



République Algérienne Démocratique et Populaire
Université Larbi Ben M'hidi Oum El Bouaghi
Faculté des Sciences exactes et sciences de la nature et de la vie
Département de mathématiques et d'informatique



Mémoire de fin d'études
Pour l'obtention du diplôme de Master en Informatique
Option VA

Thème

Diagnostic du Cancer du sein basé sur Deep Learning

Realisé par :

Sabrina Amri

Nadia Sahbi

Supervisé par :

Mme Sara Zouad

Année universitaire

2022-2023

Remerciements

Nous tenons tout d'abord à exprimer notre profonde reconnaissance envers notre encadrante, Mme SARA ZOUAD, pour son soutien inestimable tout au long de ce travail. Sa patience, sa disponibilité et ses conseils judicieux ont grandement contribué à l'avancement de notre réflexion. Nous sommes reconnaissantes de pouvoir compter sur une personne aussi compétente et dévouée.

Nous tenons à saluer et à remercier sincèrement les membres du jury d'avoir consacré leur temps à évaluer notre travail. Votre présence et votre expertise sont d'une importance cruciale pour la réussite de cet événement académique. Nous sommes conscientes du rôle essentiel que vous jouez dans l'évaluation de notre travail et nous sommes reconnaissantes de l'attention et des commentaires que vous porterez à notre mémoire.

Nous souhaitons également adresser nos sincères remerciements à nos familles, pour leur amour, leur soutien constant et leur compréhension pendant les moments où nous avons dû nous consacrer à la rédaction de ce mémoire. Leur encouragement a été une source d'inspiration précieuse et nous a aidé à persévérer.

Enfin, nous tenons à remercier toutes les personnes qui ont contribué de près ou de loin à la réalisation de ce travail.

À tous ceux qui ont joué un rôle dans la réussite de notre mémoire, nous vous sommes profondément reconnaissantes. Vos encouragements, vos conseils et votre soutien ont été essentiels.

Dédicaces

À mes parents chers et regrettés,

Je tenais à vous rendre hommage et à exprimer tout mon amour et ma gratitude envers vous. Votre présence dans ma vie a été une source de joie et de force. Papa, tu restes pour moi un modèle de détermination, de force et d'honnêteté. Maman, ta bonté, ta patience et ton dévouement envers nous ont été inestimables. Je vous remercie pour tous vos sacrifices, pour avoir tout donné pour que vos enfants grandissent et prospèrent. Votre travail acharné malgré les difficultés de la vie a contribué à notre bien-être. Je suis fière d'être votre fille et je vous dédie cette réussite.

À mon cher mari,

Je tiens à te dédier ce mémoire en reconnaissance de ton soutien et de ta présence inconditionnelle tout au long de mon parcours académique. Tu as été mon plus grand allié et une source de force et d'inspiration. Sans toi, cette réalisation n'aurait pas été possible.

À mes enfants bien-aimés,

Je souhaite exprimer mon amour éternel pour vous. Vous êtes ma plus grande fierté et ma plus grande source de bonheur. Votre amour, votre soutien et votre compréhension pendant que j'ai travaillé sur ce mémoire ont été d'une importance capitale.

Sabrina Amri

Dédicaces

Je dédie ce mémoire à mon père et ma maman,

mes sœurs, mes nièces, mes neveux

et

mes amis qui ont été une source constante de soutien et d'encouragement tout au long de mon parcours.

Votre amour inconditionnel et votre soutien m'ont donné la force et la motivation nécessaires pour surmonter les obstacles et atteindre mes objectifs.

Je vous suis profondément reconnaissante pour votre présence et votre soutien indéfectibles. Merci d'avoir cru en moi et de m'avoir encouragée à poursuivre mes rêves.

Cette réalisation est également dédiée à toutes les personnes qui ont croisé mon chemin et m'ont inspirée d'une manière ou d'une autre.

Nadia Sahbi

Résumé

Ce travail se concentre sur le développement d'une architecture de réseau de neurones artificiels pour la prédiction du cancer du sein. L'étude met en évidence l'efficacité des CNN Convolutional Neural Networks (CNN) dans l'apprentissage à partir de données génétiques et cliniques complexes. Les principales caractéristiques associées au cancer du sein sont identifiées grâce à cette méthode. La prédiction du cancer du sein est d'une grande importance clinique, permettant des décisions médicales éclairées et des traitements adaptés. Cependant, cette tâche est complexe en raison de la diversité des données disponibles. L'ensemble de données utilisé est relativement petit mais précieux en raison de sa richesse en données génétiques et cliniques. Les résultats de cette recherche constituent une avancée significative dans la compréhension de la maladie et peuvent orienter les futures recherches et le développement de méthodes plus précises de prédiction de survie.

Mots-clés : cancer du sein, réseau de neurones artificiels, CNN, données génétiques, données cliniques, décisions médicales, méthodes de prédiction.

Abstract

This work focuses on developing an architecture of artificial neural networks for breast cancer prediction. The study emphasizes the effectiveness of Convolutional Neural Networks (CNNs) in learning from complex genetic and clinical data. The primary characteristics associated with breast cancer are identified through this approach. Predicting breast cancer is of significant clinical importance as it enables informed medical decisions and personalized treatments. However, this task is complex due to the diversity of available data. The dataset used is relatively small but valuable due to its abundance of genetic and clinical data. The results of this research represent a significant advancement in understanding the disease and can guide future research and the development of more accurate prediction methods.

Keywords: breast cancer, artificial neural networks, CNN, genetic data, clinical data, medical decisions, prediction methods.

ملخص

الهدف من هذا العمل هو تطوير بنية شبكة عصبية اصطناعية تهدف إلى عمل تنبؤات لتوقع سرطان الثدي. توضح الدراسة فعالية الشبكات العصبية المتشعبة (CNN) في التعلم من البيانات الجينية والسريرية المعقدة وتحديد الخصائص الرئيسية المرتبطة بسرطان الثدي. يعتبر توقع سرطان الثدي ذو أهمية كبيرة في المجال السريري لاتخاذ قرارات طبية مدروسة وتحديد العلاجات المناسبة. ومع ذلك، فإن هذه المهمة تعتبر معقدة بسبب تنوع البيانات المتاحة. يعتبر مجموع البيانات المستخدمة صغيراً نسبياً ولكنه ثمين بسبب ثراء البيانات الجينية والسريرية. تمثل نتائج هذا البحث تقدماً كبيراً في فهم المرض ويمكن أن توجه الأبحاث المستقبلية وتطوير طرق أكثر دقة لتوقع البقاء على قيد الحياة

الكلمات المفتاحية: سرطان الثدي، الشبكات العصبية الاصطناعية، CNN، البيانات الجينية، البيانات السريرية، القرارات الطبية، طرق التوقع.

Tables des matières

Remerciements	i
Dédicaces	ii
Dédicaces	iii
Résumé	iv
ملخص	vi
Tables des matières.....	vii
Liste des figures	x
Liste des tables	xi
Introduction générale	2
1. Chapitre 1 : Systèmes d'aide à la décision pour le diagnostic du Cancer du sein	4
1. Introduction	5
2. Le cancer du sein	5
3. La classification des différents cancers du sein	6
3.1. Le carcinome canalaire	6
3.2. Le carcinome lobulaire	7
3.3. Le carcinome mucineux.....	8
4. Les sous-types.....	8
4.1. Le cancer de type luminal	8
4.2. Le cancer HER2.....	8
4.3. Le cancer triple-négatif.....	8
5. Le traitement.....	8
5.1. La radiothérapie.....	8
5.2. La chimiothérapie	9
5.3. Hormonothérapie	9
6. Les techniques de mesure	9
6.1. L'immunohistochimie	9
6.2. Microarray	9
6.3. Z-score	9
7. Système d'aide à la décision médicale	10
7.1. Définition.....	Error! Bookmark not defined.
7.2. Systèmes d'aide à la décision pour le cancer	10
8. Conclusion	12

2. Chapitre 02 : L'intelligence Artificielle & Réseaux Neurones Convolutifs	Error!
Bookmark not defined.	
2. L'intelligence artificielle	14
2.1. Historique.....	14
2.2. Définition	14
3. Les domaines d'application de l'intelligence artificielle	15
4. Types d'intelligence artificielle	17
4.1. L'apprentissage automatique (Machine Learning)	18
4.1.1. Définition	18
4.1.2. Types d'apprentissage	19
4.1.3. Applications de l'apprentissage automatique	20
4.2. Deep Learning.....	21
4.2.1. Définition	21
4.2.2. Les domaines d'application du Deep learning	22
4.3. Differences Deep learning vs Machine learning.....	23
4.4. Réseaux de neurones artificiels.....	24
4.4.1. Neurone biologique/ Neurone artificiel	24
4.4.2. Fonctionnement mathématique du neurone formel.....	26
4.4.3. Qu'est-ce qu'un réseau de neurones artificiels ?.....	27
4.4.4. Principe de fonctionnement de réseaux neuronaux artificiels.....	28
4.4.5. Fonction d'activation	28
4.4.6. La classification	29
4.4.7. L'optimiseur	29
4.4.8. Différents types de réseaux de neurones.....	29
4.4.9. Les Modèles des réseaux de neurones convolutifs.....	34
5. Travaux connexes.....	37
6. Conclusion	40
3. Chapitre 3: Conception & Réalisation	Error! Bookmark not defined.
2. Architecture générale du système de détection du cancer basée Deep learning.....	42
3. Environnement de développement de système	43
3.1. Environnement matériel	43
3.2. Environnement logiciel et langages de programmation	43
3.2.1. Langage Python.....	44
3.2.2. Keras.....	44
3.2.3. TensorFlow	44
3.2.4. PyQt5	45

3.2.5. Google colab	45
4. Le dataset utilisé.....	46
5. Les étapes de réalisation du système	47
6. Évaluation de la performance.....	56
7. Conclusion	59
Conclusion générale	61

