

الجمهورية الجزائرية الديمقراطية الشعبية  
République Algérienne Démocratique et Populaire  
وزارة التعليم العالي و البحث العلمي  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique  
جامعة عمار ثليجي  
UNIVERSITÉ AMAR TELIDJI LAGHOUAT



FACULTE DES SCIENCES  
DEPARTEMENT D'INFORMATIQUE

**Domaine** : Mathématiques et Informatique  
**Filière** : Informatique  
**Option** : Systèmes d'Information et de Décision

**MÉMOIRE DE MASTER**

**PRÉSENTÉ PAR :**

Chelali Rahil      Mecheikel Rihab

**THÈME**

---

---

**DÉTECTION DU CANCER DU SEIN DANS LES IMAGES  
ÉCHOGRAPHIQUES BASÉE SUR APPROCHES DE  
PRÉTRAITEMENT ET D'APPRENTISSAGE EN PROFONDEUR**

---

---

*Soutenu publiquement devant le jury composé de :*

Dr Laradj CHELLAMA	(University of Laghouat)	Président
Dr Younes GUELLOUMA	(University of Laghouat)	Examineur
Dr Tahar BENDOUMA	(University of Laghouat)	Examineur
Prof Mustapha Bouakkaz	(Université de Laghouat)	Encadreur
Dr Boudouh Saida Sarra	(Université de Laghouat)	Co-Encadreur

2022-2023

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

---

# *Remerciement*

*Nous remercions ALLAH, le tout-puissant d'avoir nous donner le courage, la volonté et la patience de mener à terme le présent travail.*

*Nous tenons à remercier sincèrement notre encadreur **Pr Mustapha Bouakkaz** et notre co-encadreuse **Dr Saïda Sarra Boudouh**, pour leurs gestion de ce travail et pour avoir fourni tous les précieux conseils nécessaires à son succès.*

*Nous remercions également tous les membres du jury **Dr Chellama Laradj**, **Dr Bendouma Tahar** et **Dr Guellouma Younes** pour avoir de donner leur temps pour évaluer notre travail*

*Nous n'oublions pas notre gratitude à tous les professeurs du département d'informatique et chaque professeur passe dans notre carrière universitaire.*

---

# *Dédicaces*

*Louange à Dieu tout-puissant, qui m'a permis de voir ce jour tant attendu.*

*Je dédie ce mémoire :*

*À mes chers parents, pour leur patience , leur amour, leur soutien et leurs encouragements.*

*À mes très chers frères.*

*À mes amis et mes camarades et mon binôme **Rahil**.*

*À mon encadreur le professeur **Bouakkaz Mustapha** et mon Co encadreur est ma chère amie **Boudouh Saïda Sarra**.*

***Sans** oublier tout les professeurs que ce soit du primaire, du moyen, du lycée ou de l'enseignement supérieur .*

*Merci à tous.*

***Rihab***

---

# *Dédicaces*

*Louange à Dieu tout-puissant, qui m'a permis de voir ce jour tant attendu.*

*Je dédie ce mémoire :*

*À mes parents, qui m'ont encouragé à aller de l'avant pour prendre mes études.*

*À mes très chères sœurs: **Rihab, Roumaïssa, Rania, Rym, Rabia.***

*À tous mes amis et mon binôme **Rihab**, pour leur conseil et les souvenirs des bons moments passés ensemble.*

*À mon encadreur **Bouakkaz Mustapha** pour son enseignement et son encadrement.*

*À ma co-encadreur **Saïda Sarra Boudouh** pour tous ses précieux conseils, pour son écoute, sa disponibilité et pour son soutien et sa patience.*

*Merci à tous.*

**RAHIL**

## Résumé

Le cancer du sein est l'une des causes de décès les plus fréquentes chez les femmes. Il est essentiel de détecter la maladie tôt avant qu'elle ait une chance de se propager en raison de son diagnostic tardif. Il existe plusieurs méthodes pour la détection et le diagnostic du cancer du sein, l'échographie est la technique la plus efficace. Dans cette étude, notre but est de proposer un modèle précis pour la détection du cancer du sein en images échographiques, basé sur les réseaux neuronaux convolutionnels. Un ensemble de données de 780 images d'échographie mammaire (133 normales, 437 bénignes et 210 malignes) a été utilisé. Des techniques de pré-traitement des images et d'apprentissage profond ont été utilisées, y compris l'apprentissage par transfert. Notre stratégie de pré-traitement comprenait la détection et l'extraction de la région d'intérêt. Après cela, six modèles CNN pré-formés ont été modifiés et adaptés à notre problème InceptionV3, Xception, VGG16, ResNet50V2, EfficientNetB7 et DenseNet201. Les résultats obtenus ont été satisfaisants, en particulier pour la classification des images échographiques du sein en normales et anormales, Xception, ResNet50V2 et DenseNet201 ont atteint l'accuracy la plus élevée de 100 %. Bien que les autres modèles aient obtenu d'excellents résultats, EfficientNetB7 était le modèle le plus approprié pour notre tâche avec une accuracy de 92 % pour la classification des cas bénins et malins, et de 94 % pour la classification multiple des cas normaux, bénins et malins.

**Mots clés :** Cancer du sein, échographie, Réseaux neuronaux convolutionnels, Apprentissage profond, L'apprentissage par transfert, InceptionV3, Xception, VGG16, ResNet50V2, EfficientNetB7, DenseNet201.

سرطان الثدي هو أحد أكثر أسباب الوفاة شيوعاً لدى النساء. من الضروري اكتشاف المرض مبكراً، قبل أن تتاح له فرصة الانتشار بسبب تشخيصه المتأخر. على الرغم من وجود العديد من الطرق لاكتشاف وتشخيص سرطان الثدي، إلا أن الموجات فوق الصوتية هي الأكثر فعالية. في هذه الدراسة، هدفنا هو اقتراح نموذج دقيق للكشف عن ورم الثدي في صور الموجات فوق الصوتية، بناءً على الشبكات العصبية التلافيفية. تم استخدام مجموعة بيانات صور ( 133 طبيعية و 210 خبيثة و 437 حميدة ). كما تم استخدام المعالجة المسبقة للصور وتقنيات التعلم العميق، بما في ذلك نقل التعلم. في مرحلة المعالجة المسبقة للصور، اهتمنا باستخراج منطقة الورم بدقة. تم تعديل ستة نماذج مدربة مسبقاً وتكييفها مع مشكلتنا Inception, Xception, VGG16, ResNet50V2, EfficientNetB7, DenseNet201 . كانت النتائج التي تم الحصول عليها مرضية، خاصة بالنسبة لتصنيف صور الموجات فوق الصوتية للثدي على أنها طبيعية أو غير طبيعية، بحيث حقق Xception و ResNet50V2 و EfficientNetB7 أعلى دقة بنسبة 100% . في حين حصلت النماذج الأخرى أيضاً على نتائج ممتازة، EfficientNetB7 هو أفضل نموذج مسبق لمهمتنا بدقة 92% عندما يتم تصنيف الصور بالموجات فوق الصوتية على أنها حميدة او خبيثة، و 94% عندما يتم تصنيفها على أنها حميدة أو خبيثة أو طبيعية.

الكلمات المفتاحية :

سرطان الثدي، الموجات فوق الصوتية، الشبكات العصبية التلافيفية، التعلم العميق، نقل التعلم،  
Inception ، Xception ، VGG16 ، ResNet50V2 ، EfficientNetB7 ، DenseNet201 .

## Abstract

Breast cancer is one of the most common causes of death among women. It is essential to detect the disease early before it has a chance of spreading due to its late diagnosis. Although several methods exist for breast cancer detection and diagnosis, UltraSound (US) is the most effective technique. In this study, our purpose is to propose an accurate breast cancer detection model in ultrasound images, based on Convolutional Neural Networks (CNNs). A dataset of 780 breast US images (133 normal, 437 benign, and 210 malignant) was used. Image pre-processing and deep learning techniques were employed, including transfer learning. Our pre-processing strategy included Region Of Interest (ROI) detection and extraction. After that, six pre-trained CNN models were modified and adapted to our problem. InceptionV3, Xception, VGG16, ResNet50V2, EfficientNetB7, and DenseNet201 were employed in several experiments and with various fine-tuning settings to establish the most appropriate one for each scenario. The obtained results were satisfying, especially for classifying the breast ultrasound images into normal and abnormal. Xception, ResNet50V2, and DensNet201 reached the highest accuracy of 100%. Although the remaining models achieved great results, EfficientNetB7 was the most suitable model for our task with an accuracy of 92% for the classification of benign and malignant cases, and 94% for the multi-classification of normal, benign, and malignant cases.

**Keywords** :Breast cancer, Ultrasound, Convolutional neural networks (CNN), Deep Learning, Transfer learning, InceptionV3, Xception, VGG16, ResNet50V2, EfficientNetB7, DenseNet201.

# Contents

<b>1</b>	<b>Introduction</b>	<b>1</b>
1.1	Contexte . . . . .	1
1.2	Organisation de la Mémoire . . . . .	2
<b>2</b>	<b>Intelligence Artificielle: contexte</b>	<b>3</b>
2.1	Introduction . . . . .	3
2.2	Intelligence artificielle . . . . .	4
2.3	Apprentissage automatique . . . . .	4
2.3.1	Types d'apprentissage automatique . . . . .	4
2.3.2	Réseaux de Neurones . . . . .	6
2.4	Apprentissage profond . . . . .	6
2.4.1	Réseaux de neurones de neurones convolutif . . . . .	7
2.4.1.1	Les différentes couches des réseaux de neurones convolutifs . . . . .	7
2.4.2	L'apprentissage par transfert . . . . .	9
2.4.3	Différence entre l'apprentissage profond et l'apprentissage automatique . . . . .	11
2.5	Conclusion . . . . .	11
<b>3</b>	<b>État de l'art</b>	<b>12</b>
3.1	Introduction . . . . .	12
3.2	Cancer de sein . . . . .	12
3.3	Comparaison . . . . .	15
3.4	Conclusion . . . . .	17
<b>4</b>	<b>Implémentation et résultats</b>	<b>18</b>
4.1	Introduction . . . . .	18
4.2	Méthode Proposée . . . . .	19
4.2.1	Environnement de développement . . . . .	20
4.2.1.1	Environnement matériel . . . . .	20
4.2.1.2	Environnement logiciel . . . . .	20
4.3	Dataset . . . . .	21
4.4	Prétraitement . . . . .	22
4.4.1	Extraire_ROI . . . . .	23
4.4.2	Fractionnement de l'ensemble de données équilibrées . . . . .	26

4.5	Classification et fine tuning . . . . .	27
4.6	Résultat et discussion . . . . .	32
4.6.1	Les résultats de l'entraînement . . . . .	32
4.6.2	Les résultats de test . . . . .	38
4.6.3	Comparaison avec d'autres approches . . . . .	48
4.7	Conclusion . . . . .	50
<b>5</b>	<b>Conclusion et perspectives futures</b>	<b>51</b>
5.1	Résumé de nos travaux . . . . .	51
5.2	Limites . . . . .	52
5.3	Perspectives futures . . . . .	52
	<b>Bibliography</b>	<b>53</b>

## List of Figures

2.1	l'IA et ses sous-domaines [1]. . . . .	4
2.2	Types de Machine Learning [2]. . . . .	5
2.3	Architecture des CNN [3]. . . . .	7
2.4	Exemple de la couche de convolution [4] . . . . .	8
2.5	Les types de pooling[5]. . . . .	8
2.6	Concept d'apprentissage par transfert[6]. . . . .	9
2.7	Différence entre Machine learning et Deep learning [7]. . . . .	11
3.1	Approches de classification . . . . .	13
4.1	Méthode proposé. . . . .	19
4.2	Exemples d'images de l'ensemble de données [8]. . . . .	21
4.3	prétraitement . . . . .	22
4.4	Le contenu de BDD_original. . . . .	23
4.5	Echantillons d'images de la base de données BDD_original. . . . .	24
4.6	Echantillons d'images de la base de données BDD_masque. . . . .	24
4.7	Le contenu de BDD_masque. . . . .	25
4.8	Echantillons de la base de données BDD_ROI. . . . .	25
4.9	Fine tuning et classification (Bénigne, Maligne ou Normale) . . . . .	27
4.10	Fine tuning et classification (Bénigne, Maligne) . . . . .	28
4.11	Fine tuning et classification(Normal, Anormal) . . . . .	29
4.12	Architecture du modèle EfficientNetB7 cas normal, bénigne, maligne. . . . .	30
4.13	Architecture du modèle EfficientNetB7 cas (normal, anormal) et (bénigne, maligne). . . . .	31
4.14	La courbe de loss et accuracy du modèle InceptionV3 pour la classification Normale/ Anormale. . . . .	32
4.15	La courbe de loss et accuracy du modèle Xception pour la classification Normale/ Anormale. . . . .	33
4.16	La courbe de loss et accuracy du modèle InceptionV3 pour la classification bénigne/maligne. . . . .	34
4.17	La courbe de loss et accuracy du modèle EfficientNetB7 pour la classification bénigne/maligne. . . . .	34
4.18	La courbe de loss et accuracy du modèle InceptionV3 pour la BDD_original. . . . .	35

---

4.19	La courbe de loss et accuracy du modèle DenseNet201 pour la BDD_original . . .	35
4.20	La courbe de loss et accuracy du modèle ResNet50V2 pour la BDD_masque . . .	36
4.21	La courbe de loss et accuracy du modèle EfficientNetB7 pour la BDD_masque . . .	36
4.22	La courbe de loss et accuracy du modèle DenseNet201 pour la BDD_ROI. . . .	37
4.23	La courbe de loss et accuracy du modèle EfficientNetB7 pour la BDD_ROI. . . .	37
4.24	La matrice de confusion du modèle InceptionV3 pour la classification Normale/ Anormale. . . . .	39
4.25	La matrice de confusion du modèle xception pour la classification Normale/ Anormale. . . . .	40
4.26	La matrice de confusion du modèle InceptionV3 pour la classification bénigne/- maligne . . . . .	40
4.27	La matrice de confusion du modèle EfficientNetB7 pour la classification bénigne/- maligne. . . . .	41
4.28	La matrice de confusion du modèle InceptionV3 pour la BDD_original. . . . .	41
4.29	La matrice de confusion du modèle DenseNet201 pour la BDD_original. . . . .	42
4.30	La matrice de confusion du modèle ReseNet50V2 pour la BDD_masque. . . . .	42
4.31	La matrice de confusion du modèle EfficientNetB7 pour la BDD_masque. . . . .	43
4.32	La matrice de confusion du modèle EfficientNetB7 pour la BDD_ROI. . . . .	43
4.33	La matrice de confusion du modèle DenseNet201 pour la BDD_ROI. . . . .	44

## List of Tables

3.1	Résumé des études connexes. . . . .	16
4.1	L'ensemble de données avant et après équilibrage. . . . .	23
4.2	Fractionnement des ensembles de données équilibrées (Bénigne/ Maligne/ Normale). . . . .	26
4.3	Fractionnement des ensembles de données équilibrées (Bénigne/ Maligne). . . . .	26
4.4	Fractionnement des ensembles de données équilibrées (Normale/ Anormale). . . . .	26
4.5	Résultats expérimentaux pour la classification des images d'échographie du cancer du sein en normale / anormale. . . . .	45
4.6	Résultats expérimentaux pour la classification des images d'échographie du cancer du sein en bénignes/ malignes. . . . .	45
4.7	Résultats expérimentaux pour la classification des images d'échographie du cancer du sein en bénignes/ malignes/ normale. . . . .	47
4.8	Comparaison entre les modèles proposés et les modèles existants . . . . .	49

## List of Acronyms

- AA** Apprentissage Automatique.. 3
- ANN** Artificial Neural Network.. 6
- AP** Apprentissage Profond.. 3
- API** Application Programming Interface.. 21
- BDD** Base de données.. 47
- BUSI** Breast Ultrasound Image.. 2, 15, 19, 21, 51
- CAO** Conception Assistée Par Ordinateur.. 1
- CNN** Convolutional Neural Network.. x, 1, 2, 6, 7, 8, 9, 10, 14, 51, 52
- Colab** Google Colaboratory. 20
- CONV** Couche de convolution.. 7
- DenseNet** Densely Connected Convolutional Networks.. 10
- DL** Deep Learning.. 11
- DQN** Deep Q Network.. 6
- FN** faux négatif.. 38
- FP** faux positif.. 38
- IA** Intelligence artificielle.. x, 3, 4, 11
- IRM** Imagerie Par Résonance Magnétique.. 1
- KNN** k-Nearest Neighbour.. 5
- MATLAB** Matrix LABoratory.. 20

- ML** Machine Learning.. 4, 11
- PAI** Photoacoustic imaging.. 13
- POOL** Couche de Pooling.. 8
- ResNet** Residual Network.. 10
- RN** Réseaux de Neurones.. 6
- RNN** Recurrent Neural Network. 6
- ROI** Region Of Interest.. 19
- SEODTL-BDC** Social engineering optimization with a deep transfer learning-based breast cancer detection and classification.. 13
- SVM** Support Vector Machines. 5
- VGG** Visual Geometric Group.. 10, 14, 15, 19
- VN** vrai négatif.. 38
- VP** vrai positif.. 38

## Contents

---

<b>1.1</b>	<b>Contexte</b> . . . . .	<b>1</b>
<b>1.2</b>	<b>Organisation de la Mémoire</b> . . . . .	<b>2</b>

---

### 1.1 Contexte

Le cancer du sein est un type de cancer qui commence dans le sein quand les cellules commencent à croître hors de contrôle. Le cancer du sein féminin a dépassé le cancer du poumon comme cancer le plus souvent diagnostiqué, avec environ 2,3 millions de nouveaux cas (11,7 % de tous les cas de cancer) [6]. Le cancer du sein est un cancer qui se propage rapidement et qui survient principalement chez les femmes et, dans de rares circonstances, chez les hommes également. Le dépistage précoce du cancer du sein est essentiel pour limiter la prolifération du cancer [9].

