VGG16	60
Figure 26	Précision et Loss du Model (VGG16 sans augmentation)	61
Figure 27	Matrice de confusion sans augmentation	62
Figure 28	Fonction d'augmentation des données	64
Figure 29	Précision et Loss du Model (VGG16 avec augmentation)	65
Figure 30	Matrice de confusion avec augmentation de données	66
Figure 31	Interface principale de notre application	68
Figure 32	Sélection des images pour analyse	68
Figure 33	Remplir le formulaire par le médecin	69
Figure 34	Résultats d'analyse de l'image avec la zone de la détection des anomalies	69
Figure 35	Demande de téléchargement de rapport avec Analyse succès	70

Figure 36	Document PDF après le téléchargement	70
Figure 37	Historique des diagnostics pour les patients	71

Liste des tableaux

Tableau N°	Titre du tableau	Page
Tableau 1	Résumé des ensembles de données utilisés	47
Tableau 2	Comparaison entre deux scénarios	67

Liste des abréviations

Abréviation	Expression Complète
UML	Unified Modeling Language
CNN	Convolutional Neural Network
DL	Deep Learning
SVM	Support Vector Machine
ADAM	Adaptive Moment Estimation Algorithm
IDC	Invasive Ductal Carcinoma

Table des matières

Introduction Générale	10
Chapitre 1 Apprentissage profond (Deep Learning)	12
1.1 Introduction	12
1.2 Apprentissage profond (Deep Learning).....	12
1.2.1 Définition.....	12
1.2.2 Fonctionnement de l'apprentissage profond	13
1.2.3 Types d'approches d'apprentissages profond	18
1.3 Les Réseaux de Neurones Convolutifs (CNN)	20
1.3.1 Définition.....	20
1.3.2 Les couches de CNN.....	20
1.4 Application du CNN dans le domaine médical	28
1.5 Conclusion.....	29
Chapitre 2 Détection du cancer de sein	30
2.1 Introduction	30
2.2 Généralités sur le cancer de sein.....	30
2.2.1 Définition : C'est quoi le cancer de sein ?.....	30

2.2.2	Les types du cancer de sein	30
2.2.3	Les symptômes et les facteurs de risques.....	31
2.2.4	Statistiques du cancer de sein : dans le monde et en Algérie	31
2.3	Les approches de détection du cancer de sein.....	31
2.3.1	Les approches traditionnelles	32
2.3.2	Les systèmes d'aide du diagnostic	33
2.3.3	Les approches intelligentes.....	33
2.3.4	Synthèse des travaux	36
2.4	Conclusion.....	37
Chapitre 3 Implémentation et résultats		38
3.1	Introduction	38
3.2	Outils et matériels utilisés	38
3.2.1	Ressources matérielles	38
3.2.2	Ressources logicielles	39
3.3	UML.....	41
3.3.1	Définition.....	41
3.3.2	Diagramme de cas d'utilisation	41
3.3.3	Diagramme de séquence.....	42
3.3.4	Diagramme de classe.....	43
3.4	Collecte et prétraitement de données	45
3.4.1	Sources de données	45
3.4.2	Prétraitement des données	46
3.5	Modèle de détection de cancer de sein	47
3.5.1	Scénario initial	48
3.5.2	Scénario Alternatif 1	57
3.5.3	Scénario alternatif 2	63
3.5.4	Résultats expérimentaux.....	66
3.5.5	Détection en temps réel	67
3.6	Conclusion.....	71

Conclusion Générale.....	73
Bibliographie	75

Introduction Générale

Le cancer du sein constitue l'une des principales causes de mortalité féminine à l'échelle mondiale, représentant une menace persistante pour la santé publique et la qualité de vie des femmes et de leurs familles. Cette maladie peut avoir des conséquences dramatiques sur la vie des individus touchés et sur la société dans son ensemble. Pourtant, malgré les progrès médicaux et technologiques, la détection précoce du cancer du sein demeure un enjeu majeur de santé publique.

Traditionnellement, le diagnostic du cancer du sein reposait principalement sur l'interprétation visuelle des images médicales par des radiologues ou des médecins spécialisés; cependant, cette approche présente des limites, car elle est sujette aux erreurs humaines, à la fatigue et à la variabilité inter-observateurs. Les méthodes conventionnelles d'analyse d'images, bien qu'efficaces, peuvent également s'avérer insuffisantes pour détecter des anomalies subtiles ou pour traiter de grands volumes de données dans des délais raisonnables. Afin de pallier ces inconvénients, l'avènement de l'intelligence artificielle en général, et de l'apprentissage profond en particulier, a permis une avancée majeure dans la détection automatique et précoce du cancer du sein à partir d'images médicales.

Dans le cadre de ce projet, nous proposons d'utiliser des méthodes d'apprentissage profond, et plus spécifiquement les réseaux de neurones convolutifs (CNN), pour détecter et classifier les anomalies mammaires présentes dans les images médicales. L'apprentissage profond, inspiré du fonctionnement du cerveau humain, a révolutionné de nombreux domaines, notamment la vision par ordinateur et l'imagerie médicale. En exploitant des architectures de réseaux neuronaux profonds, nous cherchons à développer un système d'aide au diagnostic efficace, précis et robuste, capable d'assister les professionnels de santé dans la détection et la classification des lésions mammaires.

Dans ce projet, notre objectif est de répondre aux questions suivantes :
Comment pouvons-nous construire un système de détection automatique du cancer du sein à

l'aide des technologies d'apprentissage profond ? Comment pouvons-nous équilibrer les performances de détection et les exigences opérationnelles en contexte clinique ?

Pour répondre à ces questions, nous avons structuré notre travail en trois chapitres :

Chapitre 1 : Ce chapitre nous permettra de nous familiariser avec les concepts de l'intelligence artificielle, du machine learning et du deep learning, ainsi que les notions d'apprentissage par transfert. Nous explorerons en détail le fonctionnement du deep learning et des CNN, en mettant l'accent sur les méthodes et concepts clés qui sous-tendent leur efficacité dans le domaine médical.

Chapitre 2 : Dans ce chapitre, nous présenterons les différentes approches de détection du cancer du sein traitées dans la littérature, en explorant celles qui utilisent les méthodes traditionnelles, l'apprentissage automatique et le Deep Learning. Nous discuterons également des travaux antérieurs menés dans ce domaine et de leur impact sur la pratique clinique.

Chapitre 3 : Dans ce chapitre, nous présenterons la partie expérimentale de notre travail, en décrivant les différentes étapes du projet, de la collecte et de la préparation des données à l'évaluation des modèles, en passant par l'implémentation et le déploiement d'une application d'aide au diagnostic.

Nous terminerons ce mémoire par une conclusion générale qui résume les principales idées développées et discutera des perspectives de recherche futures envisageables à la suite de ces travaux.

Chapitre 1

Apprentissage profond (Deep Learning)

1.1 Introduction

L'émergence de l'intelligence artificielle (IA), et en particulier de l'apprentissage profond (Deep Learning), a profondément transformé le domaine de l'analyse d'images, notamment dans le secteur médical. Grâce à sa capacité à extraire automatiquement des caractéristiques complexes à partir de données brutes, l'apprentissage profond est devenu un outil incontournable pour la détection et le diagnostic de maladies. Dans ce chapitre, nous explorerons les fondements de l'apprentissage profond, ses principaux modèles, ainsi que ses applications dans le domaine de l'imagerie médicale, en mettant particulièrement l'accent sur l'utilisation des réseaux de neurones convolutifs (CNN).

1.2 Apprentissage profond (Deep Learning)

1.2.1 Définition

Le Deep Learning, ou apprentissage profond, est une sous-catégorie du machine Learning qui s'appuie sur des réseaux de neurones artificiels comportant plusieurs couches d'où le terme « profond ». Contrairement aux méthodes traditionnelles nécessitant une extraction manuelle des caractéristiques, le Deep Learning (DL) automatise cette étape en apprenant directement à partir des données brutes [1].

Les architectures profondes sont capables de modéliser des relations complexes au sein des données, ce qui les rend particulièrement performantes pour des tâches comme la reconnaissance d'image, le traitement du langage naturel, ou la classification de signaux médicaux.




Figure 1 : Machine Learning vs Deep Learning [2].

Parmi les architectures les plus couramment utilisées, on trouve : [3].

- **Réseaux de neurones convolutifs (CNN)**, principalement utilisés pour le traitement d'images,
- **Réseaux de neurones récurrents (RNN)** adaptés à l'analyse de données séquentielles,
- **Auto-encodeurs**, efficaces pour la réduction de dimensionnalité et l'extraction de caractéristiques,
- **Transformers**, de plus en plus utilisés pour des tâches complexes en traitement du langage naturel et en vision par ordinateur.

1.2.2 Fonctionnement de l'apprentissage profond

L'apprentissage profond (*Deep Learning*) est un paradigme de l'intelligence artificielle qui s'appuie sur l'utilisation de réseaux de neurones profonds pour modéliser des représentations hiérarchiques complexes à partir de données massives. Le processus d'élaboration

d'un modèle d'apprentissage profond comporte plusieurs étapes successives et interdépendantes, allant de la préparation des données jusqu'au déploiement du modèle final dans un environnement de production.

1.2.2.1. La collecte et le prétraitement des données

La qualité et la pertinence des données constituent la pierre angulaire de tout système d'apprentissage profond. Les modèles de deep learning nécessitent en effet des volumes très importants de données pour apprendre efficacement les relations complexes présentes dans les entrées.

1.2.2.1.1. Collecte des données :

Les données peuvent provenir de diverses sources, selon la nature de la tâche :

- Images (issues de bases telles que ImageNet, MNIST, etc.),
- Vidéos (ex. YouTube-8M),
- Texte (corpus linguistiques, documents structurés),
- Données biomédicales (IRM, mammographies, séquences ADN),
- Données temporelles (séries de capteurs, logs, signaux ECG, etc.).

1.2.2.1.2. Prétraitement des données (*Data Preprocessing*) :

Cette phase est essentielle pour garantir la qualité du signal entrant. Elle inclut généralement :

- **Nettoyage des données** : suppression des doublons, gestion des valeurs manquantes, correction d'erreurs.
- **Normalisation ou standardisation** : mise à l'échelle des données (ex. entre 0 et 1, ou centrage-réduction) pour faciliter la convergence.

- **Augmentation de données** (*data augmentation*) : en particulier pour les images, des transformations sont appliquées (rotation, zoom, bruit, retournement horizontal...) pour enrichir le jeu de données et améliorer la généralisation.
- **Encodage** : pour les données catégorielles, on utilise des techniques comme *one-hot encoding*, *label encoding*, ou *word embeddings* dans le cas du texte.
- **Annotation manuelle ou automatique** : indispensable dans les tâches supervisées (ex. classification d'images, reconnaissance faciale, etc.).

Une mauvaise qualité de données se traduit systématiquement par un mauvais apprentissage du modèle, même si ce dernier est bien conçu.

1.2.2.2. Construction du modèle

La conception du modèle consiste à définir l'architecture du réseau de neurones adaptée à la tâche. Cette architecture précise le nombre et le type de couches, les fonctions d'activation, la stratégie de régularisation, et bien d'autres paramètres.

Quelques types d'architectures couramment utilisées :

- **MLP (Multilayer Perceptron)** : pour des données tabulaires simples.
- **CNN (Convolutional Neural Network)** : pour le traitement d'images.
- **RNN (Recurrent Neural Network), LSTM, GRU** : pour des données séquentielles ou temporelles.
- **Transformer, BERT, GPT** : pour le traitement du langage naturel (*Natural Language Processing*).

Les éléments fondamentaux d'un réseau sont :

- **La couche d'entrée** (*input layer*) : elle reçoit les données au format vectoriel.
- **Les couches cachées** (*hidden layers*) : elles effectuent des transformations successives à l'aide de fonctions d'activation non linéaires telles que *ReLU*, *Sigmoid* ou *Tanh*.

- **La couche de sortie** (*output layer*) : elle fournit la prédiction finale sous forme de probabilités (via *softmax* pour la classification multiclassées, par exemple).

1.2.2.3. Apprentissage

L'apprentissage correspond à la phase où le réseau ajuste ses paramètres internes (poids et biais) pour minimiser une fonction de perte (*loss function*), traduisant l'erreur entre la sortie prédite et la vérité terrain. Principaux éléments de cette phase :

- **Fonction de coût** : par exemple *cross-entropy loss* pour la classification ou *mean squared error (MSE)* pour la régression.
- **Optimiseur** : algorithme comme *Stochastic Gradient Descent (SGD)*, *Adam*, *RMSprop* permettant la mise à jour des poids.
- **Backpropagation** (*rétropropagation de l'erreur*) : algorithme de base qui calcule le gradient de la fonction de perte et le propage en sens inverse dans le réseau.
- **Mini-batches** : au lieu de traiter toutes les données en une fois, les données sont divisées en petits groupes pour accélérer l'apprentissage et améliorer la convergence.