Liste des figures

Figure 1.1: Histologie du sein	6
Figure 1.2: Le carcinome canalaire.....	7
Figure 1.3: Carcinome lobulaire.....	Error! Bookmark not defined.
Figure 1.4: Carcinome mucineux.....	Error! Bookmark not defined.
Figure 2.1: Types d'algorithmes du Machine Learning.....	20
Figure 2.2: Applications de l'apprentissage automatique.....	21
Figure 2.3: Classification d'image par le DeepLearning	22
Figure 2.4: Représentation d'un neurone biologique par Nicolas Rougier.....	25
Figure 2.5: Mise en correspondance neurone biologique /neurone artificiel par Claude Touzet	26
Figure 2.6: Structure d'un neurone artificiel	26
Figure 2.7: Architecture générale d'un reseau de neurones convolutif.....	32
Figure 2.8: Le modèle LeNet-5	35
Figure 2.9: Le modèle AlexNet.....	35
Figure 2.10: Le modèle VGG	36
Figure 2.11: Le modèle ResNet.....	36
Figure 2.12: GoogLeNet.....	37
Figure 2.13: MobileNets.....	37
Figure 3.1: Architecture générale du système.....	43
Figure 3.2: Exemple de la classe bénigne	47
Figure 3.3: Exemple de la classe maligne	47
Figure 3.4: Les étapes réalisation du système	47
Figure 3.5: La meilleure configuration du réseau proposé pour l'entraînement	47
Figure 3.6: Interface graphique principale de notre application	48
Figure 3.7: Interface graphique principale de notre application d'affichage de résultats	48
Figure 3.8: Evaluation de l'apprentissage et et l'erreursur 100 itérations.....	48

Liste des tables

Table 2.1: Différences entre l'IA faible et l'IA forte :.....	18
Table 2.2: Differences Machine learning VS Deep learning.....	24
Table2.3: Les travaux connexes.....	51
Table 3.1: Les hyper paramètre proposés.....	57
Table 3.2: Caractéristiques du sous dataset.....	58
Table 3.3: Les hyper paramètre proposés.....	62
Table 3.4: Résultat avec hyper 1.....	63
Table 3.5: Résultat avec hyper 2.....	63
Table 3.6: Résultat avec hyper 3.....	64
Table 3.7: Résultat avec hyper 4.....	64
Table 3.8: Evaluation de la performance du modèle.....	68
Table 3.9: La matrice de confusion	69



Introduction Générale

Introduction générale

Le cancer du sein est l'un des types de cancer les plus fréquents, touchant principalement les femmes, mais pouvant également affecter les hommes. Il se développe dans les tissus de la glande mammaire et peut présenter divers symptômes tels qu'une boule ou une masse dans le sein, des changements de taille ou de forme du sein, une douleur ou un écoulement au niveau du mamelon. Cependant, il est important de noter que de nombreuses femmes atteintes de cancer du sein ne présentent aucun symptôme visible.

Le diagnostic du cancer du sein se fait généralement à l'aide de techniques telles que la mammographie, l'échographie ou la biopsie. Le traitement dépend du stade et du type de cancer, mais peut inclure la chirurgie, la radiothérapie et l'hormonothérapie.

Pour prévenir le cancer du sein, il est recommandé d'adopter un mode de vie sain, notamment en maintenant un poids santé, en faisant de l'exercice régulièrement, en limitant la consommation d'alcool et en évitant le tabagisme. Les femmes sont également encouragées à effectuer des examens réguliers de dépistage tels que des mammographies et des examens cliniques des seins.

Dans le domaine de la recherche, le deep learning, une sous-catégorie de l'apprentissage automatique, a suscité un intérêt croissant. Les réseaux de neurones artificiels sont des outils puissants utilisés dans le deep learning, capables de résoudre des problèmes complexes de classification, de reconnaissance de forme et de prédiction. Dans le contexte du cancer, les réseaux de neurones peuvent contribuer à la détection précoce des tumeurs et au suivi de leur évolution dans le temps. Ils peuvent également aider à identifier les gènes associés à certains types de cancer, ouvrant ainsi la voie au développement de nouveaux traitements.

Ce mémoire de fin d'étude se concentre sur le développement d'une architecture de réseaux de neurones artificiels pour la prédiction du cancer du sein. L'étude met en évidence l'efficacité des Convolutional Neural Networks (CNNs) dans l'apprentissage à partir de données génétiques et cliniques complexes. Grâce à cette approche, les principales caractéristiques associées au cancer du sein sont identifiées. La prédiction du cancer du sein revêt une grande importance clinique, permettant des décisions médicales éclairées et des traitements adaptés. Cependant, cette tâche est complexe en raison de la diversité des données disponibles.

L'ensemble de données utilisé dans cette étude est relativement petit mais précieux en raison de sa richesse en données génétiques et cliniques. Les résultats de cette recherche

représentent une avancée significative dans la compréhension de la maladie et peuvent orienter les futures recherches et le développement de méthodes plus précises de prédiction de survie.

Ce manuscrit est structuré en trois chapitres.

Le premier chapitre aborde le contexte médical du cancer du sein, en décrivant l'anatomie de l'organe étudié, les différentes pathologies associées et les méthodes d'imagerie mammaire.

Le deuxième chapitre introduit le concept du deep learning, en fournissant une définition de l'intelligence artificielle et de ses sous-ensembles, ainsi qu'une exploration des réseaux de neurones et des méthodes d'optimisation.

Le troisième chapitre de ce mémoire présente en détail le modèle de réseau utilisé pour la prédiction du cancer du sein, ainsi que l'ensemble des outils et langages informatiques qui ont été utilisés dans le cadre de cette étude. Nous donnons également des exemples concrets d'exécution en utilisant des interfaces graphiques conviviales, ce qui facilite l'utilisation et la visualisation des résultats.

Nous terminons par une conclusion, où nous synthétisons nos résultats, soulignons leur importance et discutons des perspectives futures. Cette partie finale de notre étude constitue une opportunité de tirer des enseignements, de présenter des recommandations et d'ouvrir de nouvelles voies pour la recherche future qui peuvent avoir un impact significatif sur la santé et le bien-être des patients atteints de cette maladie.

Chapitre 1

Systemes d'aide
à la décision
pour
le diagnostic
du
Cancer du sein

A large, stylized number '1' in a dark gray color, positioned on the left side of the page. It is set against a vertical gray bar that runs from the top to the bottom of the page.

1. Introduction :

Le cancer du sein est l'un des cancers les plus répandus chez les femmes en Algérie et dans le monde entier. En Algérie, il représente environ 30% de tous les cancers diagnostiqués chez les femmes, ce qui en fait un problème de santé publique majeur.

Ce chapitre se concentre sur l'étude approfondie du cancer du sein, en commençant par une exploration de l'anatomie du sein et des différentes pathologies qui peuvent affecter cette glande importante. Nous examinerons les affections bénignes et malignes qui peuvent se développer dans les tissus mammaires, en mettant l'accent sur le cancer du sein.

Ensuite, nous aborderons les méthodes de diagnostic précoce du cancer du sein, qui jouent un rôle crucial dans la prise en charge efficace de cette maladie. Nous discuterons des techniques de dépistage telles que la mammographie, l'examen clinique des seins et l'auto-examen des seins, en soulignant leur importance pour détecter les signes précoces du cancer du sein.

2. Le cancer du sein :

Le sein est composé de graisse, de lobules et de canaux [1]. Les tissus mammaires sont influencés par des hormones, notamment l'œstrogène et la progestérone, qui sont produites tout au long de la vie [1]. Les hormones ovariennes sont impliquées dans le développement du cancer du sein chez les femmes porteuses de mutations du gène BRCA1 [2]. Les hormones stéroïdes, telles que l'estradiol et la progestérone, ont un effet sur la prolifération épithéliale mammaire [3]. Les cancers du sein triple négatifs sont le sous-type de cancer du sein le plus hétérogène et le plus défavorable, et leur traitement repose sur la chimiothérapie systémique [4]. Les tissus tumoraux hormonosensibles peuvent être traités avec des hormones stéroïdes et des inhibiteurs de l'aromatase [5]. Les marqueurs moléculaires de réponse aux hormones ovariennes et au tamoxifène dans les lésions précancéreuses mammaires et les cancers invasifs du sein ont été étudiés pour mieux comprendre le rôle des hormones ovariennes dans la cancérogenèse mammaire [6]. Enfin, la leptine, une hormone peptidique, a un impact sur le statut oxydatif et inflammatoire des cellules épithéliales mammaires saines et tumorales [6] (voir figure 1.1)

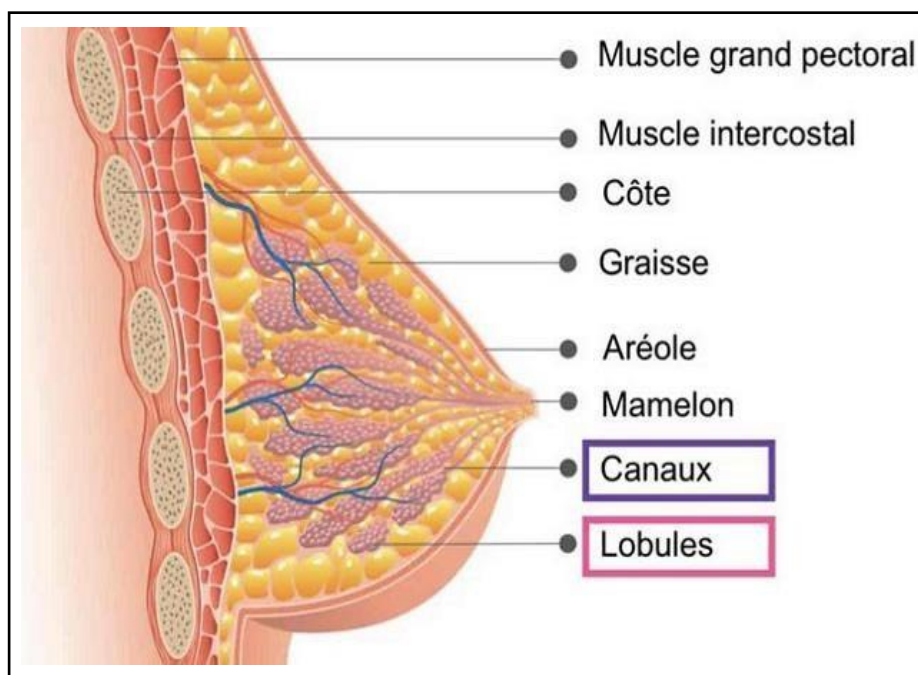


Figure 1.1: Histologie du sein

Le cancer du sein est une maladie qui se développe dans les cellules du sein. Il peut commencer dans différents endroits du sein, tels que les canaux lactifères ou les lobules. Le cancer du sein est généralement classé en fonction de l'endroit où il commence à se développer et de son apparence sous un microscope.