De nombreux outils d'imagerie sont disponibles pour détecter, classer et diagnostiquer le cancer du sein comme d'images de mammographie, d'échographie, d'imagerie par résonance magnétique (IRM) et de thermographie. L'échographie du sein l'une des modalités les plus importantes et les plus efficaces pour la détection précoce du cancer du sein en raison de sa nature non-invasive, non-radioactive et rentable [10]. Cependant, la lecture des images échographiques nécessite des radiologues bien formés et expérimentés même un expert bien formé pourrait avoir un taux élevé de variation sur le diagnostic de tumeur [11].

Par conséquent, le diagnostic assisté par ordinateur (CAO) pourrait être utilisé pour aider les radiologues dans la classification et la détection du cancer du sein [11]. Ces dernières années, les réseaux neuronaux d'apprentissage profond, en particulier les réseaux de neurones convolutifs (CNN), ont montré des performances exceptionnelles dans une variété d'applications de vision informatique telles que la détection, la segmentation et la classification des images, au lieu de s'appuyer sur des algorithmes spécialement conçus pour extraire certains types de caractéristiques, les réseaux de neurones convolutifs apprennent à distinguer les caractéristiques directement des images d'entrée et à classer les images [12]. Cependant, en raison de la grande quantité de données requises pour l'apprentissage au réseau neural convolutif et de la rareté des ensembles de données existants, en particulier dans l'industrie médicale, la précision des modèles est réduite. Sinno Jialin Pan et Qiang Yang ont suggéré une solution à ce problème,

qui est le modèle d'algorithme d'apprentissage par transfert [6]. Il applique les paramètres du modèle appris à un autre nouveau modèle afin de réduire le temps consacré au processus de formation et les données nécessaires au nouveau modèle. En raison de la rareté et des petites bases de données existantes dans le domaine médical en général et les bases de données d'échographie en particulier, l'utilisation de l'apprentissage par transfert profond devient la seule solution pour éviter de tels problèmes. Par conséquent, l'utilisation de méthodologies d'apprentissage en profondeur dans les soins de santé aidera les médecins à diagnostiquer et à identifier le cancer du sein, accélérant ainsi le processus de diagnostic [6].

Des études antérieures ont appliqué diverses méthodes d'apprentissage profond pour la détection du cancer du sein par échographie. La base de données BUSI est la base de données d'échographie publique la plus utilisée. Certaines études se sont concentrées sur la phase de pré-traitement, en raison de son importance pour avoir un meilleur processus de formation et certaines études ont sauté la phase de pré-traitement et l'équilibrage de l'ensemble de données. Naturellement, les questions suivantes se posent : La phase de pré-traitement est-elle importante pour obtenir un meilleur résultat?. Par conséquent, l'objectif principal de cette étude est de créer un modèle précis de détection des tumeurs mammaires basé sur une stratégie de pré-traitement et des techniques d'apprentissage profond, y compris l'apprentissage par transfert. Pour ce faire, nous devons connaître les limites des méthodologies existantes. En développant un modèle aussi précis, nous pouvons aider les professionnels dans la détection et le diagnostic du cancer du sein. Par conséquent, le processus de diagnostic prendra moins de temps et deviendra moins coûteux.

## 1.2 Organisation de la Mémoire

Ce mémoire est organisé comme suit :

- Dans le chapitre 2, nous avons présenté en détail tout ce qui concerne les domaines de l'intelligence artificielle, Apprentissage automatique et Apprentissage profond. En plus d'expliquer les concepts des réseaux neuronaux, leurs types et l'apprentissage par transfert, nous avons essayé d'expliquer les différences entre l'apprentissage automatique et apprentissage profond. De plus, nous détaillons le réseau de neurones convolutifs (CNN).
- Dans le chapitre 3, nous définirons tout d'abord la notion du cancer de sein. Ensuite nous avons essayé de nous concentrer sur les travaux connexes récents qui ont été créés dans le même contexte que notre étude.
- Dans le chapitre 4, nous avons expliqué les outils utilisés et nous donnons une description pour la méthode proposé, nous avons expliqué les résultats obtenus.
- Enfin, nous terminons par une conclusion générale résumant ce travail et les perspectives futures possibles.

## Intelligence Artificielle: contexte

### Contents

<b>2.1</b>	<b>Introduction</b>	<b>3</b>
<b>2.2</b>	<b>Intelligence artificielle</b>	<b>4</b>
<b>2.3</b>	<b>Apprentissage automatique</b>	<b>4</b>
2.3.1	Types d'apprentissage automatique	4
2.3.2	Réseaux de Neurones	6
<b>2.4</b>	<b>Apprentissage profond</b>	<b>6</b>
2.4.1	Réseaux de neurones de neurones convolutif	7
2.4.2	L'apprentissage par transfert	9
2.4.3	Différence entre l'apprentissage profond et l'apprentissage automatique	11
<b>2.5</b>	<b>Conclusion</b>	<b>11</b>

## 2.1 Introduction

Récemment, l'intelligence artificielle (**IA**) a connu une croissance significative et a été largement appliquée. Dans diverses applications, y compris l'apprentissage automatique (**AA**) et l'apprentissage profond (**AP**). Il est utilisé dans les soins de santé, l'agriculture, l'éducation et les jeux. Au début de ce chapitre, nous allons fournir un regard sur le domaine de l'intelligence artificielle et ses différentes branches « l'apprentissage automatique et l'apprentissage en profondeur », en définissant ce domaine, ses branches. De plus, nous avons essayé d'expliquer les différences entre **AA** et **AP**. Ensuite, nous avons expliqué les concepts des réseaux neuronaux, leurs types, l'apprentissage par transfert. Nous allons finir le chapitre par une conclusion.

## 2.2 Intelligence artificielle

En termes simples, l'intelligence artificielle désigne des systèmes ou des machines qui imitent l'intelligence humaine pour effectuer des tâches et qui peuvent s'améliorer de manière itérative en fonction des informations qu'ils recueillent[13]. La notion existe depuis des décennies, initialement inventée en 1956 par John McCarthy Professeur adjoint de l'université de Dartmouth. Toutefois, les progrès étaient limités parce qu'il était extrêmement complexe de programmer à la main les algorithmes [14]. Fondamentalement l'intelligence artificielle est une simulation de l'intelligence naturelle dans des machines qui sont programmées pour apprendre les actions des humains. Généralement, l'IA est une technologie qui résout les problèmes en combinant l'informatique et des ensembles de données massifs. Il comprend également les sous-types de l'apprentissage automatique et l'apprentissage profond, qui sont fréquemment utilisés dans le contexte de l'IA. Dans ces domaines, les algorithmes d'IA sont utilisés pour créer des systèmes experts qui font des prédictions ou des classifications basées sur des données d'entrée [15]. La figure 2.1 illustre l'IA et ses sous-domaines l'apprentissage automatique et l'apprentissage profond.




Figure 2.1: l'IA et ses sous-domaines [1].

## 2.3 Apprentissage automatique

L'apprentissage automatique ( Machine learning **ML** en anglais) est une sous-classe de l'intelligence artificielle qui se concentre sur la conception de systèmes qui apprennent ou améliorent le rendement en fonction des données qu'ils consomment. Un ordinateur est formé comment utiliser les connaissances acquises précédemment sans dépendre de l'expérience humaine pour effectuer des recommandations et de prendre des décisions [16].

### 2.3.1 Types d'apprentissage automatique

Il existe fondamentalement 4 types d'algorithmes d'apprentissage automatique(Figure 2.2):

#### 1. Apprentissage supervisé:

Nous voulons dire que nous sommes ceux qui supervisent les instructions de la machine en lui donnant toutes les entrées et les sorties.

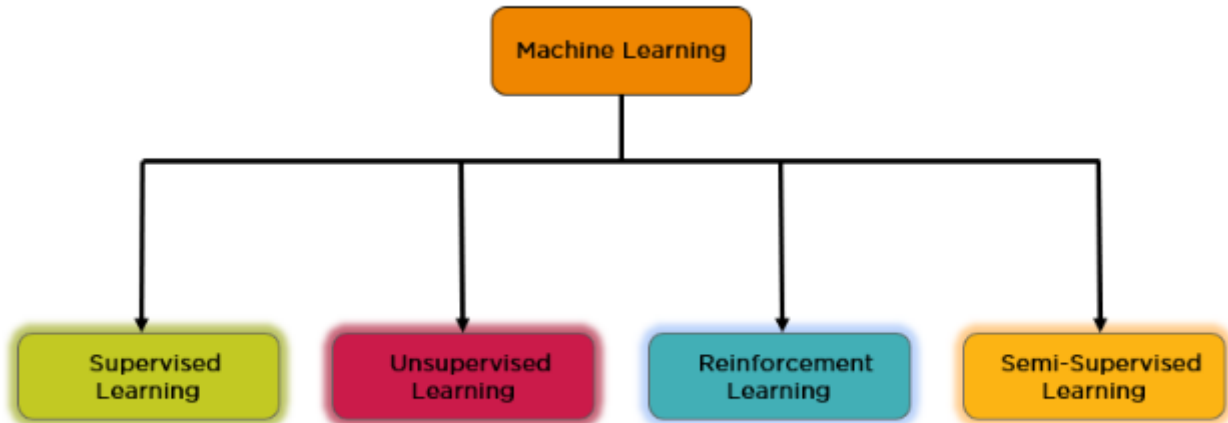


Figure 2.2: Types de Machine Learning [2].

- Les données fournies à la machine sont appelées entraînement (training), et nous voulons dire que la machine s'entraîne sur ces données. - Et quand nous disons superviser, nous devons être conscients des nouvelles données (Testing), et nous voulons dire qu'après que la machine a appris ces données, nous lui donnons dans la phase Tasting de nouvelles données pour faire la prédiction [17].

Le machine learning supervisé peut se subdiviser en deux types :

- **Classification** : la variable de sortie est une catégorie.
- **Régression** : la variable de sortie est une valeur spécifique.

Les principaux algorithmes du machine learning supervisé sont les suivants : arbres de décision, algorithme **KNN** (k-Nearest Neighbors), régression linéaire, machine à vecteurs de support (**SVM**)...[18].

## 2. Apprentissage non supervisé:

Dans le cadre du machine learning non supervisé, l'algorithme détermine lui-même la structure de l'entrée (aucune étiquette n'est appliquée à l'algorithme). Cette approche peut être un but en soi (qui permet de découvrir des structures enfouies dans les données) ou un moyen d'atteindre un certain but.

Il existe deux types de machine learning non supervisé :

- **Clustering**: l'objectif consiste à trouver des regroupements dans les données.
- **Association** : l'objectif consiste à identifier les règles qui permettront de définir de grands groupes de données.

Les principaux algorithmes du machine learning non supervisé sont les suivants : clustering/regroupement hiérarchique et réduction de la dimensionnalité [18].

## Chapter 2:

---

### 3. Apprentissage par renforcement:

L'apprentissage par renforcement correspond au cas où l'algorithme apprend un comportement étant donnée une observation. L'action de l'algorithme sur l'environnement produit une valeur de retour qui guide l'algorithme d'apprentissage [19].

Les principaux algorithmes du machine learning par renforcement sont les suivants : Q-learning, Deep Q Network (DQN)[18].

### 4. Apprentissage semi-supervisé:

Il utilise un ensemble de données étiquetées et non-étiquetées. Il se situe ainsi entre l'apprentissage supervisé qui n'utilise que des données étiquetées et l'apprentissage non-supervisé qui n'utilise que des données non-étiquetées. Il a été démontré que l'utilisation de données non-étiquetées, en combinaison avec des données étiquetées, permet d'améliorer significativement la qualité de l'apprentissage [19].

## 2.3.2 Réseaux de Neurones

Sous-ensemble des techniques d'apprentissage automatique, les réseaux de neurones (RN) sont des programmes informatiques dont l'architecture s'inspire de celle des neurones biologiques. Ces neurones artificiels, reliés entre eux et organisés en couches successives, apprennent à reconnaître des données à partir d'exemples et peuvent généraliser cet apprentissage afin d'aider à la prise de décision. Réseau neuronal se compose généralement de trois types différents de couches : les couches d'entrée, cachés, et couches de sortie [16].

**Type de réseaux neuronaux:** Il a de nombreux types, nous illustrons certains eux :

1. Réseaux neuronaux artificiels (ANN).
2. Réseau neuronal récurrent (RNN).
3. Réseau neuronal convolutif (CNN)...

## 2.4 Apprentissage profond

L'apprentissage profond ou Deep Learning, est un sous-ensemble apprentissage automatique, basé sur des réseaux neuronaux artificiels. Le processus d'apprentissage est qualifié de profond parce que la structure des réseaux neuronaux artificiels se compose de plusieurs couches d'entrée, de sortie et masquées. Chaque couche contient des unités qui transforment les données d'entrée en informations que la couche suivante peut utiliser une tâche prédictive spécifique. Grâce à cette structure, une machine est capable d'apprendre au travers de son propre traitement de données [20].

## Chapter 2:

## 2.4.1 Réseaux de neurones de neurones convolutif

Les réseaux de neurones convolutif ou (**CNN** pour Convolutional Neural Network en anglais) sont les architectures d'apprentissage profond les plus populaires et les plus intéressantes pour les images. Les réseaux de neurones convolutif sont un réseau de neurones multicouches fréquemment utilisé dans l'analyse d'images et consistent en une couche d'entrée, une couche de sortie et une couche profonde cachée [21]. L'architecture des **CNN** est montrée dans la figure 2.3.

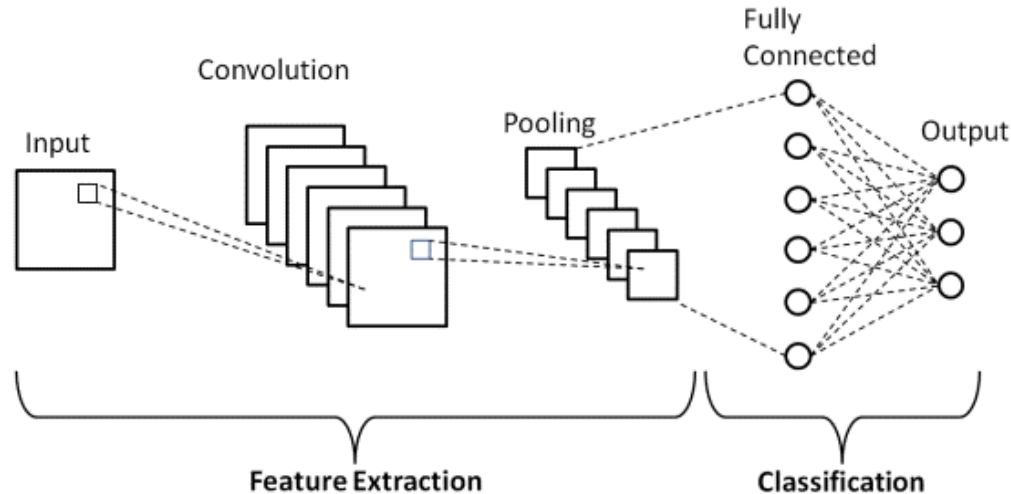


Figure 2.3: Architecture des **CNN** [3].

## 2.4.1.1 Les différentes couches des réseaux de neurones convolutifs

Dans la partie qui suit nous allons citer les couches les plus utilisées pour former un **CNN** :

1. La Couche de Convolution (**CONV**) :

Cette couche est le composant principal des réseaux de neurones convolutifs. Elle vise à déterminer la présence d'un ensemble de caractéristiques dans les images reçues en entrée. Elle consiste à appliquer un filtre enveloppant à l'image pour découvrir les caractéristiques de l'image. L'image passe à travers une série de filtres, ou noyaux de convolution, qui créent de nouvelles images appelées cartes de convolution [22].