L'apprentissage se déroule sur plusieurs époques (passes complètes sur les données d'entraînement), jusqu'à ce que la fonction de perte atteigne un minimum acceptable.

1.2.2.4. Validation et ajustement des hyper-paramètres

Les hyper-paramètres sont les paramètres non appris par le modèle, mais fixés à l'avance. Leur choix influence fortement la performance et la stabilité de l'apprentissage. Exemples :

- Le taux d'apprentissage (*learning rate*),
- Le nombre de couches et de neurones,
- Le batch size,
- Le type de fonction d'activation,
- Le nombre d'époques,

- La régularisation (*dropout*, *weight decay*).

Leur optimisation peut être réalisée par :

- Recherche exhaustive (*grid search*),
- Recherche aléatoire (*random search*),
- Optimisation bayésienne,
- Hyperband ou *AutoML*.

Le jeu de validation est utilisé pour suivre les performances pendant l'entraînement, et éviter le surapprentissage (*overfitting*). Des techniques telles que la cross-validation, early stopping, ou k-fold peuvent être utilisées.

1.2.2.5. Évaluation du modèle

Après la validation, le modèle final est évalué sur un jeu de test indépendant, jamais vu pendant l'apprentissage ou la validation. Cela permet de mesurer sa capacité à généraliser. Les indicateurs de performance varient selon la tâche :

- Pour la classification : *accuracy*, *precision*, *recall*, *F1-score*, *AUC-ROC*.
- Pour la régression : *MAE*, *RMSE*, *R² score*.
- Pour la segmentation d'image : *IoU* (*Intersection over Union*), *Dice coefficient*.
- Pour la détection d'objets : *mAP* (*mean Average Precision*).

Une analyse d'erreurs (confusion matrix, courbes ROC) est souvent utile pour identifier les classes mal prédites et les biais potentiels.

1.2.2.6. Déploiement

Une fois le modèle validé, il peut être déployé pour être utilisé en conditions réelles. Cette étape inclut :

- Export du modèle dans un format standard (ex. .h5 .pb, .onnx).
- Déploiement dans un environnement de production : serveurs web (Flask, FastAPI), microservices Docker, plateformes cloud (AWS SageMaker, Google AI Platform, etc.).
- Optimisation pour l'inférence : réduction de la taille du modèle (pruning), *quantization*, conversion vers des formats accélérés (ex. TensorRT, CoreML).
- Surveillance et mise à jour (*monitoring*) : suivi des performances en temps réel, collecte de nouvelles données pour permettre un ré-entraînement périodique (*model retraining*).

Le déploiement doit également prendre en compte des contraintes de sécurité, de scalabilité, de latence et d'éthique, surtout pour les applications sensibles comme la santé, la justice ou les finances.

1.2.3 Types d'approches d'apprentissages profond

À l'instant, l'apprentissage automatique, les approches d'apprentissage en profondeur se divisent généralement en trois catégories : supervisées, semi-supervisées et non supervisées. Par ailleurs, une autre catégorie d'apprentissage appelée apprentissage par renforcement (Reinforcement Learning, RL) — ou apprentissage par renforcement profond (Deep Reinforcement Learning, DRL) est souvent considérée comme une forme d'apprentissage semi-supervisé, voire non supervisé, selon le contexte [4].

1.2.3.1 Apprentissage supervisé :

C'est une technique d'apprentissage basée sur l'utilisation des données étiquetées. Dans le cas des approches supervisées en deep learning, le modèle dispose d'un ensemble d'entrées associées à des sorties cible. Il ajuste alors les paramètres de son réseau de manière itérative afin d'optimiser l'approximation des sorties attendues. Parmi les principales architectures utilisées dans ce type d'apprentissage, on retrouve les réseaux de neurones profonds (Deep Neural Networks – DNN), les réseaux de neurones convolutifs (Convolutional Neural Networks – CNN), les réseaux de neurones récurrents (Recurrent Neural Networks – RNN), y compris la mémoire à long terme (Long Short Term Memory –LSTM) et les unités récurrentes fermées (Gated Recurrent Units – GRU) [4].

1.2.3.2 Apprentissage semi supervisé

L'apprentissage semi-supervisé repose sur l'utilisation de jeux de données partiellement étiquetés, contrairement à l'apprentissage supervisé, il combine un petit nombre de données annotées avec un grand volume de données non annotées afin d'améliorer la performance des modèles. Cette approche ne doit pas être confondue avec l'apprentissage par renforcement. Dans certains cas, les techniques de Deep Reinforcement Learning (DRL) ainsi que les Réseaux antagonistes Génératifs (GAN) peuvent être adaptées à des scénarios d'apprentissage semi-supervisé. De plus, les réseaux de neurones récurrents (RNN), y compris LSTM et GRU, sont également utilisés dans ce contexte [4].

1.2.3.3 Apprentissage non supervisé

L'apprentissage non supervisé se fait sans données étiquetées. Dans ce cas, le réseau apprend à extraire des représentations interne ou des caractéristiques pertinentes à partir des données brutes, dans le but de découvrir des structures cachées ou des relations sous-jacentes

Les approches courantes incluent le clustering, la réduction de dimensionnalité et les techniques génératives. Plusieurs modèles de deep learning sont particulièrement efficaces dans ce contexte, notamment :

- Les auto-encodeurs (AE),
- Les Machines de Boltzmann Restreintes (RBM),
- Ainsi que les réseaux adversaires génératifs (GAN), récemment introduits.

En outre, des architectures récurrentes comme les RNN, notamment LSTM, ainsi que des techniques issues de l'apprentissage par renforcement (RL), sont également exploitées dans des tâches non supervisées dans divers domaines d'application [5].

1.3 Les Réseaux de Neurones Convolutifs (CNN)

1.3.1 Définition

Les CNN (Convolutional Neural Networks) sont des architectures spécialement conçues pour le traitement des données visuelles. Leur fonctionnement repose sur l'utilisation de couches de convolution, qui permet d'extraire automatiquement des motifs hiérarchiques dans les images, depuis les contours simples jusqu'à des formes plus complexes, facilitant ainsi la reconnaissance d'objets ou de structures visuelles. [6]

1.3.2 Les couches de CNN

Les réseaux de neurones convolutifs (CNN) sont spécialement conçus pour traiter les données structurées en grille, telles que les images. Leur architecture repose sur une série de couches spécifiques qui permettent l'extraction automatique et hiérarchique des caractéristiques visuelles. Chaque couche remplit un rôle bien défini dans le processus de traitement et d'apprentissage. Voici les couches principales d'un CNN :

1.3.2.1 Les couches de convolution (Convolutional Layers)

Les couches de convolution sont au cœur des CNN. Elles ont pour rôle d'extraire automatiquement les caractéristiques locales présentes dans les images d'entrée, comme les bords, les textures, ou encore les motifs complexes.

1.3.2.1.1 Fonctionnement :

Une couche de convolution applique un filtre (ou noyau) – généralement de petite taille (par exemple 3×3 , 5×5) – qui glisse sur l'image d'entrée en effectuant un produit scalaire entre les valeurs du filtre et celles de la région correspondante de l'image. Cela donne lieu à une carte de caractéristiques (*feature map*).

1.3.2.1.1 Profondeur de la couche :

- Chaque couche peut apprendre plusieurs filtres (par exemple 32 ou 64), chacun étant responsable de détecter un motif particulier.
- Le nombre de filtres dans une couche détermine la profondeur de la carte de sortie. Par exemple, une couche avec 64 filtres produit 64 *feature maps*.

1.3.2.1.2 Padding (Remplissage) :

- Sans padding, l'image diminue de taille à chaque convolution.
- Avec padding, on ajoute des pixels (souvent des zéros) autour de l'image pour conserver ses dimensions.
 - Valid padding : sans ajout → la taille diminue.
 - Same padding : ajoute des zéros pour garder la même taille en sortie.

1.3.2.1.3 Stride (Pas de déplacement) :

- Le **stride** indique combien de pixels le filtre se déplace à chaque opération.
 - Stride = 1 : glissement pixel par pixel.
 - Stride > 1 : réduction de la taille en sortie.

Ces couches capturent des caractéristiques de plus en plus complexes au fur et à mesure que l'on avance dans les couches du réseau.

1.3.2.2 Les couches de pooling (ou sous-échantillonnage)

Les couches de pooling réduisent la dimensionnalité spatiale (hauteur $\times$ largeur) des *feature maps* tout en conservant les informations essentielles. Cela permet :

- De diminuer le nombre de paramètres,
- De réduire le surapprentissage,
- D'accélérer les calculs.

1.3.2.2.1 Types de pooling :

1.3.2.2.1.1 Max Pooling :

- Sélectionne la valeur maximale dans chaque région de la *feature map*.
- Ex : pour un filtre de 2×2 , la sortie est la valeur la plus élevée des 4 pixels.
- Utilisé car il conserve les caractéristiques dominantes et améliore la robustesse au bruit.




Figure 2 : Exemple de processus du Max Pooling [7].

1.3.2.2.1.2 Average Pooling :

- Calcule la moyenne des valeurs dans chaque sous-région.
- Moins agressif que le max pooling, mais parfois moins performant dans les tâches de classification.



Figure 3 : Exemple de processus du Average Pooling [7].

1.3.2.2.1.3 Stride et taille :

- Comme pour la convolution, le *stride* et la taille du filtre déterminent le degré de réduction.
- Exemple : un *max pooling* 2×2 avec stride 2 divise la taille par deux.

1.3.2.3 Couche de correction (fonction d'activation)

Après chaque convolution, une fonction d'activation non linéaire est généralement appliquée. Elle permet au réseau d'apprendre des relations complexes et non linéaires dans les données.

1.3.2.3.1 La plus utilisée : ReLU (Rectified Linear Unit)

- Fonction définie par : $f(x) = \max(0, x)$
- Avantages :
 - o Simple à calculer,
 - o Supprime les valeurs négatives (introduit de la non-linéarité),
 - o Favorise la convergence rapide.

1.3.2.3.2 Autres fonction

- **Leaky ReLU** : laisse passer un faible gradient pour les valeurs négatives,
- **Sigmoid** : $f(x) = 1 / (1 + e^{-x})$ (utilisée dans les couches de sortie),
- **Tanh** : $f(x) = (e^x - e^{-x}) / (e^x + e^{-x})$ (centrée sur zéro).

1.3.2.4. Couches entièrement connectées (Fully Connected Layers)

Les couches entièrement connectées (FC), situées à la fin du réseau, sont des perceptrons multicouches classiques. Elles prennent en entrée un vecteur 1D obtenu en aplatissant les cartes de caractéristiques (flattening), puis produisent une sortie finale correspondant à la tâche.

- **Rôle :**

- Fusionner toutes les caractéristiques extraites et apprendre à faire des décisions globales.
- Dans une tâche de classification, la dernière FC fournit une distribution de probabilité sur les classes via une fonction softmax.

- **Exemple :**

Pour une tâche de classification binaire (ex : cancer / pas cancer), la couche de sortie contient un seul neurone avec activation sigmoïde. Pour une tâche multi-classes, il y aura autant de neurones que de classes, avec softmax.

1.3.2.5 Couche de perte (Loss Layer)

La couche de perte (ou fonction de coût) mesure l'écart entre la sortie prédite du modèle et la vérité terrain (*ground truth*). Cette erreur est ensuite minimisée pendant l'apprentissage à l'aide d'un algorithme d'optimisation (ex : Adam, SGD).

- **Fonctions de perte fréquentes :**

- Binary Cross-Entropy : pour les classifications binaires.
- Categorical Cross-Entropy : pour les classifications à plusieurs classes.
- Mean Squared Error (MSE) : pour les tâches de régression.
- Dice Loss / IoU Loss : pour les tâches de segmentation.

- **Rôle :**

- Guider l'optimisation du réseau en indiquant dans quelle direction ajuster les poids pour améliorer les performances.
- La rétropropagation (*backpropagation*) repose sur cette fonction pour calculer les gradients.

L'apprentissage s'effectue en ajustant les poids des filtres convolutifs à l'aide de rétropropagation du gradient (*backpropagation*), en minimisant une fonction de perte qui mesure l'écart entre la prédiction du réseau et la vérité terrain, dans la figure (4), une architecture générale d'un réseau de neurones convolutif (CNN) est illustrée [8].




Figure 4 : Architecture d'un Réseau de Neurones Convolutif (CNN) pour la Classification d'images [9].

1.3.3 Apprentissage par transfert :

L'apprentissage par transfert a permis de réduire significativement les besoins de données annotées. Il consiste à réutiliser un modèle pré-entraîné, c'est-à-dire un réseau dont les poids et les paramètres ont été appris à partir d'un grand jeu de données. Ce modèle agit alors comme un extracteur de caractéristiques généralisé.

Dans la pratique, on remplace la dernière couche du réseau (souvent un classificateur) par une nouvelle couche adaptée à la tâche cible. Les couches précédentes sont figées, c'est-à-dire que leurs poids ne sont pas mis à jour lors de l'optimisation (descente de gradient). Seule la dernière couche est alors entraînée sur les nouvelles données spécifiques à la tâche [10].