Les symptômes courants du cancer du sein peuvent inclure une masse ou une bosse dans le sein ou sous le bras, un changement de la forme ou de la taille du sein, un écoulement du mamelon, une douleur dans le sein ou une rougeur ou une desquamation de la peau autour du mamelon ou du sein. Cependant, certains cancers du sein ne présentent pas de symptômes visibles.

Le traitement du cancer du sein dépend de plusieurs facteurs, notamment le type et le stade du cancer, ainsi que de la santé générale de la personne atteinte. Les options de traitement peuvent inclure la chirurgie, la radiothérapie, la chimiothérapie, l'hormonothérapie et la thérapie ciblée. Un traitement précoce peut améliorer les chances de guérison et de survie à long terme.

3. La classification des différents cancers du sein :

3.1. Le carcinome canalaire

Est le plus non invasif et on en guérit dans presque tous les cas avec un traitement adapté. En revanche, sans traitement, il peut poursuivre sa croissance et devient invasif en se propageant à l'extérieur des canaux. (voir figure 1.2)




Figure 1.2: le carcinome canalaire

3.2. Le carcinome lobulaire




Figure 1.3: Carcinome lobulaire.

Le carcinome lobulaire se forme dans les lobules. Les cellules cancéreuses traversent leur paroi et se développent dans les tissus environnant. (voir figure 1.3)

3.3. Le carcinome mucineux

Le seul critère pour dire que c'est un carcinome mucineux est l'absence des flaques de mucines situées au niveau stromale extracellulaire. (voir figure 1.4)




Figure 1.4: Carcinome mucineux.

4. Les sous-types

4.1. Le cancer de type luminal

- luminal A : Il est fortement exprimé dans les récepteurs des œstrogènes et de la progestérone, mais pas dans HER2 (HER2-). Ce type de tumeur est généralement moins agressif.
- Luminal B : L'expression des récepteurs hormonaux est faible, mais HER2 (HER2+) peut être surexprimé. Ce type de tumeur est généralement prolifératif [7].

4.2. Le cancer HER2

Il possède des récepteurs du facteur de croissance HER2, mais pas des récepteurs des œstrogènes et/ou de la progestérone (ER- et/o RP- et HER2+).

4.3. Le cancer triple-négatif

Le cancer du sein triple négatif est un sous-type de cancer du sein dépourvu de l'expression du récepteur d'œstrogène, du récepteur de la progestérone et du récepteur 2 du facteur de croissance épidermique humain.

5. Le traitement

5.1. La radiothérapie

La radiothérapie intervient en association avec la chirurgie car le chirurgien enlève la partie visible macroscopique de la tumeur alors que la radiothérapie s'adresse à la partie invisible. Cette technique traite l'ensemble du sein par des rayonnements ionisants qui traversent le sein

et qui vont donc entrainer certain nombre de modifications au niveau de l'ADN des cellules anormales mais également des cellules normales.

5.2. La chimiothérapie

La chimiothérapie consiste en une série de 4 à 8 cycles de traitement en général intraveineux. Elle se fait par perfusion intraveineuse courte de 10 à 60 minutes, sur un rythme soit hebdomadaire, soit toutes les 3 semaines. Cette perfusion intraveineuse est potentiellement toxique pour les veines. Ce type de traitement est utilisé afin de réduire le volume tumoral et permettre un traitement conservateur.

5.3. Hormonothérapie

Son principe repose sur l'inactivation de l'action des œstrogènes au niveau des récepteurs nucléaires par suppression des œstrogènes eux même ou par action directe au niveau de leur récepteurs afin d'empêcher la prolifération.

6. Les techniques de mesure

6.1. L'immunohistochimie

Le principe de l'immunohistochimie repose sur la reconnaissance d'un antigène par un anticorps marqué dans des coupes de tissus. Cette technique utilise un seul anticorps et la procédure est courte et rapide. Cependant, elle est moins sensible en raison de la faible amplification du signal et donc rarement utilisée.

La notation basée sur l'immunohistochimie (IHC) du statut ER est utilisée pour classer les tumeurs ER positives (ER+) et ER négatives (ER-).

6.2. Microarray

La formation de tumeurs implique des changements simultanés dans des centaines de cellules et des variations dans les gènes. Les puces à ADN fournissent une plate-forme pour tester simultanément un grand nombre d'échantillons génétiques. Elle aide notamment à l'identification des polymorphismes mononucléotidiques (SNP) et des mutations, à l'identification des gènes associés à la chimiorésistance et à la découverte de médicaments. Nous pouvons aussi comparer les différents modèles de niveaux d'expression génique entre un groupe de patients cancéreux et un groupe de patients normaux et identifier le gène associé à ce cancer particulier.

6.3. Z-score

Fondamentalement, un z-score est le nombre d'écarts types par rapport à la moyenne d'un point d'information. Quoi qu'il en soit, il s'agit en fait d'une proportion du nombre d'écarts-types en dessous ou au-dessus de la population que représente un score brut. Un z-score est autrement appelé un score standard. Ce score est représenté par la formule générale. Où z

représente le z-score, x représente le score, μ représente la moyenne et σ représente l'écart type.

7. Système d'aide à la décision médicale

7.1. Définition

Un système d'aide à la décision médicale est un système informatique qui aide les médecins à prendre des décisions en matière de diagnostic, de traitement et de prévention des maladies. Ces systèmes peuvent être utilisés dans différents domaines de la médecine, tels que la régulation médicale, la définition dynamique des fonctions d'assistance d'un fauteuil électrique, la détection des arythmies cardiaques...etc.

Les systèmes d'aide à la décision pour le cancer du sein peuvent être basés sur différentes approches, telles que l'utilisation de méthodes objectives pour détecter et diagnostiquer le cancer du sein en déterminant le niveau d'expression de gènes associés au cancer du sein [8].

Les systèmes de décision assistés par ordinateur (DAO) peuvent également être développés en utilisant des outils issus de l'intelligence artificielle, tels que les systèmes immunitaires artificiels (SIA), qui peuvent être utilisés pour la classification des cellules mammaires en bénignes/malignes [9].

Une autre approche pour les systèmes d'aide à la décision pour le cancer du sein est l'utilisation de l'intelligence artificielle explicable, qui permet une visualisation à la fois quantitative et qualitative de la similarité entre les cas pour aider les médecins à comprendre les recommandations des systèmes d'aide à la décision [10].

Enfin, les systèmes d'aide à la décision pour le cancer du sein peuvent également être développés pour l'identification et la prise en charge des femmes ayant des antécédents familiaux de cancer du sein, en utilisant une bonne anamnèse familiale pour évaluer le risque de cancer du sein et en offrant des interventions chirurgicales de réduction des risques, une chimio-prévention et un dépistage poussé par imagerie par résonance magnétique en plus d'une mammographie [11].

7.2. Systèmes d'aide à la décision pour le cancer

Il existe plusieurs systèmes de diagnostic du cancer qui utilisent différentes méthodes, notamment l'intelligence artificielle, deep learning et la gestion des données massives (big data). Ces systèmes visent à améliorer la qualité de la classification et du diagnostic du cancer. Les méthodes de normalisation sont utilisées pour améliorer la qualité de la classification dans le système de diagnostic du cancer du sein. Ces systèmes utilisaient différentes méthodes pour classer les valeurs des caractéristiques statistiques et géométriques obtenues à partir d'images de biopsie mammaire telle que : un classificateur bayésien naïf, la méthode du plus proche voisin, des réseaux neuronaux et des ensembles d'arbres de décision.


Citons quelques exemples de systèmes de diagnostic du cancer :

- Système de diagnostic cytologique assisté par intelligence artificielle pour le dépistage à grande échelle du cancer du col de l'utérus [12]. Ce système vise à développer un système de cytologie assisté par l'intelligence artificielle (IA) dans le cadre du programme de dépistage du cancer du col de l'utérus, afin de pallier l'insuffisance des cytologistes dans le dépistage à grande échelle du cancer du col de l'utérus.
- Méthodes de normalisation des données pour améliorer la qualité de la classification dans le système de diagnostic du cancer du sein [13] Ce système utilise des méthodes de normalisation pour améliorer la qualité de la classification dans le système de diagnostic du cancer du sein. La normalisation consiste à transformer les valeurs des caractéristiques en un certain intervalle. La différence entre les intervalles des valeurs des caractéristiques peut conduire à une pondération implicite des caractéristiques dans leur classification.
- Système de diagnostic du cancer du sein basé sur l'apprentissage profond et utilisant des images médicales [14], Ce système utilise des principes d'intelligence artificielle et des modalités d'imagerie médicale pour assister les oncologues et les cliniciens dans le diagnostic, la confirmation et l'analyse de suivi du cancer du sein. La prise de décision est réalisée par des modèles d'apprentissage profond qui ont été entraînés sur des milliers d'images provenant de différentes modalités d'imagerie médicale.
- Acquisition d'une base de données pour les systèmes de diagnostic assisté par ordinateur du cancer du poumon [15] This system proposes a new methodology of dataset acquisition to overcome the difficulties in medical training data acquisition, such as heterogeneity and incompleteness. The system uses the LIRA database, which has been applied to training the intellectual lung cancer CAD system called by Dr. Aizimov.
- Acquisition de bases de données pour les systèmes de diagnostic assisté par ordinateur du cancer du poumon [16] Ce système propose une nouvelle méthodologie d'acquisition d'ensembles de données pour surmonter les difficultés liées à l'acquisition de données de formation médicale, telles que l'hétérogénéité et l'incomplétude. Le système utilise la base de données LIRA, qui a été appliquée à la formation du système de diagnostic assisté par ordinateur du cancer du poumon appelé par le Dr Aizimov.
- Système de diagnostic du cancer du sein utilisant la neuroévolution adaptative symbiotique

(SANE) [17] Ces systèmes utilisent différentes méthodes telles que l'intelligence artificielle, l'apprentissage profond et la gestion des big data pour améliorer la qualité de la classification et du diagnostic du cancer. Par exemple, le système de diagnostic du cancer du sein basé sur l'apprentissage profond utilise des principes d'intelligence artificielle et des modalités d'imagerie médicale pour aider les oncologues et les cliniciens dans le diagnostic, la confirmation et l'analyse de suivi du cancer du sein. Le système SANE est un système intelligent hybride de diagnostic, de pronostic et de prédiction du cancer du sein qui fait évoluer une population de neurones pour former un réseau neuronal fonctionnel.