Dans la figure 2.4 nous avons un exemple d'image, si nous en extrayons un pixel, disons que sa valeur est de 180 nous obtiendrons aussi ses 8 voisins donc nous obtenons une table de 9 valeurs, et nous avons un filtre (le orange) Le filtrage consiste essentiellement à calculer une nouvelle valeur pour le pixel et ainsi de suite pour tous les pixels [4].

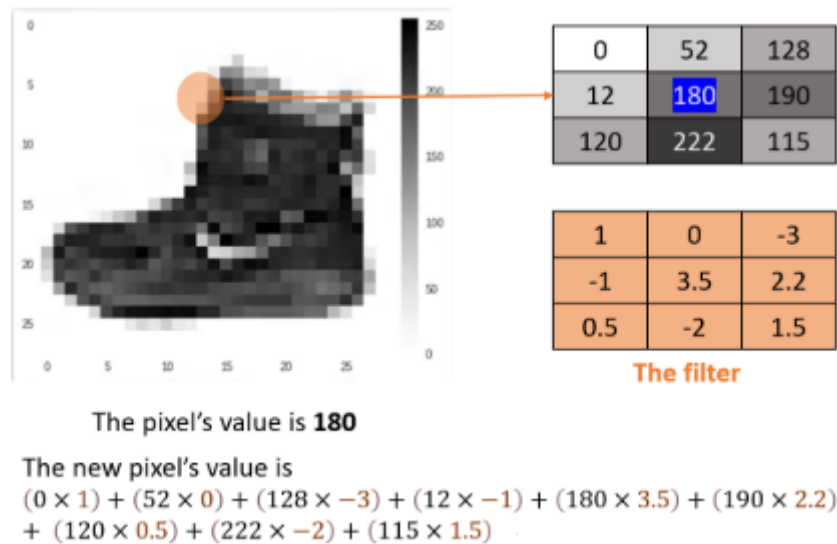


Figure 2.4: Exemple de la couche de convolution [4]

## 2. Couche de Pooling (POOL):

Le pooling est une opération simple qui consiste à réduire la taille spatiale (largeur/hauteur) de l'image sans modifier la profondeur, tout en gardant les caractéristiques de l'image. Cette opération est appliquée après une couche convolutionnelle.[23].

Les deux méthodes conventionnelles de Pooling les plus utilisées dans CNN sont Max Pooling et le mean pooling. Le Max Pooling sélectionne la valeur maximale dans la région de mise en commun. Le "mean pooling" (ou average pooling) calcule la moyenne arithmétique des éléments dans la région de regroupement (figure 2.5).

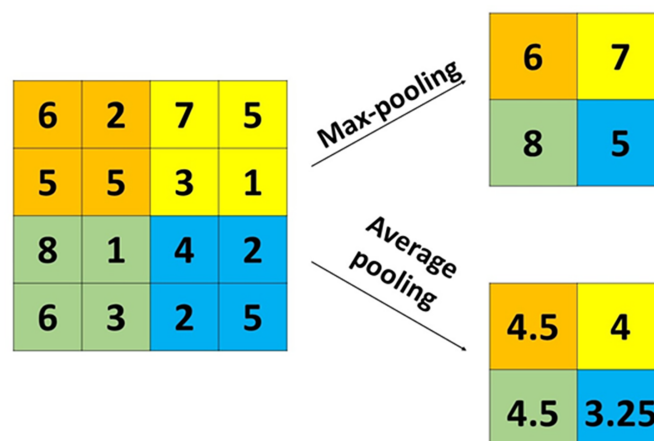


Figure 2.5: Les types de pooling[5].

## 3. Couche entièrement connectée:

La dernière partie de chaque architecture CNN (utilisée pour la classification) est constituée de couches Fully connected, où chaque neurone à l'intérieur d'une couche est connecté à chaque neurone de la couche précédente. La dernière couche des couches entièrement connectées est utilisée comme couche de

## Chapter 2:

sortie(classificateur) de architecture **CNN**. Les couches entièrement connectées utilisent le principe du réseau neuronal traditionnel a perceptron multicouche (MLP).Les couches entièrement connectée sont connectées par la couche finale de convolution ou de pooling, qui se présente sous la forme d'un ensemble de métriques (cartes de caractéristiques). Ces métriques sont aplaties(couche Flatten) pour créer vecteur et ce vecteur est ensuite introduit dans la couche entièrement connectée pour générer la sortie finale du **CNN** [24].

#### 4. Couche Flatten

Elle sert à transformer une matrice de dimension  $n*n$  en un vecteur  $1*n$  pour que ce dernier soit introduit dans la couche de sortie [23].

#### 5. Couche de régularisation (Dropout)

C'est une technique de régularisation (pour combattre l'overfitting) dont le principe est de désactiver aléatoirement à chaque itération un certain pourcentage des neurones d'une couche. Cela évite ainsi la sur spécialisation d'un neurone (et donc l'apprentissage par cœur) [25].

### 2.4.2 L'apprentissage par transfert

Apprentissage par transfert désigne l'ensemble des méthodes permettant de transférer les connaissances acquises lors de la résolution d'un problème donné vers un autre problème. En d'autres termes, l'apprentissage par transfert repose sur une idée simple, celle de ré-exploiter les connaissances acquises dans d'autres configurations (sources) pour la résolution d'un problème particulier (cible)[26] (Figure 2.6).




Figure 2.6: Concept d'apprentissage par transfert[6].

#### Modèles pré-entraînés

Un modèle pré-formé est un modèle pré-construit pour résoudre des problèmes similaires. Au lieu de créer un modèle à partir de zéro pour résoudre un problème similaire, vous pouvez utiliser le modèle formé sur un autre problème comme point de départ. Cette méthode surmonte les conséquences du temps, du potentiel matériel et de l'énorme effort requis [27].

Il existe de nombreuses modèles pré-entraînés, mais ces architectures seront utilisées dans notre études:

## Chapter 2:

- **InceptionV3**

Szegedy C, et.al. a proposé la première version du modèle profond Inception de [CNN](#) en 2016. Il y a trois modules de création typiques au 35x35 avec 288 filtres chacun pour la composante de création du réseau [28].

- **Xception**

En 2017, Chollet François a proposé la deep cnn Xception. L'architecture Xception possède 36 couches convolutionnelles formant la base d'extraction des fonctionnalités du réseau. Son architecture est une couche de convolution séparable en profondeur avec des connexions résiduelles empilées linéairement[29].

- **VGG16**

**VGG16** C'est un modèle de réseau neuronal convolutionnel ([CNN](#)) qui a été développé pour ImageNet, un ensemble de données avec plus de 14 millions d'images divisées en 1000 classes. Karen Simonyan et Andrew Zisserman de l'Université d'Oxford ont développé et présenté l'architecture VGG16 dans leur article intitulé «Very Deep Convolutional Networks for Large-Scale Image Recognition» publié en 2014. L'abréviation «**VGG**» signifie Visual Geometry Group, un groupe de chercheurs de l'Université d'Oxford qui a développé cette architecture, et « 16 » indique qu'il y a 16 couches dans cette architecture [30].

- **ResNet50v2**

est célèbre pour sa profondeur (152 niveaux) et l'ajout de blocs résiduels. En introduisant la connexion identity skip pour que les couches puissent transférer leur entrée sur la couche suivante, le résiduel a résolu le problème de la formation d'une architecture profonde compliquée [31].

- **EfficientNetB7** [32]

EfficientNet est un type de réseau de neurones convolutionnels qui utilise une méthode d'échelle unique qui échelonne uniformément chaque dimension, c.-à-d., largeur, profondeur et résolution en adoptant un coefficient composé. La principale préoccupation dans le domaine de la science des données est que les réseaux ConvNets conventionnels pourraient ne pas être efficaces. EfficientNets utilise une technique connue sous le nom de Compound Scaling pour simplifier le défi de mise à l'échelle. Nous avons utilisé pour cette étude le modèle EfficientNetB7 pré-formé à l'ensemble de données ImageNet.

- **DenseNet201** [33]

Principalement dans les réseaux neuronaux connus sous le nom de réseaux convolutionnels denses (DenseNet), chaque couche reçoit des entrées de tous les niveaux au-dessus et envoie sa carte d'entités à toutes les couches en dessous. Chaque couche dans [DenseNet](#) apprend de chaque couche avant elle d'une manière feed-forward. Dans cette étude, nous avons utilisé [DenseNet201](#), qui est une variante de [DenseNet](#), est un réseau de neurones convolutionnels à 201 couches. Il utilise la base de données ImageNet pour charger un réseau pré-formé qui a été formé sur plus d'un million d'images.

## Chapter 2:

### 2.4.3 Différence entre l'apprentissage profond et l'apprentissage automatique

La méthode utilisée pour extraire les caractéristiques utilisées par la classification est la principale distinction entre DL et ML, qui est incluse dans la même phase pour le deep Learning par rapport au machine Learning. [7]. La figure 2.7 explique la différence entre eux.

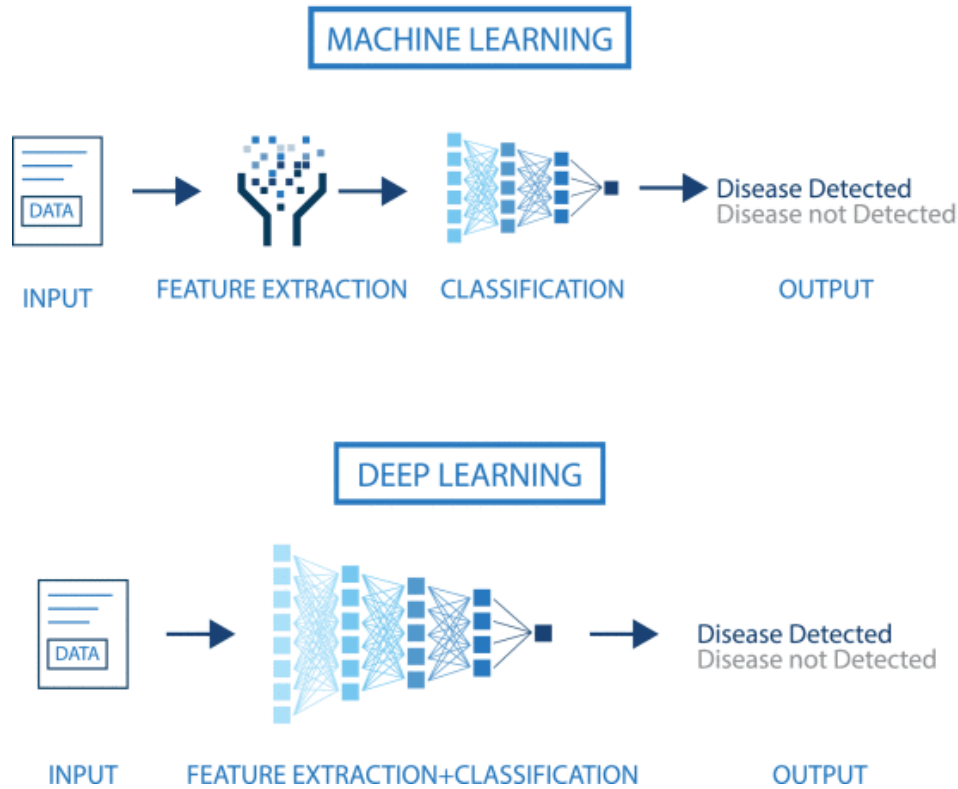


Figure 2.7: Différence entre Machine learning et Deep learning [7].

## 2.5 Conclusion

Dans ce chapitre, nous avons présenté un regard sur l'intelligence artificielle et ses différentes branches «l'apprentissage automatique et l'apprentissage en profondeur». Nous avons d'abord commencé par la description de IA, ensuite l'apprentissage automatique, en définissant ce domaine, leur types avec une étude sur les réseaux de neurones. Ensuite, nous avons passé à la description de l'apprentissage profond « Deep Learning », puis nous avons faire une étude détaillée sur un des types de réseaux de neurones, appelé réseau de neurones convolutif. Et à la fin de ce chapitre, une définition de l'apprentissage par transfert et la différence entre DL et ML. Dans le prochain chapitre, nous allons présenter quelques travaux existant pour détecter le cancer de sein.

## Contents

<b>3.1</b>	<b>Introduction</b>	<b>12</b>
<b>3.2</b>	<b>Cancer de sein</b>	<b>12</b>
<b>3.3</b>	<b>Comparaison</b>	<b>15</b>
<b>3.4</b>	<b>Conclusion</b>	<b>17</b>

### 3.1 Introduction

Dans le domaine de la détection du cancer du sein, de nombreuses études ont été publiées. Dans ce chapitre nous définirons tout d'abord la notion du cancer de sein, puis nous allons présenter quelques travaux existants dans la littérature sur la détection du cancer de sein. Ensuite, nous allons faire une comparaison et nous allons finir le chapitre par une conclusion.

### 3.2 Cancer de sein

le terme « cancer » est un le nom générique qui définit un groupe de maladies qui touchent l'organisme au niveau cellulaire. Bien qu'il existe un grand nombre de types de cancer, tous commencent par une division anormale des cellules et une croissance hors de tout contrôle de ces dernières. Ces cellules anormales peuvent se regrouper pour former une masse tissulaire nommée tumeur. Si le sein est le site d'origine primaire de la croissance d'un cancer ou d'une tumeur, l'affection est appelée « cancer du sein » [34]. Particulièrement, Le cancer du sein féminin a déjà dépassé le cancer du poumon comme principale cause d'incidence du cancer dans le monde, représentant 11,7 % de tous les cas de cancer, avec environ 2,3 millions de nouveaux cas [35]. Elle est ainsi devenue la maladie la plus fréquente dans la grande majorité des pays [35]. Le dépistage précoce et la surveillance des patientes sont considérés comme des facteurs importants du traitement du cancer du sein. parmi une variété de modalités. L'échographie est une technique pour la détection du cancer du sein. Dans le domaine de l'apprentissage automatique, l'apprentissage profond a été utilisé par plusieurs auteurs dans divers domaines, et il est apparu comme une innovation croissante [6]. Les réseaux de neurones à convolution profonde sont l'un des algorithmes d'apprentissage les plus efficaces pour comprendre le contenu visuel, avec des résultats exceptionnels en segmentation, classification, détection et extraction d'images [36]. Cependant, en raison de la

grande quantité de données requises pour la formation CNN et de la rareté des ensembles de données existants, en particulier dans l'industrie médicale, la précision des modèles est réduite. Sinno Jialin Pan et Qiang Yang ont suggéré une solution pour cette question au début de 2009, qui est l'apprentissage par transfert modèle algorithmique [37]. Il applique les paramètres du modèle appris à un autre nouveau modèle afin de réduire le temps consacré au processus de formation et les données nécessaires au nouveau modèle [6]. En raison de la rareté et des petites bases de données existantes dans le domaine médical en général et les bases de données de échographie en particulier, l'utilisation de l'apprentissage par transfert profond devient la seule solution pour éviter de tels problèmes. Par conséquent, l'utilisation de méthodologies d'apprentissage en profondeur dans les soins de santé aidera les médecins à diagnostiquer et à identifier le cancer du sein, accélérant ainsi le processus de diagnostic [6].

Dans le domaine de la détection et du diagnostic du cancer du sein, de nombreuses études ont été publiées. Pourtant, chaque groupe s'est concentré sur un sujet spécifique dans ce grand domaine. Nous nous concentrerons sur ceux qui ont travaillé sur la détection en utilisant des images échographie. et qui peut être divisé en trois catégories (Figure 3.1):

- La détection du cancer du sein: classification à classes multiples où les classes sont normale, bénigne ou maligne.
- Détection des tumeurs mammaires: classification binaire de bénignes ou malignes images échographiques.
- Détection des tumeurs mammaires, c'est aussi une classification binaire, les classes sont normales, anormales.