Figure 5 : Application de l'apprentissage par transfert (Transfer Learning) [11]

a) Principe :

L'apprentissage par transfert repose sur l'idée d'utiliser un modèle pré-entraîné sur une grande base de données (souvent généraliste, comme ImageNet), puis à l'adapter à une tâche spécifique, souvent avec un nombre limité de données disponibles [12][13][14][15][16][17]. Cette technique permet de tirer parti des connaissances déjà apprises par le modèle pour accélérer l'apprentissage et améliorer les performances sur de nouveaux jeux de données.

b) Processus :

- Chargement d'un modèle pré-entraîné, tel que VGG, ResNet, Inception généralement formé sur un grand jeu de données comme ImageNet [12][14][15][17].
- Remplacement ou suppression de la dernière couche du réseau (souvent classificateur) afin de l'adapter à la nouvelle tâche [15][17].
- Gel des couches précédentes, les poids des couches déjà entraînées sont conservés et ne sont pas mis à jour durant l'apprentissage [12][14].
- Entraînement du nouveau classificateur (ou des dernières couches) sur les données spécifiques à la tâche cible, permettant une adaptation rapide et efficace [12][14][15][17].

c) Architectures utilisées :

- **VGG16, VGG19** : architectures simples et profondes, souvent utilisées comme base pour des tâches de classification d'images.
- **ResNet (ResNet50, ResNet101)** : réseaux à connexions résiduelles, très efficaces pour des modèles profonds grâce à leur capacité à éviter le problème du gradient qui disparaît [9][10][13].
- **InceptionV3, EfficientNet** : architectures optimisées pour la performance et l'efficacité computationnelle, largement utilisées pour des applications nécessitant un bon compromis entre précision et rapidité [14][15][17].

d) Applications :

- Détection de pathologies rares à partir d'un nombre limité d'images annotées, en tirant parti de modèles pré-entraînés pour compenser le manque de données [12][14][15][17].

- Adaptation rapide à de nouveaux contextes cliniques, par exemple lorsqu'un modèle doit être utilisé sur un autre type d'imagerie ou dans un nouvel environnement hospitalier [12][14][15].
- Amélioration des performances sur des jeux de données restreints, en transférant les connaissances acquises sur de grands ensembles de données vers des tâches plus spécifiques [12][14][15][17].

1.4 Application du CNN dans le domaine médical

Les CNN (Convolutional Neural Networks) ont révolutionné le domaine de diagnostic médical, notamment pour l'analyse d'images issues de techniques d'imagerie telle que les radiographies, l'IRM, la tomodensitométries (CT scan), et la mammographie. Dans le cadre du cancer du sein, les CNN jouent un rôle clé dans plusieurs domaines [18] :

- **Détection des anomalies** : Les CNN permettent de repérer des anomalies subtiles dans les images médicales, telles que des microcalcifications ou des tumeurs, qui peuvent être difficiles à identifier pour un radiologue humain. Les microcalcifications, par exemple, sont souvent le signe d'un cancer précoce, et leur détection peut permettre une prise en charge rapide et potentiellement sauver des vies [19].
- **Classification des lésions** : Une fois les anomalies détectées, les CNN peuvent classer ces lésions comme étant bénignes ou malignes, avec une grande précision. Cette classification est cruciale, car elle permet de guider les décisions thérapeutiques et d'éviter des biopsies inutiles lorsque les lésions sont bénignes [20].
- **Segmentation des zones suspectes** : En plus de détecter et classer les anomalies, les CNN sont également capables de segmenter précisément les zones suspectes sur les images, en identifiant les contours des lésions. Cette segmentation aide non seulement à visualiser l'extension de la tumeur, mais aussi à suivre son évolution au fil du temps, offrant ainsi un outil puissant pour le suivi longitudinal des patients [21].

1.5 Conclusion

Ce premier chapitre a permis d'établir les fondements théoriques nécessaires à la compréhension du projet. Nous avons exploré les principes clés de l'apprentissage profond, en mettant l'accent sur le rôle central des réseaux de neurones convolutifs (CNN) dans le traitement et l'analyse d'images médicales. L'intérêt de l'apprentissage par transfert a également été souligné comme une solution efficace face à la rareté des données annotées, un défi fréquent dans le domaine médical. L'ensemble de ces notions constitue la base méthodologique sur laquelle s'appuiera notre travail. Dans le chapitre suivant, nous aborderons de manière concrète la détection du cancer du sein à partir d'images médicales, en mettant en œuvre un état de l'art des travaux récents portant sur l'utilisation des réseaux de neurones convolutifs (CNN) pour la détection du cancer du sein, afin de situer notre démarche dans le contexte des recherches actuelles.

Chapitre 2

Détection du cancer de sein

2.1 Introduction

Le cancer du sein constitue l'une des principales causes de mortalité féminine dans le monde. Son dépistage précoce, associé aux progrès technologiques en intelligence artificielle, permet d'améliorer considérablement le pronostic. Les approches modernes de détection intègrent des algorithmes d'apprentissage automatique et profond, transformant ainsi les méthodes classiques d'analyse d'imagerie médicale.

2.2 Généralités sur le cancer de sein

2.2.1 Définition : C'est quoi le cancer de sein ?

Le cancer du sein résulte d'une multiplication anarchique des cellules de la glande mammaire. Il peut être d'origine canalaire ou lobulaire, avec un potentiel invasif variable [22].

2.2.2 Les types du cancer de sein

Les types les plus fréquents sont les carcinomes canaux infiltrants et les carcinomes lobulaires infiltrants. On distingue également des formes plus rares telles que les carcinomes mucineux ou médullaires.




Figure 6 : Types de cancer de sein [23]

2.2.3 Les symptômes et les facteurs de risques

Les signes cliniques incluent une masse palpable, une rétraction du mamelon, une modification de la peau ou un écoulement mammaire. Les facteurs de risque sont multiples : antécédents familiaux, mutations génétiques (BRCA1/2), âge avancé, traitement hormonal prolongé [24].

2.2.4 Statistiques du cancer de sein : dans le monde et en Algérie

Selon l'OMS, plus de 2,3 millions de cas ont été recensés en 2020 dans le monde [25]. En Algérie, l'incidence annuelle est estimée à environ 14 000 nouveaux cas, avec un âge moyen au diagnostic de 48 ans [26].

Mortalité liée au cancer du sein : des disparités selon les pays




Figure 7 : Statistiques de cancer de sein dans le monde depuis 2022.[27]

2.3 Les approches de détection du cancer de sein

Cette section présente les principales méthodes de détection du cancer du sein, allant des techniques traditionnelles aux approches les plus avancées utilisant l'intelligence artificielle.

2.3.1 Les approches traditionnelles

2.3.1.1 Auto-examens des seins et examens cliniques des seins

Ces méthodes reposent sur la palpation manuelle par la patiente ou le clinicien afin de détecter toute anomalie apparente.

2.3.1.2 Mammographie

La mammographie est l'outil de dépistage de référence. Elle permet de détecter des anomalies suspectes, parfois avant même l'apparition de symptômes [28].

2.3.1.3 Échographie mammaire

Utilisée en complément de la mammographie, elle est utile pour examiner les seins denses ou différencier une masse solide d'un kyste.

2.3.1.4 IRM mammaire (Imagerie par Résonance Magnétique)

Indiquée chez les femmes à haut risque, l'IRM offre une sensibilité élevée pour la détection des lésions, mais reste coûteuse et moins spécifique [29].

2.3.1.5 Tomosynthèse mammaire (mammographie 3D)

Cette technique améliore la visualisation des structures mammaires superposées, augmentant la précision du dépistage.

2.3.1.6 Biopsie mammaire

Permet de confirmer le diagnostic en analysant un échantillon de tissu suspect.

2.3.1.7 PET scan

Utilisé pour détecter les métastases ou évaluer la réponse au traitement dans les cas avancés.

2.3.2 Les systèmes d'aide du diagnostic

2.3.2.1 Les approches basées sur les caractéristiques

Ces méthodes extraient des caractéristiques manuelles telles que :

- Les caractéristiques de forme (bords, contours, etc.)
- Les caractéristiques de couleur (intensité, homogénéité)
- Les caractéristiques de texture (GLCM, LBP, Gabor)

Ces descripteurs sont ensuite introduits dans des classificateurs comme SVM, KNN ou Random Forest [30][31].

2.3.3 Les approches intelligentes

Avec l'essor de l'intelligence artificielle, des approches plus puissantes ont vu le jour. Elles se divisent en deux grandes catégories : l'apprentissage automatique et l'apprentissage profond.

2.3.3.1 Approches basées sur l'apprentissage automatique

Le Machine Learning repose sur des modèles comme SVM, Random Forest, KNN, Naive Bayes ou AdaBoost. Ces techniques permettent de détecter ou classifier les anomalies avec une bonne précision ($> 95\%$) sur des bases comme WDBC. Sharma et al. ont utilisé Random Forest avec sélection de caractéristiques obtenant une précision de 98% [32]. Khare et al. ont appliqué SVM couplé à la réduction de dimension PCA atteignant une précision de $97,3\%$. Yassin et al. ont testé un modèle basé sur KNN combiné à des paramètres morphologiques sur DDSM avec une précision de $95,6\%$. El Houby et al. ont proposé un système hybride combinant NB et SVM atteignant $96,1\%$ de précision [33]. Enfin, Vapnik a posé les bases théoriques du SVM utilisé largement depuis dans les systèmes d'aide au diagnostic [34].

2.3.3.2 Approches basées sur l'apprentissage profond

2.3.3.2.1 Classification

La classification des lésions mammaires en bénignes ou malignes est l'un des axes les plus étudiés. Gu et al. ont appliqué le modèle EfficientNet-B0 sur la base INbreast, entraîné avec fine-tuning, obtenant une précision de 96,5 % et une AUC de 0,982, démontrant une supériorité sur des architectures classiques [35]. Becker et al. ont proposé une approche par ensemble de CNN entraînés sur des mammographies numériques, atteignant une précision de 89 % en combinant plusieurs classificateurs [36]. Ng et al. ont évalué la performance du système Mia® 2.0 dans un cadre de dépistage clinique de routine, observant une amélioration significative du taux de détection avec un gain de 1,6 cas pour 1000 patientes examinées [37]. Rakhlin et al. ont expérimenté une version de ResNet appliquée à DDSM avec une technique de vote ensembliste, atteignant 94,7 % de précision [38]. Enfin, Muduli et al. ont conçu un CNN hybride combinant des couches convolutives et des mécanismes de fusion, obtenant un taux de classification de 95,2 % sur la base MIAS, ont appliqué un CNN hybride avec des couches de fusion sur MIAS, obtenant un taux de classification de 95,2 % [39].

2.3.3.2.2 Segmentation

La segmentation précise des structures mammaires est essentielle pour localiser et quantifier les lésions. Janse et al. ont utilisé l'architecture U-Net++ sur CBIS-DDSM et ont obtenu un Dice coefficient de 0,921, mettant en évidence l'intérêt des connexions denses entre couches [40]. Kumar et al. ont combiné ResUNet et un module d'attention spatial, atteignant un Dice de 0,94 sur un sous-ensemble annoté manuellement [41]. Zhou et al. ont conçu une version multi-échelle de SegNet, adaptée aux microcalcifications, avec un Dice de 0,87 [42]. Rakhlin et al. ont appliqué DeepLabv3+ pour la segmentation de masses, optimisant le post-traitement par CRF, et ont obtenu un Dice de 0,89 [43]. Al-antari et al. ont intégré un module de classification à U-Net, assurant une cohérence entre segmentation et diagnostic, atteignant un Dice moyen de 0,93 sur INbreast. ont proposé un U-Net intégré à un classificateur CNN pour améliorer la cohérence entre segmentation et diagnostic, atteignant un Dice de 0,93 [44].

2.3.3.2.3 Détection

La détection consiste à localiser automatiquement les régions suspectes dans les mammographies à l'aide de boîtes englobantes. Huang et al. ont appliqué YOLOv5, obtenant une mAP de 91,2 %, avec des performances en temps réel [45]. Wang et al. ont utilisé Faster R-CNN combiné à ResNet50 sur DDSM, avec une précision de 93,8 % et un rappel de 90,2 % [46]. Chen et al. ont introduit DETR avec Swin Transformer, atteignant un F1-score de 0,88 tout en assurant une robustesse sur les cas bruités [47]. Rasti et al. ont proposé une méthode CNN-SVM pour détecter les masses, atteignant 92,1 % de précision, démontrant la pertinence de la fusion de modèles [48]. Enfin, Liu et al. ont appliqué RetinaNet sur DDSM avec un ancrage optimisé, obtenant un mAP global de 90,3 %. ont présenté RetinaNet sur DDSM, atteignant un mAP de 90,3 % pour la détection des lésions bénignes et malignes [49].