8. Conclusion :

En conclusion, ce chapitre nous a permis de mieux comprendre le cancer du sein et son impact sur la santé publique, en particulier en Algérie où il représente un pourcentage important des cancers diagnostiqués chez les femmes. L'étude de l'anatomie du sein et des différentes pathologies mammaires est essentielle pour détecter et diagnostiquer précocement le cancer du sein. Les techniques de dépistage telles que la mammographie, l'examen clinique des seins et l'auto-examen des seins jouent un rôle crucial dans la détection précoce de cette maladie. Une sensibilisation accrue à l'importance du dépistage précoce et de la recherche de soins médicaux appropriés est essentielle pour lutter contre le cancer du sein et améliorer les résultats de santé des femmes.



Chapitre 2

L'intelligence
Artificielle

&

Réseaux
Neurones
Convolutifs

1. Introduction

L'Intelligence Artificielle (IA) est devenue de plus en plus importante dans notre monde moderne en raison de ses nombreuses applications et avantages potentiels, l'IA peut aider à résoudre certains des plus grands défis auxquels l'humanité est confrontée aujourd'hui, et elle est appelée à jouer un rôle de plus en plus important dans notre vie quotidienne et dans le développement de notre avenir.

Dans ce chapitre, nous allons introduire l'intelligence artificielle et ses différentes sous-classes, tout en se basant sur les réseaux de neurones et le Deep Learning, l'approche utilisée pour la réalisation de notre travail.

2. L'intelligence artificielle

2.1. Historique

En 1950, Alan Turing a introduit la machine de Turing, aujourd'hui connue sous le nom de test de Turing, dans son article "Computing Machinery and Intelligence" [18]. Quelques années plus tard, le terme "intelligence artificielle" a été officiellement inventé lors d'un atelier sur l'IA organisé par John McCarthy à l'université de Dartmouth en 1956. Le développement de Lisp, un langage qui est devenu dominant dans le domaine de l'IA 30 ans plus tard, est également une invention importante de cette période. L'âge d'or de l'IA s'est produit dans les années 1970 avec l'invention des ordinateurs numériques et des microprocesseurs. C'est à cette époque que John Hopfield et Dave Rumelhart [19] ont introduit le terme "Deep Learning" (apprentissage profond), qui permet aux ordinateurs d'apprendre en s'appuyant sur l'expérience. C'est également à cette époque qu'est apparu le système expert [20], qui imite le processus de raisonnement et de prise de décision d'un expert. Dans les années 2000, le développement des smartphones, des ordinateurs portables et de l'internet a permis des avancées significatives dans le domaine de l'informatique. En 2010, l'arrivée de processeurs et de cartes graphiques puissants a donné naissance à une nouvelle approche, le Deep Learning, qui a révolutionné l'IA. Aujourd'hui, l'IA s'est étendue à différents domaines tels que la médecine, la traduction, la vision par ordinateur, et est même intégrée dans certaines voitures pour la conduite automatique.

2.2. Définition :

L'intelligence artificielle

(IA) [21] est un domaine de l'informatique qui consiste à créer des machines et des programmes capables d'effectuer des tâches qui requièrent généralement l'intelligence humaine. Cela inclut des activités telles que la reconnaissance vocale et visuelle,

l'apprentissage automatique, la prise de décision, la résolution de problèmes, la compréhension du langage naturel, et bien d'autres. Les systèmes d'IA sont basés sur des algorithmes sophistiqués qui permettent aux machines de s'adapter et de prendre des décisions sur la base de données et de modèles. Les applications de l'IA sont de plus en plus nombreuses dans de nombreux domaines, tels que les soins de santé, l'industrie, la finance, les transports, l'éducation, etc. L'IA est un sujet vaste et en constante évolution. Les récents développements en matière d'IA ont conduit à la création de divers systèmes de diagnostic pour le cancer du sein, le cancer du poumon et le cancer du col de l'utérus, entre autres. Ces systèmes utilisent l'apprentissage profond, l'apprentissage hiérarchique, la quantification vectorielle et la neuroévolution adaptative symbiotique, etc., pour faciliter le diagnostic, le pronostic et la prédiction du cancer. L'intelligence artificielle peut se définir comme « *l'ensemble de théories et de techniques mises en œuvre en vue de réaliser des machines capables de simuler l'intelligence* », selon le Larousse. Soit des ordinateurs ou des programmes avec des puissances de calcul capables de performances habituellement associées à l'intelligence humaine, et amplifiées par la technologie :

- Capacité de raisonner
- Capacité de traiter de grandes quantités de données
- Faculté de discerner des patterns et des modèles indétectables par un humain
- Aptitude à comprendre et analyser ces modèles
- Capacités à interagir avec l'homme
- Faculté d'apprendre progressivement
- Et d'améliorer continuellement ses performances

« Intelligence artificielle » couvre donc un vaste sujet, en perpétuel mutation. Et aux progrès fulgurants depuis 1950, année fondatrice de l'IA.

3. Les domaines d'application de l'intelligence artificielle :

Le domaine de l'intelligence artificielle (IA) englobe différents domaines de recherche, tels que [22] :

Systemes experts : soit un logiciel capable de simuler le comportement d'un humain effectuant une tâche très précise. C'est un domaine où l'intelligence artificielle est incontestablement un succès, dû au caractère très précis de l'activité demandée à simuler.

- **Calcul formel (opposé au calcul numérique) :** traiter les expressions symboliques. Des logiciels sur le marché, comme Mathematica, Maple, etc., effectuent tous des calculs formels.
- **Représentation des connaissances :** on entend la représentation symbolique de la connaissance pour que le logiciel soit capable de la manipuler. Un des secteurs de recherche en intelligence artificielle qui est le plus important.
- **Simulation du raisonnement humain :** tenter de mettre au point des logiques qui formalisent le mode de raisonnement (logiques modales, floues, temporelles, etc.).
- **Traitement du langage naturel :** c'est la compréhension qui reste le problème majeur à la traduction ou au résumé d'un texte dans une autre langue. De grands progrès ont été faits pour obtenir une représentation sous une forme indépendante de la langue dans laquelle l'original est écrit. Certains traducteurs orientés dans des domaines spécialisés donnent de meilleurs résultats grâce à leurs spécificités.
- **Résolution de problèmes :** Représentation, analyse et résolution de problèmes concrets. C'est le cas des jeux de réflexion tels que les échecs, le backgammon ou les dames. Dans le cas du backgammon le champion du monde est un programme. Ils restent quelques jeux qui résistent aux efforts des programmeurs.
- **Reconnaissance de la parole :** beaucoup de progrès ont été effectués. Un logiciel comme Naturally Speaking permet la dictée. Cependant, la compréhension d'un mot ou d'une phrase requiert une grande quantité d'informations extra langagières (contexte, connaissance du sujet, etc.).
- **Reconnaissance de l'écriture :** la reconnaissance de l'écriture dactylographiée n'est pas facile (malgré des logiciels assez performants sur le marché), mais l'écriture manuscrite pose des problèmes beaucoup plus complexes. Cela n'est pas étonnant dans la mesure où cette tâche peut nous poser à nous aussi des problèmes insolubles. Certains chercheurs essaient de reconstituer à partir du texte le mouvement de la main afin de comprendre ce qui est écrit.
- **Reconnaissance des visages :** considérée de longue date comme un des problèmes de l'intelligence artificielle le plus
- **Robotique :** difficile, les résultats récents deviennent intéressants avec les réseaux neuronaux. la robotique dans les usines est déjà fortement rependue. La première génération est capable d'exécuter une série de mouvements préenregistrés, la deuxième génération est dotée de capteurs de perception permettant de prendre certaines décisions

et la troisième génération possède une plus grande autonomie, elle peut se déplacer dans un environnement.

- **L'apprentissage** : un logiciel devrait avoir des capacités d'apprentissage autonome pour pouvoir être véritablement qualifié d'intelligent. Douglas Lenat travaille actuellement à la constitution d'une gigantesque base de données censée contenir toutes les connaissances partagées par les humains d'un même groupe pour leur communication. Il souhaite adjoindre un module d'apprentissage à sa base de données lui permettant de travailler seule pour collecter des informations nouvelles et réorganiser l'architecture de ses connaissances.
- **Réseaux neuronaux** : un réseau de neurones formels est un modèle rudimentaire du cerveau humain. Une cellule neuronale possède une sortie et des entrées reliées à d'autres neurones. Ces réseaux partagent des propriétés importantes avec le cerveau humain. Cela requiert une programmation non explicite et la répartition de l'information sur l'ensemble du réseau.
- **Systèmes complexes adaptatifs** : regroupement des algorithmes génétiques et des modèles de vie artificielle. En résumé succinct, l'étude des convergences vers des formes organisées des populations soumises à des lois simples et naturelles.

4. Types d'intelligence artificielle

L'intelligence artificielle (IA) peut être classée en deux catégories : l'IA faible et l'IA forte. L'IA faible [23], également connue sous le nom d'IA étroite ou d'intelligence artificielle étroite (ANI), est une IA formée et ciblée pour effectuer des tâches spécifiques. Siri, Alexa, IBM Watson et les véhicules autonomes sont des exemples d'IA faible. En revanche, l'IA forte se compose de l'intelligence artificielle générale (AGI) et de l'intelligence super-artificielle (ASI). L'AGI est une forme théorique d'IA dans laquelle une machine aurait une intelligence égale à celle des humains, avec la capacité de résoudre des problèmes, d'apprendre et de planifier l'avenir. L'AGI, également appelée super intelligence, surpasserait l'intelligence et les capacités du cerveau humain. Bien que l'IA forte soit encore entièrement théorique, les chercheurs explorent son développement.

Table des différences entre l'IA faible et l'IA forte : (voir table 2.1)

IA faible	IA forte
Connue sous le nom d'IA étroite ou d'intelligence artificielle étroite (ANI)	Composée d'intelligence artificielle générale (AGI) et d'intelligence super-artificielle (ASI).
Formée et ciblée pour effectuer des tâches spécifiques	Une forme théorique d'IA dans laquelle une machine aurait une intelligence égale à celle de l'homme.
Permet des applications robustes telles que le traitement du langage naturel et les véhicules autonomes	Elle reste entièrement théorique et aucun exemple pratique n'est utilisé aujourd'hui.