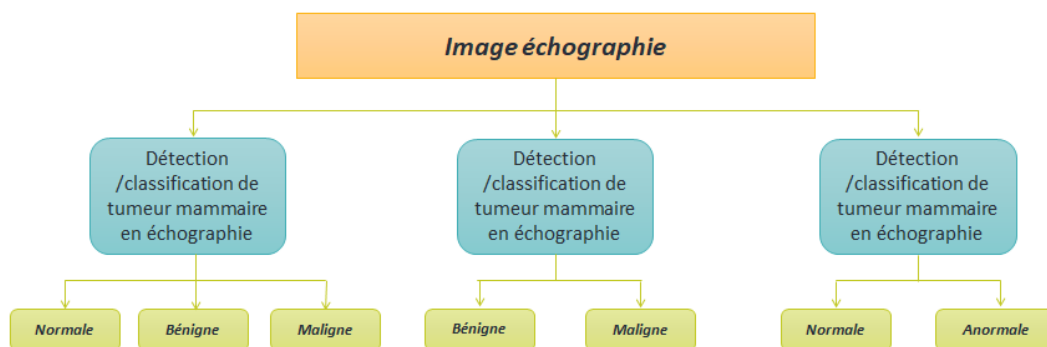


Figure 3.1: Approches de classification

En commençant par la première catégorie, qui peut être définie comme la classification des images échographiques comme normales, bénignes ou malignes. Nous pourrions aussi énumérer quelques ouvrages récents, notamment :

M. Althobaiti et al [38] ont proposé une nouvelle optimisation de l'ingénierie sociale avec un modèle de détection et de classification du cancer du sein (SEODTL-BDC) basé sur l'apprentissage en profondeur à l'aide de l'imagerie photoacoustique (PAI). Ils ont proposé des techniques en deux étapes. Le premier pré-traitement a été fait en utilisant le filtrage bilatéral d'élimination du bruit. Après cette phase de segmentation d'image a été appliquée en utilisant un modèle LEDNet léger. En outre, ResNet-18 a été utilisé pour l'extraction de fonctionnalités. Enfin, une phase de classification utilisant le classificateur SEO-RNN. En utilisant l'ensemble

de données de référence BUSI, ils ont atteint 99,40 %. Les auteurs ont utilisé ResNet-18 juste pour l'extraction de fonctionnalités, où ils auraient pu l'utiliser aussi pour la classification sans avoir besoin d'utiliser des modèles RNN.

In [39] dix modèles de classification CNN bien connus (ResNet18, ResNet50, ResNet101, InceptionV3, InceptionResNetV2, GoogleNet, MobilenetV2, SqueezeNet, DenseNet201 et Xception) ont été utilisés pour classer les images par apprentissage par transfert (TL). Un ensemble de données de 780 Images BUS (133 normales, 437 bénignes et 210 malignes) ont été utilisés. Le meilleur résultat était pour InceptionResNetV2 avec une accuracy de 82.93 %.

I.PACAL. [40], a appliqué des méthodes d'apprentissage en profondeur pour classer les images échographiques en vue de la détection précoce du cancer du sein. Les performances de classification des images US mammaires d'architectures telles que AlexNet, VGG16, VGG19, ResNet18, ResNet34, ResNet50, ResNet101, GoogleNet et EfficientNet, qui sont parmi les architectures CNN les plus basiques, ont été comparées. Ensuite, les modèles de transformateurs, qui sont l'une des architectures de deep learning les plus populaires de nos jours et montrent des performances similaires à celles des architectures de CNN dans les images médicales, sont examinés. Des études expérimentales ont été appliquées à l'ensemble de données BUSI. Le modèle vision transformer est plus efficace que d'autres modèles avec une accuracy de 88.6 %.

F. Uysal et al.[41]visant à adopter une approche différente. L'hypothèse est qu'en utilisant l'intelligence artificielle pour l'analyse échographique, le processus de diagnostic assisté par ordinateur peut être rendu plus efficace. Le but de la recherche est de classer les échantillons bénins, malins et normaux. L'ensemble de données contient 780 images au total. Les données ont été divisées en 70 % pour la formation et 30% pour la validation. Dans cet ensemble de données, l'augmentation des données et le prétraitement des données sont également appliqués. Trois modèles sont utilisés pour classer les échantillons (ResNet50, ResNeXt50, VGG16). un score d'accuracy pouvant atteindre 85.83 % peut être obtenu avec ResNeXt50 dans les images échographiques, alors que ResNet50 obtient 85.4 % et 81.11 % pour VGG16.

Passer à la deuxième catégorie, la détection du cancer du sein, où les classes sont bénignes, malignes. Nous pourrions aussi énumérer quelques ouvrages récents, comme :

Comme le VGG16 est une architecture de modèle très complexe et conçu pour le traitement d'image dense, le traitement d'image échographique est beaucoup plus simple pour ce modèle, ce qui le rend très susceptible de déborder. Une architecture StepNet avec traitement neutrosophique et regroupement de moyens flous dans les couches finales a été proposée pour le traitement d'images échographiques par Sivanandan et al[42]. Les données utilisées contenaient 580 cas bénins et 562 cas StepNet a donné une précision de 0.98%.

Y. WANG et al. [43] proposé un diagnostic assisté par ordinateur basé sur un réseau neural convolutionnel (CNN) qui classe les lésions mammaires comme bénignes et malignes. Le réseau de neurones convolutionnels proposé adopte un modèle Inception-v3 modifié pour fournir une extraction efficace des fonctionnalités dans l'imagerie ABUS. Par la suite, l'étude proposée a comparé les résultats avec les schémas conventionnels d'extraction par apprentissage automatique, en particulier l'analyse des composantes principales (PCA) et l'histogramme des gradients orientés (HOG), notre méthode a permis d'améliorer considérablement le rendement en matière de classification. L'ensemble de données utilisé contient 316 lésions mammaires. La sensibilité et la spécificité du CNN proposé étaient de 0.886 et 0.876 respectivement.

Enfin, pour la détection du cancer du sein en échographie, où les classes sont normales ou anormaux. Néanmoins, nous pourrions citer les recherches récentes suivantes:

S.cho et al. [44] a proposé une technique de segmentation des tumeurs mammaires basée sur la classification et la segmentation des images échographiques. Un réseau de classification d'ensemble de tumeurs mammaires (BTEC-Net) est conçu pour classer si une image échographique contient des tumeurs mammaires ou non. Au stade de la segmentation, le modèle RFS-UNet a été utilisé pour effectuer la segmentation uniquement sur les images classées comme anormales par le BTEC-Net. le BTEC-Net proposé a obtenu une précision de 99,487 % lorsqu'il est appliqué à l'ensemble de données BUSI.

### 3.3 Comparaison

Plusieurs études ont été mises en œuvre pour aider les spécialistes du diagnostic et de la détection du cancer du sein. Pour les études ceux mentionnés précédemment qui ont proposé un modèle de détection de tumeur du sein, qui est sur le même sujet spécifique que le nôtre. Aucun d'entre eux n'a pu atteindre une accuracy allant jusqu'à 100% (Tableau 3.1). Cela pourrait être dû à la phase de pré-traitement ([40]) ou à la quantité de données utilisées, l'ensemble de données choisi a un effet majeur sur l'accuracy du modèle puisque les reseaux de neurones convolutif profonds nécessitent une grande quantité de données. tous les travaux antérieurs, y compris ([38], [39], [42], [43], [40], [41] et [44]) ont utilisé la petite base de données ou le problème du déséquilibre des données ([38], [40], [41]) parce que si le problème du déséquilibre des données dans l'ensemble de données est supprimé, la performance augmentera encore plus. Dans notre étude, nous nous sommes concentrés à éviter ces limites en créant un modèle de détection de tumeur mammaire. Nous avons donc voulu proposer un modèle de détection des tumeurs mammaires bien formé et précis.

Table 3.1: Résumé des études connexes.

Etude	base de données	Classes	Modèles	Accuracy
M.Althobaiti, et al 2022 [38]	BUSI <sup>4</sup>	<sup>3</sup>	Modèle proposé	99.4%
S.Badawy, et al 2021 [39]	BUSI <sup>4</sup>	<sup>3</sup>	ResNet18	64.53%
			ResNet50	74.13%
			ResNet101	58.40%
			InceptionV3	65.60%
			InceptionResNetV2	82.93%
			GoogleNet	74.67%
			MobileNet-V2	52.53%
			SqueezeNet	77.33%
			DenseNet201	70.40%
Xception	58.13%			
I.PACAL 2022 [40]	BUSI <sup>4</sup>	<sup>3</sup>	AlexNet	79.5%
			VGG16	85.4%
			VGG19	78.6%
			GoogleNet	75.6%
			ResNet18	82.6%
			ResNet34	83.8%
			ResNet50	83.1%
			ResNet101	84.7%
			EfficientNet	85.6%
			Swin_Transformer	81.9%
			Vision_Transformer	88.6 %
F. Uysal, et al 2022 [41]	BUSI <sup>4</sup>	<sup>3</sup>	ResNet50	85.4%
			ResNeXt50	85.83%
			VGG16	81.11%.
Sivanandan, et al 2021 [42]	/	<sup>2</sup>	Modèle proposé	98%
Y. WANG, et al 2020 [43]	/	<sup>2</sup>	Modèle proposé	0.9468 <sup>1</sup>
S.cho et al 2022 [44]	BUSI <sup>4</sup>	<sup>2'</sup>	Modèle proposé	99.487%

<sup>1</sup> AUC :Area under curve    <sup>2</sup> Bénignes /malignes.    <sup>2'</sup> Normale/Anormale..

<sup>3</sup> Bénigne/Maligne/Normale.    <sup>4</sup> BUSI: Breast Ultrasound Images

## 3.4 Conclusion

Dans ce chapitre nous avons défini la notion du cancer de sein, puis nous avons présenté quelques travaux existant dans la littérature à propos de notre travail.

Dans le chapitre qui suit nous allons détailler notre travail pour la détection du cancer de sein à partir des images échographiques ainsi que les résultats obtenus.

## Implémentation et résultats

### Contents

---

<b>4.1</b>	<b>Introduction</b>	<b>18</b>
<b>4.2</b>	<b>Méthode Proposée</b>	<b>19</b>
4.2.1	Environnement de développement	20
<b>4.3</b>	<b>Dataset</b>	<b>21</b>
<b>4.4</b>	<b>Prétraitement</b>	<b>22</b>
4.4.1	Extraire_ROI	23
4.4.2	Fractionnement de l'ensemble de données équilibrées	26
<b>4.5</b>	<b>Classification et fine tuning</b>	<b>27</b>
<b>4.6</b>	<b>Résultat et discussion</b>	<b>32</b>
4.6.1	Les résultats de l'entraînement	32
4.6.2	Les résultats de test	38
4.6.3	Comparaison avec d'autres approches	48
<b>4.7</b>	<b>Conclusion</b>	<b>50</b>

---

## 4.1 Introduction

L'objectif de ce chapitre est de présenter les étapes de l'implémentation de notre approche proposée. on va commencer par la présentation de notre methode proposé. Puis nous allons présenter les Outils et environnement de développement utilisés pour la réalisation de notre projet. Ensuite les étapes de la réalisation du modèle et on termine par les résultats obtenus.

## 4.2 Méthode Proposée

Dans notre méthode proposée (Figure 4.1), nous proposons une étude en deux étapes pour classer les images échographiques pour la détection du cancer du sein.

La première étape est basée sur la proposition d'une approche de pré-traitement, puis nous avons visé à valider l'approche en utilisant une phase de classification des échographies. La deuxième étape a consisté à modifier puis à déterminer le modèle CNN pré-formé le mieux adapté à notre cas, ainsi que les meilleurs paramètres de réglage et les critères qui influencent les résultats. Nous avons utilisé la base de données BUSI à laquelle nous avons donné le nom BDD\_original. L'approche de prétraitement commence par l'étape d'extraction de la région d'intérêt ROI car la base de données contient deux types d'image (image masque et image d'origine). Par conséquent, il a fallu combiner les deux types pour extraire la ROI qui est dans ce cas le sein. maintenant, nous avons un nouveau base de données (BDD\_masque). Nous avons appliqué l'étape d'extraction de la ROI dans l'ensemble de données pour éliminer l'arrière-plan et conserver la zone tumorale. maintenant, nous avons un nouvel ensemble de données (BDD\_ROI). Par la suite, nous avons redimensionné et divisé nos trois ensembles de données en ensembles d'apprentissage, et ensembles de tests étant de 80 % et 20 % respectivement.

La deuxième étape, en utilisant l'apprentissage par transfert, nous avons adapté certains des modèles existants préformés à l'ensemble de données pré-traitées, afin de déterminer lesquels sont les plus appropriés pour notre étude. les modèles choisis étaient InceptionV3, Xception, VGG16, ResNet50V2, EfficientNetB7, DenseNet201. De plus, des ajustements importants ont été apportés aux modèles CNN pré-formés qui ont été utilisés pour notre étude pendant la phase de fine-tuning. Enfin, tous les modèles ont été évalués pour déterminer leur exactitude et les résultats obtenus de chaque modèle ont été comparés.

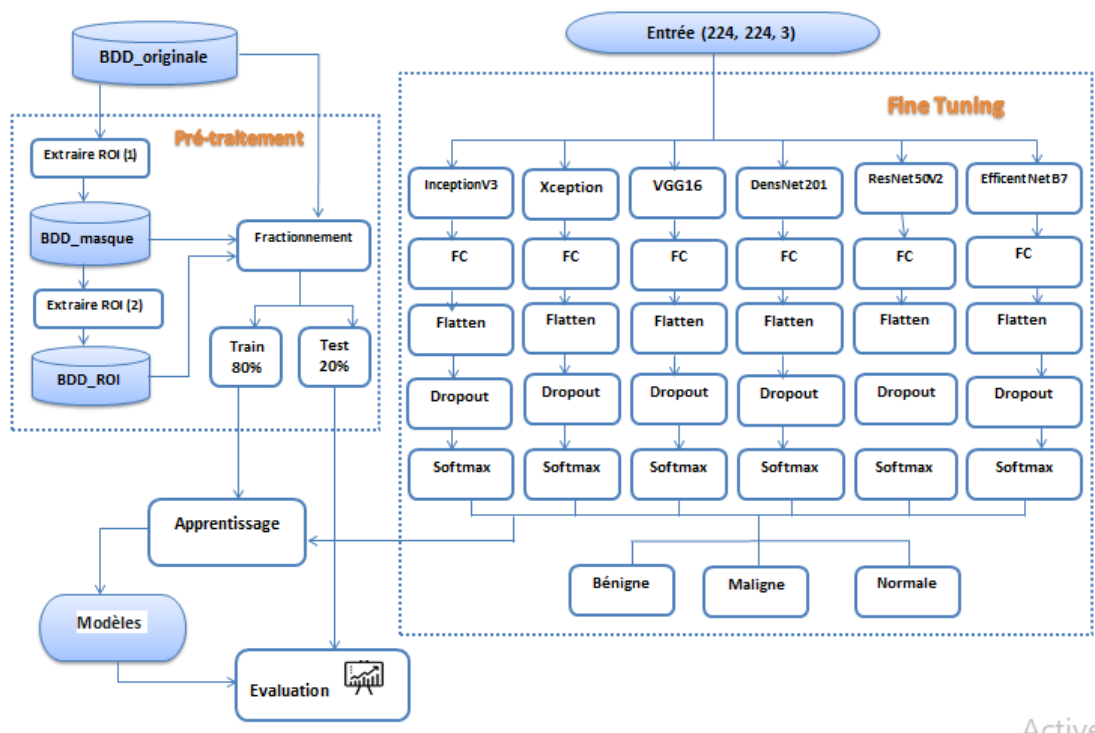


Figure 4.1: Méthode proposé.

## 4.2.1 Environnement de développement

### 4.2.1.1 Environnement matériel

Nous avons utilisé un processeur Intel Core i5 10400F avec 16 Go de RAM pour l'étape de prétraitement . Un processeur Intel(R) Core(TM) i3-2348M et une capacité mémoire de 4 Go avec Windows 10, 64 bit type système. Un PC de processeur Intel(R) Core(TM) i7-6498DU et une capacité mémoire de 8 Go avec Windows 10, 64 bit type système .

### 4.2.1.2 Environnement logiciel

- **Google Colab**

Colaboratory, souvent raccourci en "**Colab**", est un service cloud, offert par Google (gratuit), basé sur Jupyter Notebook et destiné à la formation et à la recherche dans l'apprentissage automatique. Cette plateforme permet d'entraîner des modèles de Machine Learning directement dans le cloud. Sans donc avoir besoin d'installer quoi que ce soit sur notre ordinateur à l'exception d'un navigateur. Google colab est un outil complet pour entraîner rapidement et tester rapidement des modèles d'apprentissage automatique sans avoir de contrainte matérielle[45].

- **Matlab**

**MATLAB** (Matrix LABoratory) est à la fois un langage de programmation et un environnement pour faire du calcul numérique, il permet de faire plusieurs tâches telles que: des manipulations sur des matrices, le traçage des fonctions, la visualisation de données, le traitement d'images, l'implémentation de nouveaux algorithmes, et faire des interfaces graphiques...etc[46].

- **Tensorflow**

TensorFlow est une bibliothèque de logiciels gratuite et open source pour l'apprentissage automatique et l'intelligence artificielle. Il peut être utilisé dans une gamme de tâches, mais se concentre particulièrement sur la formation et l'inférence des réseaux de neurones profonds [27].