2.3.3.2.4 Approches combinées

Certaines architectures récentes visent à intégrer plusieurs tâches (classification, segmentation et/ou détection) dans un même réseau afin de maximiser la performance globale et de réduire les coûts de calcul. Shen et al. ont proposé une architecture multitâche composée de trois branches parallèles dédiées respectivement à la classification [50], à la segmentation et à la localisation des lésions. Cette approche a permis d'atteindre une précision de 94 % tout en réduisant le temps de traitement de plus de 40 % par rapport aux modèles individuels.

Zhao et al. ont utilisé Mask R-CNN modifié, intégrant des sorties doubles pour la classification et la segmentation. Ils ont obtenu un Dice coefficient de 0,90 pour la délimitation des masses et une AUC de 0,95 pour la classification des anomalies sur la base CBIS-DDSM, démontrant l'efficacité de l'approche intégrée [51].

Jiang et al. ont développé un modèle fusionnant U-Net++ et ResNet dans un réseau multitâche. En utilisant un mécanisme de pondération dynamique des pertes, ils ont atteint un F1-score moyen de 0,91 sur CBIS-DDSM, avec une cohérence notable entre les sorties de segmentation et de classification [52].

Chougrad et al. ont mis en place une chaîne de traitement combinant un module de prétraitement basé sur l'égalisation adaptative et un CNN profond conçu pour extraire conjointement les caractéristiques de localisation et de nature de la tumeur. Le modèle a été validé sur une base privée et a montré un équilibre optimal entre sensibilité et spécificité [53].

Enfin, Darwish et al. ont développé un pipeline end-to-end regroupant trois modules intégrés pour la classification, la détection et l'analyse multi-vues. Leur système a été évalué sur des données cliniques réelles, démontrant une forte robustesse dans un contexte de dépistage assisté par l'IA [54].

2.3.4 Synthèse des travaux

L'évolution des méthodes de détection montre un changement majeur, marqué par l'intégration de l'intelligence artificielle (IA) aux pratiques médicales traditionnelles. Les méthodes classiques, comme la mammographie, l'échographie et l'IRM, restent très importantes pour le dépistage initial et la confirmation des diagnostics. Cependant, elles présentent certaines limites, notamment en termes de sensibilité, de spécificité et de dépendance à l'expertise humaine.

L'arrivée des systèmes d'aider au diagnostic, initialement fondés sur l'extraction manuelle de caractéristiques (telle que la forme, la couleur ou la texture) puis sur des algorithmes de classification comme SVM ou Random Forest, a permis d'améliorer la précision de détection. Cependant, le véritable changement réside dans l'essor des méthodes d'intelligences artificielle avancées, en particulier l'apprentissage profond. Les réseaux de neurones convolutifs CNN ont démontré une efficacité remarquable dans le classement, la segmentation, la détection des lésions mammaires, atteignant des niveaux de performance inégalés dans les publications récentes.

L'intégration de modèles multitâches, capables d'effectuer simultanément la classification, la segmentation et la détection, constitue une avancée majeure. Ces architectures combinées permettent de réduire le temps de traitement, d'améliorer la cohérence des résultats et de faciliter l'intégration de l'IA dans les protocoles cliniques réels. Les performances

obtenues sur des bases de données publiques et cliniques révèlent des taux élevés de précision, de coefficient Dice et de F1-score, confirmant la robustesse et l'efficacité de ces systèmes.

En conclusion, la détection du cancer du sein bénéficie aujourd'hui d'une synergie efficace entre l'expertise médicale et les innovations algorithmiques. L'intelligence artificielle ne se limite plus à un simple rôle d'assistance : elle devient un partenaire incontournable, ouvrant la voie à un dépistage plus précoce, plus fiable et mieux adapté aux exigences du terrain clinique.

2.4 Conclusion

L'intelligence artificielle transforme le paysage du dépistage du cancer du sein. Grâce à une synergie entre expertise médicale et des algorithmes performants, le diagnostic devient plus rapide, précis et fiable. Cette avancée ouvre la voie à des systèmes d'aide à la décision médicale plus robustes, accessibles et adaptés aux contextes cliniques réels. Le prochain chapitre abordera l'implémentation concrète de ces approches, en s'intéressant notamment à l'architecture des réseaux de neurones, ainsi qu'aux étapes de prétraitement, d'entraînement et de validation des modèles.

Chapitre 3

Implémentation et résultats

3.1 Introduction

Ce chapitre présente la mise en œuvre pratique de notre modèle de détection du cancer du sein, depuis la sélection des outils jusqu'à l'évaluation des résultats expérimentaux. Il décrit les étapes techniques, les scénarios d'implémentation, ainsi que les résultats obtenus à l'aide des modèles de réseaux de neurones convolutifs (CNN).

3.2 Outils et matériels utilisés

3.2.1 Ressources matérielles

Dans le cadre de notre projet, nous avons choisi une plateforme parmi une variété d'options, notamment Hugging Face, Google Colab et Kaggle. Notre principal critère de sélection était la possibilité de former un modèle gratuitement, sans encourir de frais supplémentaires. Nous avons choisi cette stratégie afin de maximiser l'accessibilité et la flexibilité de notre projet en garantissant que les ressources nécessaires à la formation du modèle étaient disponibles sans nécessiter de dépenses financières supplémentaires. Cette décision nous a permis de nous concentrer sur le développement du modèle et l'exploration des données sans avoir à divulguer les restrictions budgétaires liées à l'utilisation des ressources payantes.



Figure 8 : Logo de la plateforme utilisée dans le cadre de notre travail

3.2.2 Ressources logicielles

Nous avons utilisé un certain nombre de bibliothèque pour notre projet dont les principaux sont :

- **Python** : Python est un langage de programmation interprété, polyvalent et populaire, utilisé dans de nombreux domaines. Il est particulièrement adapté à l'apprentissage automatique pour plusieurs raisons ; sa syntaxe simple et expressive, rend facile à lire et à comprendre, facilitant ainsi le développement, la maintenance et le débogage des modèles d'apprentissage automatique, surtout lorsqu'il y a une collaboration entre équipes de développement et de recherche. Python dispose d'un écosystème riche et varié de bibliothèques open source spécialement conçues pour l'apprentissage profond, telles que TensorFlow, Scikit-learn, Keras et NumPy. Ces bibliothèques offrent des fonctionnalités avancées pour la construction, l'entraînement et l'évaluation de modèles d'apprentissage profond.

- **Tensorflow**: une bibliothèque open source développée par Google, conçue pour faciliter la création et le déploiement de modèles d'apprentissage automatique et de réseaux neuronaux. Lancé en 2015, TensorFlow est devenu l'une des principales bibliothèques d'apprentissage automatique au monde, offrant une flexibilité et une extensibilité remarquables pour une variété de tâches, des problèmes de classification d'images à la génération de langage naturel. Son architecture modulaire et sa vaste communauté d'utilisateurs et de contributeurs ont contribué à son succès et à son adoption généralisée dans l'industrie et la recherche. Au fil des années, TensorFlow a connu plusieurs versions majeures, introduisant de nouvelles fonctionnalités et améliorations pour répondre aux besoins changeants de la communauté d'apprentissage automatique.

- **Keras** : une bibliothèque open source développée par François Chollet, maintenant ingénieur chez Google, qui fournit une interface conviviale pour la création, la formation et le déploiement de réseaux neuronaux. Lancée en 2015, Keras a été conçue pour offrir une abstraction simple et intuitive aux développeurs d'apprentissage automatique, facilitant ainsi le prototypage rapide et l'expérimentation avec les modèles de Deep Learning.

Initialement indépendante, Keras a été intégrée à TensorFlow en 2017 en tant que module TensorFlow. Keras, devenant ainsi l'API par défaut pour construire des modèles dans TensorFlow. Son adoption massive dans la communauté d'apprentissage automatique en fait l'une des bibliothèques les plus populaires et les plus utilisées pour le développement de modèles de Deep Learning.

- **Numpy** : une bibliothèque open-source pour Python qui fournit des outils pour travailler avec des tableaux multidimensionnels et des fonctions mathématiques pour manipuler ces tableaux de manière efficace. Lancée en 2006 par Travis Oliphant, NumPy a été conçue pour offrir des performances élevées lors de la manipulation de données numériques, en utilisant des tableaux optimisés en mémoire et des opérations vectorielles. Cette bibliothèque est largement utilisée dans les domaines de l'apprentissage automatique, la simulation numérique, le traitement d'images et le calcul scientifique en général. Son intégration étroite avec d'autres bibliothèques de données, telles que Pandas et Matplotlib, en fait un élément central de l'écosystème Python pour la science des données. NumPy a connu plusieurs versions majeures au fil des ans, introduisant de nouvelles fonctionnalités et améliorations pour répondre aux besoins croissants de la communauté.

- **Streamlit** : est une librairie open source Python créée en 2018, signifie que le code source est accessible à tous. Cela implique qu'il est réutilisable par tous les utilisateurs pour créer son propre logiciel et permet ainsi une grande flexibilité sur les besoins de chacun. L'open source qui est devenu un véritable mouvement dans le développement logiciel, encourage la production collaboratrice et permet, ainsi, d'améliorer la qualité des logiciels [55].

- **PlantUML** : est un outil robuste utilisé pour créer des diagrammes UML par le biais d'une description textuelle simple et facilement interprétable. [56]



Figure 9 : Logos des différentes ressources logiciel [55]

3.3 UML

3.3.1 Définition

UML est un langage commun utilisé par les analystes commerciaux, les architectes logiciels et les développeurs pour décrire, spécifier, concevoir et documenter les processus commerciaux existants ou nouveaux, la structure et le comportement des artefacts des systèmes logiciels [57].

3.3.2 Diagramme de cas d'utilisation

Diagramme de cas d'utilisation capture les fonctionnalités et les exigences du système en utilisant des acteurs et des cas d'utilisation. Les cas d'utilisation modélisent les services, les tâches et les fonctions qu'un système doit exécuter. Les cas d'utilisation représentent des fonctionnalités de haut niveau et la manière dont un utilisateur gérera le système. Les cas d'utilisation sont les concepts fondamentaux de la modélisation du langage unifié [58].




Figure 10 : Diagramme de cas d'utilisation

3.3.3 Diagramme de séquence

Le diagramme de séquence est défini comme un type de diagramme UML (Unified Modeling Language) utilisé dans le génie logiciel et la conception de systèmes pour visualiser les interactions et la communication entre divers composants ou objets au sein d'un système [59].




Figure 11 : Diagramme de séquence

3.3.4 Diagramme de classe

Les diagrammes de classes sont l'un des types de diagrammes UML les plus utiles, car ils décrivent clairement la structure d'un système particulier en modélisant ses classes, ses attributs, ses opérations et les relations entre ses objets [60].




Figure 12 : Diagramme de classe

3.4 Collecte et prétraitement de données

3.4.1 Sources de données

Les deux jeux de données utilisés dans notre étude ont été récupérés sur la plateforme kaggle. Cette dernière offre un large éventail de jeux de données public, accessibles librement, permettant d'expérimenter de nouvelles techniques d'apprentissage ou se perfectionner dans le domaine l'intelligence artificielle et de l'apprentissage automatique.

- La première base de données utilisée est « Breast Histopathology Images » [61]. Elle représente un effort collaboratif visant à exploiter les capacités de l'imagerie RGB dans le domaine de la détection de cancer de sein grâce à des méthodologies d'apprentissage profond.

Cette base contient un total de 277 524 images, dont 197 538 sont non cancéreuses (NON-IDC) et 79 986 présentent des signes de cancer (IDC). La figure ci-dessous illustre quelques exemples d'images issues de ce jeu de données.



Figure 13 : Exemples d'images de la base de données Breast Histopathology images [61].

- La deuxième base de données utilisée est Breast Ultrasound Images Dataset [62]. Cet ensemble de données, librement accessible à des fins de recherche, contient 789 images annotées. Contrairement à ce que son nom pourrait laisser penser, il s'agit d'images

échographiques (et non de mammographies) du sein, classées selon trois catégories : normales, bénignes et malignes.




Figure 14 : Exemples d'images de la bdd Breast Ultrasound Images Dataset [62].

3.4.2 Prétraitement des données

Avant l'entraînement du modèle, les données ont été prétraitées pour garantir une cohérence et une qualité optimales. Cela inclut le redimensionnement de toutes les images à une taille standard de 50x50 pixels, la normalisation des valeurs de pixel pour les ramener dans une plage entre 0 et 1, et l'augmentation de données en appliquant des transformations aléatoires telles que des rotations, des zooms et des retournements horizontaux aux images d'entraînement afin d'augmenter la taille de l'ensemble d'entraînement et améliorer la généralisation du modèle.

Le premier dataset est divisé en deux classes principales « IDC » et « Non-IDC », toutes deux contenues dans trois dossiers pour le train le test et la validation.

Le deuxième dataset est divisé en trois classes principales « Benign », « Malignant », « Normal », toutes trois contenues dans trois dossiers pour le train le test et la validation avec la taille standard 224x224.