Table 2.1: différences entre l'IA faible et l'IA forte

4.1. L'apprentissage automatique (Machine Learning)

4.1.1. Définition

L'apprentissage automatique [24], également connu sous le nom de machine learning, est une discipline scientifique et l'un des domaines d'étude de l'intelligence artificielle. Il englobe le développement, l'analyse et la mise en œuvre de méthodes permettant à une machine d'évoluer et d'apprendre à partir de données, afin d'accomplir des tâches difficiles ou impossibles à réaliser par des moyens algorithmiques classiques.

Dans le domaine de l'apprentissage automatique, des systèmes complexes peuvent être analysés, y compris des données associées à des valeurs symboliques ou des ensembles de modalités possibles sur un attribut de valeur. L'analyse peut également concerner des données présentées sous forme de graphes, d'arbres ou de courbes, telles que des courbes d'évolution temporelle d'une mesure.

Le premier stade de l'analyse dans l'apprentissage automatique est la classification, qui consiste à associer chaque donnée à une classe. Différents systèmes d'apprentissage existent pour réaliser cette tâche. Ces systèmes utilisent des algorithmes qui permettent à un système piloté par ordinateur ou assisté par ordinateur, comme un robot, d'adapter ses analyses et ses comportements en se basant sur l'analyse de données empiriques provenant d'une base de données ou de capteurs.

Les programmes d'apprentissage automatique intègrent des capacités en probabilités, statistiques, traitement de données, analyse de données, reconnaissance (vocale, de forme, d'écriture, etc.), datamining et informatique théorique. Ils visent à permettre aux machines d'apprendre et de s'améliorer de manière autonome, en s'adaptant à de nouvelles données et en produisant des décisions et des résultats fiables et reproductibles.

4.1.2. Types d'apprentissage

Les algorithmes d'apprentissage [25] peuvent se catégoriser selon le mode d'apprentissage qu'ils emploient. Les différents types d'apprentissage incluent :

- **L'apprentissage supervisé** : dans ce type d'apprentissage, le modèle est entraîné sur un ensemble de données étiquetées, c'est-à-dire que chaque exemple est associé à une étiquette ou une réponse connue. Le modèle apprend à prédire la réponse correcte pour de nouveaux exemples en se basant sur les exemples étiquetés qu'il a vu auparavant.
- **L'apprentissage non supervisé** : dans ce type d'apprentissage, le modèle est entraîné sur un ensemble de données non étiquetées. Le modèle apprend à trouver des structures ou des motifs dans les données sans avoir de réponse connue à prédire.
- **L'apprentissage par renforcement** : dans ce type d'apprentissage, le modèle apprend à prendre des décisions en interagissant avec un environnement. Le modèle reçoit une récompense ou une punition en fonction de ses actions, ce qui lui permet d'apprendre à prendre des décisions qui maximisent la récompense.
- **L'apprentissage semi-supervisé** : dans ce type d'apprentissage, le modèle est entraîné sur un ensemble de données qui contient à la fois des exemples étiquetés et non étiquetés. Le modèle utilise les exemples étiquetés pour apprendre à prédire les étiquettes des exemples non étiquetés.
- **L'apprentissage par transfert** : dans ce type d'apprentissage, le modèle est entraîné sur une tâche et utilise ensuite les connaissances acquises pour résoudre une autre tâche similaire. Cela permet d'économiser du temps et des ressources en évitant de devoir entraîner un nouveau modèle à partir de zéro pour chaque tâche. (voir figure 2.1)

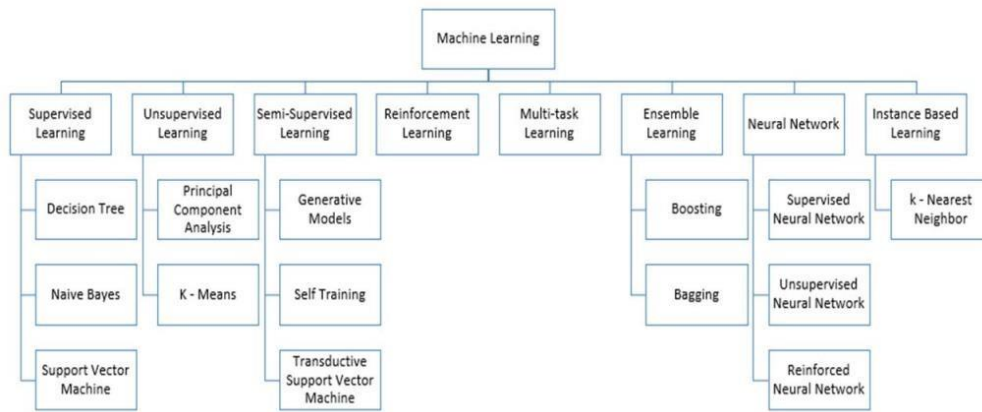


Figure 2.1: Types d'algorithmes du Machine Learning

4.1.3. Applications de l'apprentissage automatique

- Il existe plusieurs applications de l'apprentissage automatique [26], la figure ci-dessous représente ces différentes applications: (voir figure 2.2)

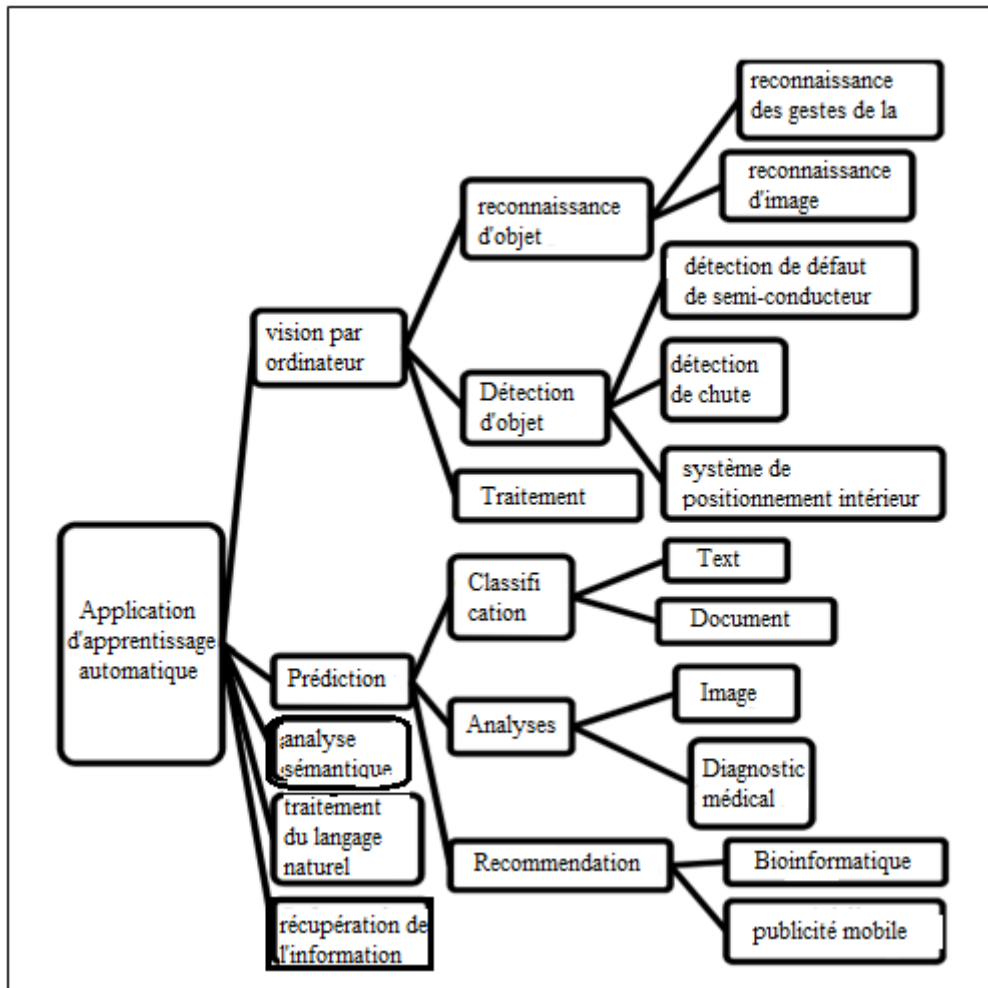


Figure 2.2: Applications de l'apprentissage automatique [26]

4.2. Deep Learning

4.2.1. Définition

Le deep learning [27] est une technique d'apprentissage automatique qui utilise des réseaux de neurones artificiels profonds pour apprendre à partir de données. Les réseaux de neurones profonds [28] sont des réseaux de neurones avec plusieurs couches cachées, ce qui leur permet de capturer des relations complexes entre les données d'entrée et les sorties souhaitées. Le fonctionnement du deep learning peut être décrit en plusieurs étapes :

1. Collecte de données : Les données sont collectées et préparées pour l'apprentissage.
2. Construction du modèle : Un modèle de réseau de neurones profond est construit avec des couches cachées pour apprendre à partir des données.
3. Apprentissage : Le modèle est entraîné sur les données d'apprentissage en ajustant les poids des connexions entre les neurones pour minimiser l'erreur de prédiction.
4. Validation : Le modèle est évalué sur des données de validation pour s'assurer qu'il généralise bien et ne surajuste pas les données d'apprentissage.

5. Test : Le modèle est testé sur des données de test pour évaluer ses performances.

- Le deep learning est utilisé dans de nombreuses applications, telles que la classification d'images, la reconnaissance de la parole, la traduction automatique, etc. Les recherches actuelles portent sur l'amélioration des performances des réseaux de neurones profonds, la prévention de l'overfitting, l'optimisation des architectures de réseau, etc. (voir figure 2.3)




Figure 2.3: Classification d'image par le DeepLearning

4.2.2. Les domaines d'application du Deep learning

Le deep learning est utilisé dans de nombreux domaines, tels que :

- **L'analyse de données textuelles** : Des outils tels que Hyperdeep sont utilisés pour analyser les données textuelles et en extraire des informations cachées au plus profond des couches intermédiaires du deep learning [29].
- **La reconnaissance de gestes** : Le deep learning est utilisé pour la reconnaissance de gestes, qui offrent un mélange complexe de poses corporelles et de mouvements, encodées sous des modalités très variées [30].
- **La classification d'images médicales** : Le deep learning est utilisé pour la classification d'images médicales, où il est utilisé pour produire la classe ou le type de la maladie [31].
- **L'interface Homme-machine** : Le deep learning est utilisé pour améliorer les interfaces Homme-machine, en particulier pour répliquer notre capacité à traiter continuellement des flux d'informations [30].