- **Keras**

Keras est une bibliothèque de logiciels open source qui fournit une interface Python pour les réseaux de neurones artificiels. Keras agit comme une interface pour la bibliothèque TensorFlow [27].

### - Les modèles de transfert d'apprentissage

Selon l'API Keras, il existe différents modèles disponibles. Dans cette étude, six modèles pré-entraînés ont été utilisés pour la détection des tumeurs mammaires : Inception V3, Xception, VGG16, ResNet50 V2, EfficientNet B7, DenseNet201.

## 4.3 Dataset

Un ensemble de données (Breast Ultrasound Image BUSI) open-source sur la plateforme Kaggle [47] a été utilisé pour classer les images du cancer du sein. L'ensemble de données est déjà utilisé dans la littérature. Ces données recueillies auprès de 600 patients âgés de 25 à 75 ans en 2018 ont été obtenues par Al-Dhabyani et al., partagées en tant que source ouverte [8]. L'ensemble de données comprend 780 images d'une taille moyenne de 500\*500 pixels. Les images sont au format PNG. Cet ensemble de données comprend trois catégories: normale (133 images), maligne (210 images) et bénigne (487 images).

La figure 4.2 présente un échantillon de l'ensemble de données.




Figure 4.2: Exemples d'images de l'ensemble de données [8].

## 4.4 Prétraitement

Le prétraitement de l'ensemble de données est essentiel pour obtenir un rendement et une précision accrus. La figure 4.3 représente le prétraitement de notre ensemble de données.

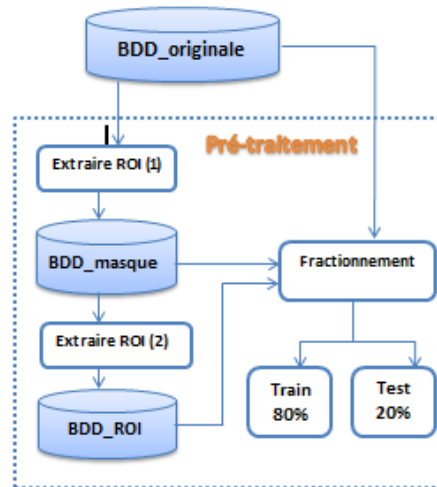


Figure 4.3: prétraitement

Dans l'ensemble de données "BDD\_originale":

- Si le modèle de classification est multi-classe, la base de données contient 780 images (normal=133, Bénigne = 437 et Maligne = 210).
- Si le modèle de classification est une classification binaire (Bénigne, Maligne), la base de données contient 647 images (Bénigne = 437 et Maligne = 210). et si le modèle de classification (Normale, Anormale), la base de données contient les cas normaux et les cas anormaux sont une combinaison de cas bénins et malins (Normale = 133, Anormale = 647).

- **Équilibrage de la base de données**

L'ensemble de données récupéré pour cette étude n'était déséquilibré selon la classe, c'est-à-dire que le nombre d'images de tissus normaux, malins et bénins dans l'ensemble de données n'étaient pas égales. Les ensembles de données non équilibrés sont un gros problème pour les modèles d'apprentissage profond que nous avons rencontrés nous-mêmes lors des premiers essais d'entraînement qui ont donné à des mauvais résultats. Pour résoudre ce problème, nous avons un choix : minimiser le nombre d'images dans la classe majoritaire (Table 4.1).

Table 4.1: L'ensemble de données avant et après équilibrage.

	Classe	Les données avant équilibrage	Les données après équilibrage
<b>Classification multiple</b>	Bénignes	437	133
	Malignes	210	133
	Normale	133	133
<b>Classification binaire</b>	Bénignes	437	210
	Malignes	210	210
	Normale	133	133
	Anormal(Bénignes /Malignes)	647	133

#### 4.4.1 Extraire\_ROI

##### Extraire\_ROI(1)

Notre base de données (BDD\_original) contient trois catégories benign, malignant et normal. Et chaque catégorie contient deux types d'images, une image originale et son masque et peut-être contient plusieurs masques. la figure 4.4 représente la contenu de notre base de données, et la figure 4.5 illustre un exemple de deux images Bénign et son masque. où la première est bénigne et la deuxième est son masque.

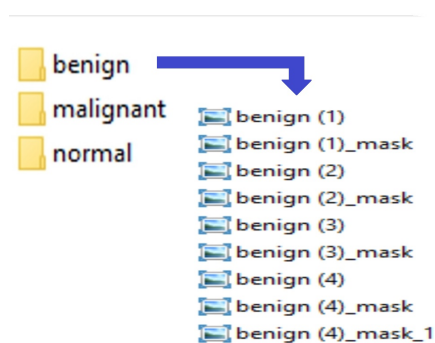




Figure 4.4: Le contenu de BDD\_original.



(a) Bénign(1).



(b) Bénign(1)\_mask.

Figure 4.5: Echantillons d'images de la base de données BDD\_original.

tous les images de notre base de données faire :

si la première image est une image originale faire la recherche de leur image masque .

multiplier les deux images .

enregistrer la nouvelle image .

sinon

lire l'image suivante .

La figure 4.6 illustre un exemple de notre nouveau base de données BDD\_masque et la figure 4.7 représente le contenu de notre base de données.



Figure 4.6: Echantillons d'images de la base de données BDD\_masque.




Figure 4.7: Le contenu de BDD\_masque.

### Extraire\_ROI(2)

On applique l'algorithme suivant dans la BDD\_masque, en première étape il commence par lire les différentes lignes de cette matrice (image) de la base de données masque, si il tombe sur une cellule blanche il passe à la ligne suivante, dans le cas contraire il supprime la ligne. En deuxième étape il fait même procédure aux différentes colonnes. La figure 4.8 illustre un exemple de notre nouveau base de données BDD\_ROI.



Figure 4.8: Echantillons de la base de données BDD\_ROI.

### 4.4.2 Fractionnement de l'ensemble de données équilibrées

On a divisé les données à 80 % des données du dataset pour l'entraînement et les 20 % restants seront exploités pour le test. comme le montre les tables 4.2,4.3, 4.4.

Table 4.2: Fractionnement des ensembles de données équilibrées (Bénigne/ Maligne/ Normale).

Classe	Bénigne	Maligne	Normale	Totale
Nombre d'images	133	133	133	399
Train (80%)	106	106	106	318
Test (20%)	27	27	27	81

Table 4.3: Fractionnement des ensembles de données équilibrées (Bénigne/ Maligne).

Classe	Bénigne	Maligne	Totale
Nombre d'images	210	210	420
Train (80%)	168	168	336
Test (20%)	42	42	84

Table 4.4: Fractionnement des ensembles de données équilibrées (Normale/ Anormale).

Classe	Normale	Anormal		Totale
		Bénigne	Maligne	
Nombre d'images	133	66	67	266
Train (80%)	106	53	53	212
Test (20%)	27	13	14	54

- Importer un ensemble de données

La prochaine étape, L'importation des données dans les notebooks Google Colaboratory.

## 4.5 Classification et fine tuning

Dans notre cas, nous utilisons six modèles pré-entraînés ( InceptionV3, Xception, VGG16, ResNet50V2, EfficientNetB7, DenseNet201) nous les avons adapté à notre nouveau cas. C'est pour cela, nous avons effectué les changements suivants pour tous les modèles :

La première approche est le cas d'une classification multi-classe:

- Premièrement, La première couche de notre modèle a l'entrée de la forme 224x224 qui est la taille de notre image puis on a importé les modèles sans inclure le haut, ce qui signifie que nous n'avons pas inclus la couche entièrement connectée au sommet des réseaux.
- Suivant, on ajoute une couche entièrement connectée "dense" de 512 neurones avec une fonction d'activation ReLU.
- on ajout une couche Flatten suivie par une couche Dropout.
- Et pour la sortie du réseau, parce que notre cas avait une classification multi-classe, nous avons introduit une sortie avec une fonction d'activation softmax pour ajuster le modèle à notre situation (figure 4.9).

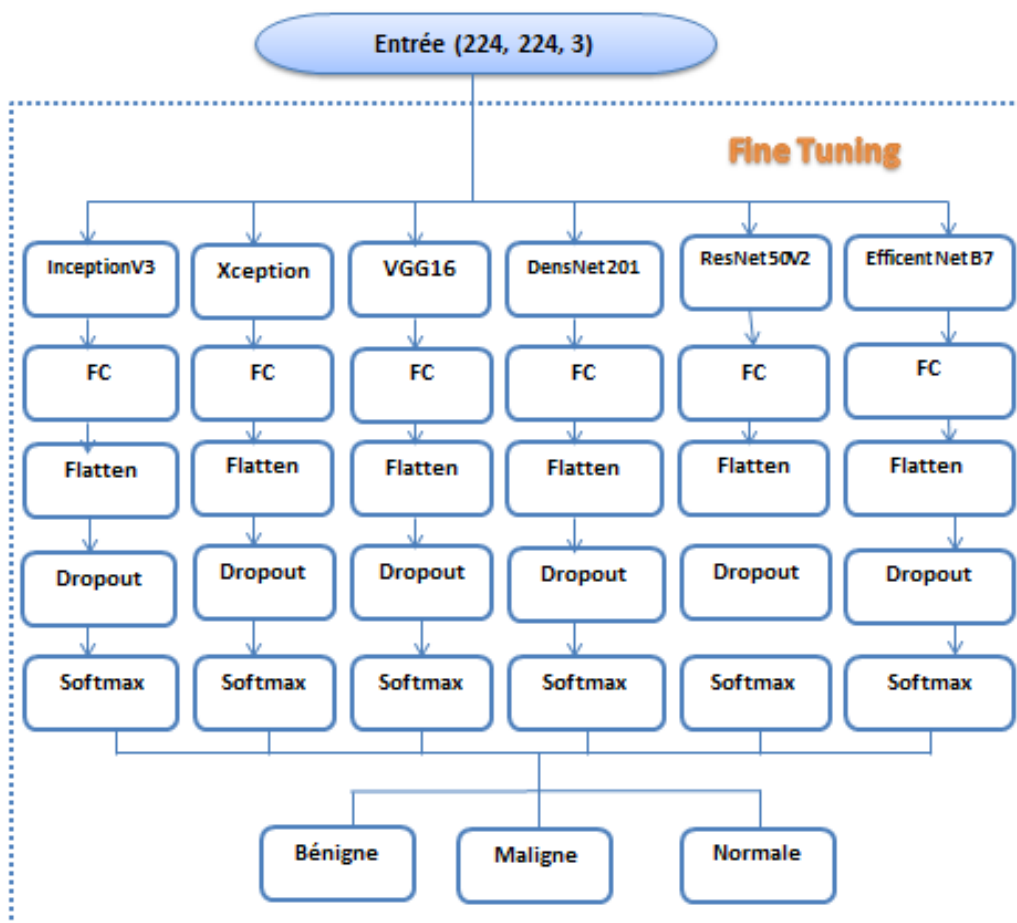


Figure 4.9: Fine tuning et classification (Bénigne, Maligne ou Normale)

La deuxième approche est le cas d'une classification binaire:

- Premièrement, La première couche de notre modèle a l'entrée de la forme 224x224 qui est la taille de notre image puis on a importé les modèles sans inclure le haut, ce qui signifie que nous n'avons pas inclus la couche entièrement connectée au sommet des réseaux.
- Suivant, on ajout une couche entièrement connectée "dense" de 512 neurones avec une fonction d'activation ReLU.
- on ajout une couche Flatten suivie par une couche Dropout.
- Et pour la sortie du réseau, parce que notre cas avait une classification binaire, nous avons introduit une sortie avec une fonction d'activation sigmoïde pour ajuster le modèle à notre situation (figures 4.10, 4.11).

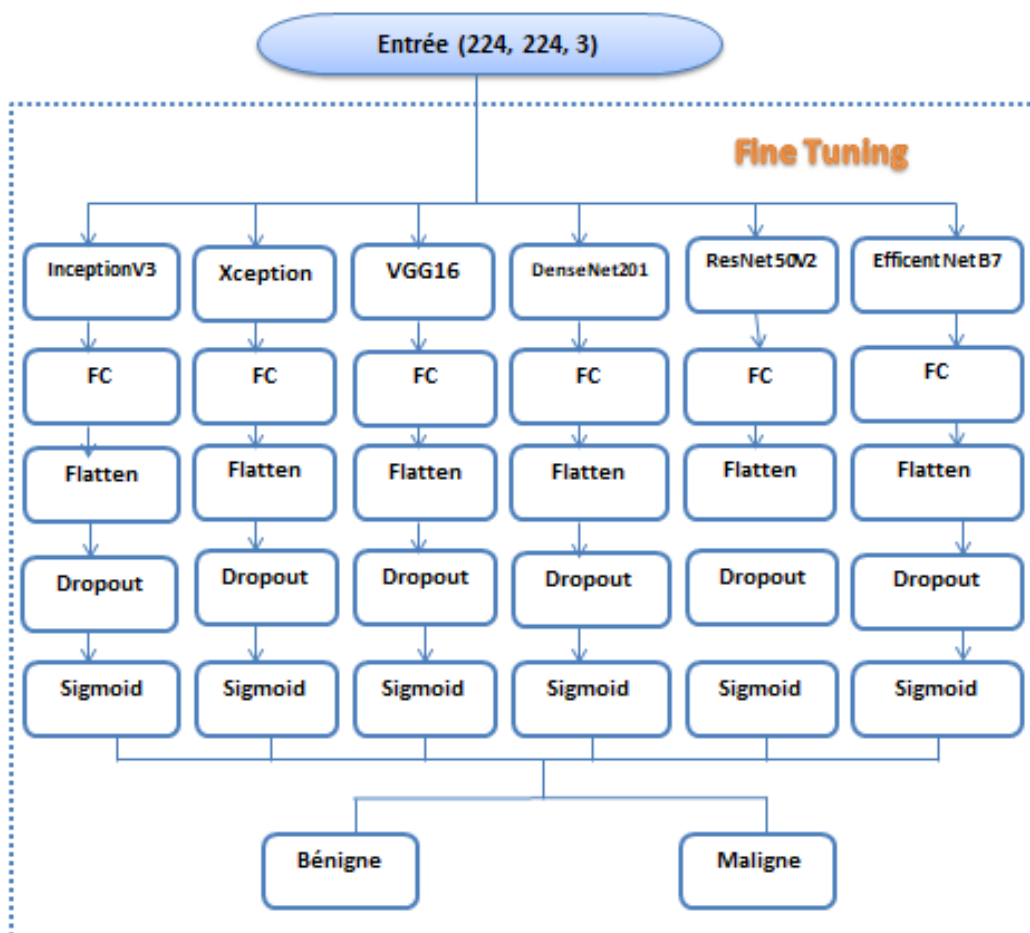


Figure 4.10: Fine tuning et classification (Bénigne, Maligne)

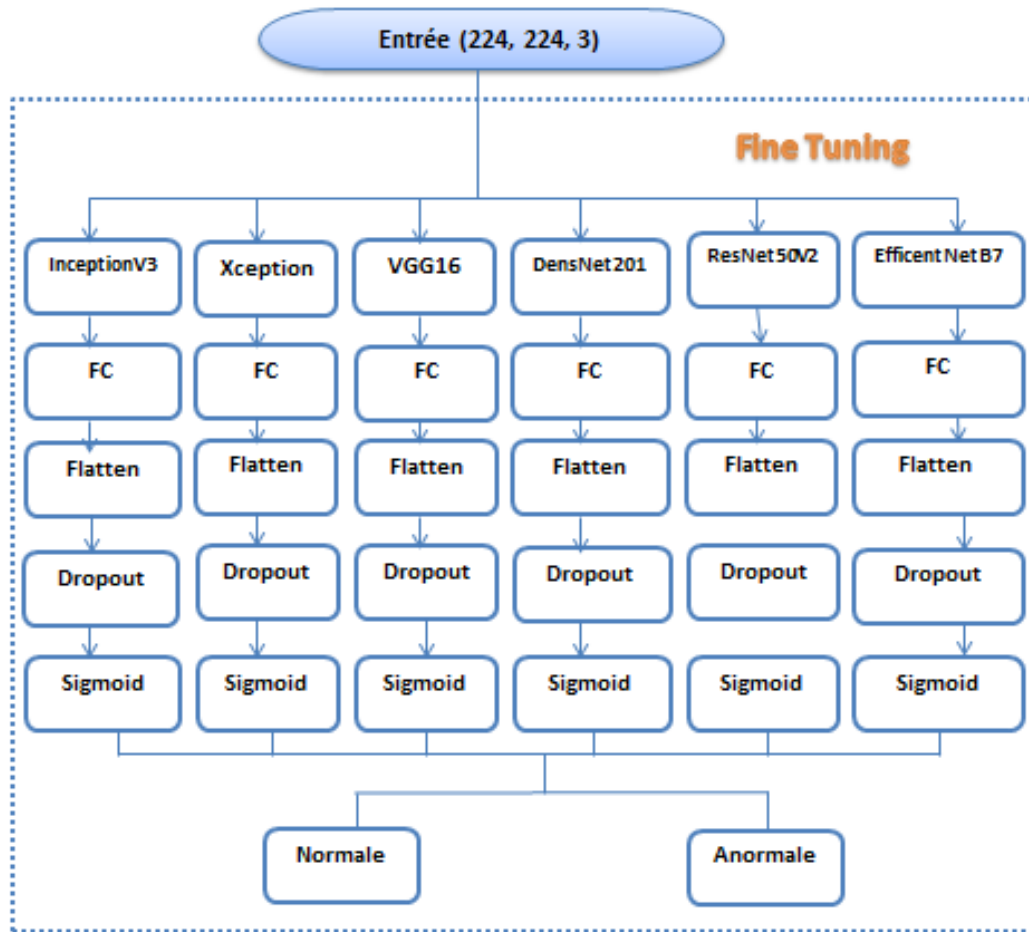


Figure 4.11: Fine tuning et classification(Normal, Anormal)

- Nous pouvons appeler `model.summary()` pour voir la taille et la forme de notre modèle.