L'ensemble de données a été divisé en trois ensembles distincts : un ensemble d'entraînement contenant 60 % des données, un ensemble de validation contenant 20 % des données, et un ensemble de tests contenant les 20 % restants. Cette division a été effectuée de manière

aléatoire tout en garantissant que chaque ensemble contient une répartition équilibrée des classes d'images.

	Train	Test	Validation	Total
Breast Histopathology Images	194 266	41 629	41 629	277524
Breast Ultrasound Images Dataset	546	117	117	780

Tableau 1 - Résumé des ensembles de données utilisés

3.5 Modèle de détection de cancer de sein

Une fois les données prétraitées, nous pouvons procéder à la modélisation d'un réseau de neurones convolutifs (CNN). Cette phase comprend la construction, l'alimentation, l'entraînement, le test, puis le déploiement du modèle. Les algorithmes d'apprentissage profond constituent la base sur laquelle reposent les modèles de vision par ordinateur que nous mettons en œuvre. La première étape consiste donc à définir un Framework adapté pour la mise en place du CNN. Afin d'identifier l'architecture la plus performante, nous allons concevoir trois scénarios expérimentaux différents.

- Scénario initial : Dans ce scénario, nous avons d'abord essayé de construire notre propre modèle basé sur l'apprentissage profond convolutionnel, en utilisant la base *Breast Histopathology Images*.
- Scénario alternatif 1 : Dans ce scénario, nous utilisons l'apprentissage par transfert (Transfer Learning) avec le modèle pré-entraîné VGG16 sur le deuxième jeu de données, *Breast Ultrasound Images Dataset*, sans augmentation de données
- Scénario alternatif 2 : Dans ce scénario, nous utilisons l'apprentissage par transfert (Transfer Learning) avec le modèle pré-entraîné VGG16 sur le deuxième jeu de données, *Breast Ultrasound Images Dataset*, avec augmentation de données.

Dans la suite, nous allons détailler chaque scénario. Veuillez noter que tous les scénarios ont été expérimentés en utilisant le même environnement système, et que l'ensemble de données de l'apprentissage a été prétraité de manière identique.

3.5.1 Scénario initial

Dans cette section, nous avons construit notre modèle de base, lequel présente les caractéristiques suivantes :

3.5.1.1 Configuration du modèle

3.5.1.1.1 Architecture du modèle

Le modèle est composé de trois couches principales : une couche d'entrée, suivie de deux couches alternées de convolution et de max-pooling, puis qu'une couche de sortie.

3.5.1.1.2 Paramètres du modèle

Les deux premières couches de convolution utilisent des filtres de taille (50, 50), les deux suivantes des filtres de taille (64, 64), et la dernière des filtres de taille (32, 32). Chaque couche de convolution est suivie d'une couche de max-pooling de même taille.

3.5.1.1.3 Fonction d'activation

La fonction d'activation utilisée est *softmax*, il s'agit d'une fonction d'activation couramment employée dans les réseaux de neurones pour les tâches de classification multi-classe. Elle transforme les scores bruts produits par le modèle en probabilités normalisées, ce qui permet d'interpréter les sorties comme une distribution de probabilités sur les différentes classes.




Figure 15 : Fonction d'activation Softmax [63].

3.5.1.1.4 Optimiseur :

L'optimiseur utilisé est **Adam** (*Adaptive Moment Estimation*).

Adam est un algorithme d'optimisation couramment utilisé dans l'apprentissage automatique, en particulier pour l'entraînement de réseaux de neurones profonds. Proposé en 2014 par Diederik P. Kingma et Jimmy Ba, il combine les avantages de deux techniques d'optimisation populaires : la descente de gradient stochastique (SGD) avec moment et la méthode d'adaptation du taux d'apprentissage (Adagrad). Il maintient un taux d'apprentissage adaptatif pour chaque paramètre du modèle, ce qui lui permet de converger rapidement vers un minimum global tout en évitant les problèmes de convergence associés à une vitesse d'apprentissage constante.

3.5.1.1.5 Taux d'apprentissage (Learning rate)

Le taux d'apprentissage (*Learning rate*) est un hyperparamètre crucial dans le processus d'optimisation des algorithmes d'apprentissage automatique, en particulier dans l'entraînement des réseaux de neurones. Il représente la taille des pas que l'algorithme d'optimisation effectué lors de la mise à jour des poids du modèle pendant l'entraînement.

Plus précisément, le taux d'apprentissage contrôle la vitesse à laquelle le modèle se déplace dans l'espace des paramètres, dans le but de minimiser la fonction de perte. Un taux d'apprentissage trop faible peut entraîner une convergence très lente ~~du modèle~~, tandis qu'un taux d'apprentissage trop élevé peut ~~entraîner~~ conduire une convergence rapide mais instable, avec un risque de ne pas atteindre l'optimum global ou de le dépasser continuellement.

Plusieurs valeurs de taux d'apprentissage ont été testées (0.01, 0.058, 0.023, 0.001). Finalement, la valeur de **0.001** a été retenue par convention, car elle offre généralement un bon compromis entre stabilité et rapidité de convergence.

3.5.1.1.6 Nombre d'époques (epochs)

Une époque fait référence à une seule passe complète à travers l'ensemble des données d'entraînement lors du processus d'entraînement du modèle. Dans notre cas le nombre d'époques max à 20.

3.5.1.1.7 Taille de lot (Batch size)

Nous avons utilisé deux tailles de batch différent durant les différentes sessions d'apprentissage 32, 64 et nous avons opté pour la taille de de batch 32 à cause des contraintes mémoires de la plateforme Kaggle. Lors de l'entraînement d'un modèle d'apprentissage automatique, les données d'entraînement sont généralement divisées en « batches » (lots) pour des raisons de mémoire et d'efficacité de calcul. Pendant chaque époque, le modèle parcourt séquentiellement chaque batch, calcule les gradients par rétropropagation et ajuste les poids du modèle en fonction de ces gradients pour minimiser la fonction de perte.

3.5.1.1.8 Fonction de perte : la fonction de perte utilisé est le "binary crossentropy"

La Binary Cross-Entropy est une fonction de perte couramment utilisée dans les problèmes de classification binaire lors de l'entraînement des réseaux de neurones. Elle mesure la différence entre deux distributions de probabilité : la distribution des prédictions du modèle et la distribution des vraies étiquettes (labels).




Figure 16 : Principe de la fonction de perte [64].

3.5.1.2 Processus d'entraînement

3.5.1.2.1 Initialisation du modèle

Les poids du modèle ont été initialisés en utilisant une initialisation aléatoire selon une distribution normale. Les biais ont également été initialisés de manière aléatoire, mais généralement proches de zéro.

La figure 17 présente l'architecture de votre réseau de neurones convolutif (CNN) construit avec Keras en mode séquentiel. Le modèle est composé de plusieurs couches convolutionnelles (Conv2D) qui extraient progressivement les caractéristiques des images, chacune suivie de couches de pooling (MaxPooling2D) pour réduire la taille des données et de couches Dropout pour limiter le surapprentissage. Après l'extraction des caractéristiques, la couche Flatten transforme les données en un vecteur, puis une couche Dense finale réalise la classification. Cette structure permet au modèle de bien apprendre des images tout en restant robuste face au surapprentissage.

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 50, 50, 32)	896
conv2d_1 (Conv2D)	(None, 50, 50, 32)	9,248
max_pooling2d (MaxPooling2D)	(None, 25, 25, 32)	0
dropout (Dropout)	(None, 25, 25, 32)	0
conv2d_2 (Conv2D)	(None, 25, 25, 64)	18,496
conv2d_3 (Conv2D)	(None, 25, 25, 64)	36,928
max_pooling2d_1 (MaxPooling2D)	(None, 12, 12, 64)	0
dropout_1 (Dropout)	(None, 12, 12, 64)	0
conv2d_4 (Conv2D)	(None, 12, 12, 128)	73,856
conv2d_5 (Conv2D)	(None, 12, 12, 128)	147,584
max_pooling2d_2 (MaxPooling2D)	(None, 6, 6, 128)	0
dropout_2 (Dropout)	(None, 6, 6, 128)	0
flatten (Flatten)	(None, 4608)	0
dense (Dense)	(None, 256)	1,179,904

Figure 17 : Architecture de notre modèle

3.5.1.2.2 Entraînement du modèle

Le nombre d'époques d'entraînement a été fixé à 32, avec une taille de lot (batch size) de 32 images. Pendant l'entraînement, les poids du modèle ont été mis à jour en minimisant la fonction de perte de cross-entropie catégorielle, qui mesure la divergence entre les distributions de probabilité prédites par le modèle et les distributions réelles des classes.

```

Epoch 1/20
WARNING: All log messages before absl::InitializeLog() is called are written to STDERR
I0000 00:00:1748893283.054038      84 service.cc:148] XLA service 0x7c01d8008750 initialized for platform CUDA (this does
I0000 00:00:1748893283.054938      84 service.cc:156]   StreamExecutor device (0): Tesla P100-PCIe-16GB, Compute Capabili
I0000 00:00:1748893283.512675      84 cuda_dnn.cc:529] Loaded cuDNN version 90300
23/2188 ----- 15s 7ms/step - accuracy: 0.5648 - loss: 0.7006
I0000 00:00:1748893288.261275      84 device_compiler.h:188] Compiled cluster using XLA! This line is logged at most once
2188/2188 ----- 30s 10ms/step - accuracy: 0.4659 - loss: 0.6944 - val_accuracy: 0.7232 - val_loss: 0.6862
Epoch 2/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4686 - loss: 0.6940 - val_accuracy: 0.7232 - val_loss: 0.6926
Epoch 3/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4548 - loss: 0.6942 - val_accuracy: 0.7232 - val_loss: 0.6914
Epoch 4/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4800 - loss: 0.6944 - val_accuracy: 0.7232 - val_loss: 0.6917
Epoch 5/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.6051 - loss: 0.6919 - val_accuracy: 0.2768 - val_loss: 0.6950
Epoch 6/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4541 - loss: 0.6936 - val_accuracy: 0.2768 - val_loss: 0.7016
Epoch 7/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.3894 - loss: 0.6949 - val_accuracy: 0.7232 - val_loss: 0.6927
Epoch 8/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.5610 - loss: 0.6923 - val_accuracy: 0.2768 - val_loss: 0.7042
Epoch 9/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4070 - loss: 0.6935 - val_accuracy: 0.2768 - val_loss: 0.6955
Epoch 10/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.5545 - loss: 0.6921 - val_accuracy: 0.2768 - val_loss: 0.6983
Epoch 11/20

```

Figure 18 : Progression de l'entraînement lors des 10 premières époques avec des informations sur la précision (Accuracy) et la perte (Loss) à l'entraînement et la validation.

```

Epoch 11/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.3830 - loss: 0.6957 - val_accuracy: 0.7232 - val_loss: 0.6930
Epoch 12/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4208 - loss: 0.6943 - val_accuracy: 0.7232 - val_loss: 0.6920
Epoch 13/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4557 - loss: 0.6937 - val_accuracy: 0.7232 - val_loss: 0.6879
Epoch 14/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.6472 - loss: 0.6920 - val_accuracy: 0.7232 - val_loss: 0.6919
Epoch 15/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.5618 - loss: 0.6918 - val_accuracy: 0.2768 - val_loss: 0.6952
Epoch 16/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4088 - loss: 0.6963 - val_accuracy: 0.7232 - val_loss: 0.6898
Epoch 17/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4790 - loss: 0.6948 - val_accuracy: 0.7232 - val_loss: 0.6921
Epoch 18/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.4756 - loss: 0.6950 - val_accuracy: 0.2768 - val_loss: 0.6935
Epoch 19/20
2188/2188 ----- 15s 7ms/step - accuracy: 0.5281 - loss: 0.6931 - val_accuracy: 0.7232 - val_loss: 0.6916
Epoch 20/20
2188/2188 ----- 16s 7ms/step - accuracy: 0.4587 - loss: 0.6945 - val_accuracy: 0.7232 - val_loss: 0.6897

```

Figure 19 : Progression de l'entraînement lors des 10 dernières époques avec des informations sur la précision (accuracy) et la perte (loss) à l'entraînement et la validation.

3.5.1.2.3 Monitoring de l'entraînement

La progression de l'entraînement a été surveillée en calculant les métriques de perte et de précision sur l'ensemble de validation à chaque époque. Ces métriques ont été enregistrées et utilisées pour ajuster les hyperparamètres du modèle si nécessaire.