- **La détection d'oiseaux de mer** : Le deep learning est utilisé pour la détection d'oiseaux de mer sur des images aériennes d'îles pour des biologistes [32].
- **La prévention et la détection du crime** : Le deep learning est utilisé dans des applications critiques telles que la prévention et la détection du crime [33].

Les recherches actuelles portent sur l'amélioration des performances des réseaux de neurones profonds dans ces domaines et dans de nombreux autres.

4.3. Differences Deep learning vs Machine learning

Machine learning et deep learning sont deux sous-domaines de l'apprentissage automatique.

Voici les principales différences entre les deux :

Machine learning :

- Utilise des algorithmes pour apprendre à partir de données et effectuer des tâches spécifiques.
- Les algorithmes sont conçus pour extraire des caractéristiques des données et les utiliser pour prendre des décisions.
- Les modèles sont souvent moins complexes que ceux du deep learning.
- Les modèles sont souvent plus faciles à interpréter que ceux du deep learning.
- Les modèles nécessitent souvent moins de données pour s'entraîner que ceux du deep learning.

Deep learning :

- Utilise des réseaux de neurones artificiels pour apprendre à partir de données et effectuer des tâches spécifiques.
- Les réseaux de neurones sont conçus pour apprendre directement à partir des données, sans avoir besoin d'extraire des caractéristiques.
- Les modèles sont souvent plus complexes que ceux du machine learning.
- Les modèles sont souvent plus difficiles à interpréter que ceux du machine learning.
- Les modèles nécessitent souvent plus de données pour s'entraîner que ceux du machine learning. (table 2.2)

-

Caractéristique	Machine learning	Deep learning
Utilisation d'algorithmes	Oui	Oui
Extraction de caractéristiques	Oui	Non
Complexité des modèles	Moins complexe	Plus complexe
Interprétabilité des modèles	Plus facile	Plus difficile
Quantité de données nécessaire pour l'entraînement	Moins	Plus

Table 2.2: Differences Machine learning VS Deep learning

4.4. Réseaux de neurones artificiels

4.4.1. Neurone biologique/ Neurone artificiel

- Les réseaux de neurones artificiels [34] sont des modèles de calcul inspirés du fonctionnement des neurones biologiques. Les neurones biologiques sont des cellules nerveuses interconnectées dans le cerveau humain, qui communiquent entre elles via des signaux électriques et chimiques. Le cerveau humain comporte en moyenne environ 10 milliards de neurones, chaque neurone communiquant en moyenne avec 10^4 autres neurones grâce à l'axone. Le fonctionnement d'un neurone biologique est simple : l'information est reçue par d'autres neurones via les dendrites, puis traitée par le soma qui représente le cœur du neurone. Ensuite, ce signal est transmis vers la synapse par le biais de l'axone pour être transmis vers d'autres neurones. Un neurone formel est une représentation artificielle et schématique d'un neurone biologique, utilisé dans les réseaux de neurones artificiels. Les synapses sont modélisées par des poids, le soma ou corps cellulaire est modélisé par la fonction de transfert, appelée aussi fonction d'activation, et l'axone par l'élément de sortie. Les réseaux de neurones artificiels sont généralement optimisés par des méthodes d'apprentissage de type statistique, ce qui les place dans la famille des applications statistiques et dans la famille des méthodes de l'intelligence artificielle. Les réseaux de neurones artificiels sont utilisés dans de nombreux domaines, tels que la vision par ordinateur, la traduction automatique, le traitement du langage naturel et la prévision de défaillance des entreprises. (voir figure 2.4)

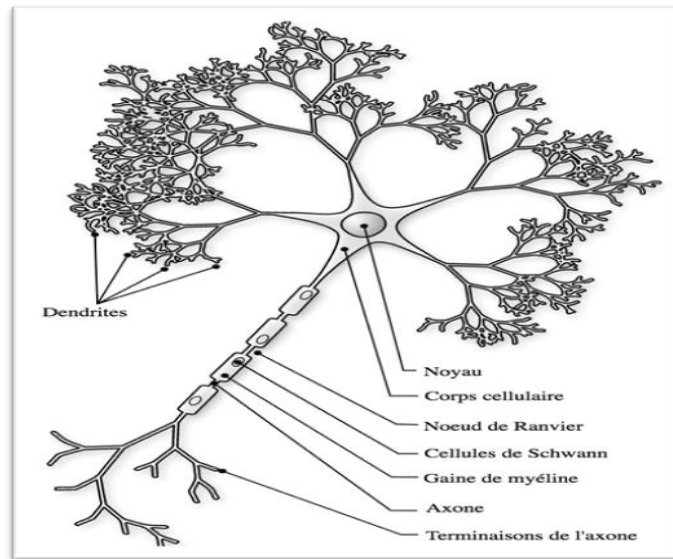


Figure 2.4: Représentation d'un neurone biologique par Nicolas Rougier [35].

Un neurone biologique reçoit des entrées ou signaux transmis par d'autres neurones (interaction dendrites- synapse). Au niveau du corps (soma), le neurone analyse et traite ces signaux en les sommant. Si le résultat obtenu est supérieur au seuil d'activation (ou d'excitabilité), il envoie une décharge alors nommé **potentiel d'action** le long de son axone vers d'autres neurones biologiques.

Un neurone formel est une représentation artificielle et schématique d'un neurone biologique

- Les synapses sont modélisées par des poids,
- Le soma ou corps cellulaire est modélisé par la fonction de transfert, appelé aussi fonction d'activation
- L'axone par l'élément de sortie (voir figure 2.5)




Figure 21.5: Mise en correspondance neurone biologique / neurone artificiel par Claude Touzet [34]

4.4.2. Fonctionnement mathématique du neurone formel

- Un neurone formel, au même titre qu'un neurone biologique, reçoit plusieurs stimuli via les poids. Il analyse ces informations et fournit un résultat en suivant. (voir figure 2.6)

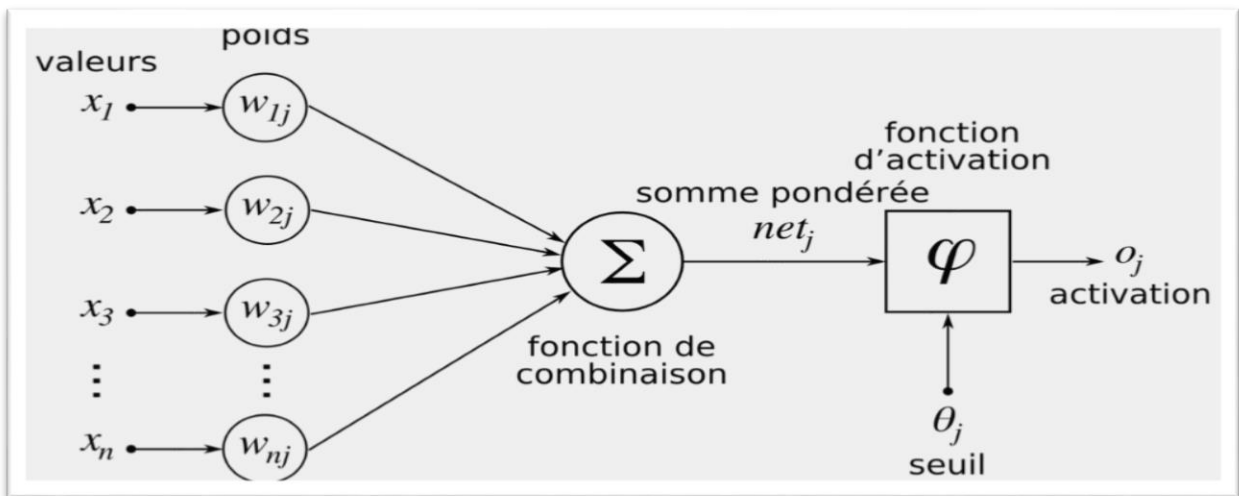


Figure 2.6: Structure d'un neurone artificiel [34]

Regardons plus en détail :

- Chaque poids possède une valeur notée w_{ij} . Cette notation, la plus répandue dans la littérature scientifique, désigne le poids allant d'un neurone formel i au neurone formel j .
- Chaque poids transmet une information/un stimulus provenant du neurone source i noté x_i .

- Ce stimulus (sa valeur) correspondant à l'information envoyé par le neurone source i est modulé par le poids liant les neurones i et j . Mathématiquement cela se traduit par :

$$W_{ij} * x_i$$

- Ainsi neurone j reçoit autant de stimuli que de poids, dont il fait la somme

$$\sum (W_{ij} * x_i)$$

Si l'on note n le nombre de neurones sources liées au neurones j , une notation mathématique plus complète serait :

$$\sum_{i=0}^n (W_{ij} * x_i)$$

Cette expression se lit alors comme ce qui suit : "la somme de toutes les multiplications des valeurs des n neurones sources par les poids associant ces neurones sources au neurone j considéré " (i prenant les valeurs : 0, 1, 2, ..., n)

C'est cette somme que le neurone formel j doit alors traiter ! Il utilise pour cela la fonction de transfert.

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

Les réseaux de neurones, également appelés réseaux de neurones artificiels (ANN) ou réseaux de neurones simulés (SNN), constituent un sous-ensemble de l'apprentissage automatique et sont au cœur des algorithmes d'apprentissage en profondeur. Leur nom et leur structure sont inspirés du cerveau humain, imitant la manière dont les neurones biologiques s'envoient des signaux.

Les réseaux de neurones artificiels (ANN) sont constitués de couches nodales, contenant une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Chaque nœud, ou neurone artificiel, se connecte à un autre et possède un poids et un seuil associés. Si la sortie d'un nœud est supérieure à la valeur de seuil spécifiée, ce nœud est activé et envoie des données à la couche suivante du réseau. Sinon, aucune donnée n'est transmise à la couche suivante du réseau.

Les réseaux de neurones s'appuient sur des données d'entraînement pour apprendre et améliorer leur précision au fil du temps. Cependant, une fois que ces algorithmes d'apprentissage sont réglés avec précision, ils constituent des outils puissants en

informatique et en intelligence artificielle, nous permettant de classer et de regrouper des données à une vitesse élevée.