**Architecture du modèle EffcientNetB7:**

- La figure 4.12 représente une architecture du modèle EffcientNetB7 cas normal, bénigne, maligne.

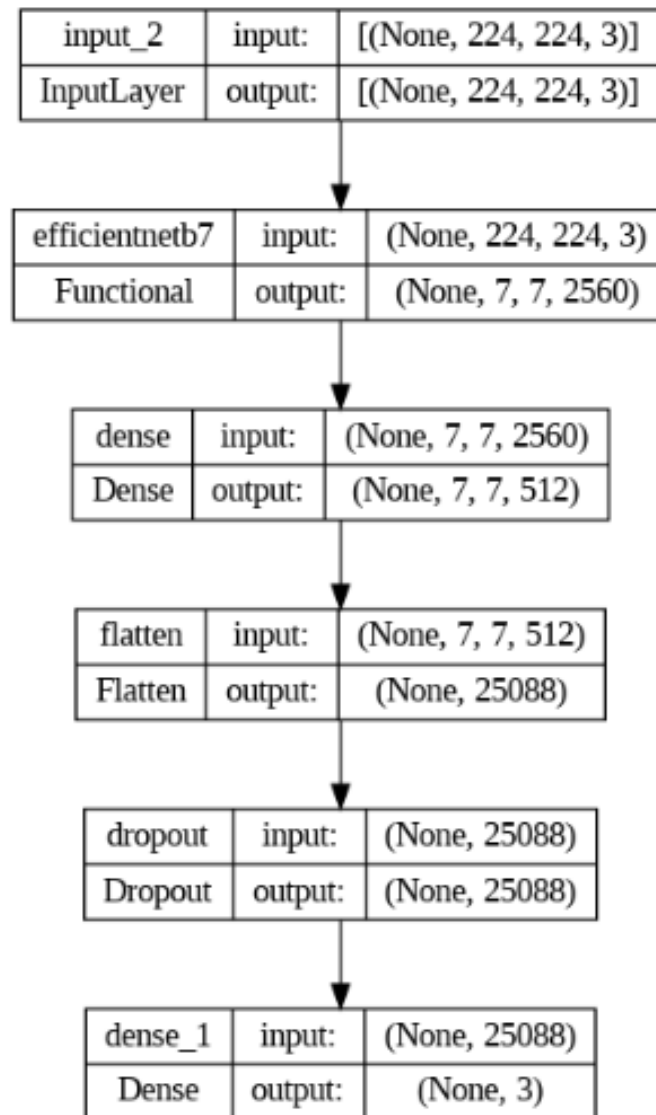


Figure 4.12: Architecture du modèle EfficientNetB7 cas normal, bénigne, maligne.

- La figure 4.13 représente une architecture du modèle EfficientNetB7 cas (normal, anormal) et (Bénigne, maligne).

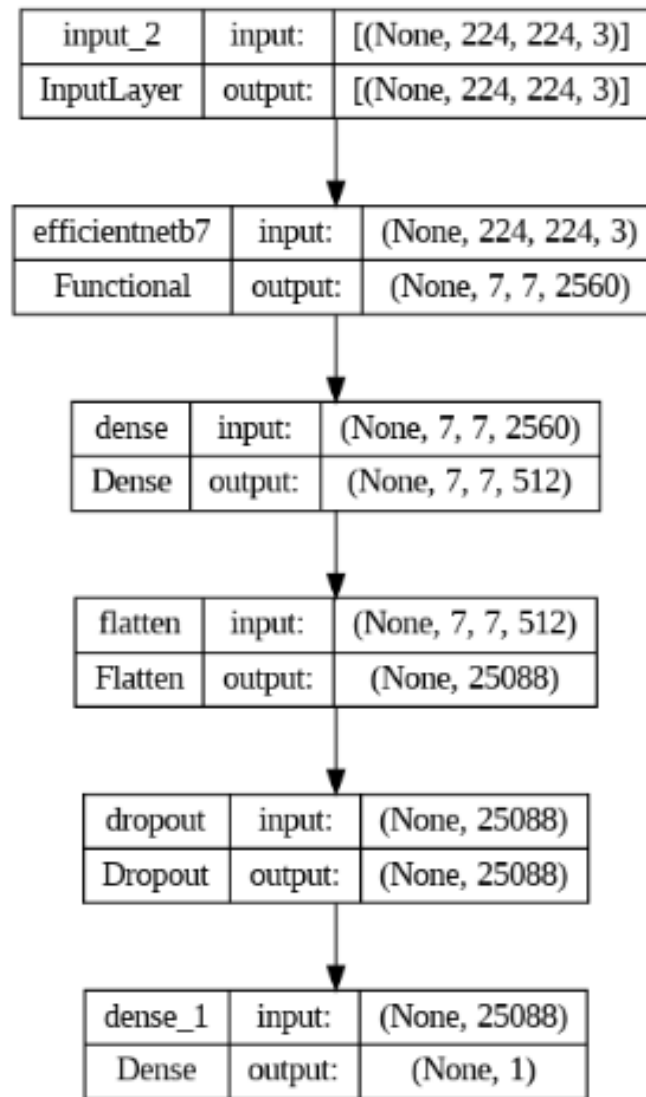


Figure 4.13: Architecture du modèle EfficientNetB7 cas (normal, anormal) et (bénigne, maligne).

- Nous compilons le modèle en utilisant rmsprop comme optimiseur , categorical\_crossentropy comme fonction de loss dans le cas classification multi-classe et binary\_crossentropy dans le cas classification binaire, et nous spécifions accuracy comme la métrique.
- Maintenant il est temps d'entraîner les modèles pour 100 époques, 10 étapes par époque.

## 4.6 Résultat et discussion

Dans cette partie , nous allons discuter les résultats de l'entraînement et de test des modèles( InceptionV3, Xception, VGG16, ResNet50V2, EfficientNetB7, DenseNet201) pour les trois cas de classification.

### 4.6.1 Les résultats de l'entraînement

Les résultats de l'entraînement pour 100 époques sont exposés sous forme de courbes de accuracy et loss.

#### Première catégorie : classification binaire

Pour la classification binaire nous avons utilisé l'ensemble de données "BDD\_ROI".

##### 1. Cas1: normal ou anormal:

Cas1 peut-être défini comme la classification des images échographiques comme normale ou anormale.. Nous avons obtenu les résultats de chaque modèle préformé. Parmi les pires résultats a obtenu est le modèle préformé InceptionV3, comme le montre la figure 4.14. Et parmi les meilleurs résultats a obtenu est le modèle préformé Xception, comme le montre la figure 4.15.

- InceptionV3




Figure 4.14: La courbe de loss et accuracy du modèle InceptionV3 pour la classification Normale/ Anormale.

- **Xception**




Figure 4.15: La courbe de loss et accuracy du modèle Xception pour la classification Normale/Anormale.

Les figures 4.14, 4.15, représente les courbes de loss et accuracy d’entraînement du modèles InceptionV3, Xception avec un nombre d’époques égal à 100.

D’après ces figures, nous pouvons voir que l’accuracy d’entraînement est en train d’augmenter avec le nombre d’époques est commencé à être stable à 100% à partir de l’époque 27, 9 pour InceptionV3, Xception respectivement. Tandis que loss d’entraînement diminue avec le nombre d’époques. puis a commencé à être stable à partir de l’époque 27 pour le modèle InceptionV3 et à partir de l’époque 9 pour le modèle Xception.

## 2. Cas 2: bénigne ou maligne

Cas2 définit la classification des images échographiques comme bénigne ou maligne. Le pire résultat a obtenu par le modèle InceptionV3, comme le montre la figure 4.16. Et le meilleur résultat a obtenu par le modèle EfficientNetB7, comme le montre la figure 4.17.

- **InceptionV3**

La figure 4.16, représente les courbes de loss et accuracy d’entraînement du modèle InceptionV3 avec un nombre d’epochs égal à 100.

D’après ces figures, nous pouvons voir que l’accuracy d’entraînement est en train d’augmenter avec le nombre d’époques mais ni pas stable, tandis que loss d’entraînement diminue avec le nombre d’époques.




Figure 4.16: La courbe de loss et accuracy du modèle InceptionV3 pour la classification bénigne/maligne.

- **EfficientNetB7**




Figure 4.17: La courbe de loss et accuracy du modèle EfficientNetB7 pour la classification bénigne/maligne.

La figure 4.17 représente les courbes de loss et accuracy d'entraînement du modèle EfficientNetB7 avec un nombre d'époques égal à 100.

D'après ces figures, nous pouvons voir que l'accuracy d'entraînement est en train d'augmenter avec le nombre d'époques et commencé à être stable à 100% à partir de l'époque 27. Tandis que loss d'entrainement diminue avec le nombre d'époques.

## Deuxième catégorie : classification multi-classe

### 1. BDD\_originale

parmi les pires résultats a obtenu par le modèle pré-formé InceptionV3, comme le montre la figure 4.18. le meilleur résultat a obtenu est le modèle pré-formé DenseNet201, comme le montre la figure 4.19.

- **InceptionV3**


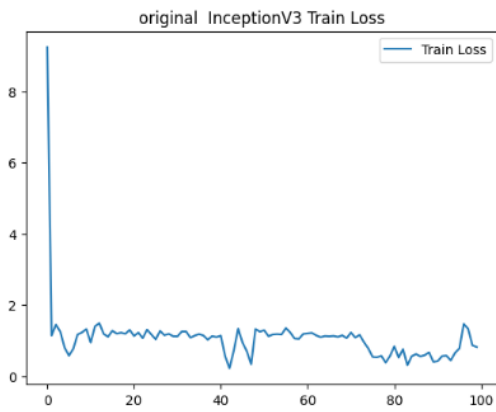


Figure 4.18: La courbe de loss et accuracy du modèle InceptionV3 pour la BDD\_ original.

- **DenseNet201**


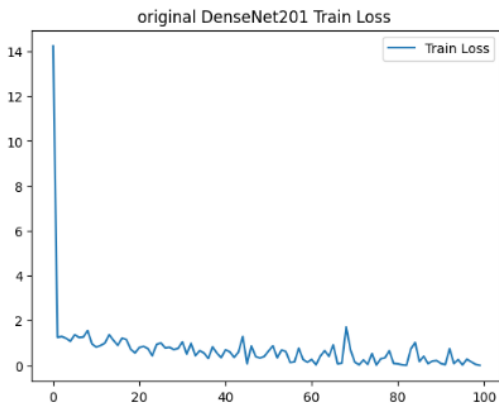


Figure 4.19: La courbe de loss et accuracy du modèle DenseNet201 pour la BDD\_ original

Les figures 4.18, 4.19 représente les courbes de loss et accuracy d’entraînement du modèles InceptionV3, DenseNet201 avec un nombre d’époque égal à 100.

D’après ces figures, nous pouvons voir que l’accuracy d’entraînement est en train d’augmenter avec le nombre d’époques mais ni pas stable, tandis que le loss d’entraînement diminue avec le nombre d’époques.

## 2. BDD\_masque

le pire résultat a obtenue par le modèle pré-formé ResNet50v2, comme le montre la figure 4.20. le meilleur résultat a obtenu par le modèle pré-formé EfficientNetB7, comme le montre la figure 4.21.

- **ResNet50V2**

La figure 4.20 représente les courbes de loss et accuracy d’entraînement du modèle ResNet50V2 avec un nombre d’époques égal à 100. D’après ces figures 4.20 nous pouvons voir que l’accuracy d’entraînement est en train d’augmenter avec le nombre d’époques mais ni pas stabe, tandis que le loss d’entrainement diminue avec le nombre d’époques.




Figure 4.20: La courbe de loss et accuracy du modèle ResNet50V2 pour la BDD\_mask

- **EfficientNetB7**




Figure 4.21: La courbe de loss et accuracy du modèle EfficientNetB7 pour la BDD\_mask

La figure 4.21, représente les courbes de loss et accuracy d'entraînement du modèles EfficientNetB7 avec un nombre d'époques égal à 100.

D'après ce figure, nous pouvons voir que l'accuracy d'entraînement est en train d'augmenter avec le nombre d'époques et commencé à être stable à 100% à partir de l'époque soixante-treize pour EfficientNetB7 tandis que le loss d'entrainement diminue avec le nombre d'époques puis a commencé à être stable.

### 3. BDD\_ROI

le pire résultat a obtenue par le modèle DenseNet201, comme le montre la figure 4.22. Et la meilleur résultat a obtenue par le modèle pré-formé EfficientNetB7, comme le montre la figure 4.23.

- **DenseNet201**

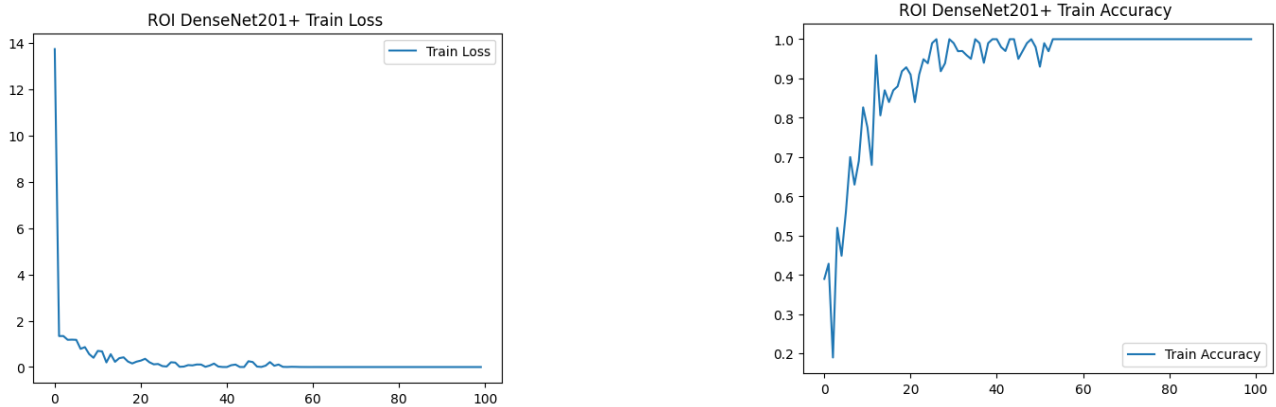


Figure 4.22: La courbe de loss et accuracy du modèle DenseNet201 pour la BDD\_ROI.

- **EfficientNetB7**




Figure 4.23: La courbe de loss et accuracy du modèle EfficientNetB7 pour la BDD\_ROI.

Les figures 4.23, représente les courbe de loss et accuracy d'entraînement du modèle EfficientNetB7, DenseNet201 avec un nombre d'époques égal à 100.

D'après ce figure, nous pouvons voir que l'accuracy d'entraînement est en train d'augmenter avec le nombre d'époques et commencé à être stable à 100% à partir de l'époque 60, 54 pour EfficientNetB7, DenseNet201 respectivement, Tandis que loss d'entraînement diminue avec le nombre d'époques. puis a commencé à être stable.60.

## 4.6.2 Les résultats de test

Plusieurs paramètres d'évaluation sont utilisés pour examiner une classification, comme la Accuracy (4.1), la sensibilité (rappel) (4.2), la précision (4.3). En nous basant sur la matrice de confusion, nous avons pu établir leurs valeurs.

### Accuracy

Le paramètre d'accuracy permet de déterminer le taux de prédiction correct parmi toutes les classes positives et négatives. Il se calcule en divisant la somme des TP et des TN par le nombre total d'exemples[48].