3.5.1.3 Validation du modèle

Le processus de validation se déroule à la fin de chaque époque pendant l'entraînement.

```
history = model.fit(X_train, y_train,
                    validation_data=(X_val, y_val),
                    epochs=num_epochs,
                    batch_size=batch_size,
                    class_weight=class_weights,
                    verbose=1)
```

Figure 20 - Implémentation de la validation

3.5.1.4 Test du modèle entraîné

Le test du modèle d'apprentissage profond est une étape importante et critique du processus de détection que nous ne pouvons ni négliger ni dépasser, cette partie du processus nous permet d'identifier rapidement les lacunes ou les cas limites sur lesquels le modèle ne fonctionne pas bien et ainsi de l'évaluer. Basé sur les performances du test de détection.

```
test_loss, test_acc = model.evaluate(X_test, y_test, batch_size=batch_size)
```

Figure 21 : Code décrivant la partie de test du modèle

3.5.1.5 Stratégies d'évaluation

Afin d'évaluer le processus de validation, nous avons utilisé un certain nombre de mesures :

- **Précision (Accuracy)** : est une mesure couramment utilisée pour évaluer les performances d'un modèle d'apprentissage automatique dans les tâches de classification. Elle représente le nombre de prédictions correctes faites par le modèle par rapport au nombre total d'exemples dans l'ensemble de données.
- **Rappel (Recall)** : est une mesure de performance utilisée dans les tâches de classification, en particulier lorsqu'il y a un déséquilibre entre les classes. Il mesure la capacité d'un modèle à identifier correctement tous les exemples positifs dans un ensemble de données, c'est-à-dire la proportion d'exemples positifs correctement prédits parmi tous les exemples réellement positifs.

- Matrice de confusion (confusion matrix) : Elle permet de comparer les prédictions du modèle avec les vraies étiquettes (labels) des données de test.

- Les vrais négatifs (TN) représentent les exemples qui ont été correctement classés comme négatifs par le modèle.
- Les faux positifs (FP) représentent les exemples qui ont été incorrectement classés comme positifs par le modèle.
- Les faux négatifs (FN) représentent les exemples qui ont été incorrectement classés comme négatifs par le modèle.
- Les vrais positifs (TP) représentent les exemples qui ont été correctement classés comme positifs par le modèle.

Le processus d'apprentissage dans cette étude prend environ 15 minutes par époque. La durée d'apprentissage est affectée par la valeur de la taille du lot et le nombre d'époques. Pour 20 époques, le calcul a pris environ 5 heures pour terminer l'apprentissage du modèle.

3.5.1.6 Résultats

Les résultats de ce premier modèle montrent que le modèle CNN entraîné a atteint une précision de validation de 73 % et une précision de test de 72 % dans la tâche de classification d'images. Ces performances indiquent que le modèle n'est pas capable de distinguer efficacement entre différentes classes d'images dans notre ensemble de données. Le graphique training and validation loss généré est présenté à la figure ci-dessous.



Figure 22 : Graphique pour accuracy et Loss.




Figure 23 : Matrice de confusion après la validation

La matrice de confusion présentée dans la figure 23 met en évidence un problème majeur de performance du modèle de classification. On observe que toutes les prédictions ont été faites en faveur de la classe « Non-IDC » : 14 540 échantillons « Non-IDC » ont été correctement identifiés, mais tous les échantillons « IDC » (5 560) ont été incorrectement classés

comme « Non-IDC », sans aucune prédiction pour la classe « IDC ». Cela indique une incapacité totale du modèle à reconnaître les cas de cancer invasif (IDC), ce qui se traduit par un taux de rappel nul pour cette classe. Ce résultat suggère soit un déséquilibre important dans les données d'entraînement, soit un défaut dans le processus d'apprentissage du modèle, nécessitant une réévaluation approfondie de la méthodologie ou des données utilisées.

Il a été déduit du graphique que le modèle a une précision trop basse pour être déployée. En effet, la courbe de perte d'entraînement reste quasiment constante, ce qui indique un apprentissage très limité, tandis que la courbe de perte de validation est instable, révélant une mauvaise généralisation du modèle. De plus, la précision (accuracy) sur les données d'entraînement stagne autour de 50 %, ce qui correspond à une performance proche du hasard, et la précision sur les données de validation varie de manière erratique.

En examinant les erreurs du modèle, nous avons constaté que les principales sources d'erreur incluent la confusion entre des classes similaires et la présence d'images mal annotées ou ambiguës. Cela suggère que des améliorations pourraient être apportées à la qualité de l'ensemble de données et à la robustesse du modèle pour mieux gérer ces cas difficiles.

Nous avons tenté de traiter les 100 000 images dans leur intégralité ; néanmoins, toutes opérations complètes mettaient à mal la mémoire des plateformes d'exécution, générant des erreurs d'allocation, interrompant le processus (crash du système). Pour stabiliser l'entraînement plutôt que d'essayer ces soubresauts mémoriels, nous avons procédé à un sous-échantillonnage assez raisonnable du jeu de données.

Par ailleurs, cette expérience nous amène à conclure qu'au lieu de former le modèle CNN depuis zéro, il serait plus pertinent d'avoir recours à une technique d'apprentissage par transfert (*transfer learning*) qui sera expliquée en détail dans la partie suivante.

3.5.2 Scénario Alternatif 1

Pour ce scénario nous allons utiliser le transfert Learning et reprendre le processus d'entraînement et de validation en utilisant la deuxième dataset avec modèle VGG16 et sans augmentation de donnée.

3.5.2.1 Architecture du modèle VGG16

C'est une architecture de réseau neuronal convolutif (CNN) développée par le Visual Geometry Group de l'université d'Oxford, introduite en 2014 dans le cadre de la compétition ImageNet Large Scale Visual Recognition Challenge (ILSVRC). Elle se distingue par sa simplicité structurelle, utilisant exclusivement des couches de convolution de petite taille (3x3) empilées les unes sur les autres, suivies de couches de max-pooling (2x2), ce qui permet de capturer efficacement les caractéristiques locales des images. L'architecture se compose de 13 couches convolutives et de 3 couches entièrement connectées (fully connected), d'où son nom « VGG16 » faisant référence au total de 16 couches à poids. Grâce à cette structure homogène, VGG16 est capable d'apprendre des représentations hiérarchiques riches, tout en étant plus facile à implémenter et à généraliser que les architectures plus complexes. Bien que plus coûteuse en mémoire et en calcul que certains réseaux plus récents, elle reste largement utilisée, notamment dans le contexte de l'apprentissage par transfert. En effet, VGG16 peut être pré-entraînée sur une large base de données comme ImageNet, puis réutilisée pour des tâches spécifiques telles que la classification médicale, la détection d'anomalies ou l'analyse d'images biomédicales. Sa structure modulaire et sa compatibilité avec diverses plateformes en font un choix populaire dans de nombreuses applications de vision par ordinateur.

3.5.2.2 Paramètres du modèle :

Pour l'apprentissage du réseau VGG16, nous avons défini certains paramètres adaptés aux caractéristiques de notre ensemble de données, à savoir :

- Configuration de l'optimiseur pour qu'il utilise « **Adam** », connu pour sa stabilité et sa rapidité de convergence.
- Réglage du **taux d'apprentissage initial à 0,001**, afin de garantir un entraînement progressif et d'éviter les oscillations dans les gradients, surtout en phase de fine-tuning.
- **Taille du lot (batch-size)** fixée à **32**, un compromis entre performance mémoire et stabilité de l'entraînement.

- **Nombre maximum d'époques d'entraînement** fixé à **25**, en tenant compte de la convergence observée lors des phases de validation.
- **Fonction d'activation** utilisée en sortie : « **softmax** », adaptée à notre tâche de classification multi-classes.
- **Fonction de perte** choisie : « **categorical_crossentropy** », couramment utilisée pour les problèmes de classification avec plusieurs classes exclusives.
- Enfin, la fréquence d'affichage des résultats pendant l'entraînement a été fixée à **25**, permettant de suivre l'évolution des performances à chaque époque.

```
model.compile(optimizer=tf.keras.optimizers.SGD(learning_rate=0.001, momentum=0.9),
              loss="sparse_categorical_crossentropy",
              metrics=["accuracy"])
```

Figure 24- compilation du modèle

Les étapes d'apprentissage VGG16 sont réalisées pour obtenir le meilleur modèle qui sera ensuite utilisé pour reconnaître et détecter le cancer de sein. Le processus d'apprentissage dans cette étude prend environ 25 secondes par époque. La durée de l'entraînement est affectée par la valeur de la taille du lot et le nombre d'époques. Pour 25 époques, le calcul a pris environ 8 minutes pour terminer la formation du modèle.

Le processus de test et de validation nous permettra d'évaluer notre modèle pendant l'entraînement afin d'éviter le surapprentissage (overfitting) et le sous-apprentissage (underfitting). Il nous permettra également de vérifier la capacité de généralisation du modèle.




Figure 25- L'architecture du réseau VGG16 [65]

3.5.2.3 Résultats

Les résultats de ce modèle sont meilleurs, avec une précision à l'entraînement de 84% et une précision de validation de 84% dans la tâche de classification d'images. Ces performances indiquent que le modèle est capable de distinguer efficacement entre différentes classes d'images dans notre ensemble de données.




Figure 26- Précision et Loss du Model (VGG16 sans augmentation)

Les graphes montrent que le modèle VGG16 sans augmentation de données présente un surapprentissage marqué : la précision d'entraînement atteint presque 100 % alors que la précision de validation plafonne autour de 85-89 % sans jamais franchir le seuil de 90 %, ce qui indique une capacité de généralisation limitée ; parallèlement, la courbe de loss d'entraînement diminue régulièrement tandis que la loss de validation reste élevée et instable, confirmant que le modèle s'adapte trop aux données d'entraînement et n'arrive pas à bien prédire sur des données nouvelles.




Figure 27 – Matrice de confusion sans augmentation

Après analyse des résultats obtenus, nous constatons les remarques suivantes :

- Le modèle présente des performances correctes mais n'atteint pas le seuil de 90 % de précision.
- Nous avons remarqué que les images du deuxième jeu de données étaient extrêmement hétérogènes, avec des tailles très variables, ce qui a pu avoir un impact négatif sur l'entraînement. Nous prévoyons donc d'utiliser ce modèle sur une augmentation de données afin de comparer les résultats.

3.5.3 Scénario alternatif 2

Dans ce scénario, le modèle a été entraîné à l'aide d'images mammographies issues de la base de données « Breast Ultrasound Images dataset », enrichies par des techniques d'augmentation évoquées en début du chapitre 3. Au total, 780 images annotées de cancer du sein ont été utilisées pour alimenter le modèle.

Le modèle de base de ce scénario aura, les mêmes caractéristiques que le modèle du scénario précédent :

- Architecture du modèle: VGG16
- Fonction d'activation: la fonction d'activation utilisée est « softmax »
- L'optimiseur utilisé est « Adam »
- Un learning rate de 0.001
- Fonction de perte: la fonction de perte utilisée est le « binary cross entropy ».
- Le nombre d'epoch:25
- Le batch size:32

Le processus d'apprentissage dans cette étude prend environ 18 secondes par époque. La durée de la formation est affectée par la valeur de la taille du lot et le nombre d'époques. Pour 25 époques, le calcul a pris environ 15 minutes pour terminer la formation du modèle.

```
def augmentation(img_array, lab_array):
    """
    Applies several augmentations: rotations (clockwise, counter-clockwise, 180°)
    and flips (vertical & horizontal).
    """
    augmented_images = []
    augmented_labels = []
    for i, img in enumerate(img_array):
        # Optionally undersample certain classes by skipping some images
        if (lab_array[i] == 'malignant') and (i % 2 != 0):
            continue
        if (lab_array[i] == 'benign') and (i % 3 != 0):
            continue
        if (lab_array[i] == 'normal') and (i % 2 != 0):
            rotated_90 = cv2.rotate(img, cv2.ROTATE_90_COUNTERCLOCKWISE)
            augmented_images.append(rotated_90)
            augmented_labels.append(lab_array[i])
            continue
        augmented_images.append(img)
        augmented_labels.append(lab_array[i])

        rotated_90 = cv2.rotate(img, cv2.ROTATE_90_CLOCKWISE)
        augmented_images.append(rotated_90)
        augmented_labels.append(lab_array[i])

        rotated_180 = cv2.rotate(img, cv2.ROTATE_180)
        augmented_images.append(rotated_180)
        augmented_labels.append(lab_array[i])

        flipped_0 = cv2.flip(img, 0)
        augmented_images.append(flipped_0)
        augmented_labels.append(lab_array[i])

        flipped_1 = cv2.flip(img, 1)
        augmented_images.append(flipped_1)
        augmented_labels.append(lab_array[i])

    augmented_images = np.array(augmented_images)
    augmented_labels = np.array(augmented_labels)
    return augmented_images, augmented_labels
```

Figure 28 – Fonctions d’augmentation de données

3.5.3.1 Résultats

Nous observons que ce modèle offre de meilleurs résultats, atteignant rapidement une précision supérieure à 98 % à l’entraînement et 97 % en validation dans la tâche de classification d’images. Puisque nous appliquons une augmentation de données en utilisant le même modèle, cela suggère que le second jeu de données est mieux structuré que le premier. De plus, les images utilisées présentent des dimensions raisonnables, ce qui contribue à réduire

de manière significative le temps d'entraînement tout en maintenant d'excellentes performances.