4.4.4. Principe de fonctionnement de réseaux neuronaux artificiels

Les réseaux de neurones artificiels sont une méthode d'apprentissage machine qui utilise des modèles mathématiques inspirés par le fonctionnement du cerveau humain. Les réseaux de neurones sont constitués de nombreuses unités de traitement appelées "neurones", qui sont organisées en couches. Le processus de fonctionnement des réseaux de neurones artificiels commence par l'entrée de données, appelées "données d'entrée", qui sont transmises à la couche de neurones d'entrée. Chaque neurone d'entrée est connecté à des neurones dans la couche suivante, appelée couche cachée. Les neurones de la couche cachée effectuent des calculs sur les données entrantes et transmettent les résultats aux neurones de la couche suivante. Le processus de calcul est répété pour chaque couche cachée jusqu'à ce que les données atteignent la dernière couche, appelée couche de sortie, qui produit les résultats finaux. Les résultats peuvent être utilisés pour la classification, la prédiction ou la reconnaissance de motifs. Le processus de formation des réseaux de neurones artificiels consiste à ajuster les poids des connexions entre les neurones pour minimiser une fonction de coût, qui mesure l'écart entre les résultats produits par le réseau et les résultats attendus. Cette étape est réalisée à l'aide d'un algorithme d'optimisation tel que la rétropropagation du gradient. Une fois que le réseau de neurones est formé, il peut être utilisé pour effectuer des prédictions sur de nouvelles données en utilisant les poids appris pendant la phase d'apprentissage.

4.4.5. Fonction d'activation

La fonction d'activation [34] est une fonction mathématique appliquée à la sortie d'un neurone artificiel pour déterminer si ce neurone doit être activé ou non. Cette fonction est généralement non linéaire et permet aux réseaux de neurones artificiels de modéliser des relations complexes entre les entrées et les sorties. Les fonctions d'activation couramment utilisées comprennent la fonction sigmoïde, la fonction tangente hyperbolique et la fonction ReLU (Rectified Linear Unit). La fonction sigmoïde est une fonction en forme de S qui transforme les valeurs d'entrée en une plage de valeurs entre 0 et 1, ce qui permet de modéliser des probabilités. La fonction tangente hyperbolique est similaire à la fonction sigmoïde, mais elle transforme les valeurs d'entrée en une plage de valeurs entre -1 et 1. La fonction ReLU est une fonction linéaire pour les valeurs positives et une fonction constante pour les valeurs négatives, ce qui la rend plus rapide à calculer que les fonctions sigmoïde et tangente

hyperbolique. Les fonctions d'activation sont un élément clé des réseaux de neurones artificiels et leur choix peut avoir un impact significatif sur les performances du réseau.

4.4.6. La classification

La classification est l'une des applications les plus courantes des réseaux de neurones artificiels. Les réseaux de neurones peuvent être entraînés à classer des données en fonction de leurs caractéristiques. Par exemple, un réseau de neurones peut être entraîné à classer des images en fonction de leur contenu, comme la reconnaissance de visages ou la détection d'objets. Les réseaux de neurones peuvent également être utilisés pour la classification de données textuelles, telles que la classification de courriels en spam ou non-spam. Les réseaux de neurones artificiels sont souvent utilisés pour la classification en raison de leur capacité à modéliser des relations complexes entre les entrées et les sorties. Les réseaux de neurones peuvent également être utilisés pour la classification en temps réel, ce qui les rend utiles pour les applications telles que la reconnaissance de la parole et la détection d'objets en temps réel. Les réseaux de neurones artificiels sont souvent optimisés par des méthodes d'apprentissage de type statistique, ce qui leur permet de prendre des décisions s'appuyant davantage sur la perception que sur le raisonnement logique formel.

4.4.7. L'optimiseur

L'optimiseur est un élément clé dans l'entraînement des réseaux de neurones artificiels. L'optimiseur est responsable de la mise à jour des poids du réseau de neurones afin de minimiser la fonction de perte. Les optimiseurs les plus couramment utilisés sont la descente de gradient stochastique (SGD) [35], l'optimiseur Adam [36] et l'optimiseur Adagrad [37]. La SGD est l'optimiseur le plus simple et le plus couramment utilisé. Il met à jour les poids du réseau en fonction du gradient de la fonction de perte par rapport à chaque poids. L'optimiseur Adam est un optimiseur adaptatif qui ajuste les taux d'apprentissage pour chaque poids en fonction de l'historique des gradients. L'optimiseur Adagrad est un autre optimiseur adaptatif qui ajuste les taux d'apprentissage pour chaque poids en fonction de la fréquence des mises à jour précédentes de chaque poids. Le choix de l'optimiseur peut avoir un impact significatif sur les performances du réseau de neurones, et il est souvent nécessaire de tester plusieurs optimiseurs pour trouver celui qui fonctionne le mieux pour une tâche donnée.

4.4.8. Différents types de réseaux de neurones

Il existe différents types de réseaux de neurones artificiels, chacun ayant des architectures et des fonctions spécifiques. Voici quelques exemples de types de réseaux de neurones :

1. **Réseaux de neurones multicouches** : ces réseaux sont constitués de plusieurs couches de neurones, chacune étant connectée à la couche précédente et à la couche suivante. Les réseaux de neurones multicouches sont souvent utilisés pour la classification et la reconnaissance de motifs.
2. **Réseaux de neurones récurrents** : ces réseaux sont conçus pour traiter des données séquentielles, telles que des séquences de mots ou de sons. Les réseaux de neurones récurrents ont des connexions récurrentes qui leur permettent de prendre en compte l'historique des données précédentes.
3. **Réseaux de neurones convolutifs** : ces réseaux sont conçus pour traiter des données en deux dimensions, telles que des images. Les réseaux de neurones convolutifs utilisent des filtres pour extraire des caractéristiques de l'image, puis les combinent pour effectuer une classification.

Dans notre projet, nous nous intéressons à ce type de réseaux de neurones.

4. **Réseaux de neurones auto-encodeurs** : ces réseaux sont conçus pour apprendre une représentation compressée des données d'entrée. Les réseaux de neurones auto-encodeurs sont souvent utilisés pour la réduction de dimensionnalité et la reconstruction d'images.
5. **Réseaux de neurones adversaires** : ces réseaux sont conçus pour générer des données synthétiques qui ressemblent à des données réelles. Les réseaux de neurones adversaires sont souvent utilisés pour la génération d'images et la synthèse de voix.

Chacun de ces types de réseaux de neurones a des avantages et des inconvénients, et le choix du type de réseau dépend de la tâche à accomplir.

Les réseaux de neurones diffèrent par plusieurs paramètres, notamment :

- La topologie des connexions entre les neurones ;
- La fonction d'agrégation utilisée (somme pondérée, distance pseudo-euclidienne...);
- La fonction de seuillage utilisée (sigmoïde, échelon, fonction linéaire, fonction de Gauss...);
- L'algorithme d'apprentissage (rétropropagation du gradient, cascade corrélation) ;
- La méthode de dégradation des pondérations (weight decay), permettant d'éviter les effets de bord et de neutraliser le sur apprentissage.

D'autres paramètres, spécifiques à certains types de réseaux de neurones, tels que la méthode de relaxation pour les réseaux de neurones (réseaux de Hopfield par exemple) qui ne sont pas à propagation simple (perceptron multicouche par exemple), peuvent également

être utilisés. Les recherches actuelles portent sur l'étude de la convergence des réseaux de neurones, la synchronisation des réseaux de neurones, la prévention de l'overfitting, l'optimisation des performances, etc. Les résultats de ces recherches ont permis d'améliorer considérablement les performances des réseaux de neurones dans de nombreuses applications, telles que la classification d'images, la reconnaissance de la parole, la traduction automatique, etc.

Nous allons voir en détail les réseaux de neurone convolutif vu que c'est notre champ de recherche.

Les réseaux de neurones convolutifs [38], également connus sous le nom de CNN (Convolutional Neural Networks) ou ConvNet, sont un type de réseau de neurones artificiels utilisés dans le domaine de l'apprentissage automatique. Inspirés par le cortex visuel des animaux, ces réseaux sont conçus de manière à reproduire le schéma de connexion des neurones dans cette région du cerveau. La structure d'un réseau de neurones convolutifs comprend deux types de neurones artificiels organisés en couches pour traiter l'information de manière séquentielle. La première couche est la couche convolutive, où une fonction de convolution est appliquée à une portion limitée de l'image (appelée "champ réceptif") [38]. Cette couche permet de détecter des caractéristiques visuelles telles que les contours, les textures et les motifs présents dans l'image. Ensuite, les sorties de la couche convolutive sont généralement soumises à une couche de mise en commun (pooling), qui réduit la dimension de l'image en prenant les valeurs les plus importantes dans des régions voisines [38]. Cela permet de réduire la quantité de données à traiter tout en conservant les caractéristiques essentielles. Enfin, les sorties de la couche de mise en commun sont transmises à une ou plusieurs couches entièrement connectées, où les neurones sont connectés à tous les neurones de la couche précédente [38].

- Ces couches finales sont responsables de la classification ou de la prédiction des données en fonction des caractéristiques extraites des couches précédentes. Les réseaux de neurones convolutifs sont largement utilisés dans des domaines tels que la reconnaissance d'images et de vidéos, les systèmes de recommandation et le traitement du langage naturel [38]. Leur capacité à extraire automatiquement des caractéristiques pertinentes à partir des données en fait des outils puissants pour résoudre une variété de tâches de traitement de l'information. (voir figure 2.7)




Figure 2.7: Architecture générale d'un réseau de neurones convolutif [39].

Une architecture de réseau de neurones convolutifs est formée par un empilement de couches de traitement :

- La couche de convolution (CONV) qui traite les données d'un champ récepteur ;
- La couche de pooling (POOL), qui permet de compresser l'information en réduisant la taille de l'image intermédiaire (souvent par sous-échantillonnage) ;
- La couche de correction (ReLU), souvent appelée par abus « ReLU » en référence à la fonction d'activation (Unité de rectification linéaire) ;
- La couche « entièrement connectée » (FC), qui est une couche de type perceptron ;
- La couche de perte (LOSS).