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN} \quad (4.1)$$

### Rappel:

En termes de classification, le recall ou rappel correspond au pourcentage d'exemples positifs qu'un modèle a automatiquement classé parmi tous les exemples positifs[48].

$$Rappel = \frac{VP}{FN + VP} \quad (4.2)$$

### Précision

la précision correspond à un pourcentage des exemples positifs. Toutefois, ce paramètre s'intéresse aux données étiquetées positives par le modèle[48].

$$Precision = \frac{VP}{VP + FP} \quad (4.3)$$

À partir des résultats de la matrice de confusion de chaque modèle, nous avons pu calculer leur Accuracy, leur sensibilité (rappel), leur précision à l'aide des valeurs obtenues en tant que vrai positif (VP), vrai négatif (VN), faux positif (FP) et faux négatif (FN).

- **Vrai Positif (VP):** La valeur réelle et la valeur prévue devraient être les mêmes.
- **Vrai Négatif (VN):** La somme des valeurs de toutes les colonnes et lignes sauf les valeurs de cette classe pour lesquelles nous calculons les valeurs.
- **Faux Positif (FP):** La somme des valeurs de la colonne correspondante à l'exception de la valeur VP.
- **Faux Négatif (FN):** La somme des valeurs des lignes correspondantes à l'exception de la valeur VP.

Pour évaluer notre modèle, nous avons utilisé 20% de l'ensemble de données comme ensemble de tests comme mentionné précédemment. Nous avons obtenu les résultats suivants :

## Première catégorie : classification binaire

### 1. Cas 1: normale ou anormale

- **InceptionV3**

La figure 4.24 représente la matrice de confusion qu'est un tableau à double entrée. Les lignes, s'expriment les prédictions par rapport aux différentes classes définies. Les colonnes expriment les véritables étiquettes. Comme nous le remarquons dans la figure, 1 image a été mal classé. 1 image maligne a été classée bénigne et 53 cas ont été bien classés.




Figure 4.24: La matrice de confusion du modèle InceptionV3 pour la classification Normale/Anormale.

- **Xception**

Comme nous le remarquons dans la figure 4.25, toutes les 54 images du test ont été correctement prédites par notre modèle.

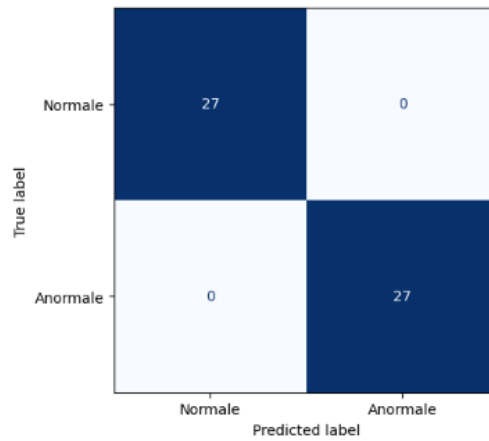


Figure 4.25: La matrice de confusion du modèle xception pour la classification Normale/ Anormale.

## 2. Cas 2: bénigne ou maligne

- **InceptionV3**

Comme nous le remarquons dans la figure 4.26, 26 cas ont été mal classés.

- Le nombre 4 représente le nombre d'images de fausses prédictions, cela signifie que lorsque nous lui avons donné un échantillon de photos de bénignes, il a prédit qu'il s'agissait de photos de malignes.

- Le nombre 22 représente le nombre d'images de fausses prédictions, cela signifie que lorsque nous lui avons donné un échantillon de photos de malignes, il a prédit qu'il s'agissait de photos de bénignes.




Figure 4.26: La matrice de confusion du modèle InceptionV3 pour la classification bénigne/-maligne .

- **EfficientNetB7**

Comme nous le remarquons dans la figure 4.27, 7 cas ont été mal classés. 1 image bénigne a été classé maligne et 6 image malignes ont été classées bénignes.




Figure 4.27: La matrice de confusion du modèle EfficientNetB7 pour la classification bénigne/-maligne.

## Deuxième catégorie : classification multi-classe

### 1. BDD\_originale

- **InceptionV3**

Comme nous le remarquons, dans la figure 4.28. 108 cas ont été mal classés. 54 images malignes ont été classées bénignes, 54 images normale ont été classées bénignes.

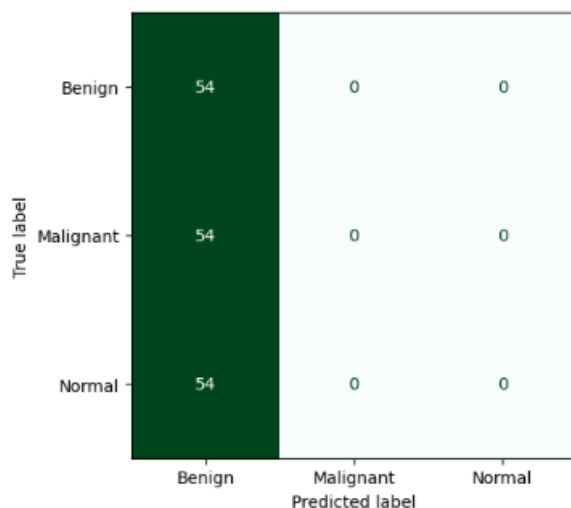


Figure 4.28: La matrice de confusion du modèle InceptionV3 pour la BDD\_original.

- **DenseNet201**

Comme nous le remarquons dans la figure 4.29, 83 cas ont été mal classés. 1 image bénignes a été classées malignes et 1 image bénignes a été classées normale. 52 images malignes ont été classées bénignes et 2 images malignes ont été classées normale. 27 images normale ont été classées bénignes.




Figure 4.29: La matrice de confusion du modèle DenseNet201 pour la BDD\_original.

## 2. BDD\_masque

- **ResNet50V2**

Comme nous le remarquons dans la figure 4.30, 30 cas ont été mal classés. 5 images bénignes ont été classées malignes et 15 images malignes ont été classées bénignes et 1 image maligne a été classées normale, 8 images normale ont été classées bénignes et 1 image normale a été classé maligne.




Figure 4.30: La matrice de confusion du modèle ReseNet50V2 pour la BDD\_masque.

- **EfficientNetB7**

Comme nous le remarquons dans la figure 4.31, 16 cas ont été mal classés. 12 images bénignes ont été classées malignes et 4 images malignes ont été classées bénignes.

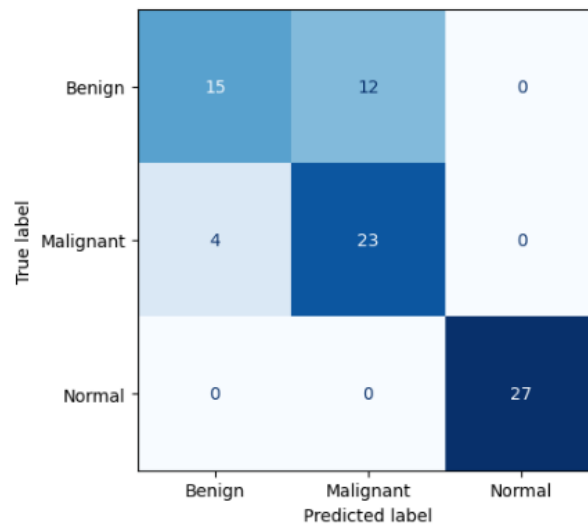


Figure 4.31: La matrice de confusion du modèle EfficientNetB7 pour la BDD\_masque.

### 3. BDD\_ROI

- **EfficientNetB7**

Comme nous le remarquons dans la figure 4.32, 5 cas ont été mal classés. 5 images malignes ont été classées bénignes et 1 image maligne a été classé normale.

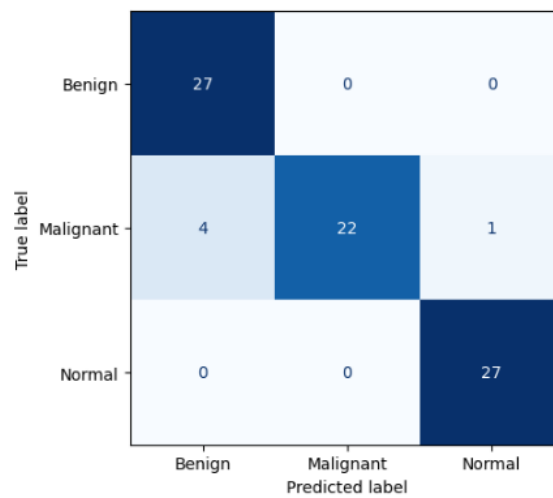


Figure 4.32: La matrice de confusion du modèle EfficientNetB7 pour la BDD\_ROI.

- **DenseNet201**

Comme nous le remarquons dans la figure 4.33, 13 cas ont été mal classés. 5 images bénignes ont été classées malignes et 8 images malignes ont été classées bénignes.

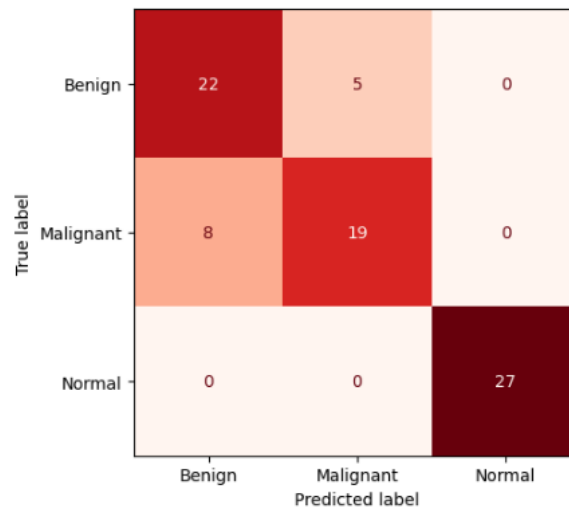


Figure 4.33: La matrice de confusion du modèle DenseNet201 pour la BDD\_ROI.

- **Comparaison des résultats de l'approche de classification binaire**

D'après le tableau 4.5 qui contient les résultats expérimentaux pour la classification des images échographiques du cancer du sein en tumeur normale ou anormale. Les résultats obtenus de chaque modèle ont été considérés comme les résultats finaux. À partir de chaque matrice de confusion des résultats finaux pour chaque modèle, nous avons réussi à calculer : l'accuracy moyenne, la précision moyenne et rappel moyen.

- D'autre part, nous remarquons que les modèles Xception, DenseNet201 et ResNet50V2 qui ont obtenu les meilleurs résultats qui ont obtenu la même accuracy qui égale 100% et même précision qui égale 100% et aussi le même rappel qui égale 100%.
- De plus, nous remarquons que les modèles InceptionV3, VGG16 et EfficientNetB7 qui ont obtenu les mêmes résultats qui ont obtenu accuracy qui égale 98% et précision qui égale 98% et aussi le même rappel qui égale 98%.

Table 4.5: Résultats expérimentaux pour la classification des images d'échographie du cancer du sein en normale / anormale.

Les modèles	Accuracy	Rappel	Précision
InceptionV3	98%	98%	98%
Xception	100%	100%	100%
VGG16	98%	98%	98%
ResNet50V2	100%	100%	100%
EfficientNetB7	98%	98%	98%
DenseNet101	100 %	100 %	100 %

D'après le tableau 4.6 qui contient les résultats expérimentaux pour la classification des images échographiques du cancer du sein en tumeurs bénignes ou malignes. À partir de chaque matrice de confusion des résultats finaux pour chaque modèle, nous avons réussi à calculer : l'accuracy moyenne, la précision moyenne et rappel moyen.

- D'autre part, nous remarquons que le modèle EfficientNetB7 a obtenu les meilleurs résultats parmi les autres modèles qui obtenu l'accuracy qui égal 92% et précision qui égal 92% et rappel qui égal 92%.
- De plus, nous remarquons que le modèle DenseNet201 qui obtenu l'accuracy qui égal 89%. et les modèle Xception, VGG16, ResNet50V2 qui obtenus accuracy qui égale 86%, 82% et 76% respectivement et précision qui égal 86%, 83%, 77% respectivement et rappel qui égal 86%, 82%, 76% respectivement.
- À la fin en remarquons que le modèle InceptionV3 obtenu le mauvaise résultats parmi les autres modèles, qui obtenu accuracy qui égal 69% et précision qui égal 73% et rappel qui égal 69%.

Table 4.6: Résultats expérimentaux pour la classification des images d'échographie du cancer du sein en bénignes/ malignes.

Les modèles	Accuracy	Rappel	Précision
InceptionV3	69%	69%	73%
Xception	86%	86%	86%
VGG16	82%	82%	83%
ResNet50V2	76%	76%	77%
EfficientNetB7	92%	92%	92%
DenseNet101	89 %	89 %	89 %

## • Comparaison des résultats de l'approche de classification multi-classe

D'après le tableau 4.7 qui contient les résultats expérimentaux pour la classification des images échographiques du cancer du sein en tumeurs bénignes, malignes ou normal dans les trois ensembles de données. À partir de chaque matrice de confusion des résultats finaux pour chaque modèle, nous avons réussi à calculer : l'accuracy moyenne, la précision moyenne et rappel moyenne.

- Dans l'ensemble de données **BDD\_original**, le modèle DenseNet201 qui obtenu les meilleurs résultats qui obtenu accuracy qui égal 49% et précision qui égal 43% et rappel qui égal 49%. De plus, nous remarquons que le modèle EfficientNet B7 qui obtenu l'accuracy qui égal 46% et précision qui égal 56% et rappel qui égal 46%. nous remarquons aussi que les modèles Xception et ResNet50 V2 qui obtenus les mêmes accuracy qui égal 36% et précisions qui égale 29%,32% respectivement et le même rappel qui égale 36%. À la fin en remarquons que les modèles Inception V3 et VGG16 obtenus le mauvaise résultats parmi les autres modèles, qui obtenus accuracy qui égal 33% et le même précision qui égale 11% et le même rappel qui égales 33%.
- Dans la base de données **BDD\_masque**, le modèle EfficientNetB7 qui obtenu les meilleurs résultats qui obtenu accuracy qui égal 80 % et précision qui égal 82% et rappel qui égal 80 %. De plus, nous remarquons que les modèles Xception, DenseNet201 et VGG16 qui obtenus accuracy qui égal 74 %, 73 %, 72 % respectivement, et précision qui égale 77 %, 73 %, 74 % respectivement et rappel qui égale 74 %, 73 %, 72 % respectivement. À la fin en remarquons que les modèles Inception V3, ResNet50V2 obtenus le mauvaise résultats parmi les autres modèles, qui obtenus accuracy qui égales 64%, 63% respectivement et précisions qui égales 75%, 69% respectivement et rappel qui égale 64%, 63% respectivement.
- Dans la base de données **BDD\_ROI**, le modèle EfficientNetB7 qui obtenu les meilleurs résultats qui obtenu accuracy qui égal 94% et précision qui égal 95% et rappel qui égal 94%. De plus, nous remarquons que les modèles Inception V3, Xception, ResNet50V2,VGG16 qui obtenus accuracy qui égal 90 %, 86 %, 86 % et 85% respectivement, et précisions qui égales 92 %, 86 %, 87 % et 85% respectivement et rappel qui égales 90%, 86 %, 86 % et 85%. À la fin en remarquons que le modèle DenseNet201 obtenu le mauvaise résultats parmi les autres modèles, qui obtenu accuracy qui égal 84% et précision qui égal 84% et rappel qui égal 84%.

D'après les résultats obtenus dans les trois ensembles de données, nous pouvons conclure que les meilleurs résultats se trouvent dans l'ensemble de données "BDD\_ROI", avec une accuracy obtenue par EfficientNetB7 qui égal 94% Cela était dû à les étapes de prétraitement.

Table 4.7: Résultats expérimentaux pour la classification des images d'échographie du cancer du sein en bénignes/ malignes/ normale.

<b>BDD</b>	<b>Les modèles</b>	<b>Accuracy</b>	<b>Précision</b>	<b>Rappel</b>
<b>BDD_original</b>	Inception V3	33%	11%	33%
	Xception	36%	29%	36%
	VGG16	33%	11%	33%
	ResNet50 V2	36%	32%	36%
	EfficientNet B7	46%	56%	46%
	DenseNet201	49%	43%	49%
<b>BDD_masque</b>	Inception V3	64%	75%	64%
	Xception	74%	77%	74%
	VGG16	72%	74%	72%
	ResNet50 V2	63%	69%	63%
	EfficientNet B7	80%	82%	80%
	DenseNet201	73%	73%	73%
<b>BDD_ROI</b>	Inception V3	90%	92%	90%
	Xception	86%	86%	86%
	VGG16	85%	85%	85%
	ResNet50 V2	86%	87%	86%
	EfficientNet B7	94%	95%	94%
	DenseNet101	84 %	84 %	84 %

### 4.6.3 Comparaison avec d'autres approches

Sur la base des résultats obtenus (Tableau 4.8), nous pouvons conclure que notre technique génère des bons résultats par rapport à la recherche précédente présentée dans le deuxième chapitre détectant les tumeurs du sein.