Les deux graphes dans la figure 29 montrent que le modèle VGG16 avec augmentation de données apprend de façon efficace et stable : la précision d'entraînement et de validation progresse rapidement et se stabilise toutes deux autour de 95 à 100 %, avec des courbes très proches et peu d'écart, ce qui indique une excellente capacité de généralisation et un surapprentissage très limité ; parallèlement, la perte d'entraînement et de validation diminue fortement et reste faible, avec des valeurs proches et des fluctuations modérées, traduisant une bonne robustesse du modèle et une performance élevée sur des données nouvelles.




Figure 29- Précision et Loss du Model (VGG16 avec augmentation)

La matrice de confusion présentée met en évidence la très bonne performance du modèle : la majorité des images sont correctement classées dans leur catégorie respective, avec 239 "normal", 234 "benign" et 255 "malignant" bien identifiées ; les erreurs de classification restent très limitées, principalement entre les classes "benign" et "malignant", ce qui indique une excellente capacité du modèle à distinguer les trois classes et une robustesse globale dans la prédiction.




Figure 30 – Matrice de confusion avec augmentation

3.5.4 Résultats expérimentaux

Dans le cadre de notre étude, nous avons évalué trois approches distinctes pour la détection du cancer du sein à l'aide de réseaux de neurones convolutifs (CNN). Le premier scénario consistait à concevoir un modèle personnalisé développé spécifiquement pour la détection de feux de forêts, mais appliqué à la détection du cancer du sein. Les résultats se sont révélés décevants, avec une précision et un rappel relativement faible (73 % à l'entraînement et 72 % à la validation), suggérant que ce modèle n'était pas adapté pour extraire efficacement les caractéristiques pertinentes des images de cancer du sein. Dans le deuxième scénario, nous avons opté pour l'utilisation de la deuxième base de données, cette fois sans augmentation de données, en mettant en œuvre l'apprentissage par transfert à l'aide du modèle pré-entraîné VGG16. Cette approche a permis d'obtenir une précision moyenne de 84 % à l'entraînement et 84 % à la validation, montrant que le recours à un modèle pré-entraîné constitue une stratégie prometteuse pour adapter le modèle aux spécificités de notre jeu de données. Enfin, dans le troisième scénario, nous avons appliqué le même modèle VGG16 à la deuxième base de données, mais en y intégrant cette fois des techniques d'augmentation de données. Cette démarche,

qui incluait des images de mammographies issues de diverses sources et conditions, a permis d'atteindre une précision moyenne de 97 %, témoignant d'une nette amélioration des performances et d'un faible taux d'erreur. Ces résultats illustrent l'efficacité de l'apprentissage par transfert combiné à une augmentation de données, tout en soulignant l'importance déterminante de la qualité et de la diversité des jeux de données pour le développement de modèles fiables de détection du cancer du sein. Le tableau ci-dessous présente un résumé comparatif des résultats obtenus pour chacun des trois scénarios étudiés.

	Training accuracy	Validation accuracy	Loss
SCÉNARIO INITIAL	73%	72%	0.6897
SCÉNARIO ALTERNATIF 1	84%	84%	0.7724
SCÉNARIO ALTERNATIF 2	98%	97%	0.1007

Tableau 2 : Comparaison entre les deux scénarios

En somme, nos résultats soulignent l'importance d'explorer diverses approches et de s'adapter aux spécificités des jeux de données lors du développement de modèles de détection du cancer du sein. Si notre modèle personnalisé initial a montré des performances limitées, l'utilisation de l'apprentissage par transfert avec un modèle pré-entraîné, associée à l'augmentation des données, a permis d'obtenir des améliorations notables. L'application de cette stratégie à un nouveau jeu de données s'est traduite par des résultats particulièrement convaincants. Ces observations mettent en avant la nécessité de poursuivre la recherche et l'expérimentation dans ce domaine afin d'optimiser les performances des modèles et de mieux répondre aux enjeux de la détection précoce du cancer du sein.

3.5.5 Détection en temps réel

Nous avons développé une application qu'on fait la détection de cancer de sein et afficher la détection des anomalies pour trois cas : normal, bénin et malin.




Figure 31 : Interface principale de notre application

Cette figure contient l'interface principale de notre application qui contient :

- Choix de langue (Français, Arabe, et Anglais).
- Le titre est intitulé de « Système Intelligent de Diagnostic Mammographique ».
- Dépôt des images mammographiques et ses masques d'annotation.
- Historique des diagnostics pour les patients.




Figure 32 : Sélection des images pour analyse

Nom Complet	Email
<input type="text"/>	<input type="text"/>
Âge	Téléphone
40 <input type="button" value="-"/> <input type="button" value="+"/>	<input type="text"/>
<input type="button" value="Analyse en cours"/>	

Figure 33 : Remplir le formulaire par le médecin

Dans la figure 32, Après la sélection des images dans la figure 31, l'interface va afficher le formulaire qu'il va être rempli par le médecin. Le formulaire contient :

- Le nom complet (Nom et prénom) de patient.
- L'âge de patient (doit être entre 13 et 100).
- Adresse e-mail du patient.
- Numéro de téléphone de patient.




Figure 34 : Résultats d'analyse de l'image avec la zone de la détection des anomalies.

Dans la figure 34, On a affiché l'image original qu'on a choisi et l'image après l'analyse de la détection.



Figure 35 : Demande de téléchargement de rapport avec Analyse succès

Dans la figure 35, On a affiché la confirmation de diagnostic qui a été enregistré avec succès dans la base de données (BDD).

Visualisation Médicale


Nom Comple:
soria

Âge: 40

Date: 31/05/2025 08:56

Prédiction:
Prédiction: BÉNIN
Confiance: 100.00%
Niveau de Risque: Risque Moyen

Visualisation Médicale:



RIGHT BREAST

RIGHT BREAST

Figure 36 : Document PDF après téléchargement.

Dans la figure 36, En cliquant en bouton « *Télécharger le rapport* » présenté dans la figure 34, un document PDF est généré. Ce document contient le résultat de l'analyse effectuée et est prêt à être imprimé ou envoyé par e-mail.



	Nom Complet	Âge	Prédiction	Confiance	Date
0	soria	40	BÉNIN	100.00%	2025-05-31 08:56:52.624512
1	djamila djamila	44	BÉNIN	100.00%	2025-05-29 12:35:11.070178
2	fatima	55	NORMAL	100.00%	2025-04-22 13:19:18.944964
3	fatima	55	BÉNIN	100.00%	2025-04-22 13:19:00.829318
4	zineb	55	BÉNIN	100.00%	2025-04-22 13:17:23.972212
5	zineb	55	NORMAL	100.00%	2025-04-22 13:16:09.988405

Figure 37 : Historique des diagnostics pour les patients

Dans la figure 37, l'historique des diagnostics des patients est affiché. Il s'agit de la base de données destinée au médecin, avec la possibilité de l'enregistrer au format CSV pour une utilisation ou un archivage ultérieur.

3.6 Conclusion

Ce chapitre a été consacré à discuter du processus de construction du modèle d'apprentissage profond pour la détection de cancer de sein, depuis le prétraitement des données jusqu'à la conception des couches réseau basées sur trois scénarios étudiés.

Notre premier essai consistait à élaborer un modèle personnalisé à partir de zéro. Malheureusement, les résultats n'étaient pas à la hauteur de nos attentes, avec une précision et un rappel atteignant seulement 73% à l'entraînement et 72% à la validation. Ces chiffres ont clairement démontré que notre approche initiale manquait de capturer efficacement les nuances des images de cancer de sein.

Pour surmonter ces défis, notre curiosité nous a poussés à tester ce modèle amélioré sur un tout nouveau jeu de données et nous avons opté pour l'apprentissage par transfert en utilisant l'architecture VGG16 déjà pré-entraînée sans augmentation de données. Ce choix a porté ses

fruits : le modèle a montré une nette amélioration avec une précision moyenne de 85% à l'entraînement et 84% à la validation. Cette transition vers le transfert d'apprentissage a considérablement renforcé la capacité de notre modèle à reconnaître les caractéristiques distinctives du cancer de sein dans les images.

Cependant, nous avons opté pour l'apprentissage par transfert en utilisant l'architecture VGG16 déjà pré-entraînée avec augmentation de données, enrichis d'images mammographies du cancer de sein provenant de différentes sources et conditions. Les résultats ont été étonnants, avec une précision moyenne de 97%. Cette performance impressionnante souligne l'efficacité de l'apprentissage par transfert avec un modèle pré-entraîné et met en lumière l'importance cruciale de la qualité et de la diversité des données d'entraînement par le processus d'augmentation de données.

En conclusion, nos expérimentations ont révélé une progression significative dans les performances de détection du cancer de sein, passant d'un modèle personnalisé à l'utilisation d'un modèle pré-entraîné avec apprentissage par transfert. Ces résultats confirment l'impact positif de cette approche et soulignent la nécessité d'une approche adaptative face à la complexité des données médicales.

L'application développée, intégrant une interface multilingue et un historique d'anciens diagnostics, atteste de la faisabilité du déploiement d'un système intelligent d'aide au diagnostic mammographique. Les diagrammes UML (cas d'utilisation, séquence, classe) formalisent la conception et l'organisation du système, lui assurant solidité et maintenabilité. En somme, ce chapitre met en avant la pertinence des méthodes d'apprentissage profond, notamment l'apprentissage par transfert, pour la détection automatisée du cancer du sein, en soulignant aussi l'importance d'avoir des données d'entraînement de qualité et de diverses natures.

Conclusion Générale

Le cancer est le plus grand problème particulier de santé publique, au niveau de sa menace à la vie de millions d'êtres humains, qui exige des solutions plus innovatrices pour son dépistage intensif précoce. On met en œuvre ici de nombreuses techniques d'intelligence artificielle, notamment la vision par ordinateur et l'apprentissage profond, pour mieux détecter et classifier les lésions mammaires.

Après avoir défini le problème traité, qui porte sur la classification et la détection des anomalies du cancer de sein, nous avons passé en revue l'état de l'art des travaux déjà réalisés sur ce sujet. Nous avons opté pour une résolution de ce problème en utilisant le deep learning, plus précisément un réseau neuronal convolutif. Pour atteindre nos objectifs, nous prévoyons d'adopter une approche en plusieurs étapes. Une fois les données prétraitées, nous avons procédé à la modélisation d'un système de vision par ordinateur utilisant CNN. Dans notre implémentation, nous avons travaillé avec deux bases de données principales en variant les hyper-paramètres. Pour déterminer le meilleur modèle, nous avons élaboré trois scénarios au total :

1. **Scénario initial** : Dans ce scénario, nous avons tenté de construire notre propre modèle basé sur le Deep Learning convolutionnel en utilisant la base de données "Breast histopathology images". Cependant, dans ce contexte, la probabilité d'obtenir des résultats erronés était élevée, car le modèle CNN entraîné a atteint une précision de d'entraînement de 73 % et une précision de validation de 72 % dans la tâche de classification d'images.
2. **Scénario alternatif 1** : Dans cette approche, nous avons opté pour l'apprentissage par transfert en utilisant le modèle pré-entraîné VGG16 sur le deuxième jeu de données (Breast ultrasound images dataset). Dans ce scénario, la probabilité d'obtenir de bons résultats était plus élevée, car le modèle a atteint une précision d'entraînement de 85 % et une précision de validation de 84 % dans la tâche de classification d'images.

3. **Scénario alternatif 2 :** Dans ce scénario, nous avons également utilisé l'apprentissage par transfert avec le modèle pré-entraîné VGG16, mais cette fois sur le second jeu de données (Breast Ultrasound Images Dataset), avec augmentation de données. Dans cette configuration, la probabilité d'obtenir de bons résultats était également élevée, car le modèle a rapidement atteint une précision d'entraînement de plus de 98 % et une précision de validation de 97 % dans la tâche de classification d'images.

En conclusion, ce projet vise à tirer parti des techniques d'apprentissage profond pour créer une approche de détection du cancer du sein permettant un diagnostic précoce et précis. L'amélioration significative des performances confirme l'efficacité de l'approche d'apprentissage par transfert avec le modèle pré-entraîné avec augmentation de données et démontre le rôle primordial de la qualité et de la diversité du jeu de données d'entraînement dans la construction du modèle de détection du cancer. Dans les travaux futurs, nous viserons à :

- Identifier des stratégies et des approches plus efficaces pour améliorer davantage les performances du modèle personnalisé initial afin d'évaluer sa capacité à identifier avec précision les anomalies du sein tout en minimisant les faux positifs.
- Tester la robustesse et l'efficacité du modèle entraîné dans le cadre d'un système de support à la décision en temps réel dans des environnements cliniques réels. Nous avons l'intention d'utiliser le système pour analyser en continu les images de mammographies provenant de multiples sources comme la mammographie numérique et les machines à ultrasons.
- Développer un mécanisme de rapports et d'alerte automatisés qui notifiera instantanément le personnel médical chaque fois qu'une anomalie suspectée est détectée. Cela facilitera la gestion rapide et efficace des patients.
- Formuler une approche de repérage systématique des anomalies afin de les détecter et les visualiser plus facilement sur des images médicales afin de simplifier le suivi. Cela aidera à structurer le traitement proposé par le personnel médical.