Ainsi, lorsque nous comparons nos résultats avec des études [39], [40], and [41] utilisant un classificateur multi-classes (bénin, malin et normal), il est évident que nous avons eu des résultats supérieurs où nous avons atteint un score d'accuracy jusqu'à 94% avec EfficientNetB7. Cela était dû à plusieurs facteurs : l'ensemble de données équilibré, les étapes de prétraitement. Nous pouvons également observer que, bien que certaines des études précédentes aient utilisé les mêmes modèles pré-formés, tels que VGG16 ([40],[41]), Inception, Xception, DenseNet201 ([39]), nos résultats sont toujours les meilleurs. Nous pouvons l'attribuer au paramètre que nous avons modifié dans nos modèles, ce qui nous a permis d'obtenir les meilleurs résultats. En outre, les résultats pour notre technique étaient inférieurs à [38], nous pouvons expliquer cela parce que notre ensemble de données est petit. Lorsque nous comparons nos résultats avec les études précédentes (tableau 4.8) qui ont utilisé un classificateur pour les bénignes et les malignes en particulier les travaux proposés dans [42] ainsi que [43], dans notre étude, nous avons observé qu'un score d'accuracy jusqu'à 92% avec EfficientNetB7 et était inférieurs à [42], Cela peut être dû à l'utilisation d'un petit ensemble de données.

Dans notre étude, la classification des images échographiques du cancer du sein en tumeur normale ou anormale. Nous comparons notre résultat avec le travail [44]. Nous remarquons que notre résultat est meilleur que les résultats de ce travail Cela était dû à les étapes de prétraitement.

Table 4.8: Comparaison entre les modèles proposés et les modèles existants

Etude	Classes	Accuracy	Rappel	Précision
Inception V3 <sup>1</sup>	3	90%	90%	92%
Xception <sup>1</sup>	3	86%	86%	86%
VGG16 <sup>1</sup>	3	85%	85%	85%
ResNet50 V2 <sup>1</sup>	3	86%	86%	87%
EfficientNet B7 <sup>1</sup>	3	94%	94%	95%
DenseNet101 <sup>1</sup>	3	84 %	84 %	84 %
Inception V3 <sup>1</sup>	2	69%	69%	73%
Xception <sup>1</sup>	2	86%	86%	86%
VGG16 <sup>1</sup>	2	82%	82%	83%
ResNet50 V2 <sup>1</sup>	2	76%	76%	77%
EfficientNet B7 <sup>1</sup>	2	92%	92%	92%
DenseNet101 <sup>1</sup>	2	89 %	89 %	89 %
Inception V3 <sup>1</sup>	2'	98%	98%	98%
Xception <sup>1</sup>	2'	100%	100%	100%
VGG16 <sup>1</sup>	2'	98%	98%	98%
ResNet50 V2 <sup>1</sup>	2'	100%	100%	100%
EfficientNet B7 <sup>1</sup>	2'	98%	98%	98%
DenseNet101 <sup>1</sup>	2'	100%	100%	100%
M.Althobaiti, et al 2022 [38]	3	99.4%	98.9%	98.9%
S.Badawy, et al 2021 [39] <sup>5</sup>	3	82.93%	/	/
I.PACAL 2022[40] <sup>6</sup>	3	88.6%	87.4%	90.1%
F. Uysal, et al 2022 [41] <sup>7</sup>	3	85.83	/	/
Sivanandan, et al 2021[42] <sup>4</sup>	2	98%	98%	98%
Y. WANG, et al 2020 [43] <sup>4</sup>	2	/	88.6%	/
S.cho et al 2022 [44]	2'	99.487%	99.846 %	99.538%

<sup>1</sup> Notre Approche.    <sup>2</sup> Bénignes /Malignes.    <sup>2'</sup> Normale./Anormale.

<sup>3</sup> Bénigne/Maligne/Normale.    <sup>4</sup> méthode proposée.

<sup>5</sup> InceptionResNetV2.    <sup>6</sup> Vision\_Transformer.    <sup>7</sup> ResNeXt50.

## 4.7 Conclusion

Nous avons présenté dans ce chapitre notre méthode proposée, bibliothèques utilisées pour l'implémentation, les résultats obtenus, et nous avons comparé notre résultats avec autres travail.

## Conclusion et perspectives futures

### Contents

<b>5.1</b>	<b>Résumé de nos travaux</b>	<b>51</b>
<b>5.2</b>	<b>Limites</b>	<b>52</b>
<b>5.3</b>	<b>Perspectives futures</b>	<b>52</b>

### 5.1 Résumé de nos travaux

Dans cette étude, nous avons proposé un modèle précis de détection des tumeurs mammaires en utilisant une stratégie de prétraitement et des techniques d'apprentissage profond et l'apprentissage par transfert. Six modèles CNN préformés ont été modifiés et adaptés à notre cas : InceptionV3, EfficientNetB7, DenseNet201, Xception, ResNet50V2 et VGG16. la base de données d'images d'échographie du sein (BUSI) a été utilisée pour former et tester le modèle. Et à l'aide de l'ensemble de tests, le modèle a été évalué, puis, en fonction de la matrice de confusion, l'accuracy, rappel et la précision ont été calculées pour chacun. En conséquence, nous avons été en mesure d'atteindre notre objectif en créant un modèle de détection de tumeur du sein précis. Nous avons également réussi à déterminer que:

- Xception, DensNet201 et ResNet50V2 ont obtenu les meilleurs résultats, qui obtenus accuracy qui égale 100 %, suivi par InceptioV3, VGG16 et EfficientNetB7 qui obtenu accuracy qui égales 98 % lorsque les images échographiques sont classées comme normale ou anormale.
- EfficientNetB7 est le meilleur modèle pré-formé pour notre tâche qui obtenus accuracy qui égale 92 % lorsque les images ultrasonores sont classées comme bénigne ou maligne.
- EfficientNetB7 est le meilleur modèle pré-formé pour notre tâche, atteignant la plus haute accuracy qui égale 94 % lorsque les images échographiques sont classées comme bénigne, maligne ou normale.

## 5.2 Limites

nous ne pouvons pas nier que notre modèle proposé ait certaines limites telles que l'ensemble de données utilisé est considéré comme une petite quantité de données par rapport à ce que CNN exige. Nous n'avons pas utiliser de filtres dans le prétraitement, la manque de matériel satisfaisant pour notre projet.

## 5.3 Perspectives futures

Notre travail, comme tous les travaux de recherche présente quelques perspectives, qui sont considérés comme des futurs travaux:

- Premièrement, nous avons l'intention d'améliorer notre technique en augmentant la taille de la base de données.
- Deuxièmement, Nous pouvons également essayer de nouveaux modèles pré-formés pour obtenir une meilleure accuracy.
- Troisièmement, nous appliquons les filtres en phase de pré-traitement.
- Enfin, notre approche pourrait être utilisée pour détecter les tumeurs dans d'autres organes, comme les tumeurs cérébrales.

## Bibliography

- [1] Qu'est-ce que l'intelligence artificielle?. <https://vie-etudiante.cegepjonquiere.ca/qu-est-ce-que-l-intelligence-artificielle.html>.
- [2] Mayank Banoula. Supervised machine learning: All you need to know. <https://www.simplilearn.com/tutorials/machine-learning-tutorial/supervised-machine-learning>, date de consultation, 14.05.2023.
- [3] MK Gurucharan. Basic cnn architecture: Explaining 5 layers of convolutional neural network. <https://www.upgrad.com/blog/basic-cnn-architecture/>, date de consultation 29,03,2023.
- [4] Saida Sarra Boudouh. Clothing classification using convolutional neural networks. 2021.
- [5] Esraa A. Mohamed, Tarek Gaber, Omar Karam, and Essam A Rashed. A novel cnn pooling layer for breast cancer segmentation and classification from thermograms. *Plos one*, 17(10):e0276523, 2022.
- [6] Saida Sarra Boudouh and Mustapha Bouakkaz. Breast cancer: toward an accurate breast tumor detection model in mammography using transfer learning techniques. *Multimedia Tools and Applications*, pages 1–24, 2023.
- [7] Protima Khan, Md Fazlul Kader, SM Riazul Islam, Aisha B Rahman, Md Shahriar Kamal, Masbah Uddin Toha, and Kyung-Sup Kwak. Machine learning and deep learning approaches for brain disease diagnosis: principles and recent advances. *IEEE Access*, 9:37622–37655, 2021.
- [8] Walid Al-Dhabyani, Mohammed Gomaa, Hussien Khaled, and Aly Fahmy. Dataset of breast ultrasound images. *Data in brief*, 28:104863, 2020.
- [9] R Karthik, R Menaka, GS Kathiresan, M Anirudh, and M Nagharjun. Gaussian dropout based stacked ensemble cnn for classification of breast tumor in ultrasound images. *Irbm*, 43(6):715–733, 2022.
- [10] Min Xian, Yingtao Zhang, Heng-Da Cheng, Fei Xu, Boyu Zhang, and Jianrui Ding. Automatic breast ultrasound image segmentation: A survey. *Pattern Recognition*, 79:340–355, 2018.

- 
- [11] Woo Kyung Moon, Yan-Wei Lee, Hao-Hsiang Ke, Su Hyun Lee, Chiun-Sheng Huang, and Ruey-Feng Chang. Computer-aided diagnosis of breast ultrasound images using ensemble learning from convolutional neural networks. *Computer methods and programs in biomedicine*, 190:105361, 2020.
- [12] Mohammed Ahmed, Alaa AlZoubi, and Hongbo Du. Improving generalization of enas-based cnn models for breast lesion classification from ultrasound images. In *Medical Image Understanding and Analysis: 25th Annual Conference, MIUA 2021, Oxford, United Kingdom, July 12–14, 2021, Proceedings 25*, pages 438–453. Springer, 2021.
- [13] Qu'est-ce que l'intelligence artificielle (ia) ? | oracle algeria. <https://www.oracle.com/dz/artificial-intelligence/what-is-ai/>.
- [14] M Durand, A Shaikh, Mélanie Billi, and Eric Lechevallier. Applications médicales de l'intelligence artificielle: opportunités & challenges. *Progrès en Urologie-FMC*, 30(2):F63–F68, 2020.
- [15] Khadidja Iznasni. Driver drowsiness detection using deep learning approaches.
- [16] Nadjat Bouafia. *Classification efficace des vêtements de mode basée sur les approches: apprentissage automatique ML et apprentissage profond DL*. PhD thesis, FACULTE MATHEMATIQUES ET INFORMATIQUE-DEPARTEMENT INFORMATIQUE-OPTION ..., 2020.
- [17] Ketfi Akram. *Classification des images utilisant les réseaux de neurones de convolution*. PhD thesis, Faculté des Sciences et Technologies, 2021.
- [18] Machine learning : définition et fonctionnement. <https://www.talend.com/fr/resources/what-is-machine-learning/>, date de consultation, 26.03.2023.
- [19] Machine learning : L'apprentissage par renforcement. [https://www-igm.univ-mlv.fr/~dr/XPOSE2014/Machin\\_Learning/D\\_Machine\\_Learning.html](https://www-igm.univ-mlv.fr/~dr/XPOSE2014/Machin_Learning/D_Machine_Learning.html), date de consultation, 14.05.2023.
- [20] Apprentissage profond et apprentissage automatique. <https://learn.microsoft.com/fr-fr/azure/machine-learning/concept-deep-learning-vs-machine-learning>, date de consultation, 07.06.2023.
- [21] Íshak PACAL. Deep learning approaches for classification of breast cancer in ultrasound (us) images. *Journal of the Institute of Science and Technology*, 12(4):1917–1927.
- [22] Hadjer Hammani, Khawla Hamza, and Nassima Mellal. Développement d'une application android pour le diagnostic du covid-19 basée deep learning. 2022.
- [23] soltani yacine. Fusion d'information par deep learning pour l'aide au diagnostic du cancer du sein. Mémoire de Master en Génie Électrotechnique Et Automatique, Université Saad Dahleb - Blida, 2020-2021.
- [24] Anirudha Ghosh, Abu Sufian, Farhana Sultana, Amlan Chakrabarti, and Debashis De. Fundamental concepts of convolutional neural network. *Recent trends and advances in artificial intelligence and Internet of Things*, pages 519–567, 2020.
- [25] Salima BELHADEF and Khadidja BENABDALLAH. *Segmentation des images IRM cérébrales par apprentissage profond*. PhD thesis.

- [26] Sidi Mohammed Khattra, Oussama Boulfous, and Souad Encadreur Biad. *Classification des images par apprentissage profond deep learning*. PhD thesis, Université de Jijel, 2022.
- [27] Iness Hamed. *Un système intelligent d'aide à la décision pour la planification urbaine*. PhD thesis, Université Larbi Tébessi-Tébessa, 2022.
- [28] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens, and Zbigniew Wojna. Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 2818–2826, 2016.
- [29] François Chollet. Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1251–1258, 2017.
- [30] Karen Simonyan and Andrew Zisserman. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [31] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Identity mappings in deep residual networks. In *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14*, pages 630–645. Springer, 2016.
- [32] Mingxing Tan and Quoc Le. Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning*, pages 6105–6114. PMLR, 2019.
- [33] Gao Huang, Zhuang Liu, Laurens Van Der Maaten, and Kilian Q Weinberger. Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4700–4708, 2017.
- [34] MEHIDI Aïcha. *Détection des micro-calcifications par les modèles markoviens pour des tissus mammaires*. PhD thesis, Thèse de Doctorat de l'Université de Mostaganem Algérie, p139, 2019.
- [35] Hyuna Sung, Jacques Ferlay, Rebecca L Siegel, Mathieu Laversanne, Isabelle Soerjomataram, Ahmedin Jemal, and Freddie Bray. Global cancer statistics 2020: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: a cancer journal for clinicians*, 71(3):209–249, 2021.
- [36] Asifullah Khan, Anabia Sohail, Umme Zahoora, and Aqsa Saeed Qureshi. A survey of the recent architectures of deep convolutional neural networks. *Artificial intelligence review*, 53:5455–5516, 2020.
- [37] Jianye Zhou, Xinyu Yang, Lin Zhang, Siyu Shao, and Gangying Bian. Multisignal vgg19 network with transposed convolution for rotating machinery fault diagnosis based on deep transfer learning. *Shock and Vibration*, 2020:1–12, 2020.
- [38] Maha M Althobaiti, Amal Adnan Ashour, Nada A Alhindi, Asim Althobaiti, Romany F Mansour, Deepak Gupta, and Ashish Khanna. Deep transfer learning-based breast cancer detection and classification model using photoacoustic multimodal images. *BioMed Research International*, 2022, 2022.

- 
- [39] Samir M Badawy, Abd El-Naser A Mohamed, Alaa A Hefnawy, Hassan E Zidan, Mohammed T GadAllah, and Ghada M El-Banby. Classification of breast ultrasound images based on convolutional neural networks- a comparative study. In *2021 International Telecommunications Conference (ITC-Egypt)*, pages 1–8. IEEE, 2021.
- [40] İshak PACAL. Deep learning approaches for classification of breast cancer in ultrasound (us) images. *Journal of the Institute of Science and Technology*, 12(4):1917–1927.
- [41] Fatih Uysal and Mehmet Murat Köse. Classification of breast cancer ultrasound images with deep learning-based models. *Engineering Proceedings*, 31(1):8, 2022.
- [42] Revathy Sivanandan and J Jayakumari. A new cnn architecture for efficient classification of ultrasound breast tumor images with activation map clustering based prediction validation. *Medical & Biological Engineering & Computing*, 59:957–968, 2021.
- [43] Yi Wang, Eun Jung Choi, Younhee Choi, Hao Zhang, Gong Yong Jin, and Seok-Bum Ko. Breast cancer classification in automated breast ultrasound using multiview convolutional neural network with transfer learning. *Ultrasound in medicine & biology*, 46(5):1119–1132, 2020.
- [44] Se Woon Cho, Na Rae Baek, and Kang Ryoung Park. Deep learning-based multi-stage segmentation method using ultrasound images for breast cancer diagnosis. *Journal of King Saud University-Computer and Information Sciences*, 34(10):10273–10292, 2022.
- [45] Zina Kabouche, Akila Rebai, and Lamia Hamza. Développement d’un système d’aide au diagnostic des pathologies des poumons. 2022.
- [46] Katia Lounis and Dahbia Moussi. *La Classification d’images d’insectes ravageurs en utilisant le Deep Learning*. PhD thesis, Université Mouloud Mammeri, 2020.
- [47] kaggle. <https://www.kaggle.com/datasets/aryashah2k/breast-ultrasound-images-dataset>, date de consultation, 08.05.2023.
- [48] Confusion matrix: définition et interprétation. <https://intelligence-artificielle.com/confusion-matrix-dossier-complet/>, date de consultation, 21.05.2023.