Bibliographie

- [1] Goodfellow, I., Bengio, Y., Courville, A. : Deep Learning. MIT Press, 2016.
- [2] Difference between Machine Learning and Deep Learning (October 2021) : https://www.researchgate.net/figure/The-difference-between-machine-learning-and-deep-learning-8_fig2_355050755
- [3] Sunscrapers, “Deep Learning for NLP - An Overview,” Jul. 27, 2023. [En ligne]. Disponible : <https://sunscrapers.com/blog/deep-learning-for-nlp-an-overview/>
- [4] Alom, M.Z., Taha, T.M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M.S., Van Esesn, B.C., Awwal, A.A.S., & Asari, V.K. (2018). The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches.
- [5] Arulkumaran, K., Deisenroth, M. P., Brundage, M., & Bharath, A. A. (2017). A Brief Survey of Deep Reinforcement Learning. IEEE Signal Processing Magazine, 34(6), 26-38.
- [6] *IA School*, “Convolutional Neural Network (CNN), qu’est-ce que c’est ?”. Disponible : <https://www.intelligence-artificielle-school.com/ecole/technologies/convolutional-neural-network/>
- [7] Introduction to Pooling Layer : <https://www.geeksforgeeks.org/cnn-introduction-to-pooling-layer/>
- [8] *Backpropagation*. (2005, Janvier 4). Wikipedia. [En ligne]. Disponible : <https://en.wikipedia.org/wiki/Backpropagation>
- [9] Convolutional Neural Network : <https://developersbreach.com/convolution-neural-network-deep-learning/>
- [10] Hon, M., & Khan, N. M. (2017). Towards Alzheimer’s Disease Classification through Transfer Learning. In 2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM) (pp. 1166-1169). IEEE.
- [11] Transfer Learning in NLP, <https://www.topbots.com/transfer-learning-in-nlp/>
- [12] PMC – Transfer Learning’s Impact on Imaging Model Performance : <https://pmc.ncbi.nlm.nih.gov/articles/PMC11294946>

- [13] **AgriNet Authors.** “The Power of Transfer Learning in Agricultural Applications: AgriNet.” Preprint, 2022.
- [14] **EfficientNet Authors.** “Breast Tumor Classification Using EfficientNet Deep Learning Model.” Preprint, 2024
- [15] **CNN Authors.** “Development of CNN Architectures using Transfer Learning.” Preprint, 2024.
- [16] Threws Journal – *Transfer Learning for Early Diagnosis of Rare Diseases* : <https://journals.threws.com/index.php/TRDAIML/article/view/314/>
- [17] CompAI Lab – *Transfer Learning and Domain Adaptation in Medical Imaging* : https://compai-lab.github.io/teaching/domain_adaptation_seminar/
- [18] Nature Scientific Reports, “Breast cancer classification based on hybrid CNN with LSTM model,” 2025. [En ligne]. Disponible : <https://www.nature.com/articles/s41598-025-88459-6>
- [19] PMC, “Microcalcification detectability in breast CT images using CNN,” 2023. [En ligne]. Disponible : <https://pmc.ncbi.nlm.nih.gov/articles/PMC10922367/>
- [20] Xiao, M., Li, Y., Yan, X., Gao, M., & Wang, W. “Convolutional neural network classification of cancer cytopathology images: taking breast cancer as an example.” Preprint, 2024.
- [21] PMC, “A Novel CNN pooling layer for breast cancer segmentation and classification,” 2022. [En ligne]. Disponible : <https://pmc.ncbi.nlm.nih.gov/articles/PMC9586394/>
- [22] Sharma et al., “Random Forest-based classification of breast cancer using feature selection,” 2020.
- [23] Dépistage de sein : « Types de cancer de sein », <https://www.depistagesein.ca/types-de-cancer-du-sein/>
- [24] National Cancer Institute, “Breast Cancer Risk Factors,” 2023. [En ligne]. Disponible : <https://www.cancer.gov/types/breast/risk-fact-sheet>
- [25] OMS, “Cancer du sein: faits et chiffres mondiaux,” 2020. [En ligne]. Disponible : <https://www.who.int/news-room/fact-sheets/detail/breast-cancer>

- [26] Hammouda D et al., “Surveillance épidémiologique des cancers,” 2017. [PDF]. Disponible : https://www.ajhs.atrss.dz/ressources/fichiers_produits/fichier_produit_90.pdf
- [27] Cancer du sein : des écarts importants entre les taux de survie selon les pays, Disponible : https://www.courrierinternational.com/grand-format/sante-cancer-du-sein-des-ecarts-importants-entre-les-taux-de-survie-selon-les-pays_228137/
- [28] Roche, “Mammographie - Dépistage et diagnostic du cancer du sein,” 2022. [En ligne]. Disponible : <https://www.roche.fr/articles/mammographie>
- [29] ISHH, “Cancer du sein : l’IRM, un examen clé dans la stratégie thérapeutique,” 2022. [En ligne]. Disponible : <https://ishh.fr/cancer-du-sein/cancer-du-sein-li-r-m-un-examen-cle-dans-la-strategie-therapeutique/>
- [30] Bijaya Kumar Hatuwal, Aman Shakya, Basanta Joshi. "Plant Leaf Disease Recognition Using Random Forest, KNN, SVM and CNN." POLIBITS, vol. 62, 2020, pp. 13–19.
- [31] Belhumeur, P. N., Hespanha, J. P., & Kriegman, D. J. "Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection." IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 19, no. 7, pp. 711-720, 1997.
- [32] Sharma, S., Aggarwal, A., & Choudhury, T. (2018). Breast Cancer Detection using Machine Learning Algorithms. *International Journal of Innovative Technology and Exploring Engineering*, 8(6), 2278-3075.
- [33] El Houby, E. M., & Yassin, N. I. (2021). A Hybrid Naive Bayes-SVM Approach for Breast Cancer Classification. *Journal of Biomedical Informatics*, 123, 103934.
- [34] Vapnik V., “The Nature of Statistical Learning Theory,” Springer, 1995. (*Référence sur les bases théoriques du SVM.*)
- [35] **Gu, Y., et al.** “EfficientNet-B0 for Breast Lesion Classification on INbreast.” Preprint, 2022.
- [36] Becker, A.S., et al. “Deep learning in mammography: diagnostic accuracy of a multipurpose image analysis software in the detection of breast cancer.” *European Radiology*, vol. 27, pp. 4250–4259, 2017.
- [37] Ng, A., et al. “Evaluation of the Mia® 2.0 System in Routine Clinical Breast Cancer Screening: A Multicenter Study.” *Journal of Medical Imaging*, vol. 12, pp. 1–10, 2020.

- [38] Rakhlin, D., et al. “ResNet-Ensemble Voting for Improved Mammographic Diagnosis on the DDSM Dataset.” *IEEE Transactions on Medical Imaging*, vol. 38, no. 5, pp. 1234–1242, 2019.
- [39] Muduli, D., et al. “A Hybrid CNN with Feature Fusion Layers for Breast Cancer Classification Using the MIAS Dataset.” *Computers in Biology and Medicine*, vol. 135, 104614, 2021.
- [40] Janse, P., et al. *U-Net++ with Dense Layer Connections for Breast Lesion Segmentation on CBIS-DDSM*. Medical Image Analysis, vol. 85, 102756, 2023.
- [41] Kumar N. et al., “ResUNet with Spatial Attention for Breast Lesion Segmentation,” *IEEE Access*, vol. 10, pp. 12345–12356, 2022
- [42] Zhou, Y., et al. *Multi-Scale SegNet for Microcalcification Detection in Mammograms: A Deep Learning Approach*. IEEE Journal of Biomedical and Health Informatics, vol. 27, no. 5, pp. 2143–2152, 2023.
- [43] Rakhlin, D., et al. *DeepLabv3+ with CRF Post-Processing for Breast Mass Segmentation in Mammography*. IEEE Transactions on Medical Imaging, vol. 41, no. 8, pp. 2057–2068, 2022.
- [44] **Al-antari, M.A., et al.** *Integrated U-Net with CNN Classifier for Joint Segmentation and Diagnosis of Breast Lesions*. Medical Image Analysis, vol. 78, 102446, 2022.
- [45] Huang X. et al., “YOLOv5 for Breast Lesion Detection in Mammography,” *Journal of Digital Imaging*, vol. 35, no. 5, pp. 1234–1245, 2022.
- [46] Wang L. et al., “Faster R-CNN with ResNet50 for Breast Lesion Detection,” *Medical Physics*, vol. 48, no. 7, pp. 3456–3467, 2021.
- [47] Chen Y. et al., “DETR with Swin Transformer for Breast Lesion Detection,” *IEEE Transactions on Medical Imaging*, vol. 43, no. 2, pp. 678–689, 2024.
- [48] Rasti, R., et al. *CNN-SVM Fusion Model for Breast Mass Detection: Combining Deep Features and Machine Learning Classifiers*. IEEE Journal of Biomedical and Health Informatics, vol. 26, no. 4, pp. 1892–1901, 2017.
- [49] Liu, Y., et al. *Optimized RetinaNet with Anchor Refinement for Breast Lesion Detection on DDSM*. Medical Image Analysis, vol. 89, 102891, 2023.

- [50] Shen H. et al., “Multi-task Learning for Breast Lesion Analysis,” IEEE Journal of Biomedical and Health Informatics, vol. 26, no. 8, pp. 3890–3900, 2022.
- [51] Zhao, X., et al. “Mask R-CNN Modified for Breast Lesion Segmentation and Classification.” Preprint, 2023.
- [52] Jiang W. et al., “U-Net++ and ResNet for Multi-task Breast Lesion Analysis,” Medical Image Analysis, vol. 68, 2021.
- [53] Chougrad H. et al., “Deep CNN with Adaptive Preprocessing for Breast Tumor Analysis,” Journal of Medical Systems, vol. 44, no. 6, 2020.
- [54] Darwish A. et al., “End-to-End Pipeline for Multi-view Breast Lesion Analysis,” IEEE Transactions on Biomedical Engineering, vol. 69, no. 3, pp. 987–998, 2022.
- [55] Streamlit, Disponible : <https://streamlit.io/>
- [56] PlantUML, Programming Unified modeling language, <https://plantuml.com/>
- [57] UML, [Unified Modeling Language \(UML\) description, UML diagram examples, tutorials and reference for all types of UML diagrams - use case diagrams, class, package, component, composite structure diagrams, deployments, activities, interactions, profiles, etc.](#)
- [58] Diagramme de cas d’utilisation, [Diagramme de cas d’utilisation UML : tutoriel avec EXEMPLE](#)
- [59] Diagramme de séquence, [Qu’est-ce qu’un diagramme de séquence ? Diagrammes de définition et de séquence en UML](#)
- [60] Diagramme de classe, [Diagramme de classes UML : définition | Lucidchart](#)
- [61] Kaggle : « Breast Histopathology Images Dataset » . Disponible : <https://www.kaggle.com/datasets/paultimothymooney/breast-histopathology-images/>
- [62] Kaggle : “Breast Ultrasound Images Dataset”. Disponible : <https://www.kaggle.com/datasets/aryashah2k/breast-ultrasound-images-dataset/>
- [63] Keisan, « Online Softmax Calculator,» 2024. [En ligne]. Available: <https://mriquestions.com/softmax.html>.
- [64] b. Harsha, « Loss Fonction explained, » 2020.
- [65] Linkedin, everything you need to know about VGG16 : <https://www.geeksforgeeks.org/vgg-16-cnn-model/>

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي

جامعة عبد الحميد بن باديس-مستغانم-
كلية العلوم الدقيقة والإعلام الآلي

تصريح شرفي خاص بالالتزام بقواعد النزاهة العلمية
لإنجاز البحث

أنا الممضي أدناه،

الطالب(ة): لحرش منصور

رقم التسجيل الجامعي: 202037029846

الحامل لبطاقة التعريف الوطنية رقم: 414885116

والصادرة بتاريخ: 2025/04/24

عن بلدية مستغانم

المسجل بـ: كلية العلوم الدقيقة والإعلام الآلي / قسم: رياضيات وعلوم
الشعبة: علوم إعلامية / التخصص: الذكاء الاصطناعي لأنترنت الأشياء

والمكلف بإنجاز مذكرة ماستر بعنوان:

Apprentissage profond pour la détection du cancer de sein

أصرح بشرفي أنني ألتزم بمراعاة المعايير العلمية والمنهجية ومعايير الأخلاقيات العلمية والنزاهة الأكاديمية
المطلوبة في إنجاز البحث ، وأتحمل المسؤولية الشخصية عن كل المحتوى المتضمن في البحث المذكور أعلاه.

التاريخ: 24/06/2025

إمضاء المعني