Les réseaux de neurones convolutifs sont entraînés pour la classification d'images en utilisant des techniques d'apprentissage supervisé [39]. Voici quelques exemples de méthodes d'entraînement pour les réseaux de neurones convolutifs:

- **Fine-tuning** : Cette technique consiste à utiliser un réseau de neurones pré-entraîné sur un grand ensemble de données, tel que l'ensemble de données ImageNet, et à ajuster les poids du réseau pour une tâche spécifique. Les couches supérieures du réseau sont remplacées par de nouvelles couches de classification, et les poids des couches inférieures sont ajustés pour mieux s'adapter aux nouvelles données.
- **Data augmentation** : Cette technique consiste à générer des images supplémentaires à partir des images existantes en appliquant des transformations telles que la rotation, le zoom et le décalage. Cela permet d'augmenter la taille de l'ensemble de données et de réduire le surapprentissage.
- **Dropout**: Cette technique consiste à désactiver aléatoirement certains neurones pendant l'entraînement pour éviter le surapprentissage.
- **Batch normalization**: Cette technique consiste à normaliser les activations de chaque couche pour accélérer l'entraînement et améliorer la stabilité du réseau.

- **Cyclic Annealing Training:** Cette technique consiste à utiliser un entraînement par recuit cyclique pour accélérer l'entraînement du réseau de neurones convolutifs.

Ces techniques d'entraînement sont souvent combinées pour améliorer les performances des réseaux de neurones convolutifs pour la classification d'images. Les réseaux de neurones convolutifs sont souvent entraînés sur des ensembles de données massifs. Les performances des réseaux de neurones convolutifs peuvent être évaluées en utilisant des métriques telles que la précision, le rappel et la F-mesure [40].

Paramètre d'entraînement

Pour entraîner un modèle CNN, il est important de définir correctement les paramètres d'entraînement afin d'optimiser les performances du modèle [39]. Voici quelques-uns des paramètres d'entraînement clés que vous devez définir :

- **La taille des lots (batch size) :** c'est le nombre d'images que vous passez simultanément dans votre modèle lors de l'entraînement. Plus la taille du lot est grande, plus l'entraînement sera rapide, mais cela nécessite également plus de mémoire.
- **Le nombre d'époques :** cela correspond au nombre de fois où l'ensemble des données sera parcouru pendant l'entraînement. Plus le nombre d'époques est élevé, plus le modèle aura la possibilité d'apprendre des données, mais cela peut également augmenter le risque de sur-apprentissage.
- **La fonction de perte :** c'est une mesure de l'écart entre les prédictions du modèle et les valeurs réelles. Elle est utilisée pour guider la mise à jour des poids du modèle pendant l'entraînement. Il existe plusieurs fonctions de perte, comme la fonction de perte de log vraisemblance (log-likelihood loss), la fonction d'erreur quadratique moyenne (mean squared error), la fonction d'erreur absolue moyenne (mean absolute error), etc. La taille de l'image en entrée : il est important de spécifier la taille des images en entrée qui seront utilisées pour entraîner le modèle. La taille de l'image en entrée peut affecter les performances du modèle, ainsi que la vitesse d'entraînement.
- **La fonction d'activation :** c'est une fonction mathématique appliquée à la sortie de chaque couche pour introduire la non-linéarité dans le modèle. Les fonctions d'activation couramment utilisées dans les modèles CNN incluent la fonction ReLU (Rectified Linear Unit), la fonction sigmoïde et la fonction tangente hyperbolique.
- **La taille et le nombre de filtres de convolution :** les filtres de convolution sont des matrices utilisées pour extraire les caractéristiques de l'image en entrée. Il est important de choisir la

taille et le nombre de filtres de convolution en fonction de la complexité de l'image en entrée et du problème de classification.

- **La taille des couches de pooling (pooling layer size)** : les couches de pooling sont utilisées pour réduire la dimensionnalité de la sortie de la couche de convolution précédente. Il est important de choisir la taille des couches de pooling en fonction de la complexité de l'image en entrée et de la taille de la couche de convolution précédente.
- **La taille des filtres (filter size)** : c'est la dimension des matrices de poids qui glissent sur l'image en entrée pour extraire des caractéristiques. Plus la taille du filtre est grande, plus le modèle pourra capturer des motifs complexes, mais cela augmente également le nombre de paramètres à entraîner.
- **Le nombre de filtres (number of filters)** : c'est le nombre de filtres de convolution qui sont appliqués sur l'image en entrée. Chaque filtre détecte des motifs spécifiques dans l'image, et plus il y a de filtres, plus le modèle peut extraire de caractéristiques. Cependant, cela augmente également le nombre de paramètres à entraîner.
- **La couche entièrement connectée (fully connected layer)** : c'est une couche qui prend en entrée les caractéristiques extraites par les couches de convolution et les aplatit en un vecteur pour effectuer la classification. Le nombre de neurones dans cette couche dépend de la taille de l'entrée et du nombre de classes à prédire.
- **La régularisation** : c'est une technique utilisée pour éviter le sur-apprentissage en ajoutant une pénalité aux poids du modèle. Les techniques courantes sont la régularisation L1, L2, et dropout.

Nous pouvons également définir les hyperparamètres (c'est des paramètres qui ne sont pas appris par le modèle) avant l'entraînement, tels que le taux d'apprentissage, la taille du lot, le nombre d'époques, etc

4.4.9. Les Modèles des réseaux de neurones convolutifs

Les modèles de réseaux de neurones convolutifs [39] sont des sujets de recherche très actifs dans le domaine de l'apprentissage automatique. Cependant, les résultats de recherche sur les réseaux de neurones convolutifs sont souvent présentés dans le contexte plus large des réseaux de neurones artificiels. Les modèles de réseaux de neurones convolutifs peuvent être classés en deux catégories principales : les modèles à une seule tâche et les modèles à plusieurs tâches. Les modèles à une seule tâche sont conçus pour effectuer une tâche de classification spécifique, telle que la reconnaissance d'images. Les modèles à plusieurs tâches sont conçus pour effectuer plusieurs tâches de classification simultanément, telles que la reconnaissance d'images et la reconnaissance de la parole. Les modèles de réseaux de neurones convolutifs peuvent

également être classés en fonction de leur architecture. Les architectures les plus courantes sont les suivantes :

- **Le modèle LeNet-5** : Ce modèle a été développé pour la reconnaissance de caractères manuscrits et est souvent considéré comme le premier modèle de réseau de neurones convolutifs. Il est composé de deux couches convolutives, suivies de deux couches de mise en commun et de trois couches entièrement connectées. (voir figure 2.8)




Figure 2.8: Le modèle LeNet-5

- **Le modèle AlexNet**: Ce modèle a été développé pour la reconnaissance d'images et a remporté le concours ImageNet en 2012. Il est composé de cinq couches convolutives, suivies de trois couches de mise en commun et de trois couches entièrement connectées. (voir figure 2.9)




Figure 2.9: Le modèle AlexNet

- **Le modèle VGG** : Ce modèle a été développé pour la reconnaissance d'images et est connu pour sa profondeur. Il est composé de 19 couches convolutives, suivies de cinq couches de mise en commun et de trois couches entièrement connectées. (voir figure 2.10)




Figure 2.10: Le modèle VGG

- **Le modèle ResNet** : Ce modèle a été développé pour la reconnaissance d'images et est connu pour sa capacité à résoudre le problème de la disparition du gradient. Il est composé de plusieurs blocs résiduels, chacun contenant plusieurs couches convolutives. (voir figure 2.11)

•

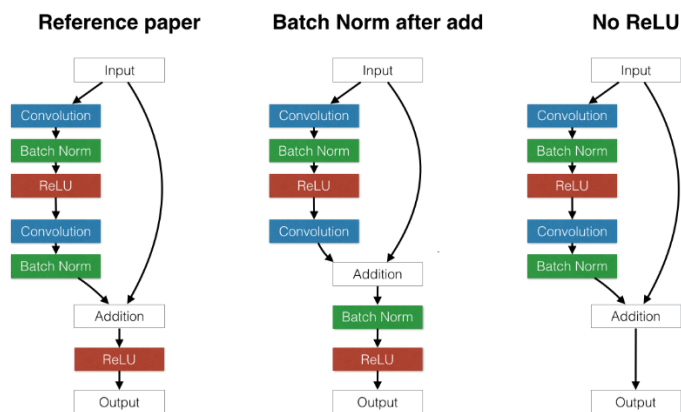


Figure 2.11: Le modèle ResNet

- **GoogLeNet** : GoogLeNet est l'architecture CNN utilisée par Google pour remporter la tâche de classification ILSVRC 2014. Il a été développé par Jeff Dean, Christian Szegedy, Alexandro Szegedy et al. Il a été démontré qu'il avait un taux d'erreur considérablement réduit par rapport aux précédents gagnants AlexNet et ZF-Net. En termes de taux d'erreur, l'erreur est nettement inférieure à VGG. Il réalise une architecture plus profonde en utilisant un certain nombre de techniques distinctes, notamment la convolution 1×1 et la mise en commun de la moyenne globale. Vous trouverez ci-dessous le schéma fonctionnel simplifié représentant l'architecture GoogLeNet CNN : (voir figure 2.12)

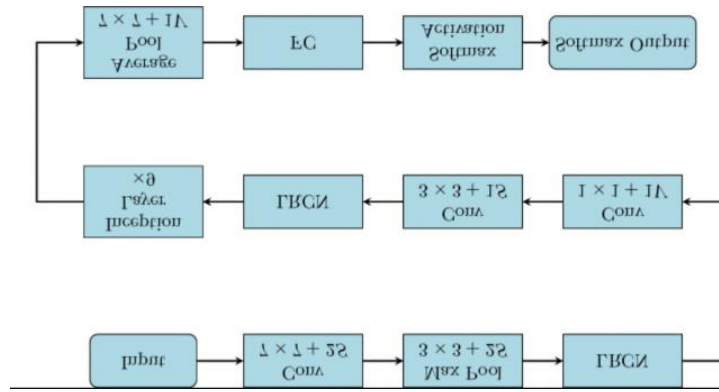


Figure 2.12: GoogLeNet

- MobileNets** : Les MobileNets sont des CNN qui peuvent être installés sur un appareil mobile pour classer des images ou détecter des objets avec une faible latence. Les MobileNets ont été développés par Andrew G Trillion et al.. Ce sont généralement de très petites architectures CNN, ce qui les rend faciles à exécuter en temps réel à l'aide d'appareils intégrés tels que les smartphones et les drones. L'architecture est également flexible, elle a donc été testée sur des CNN avec 100 à 300 couches et elle fonctionne toujours mieux que d'autres architectures comme VGGNet. (voir figure 2.13)

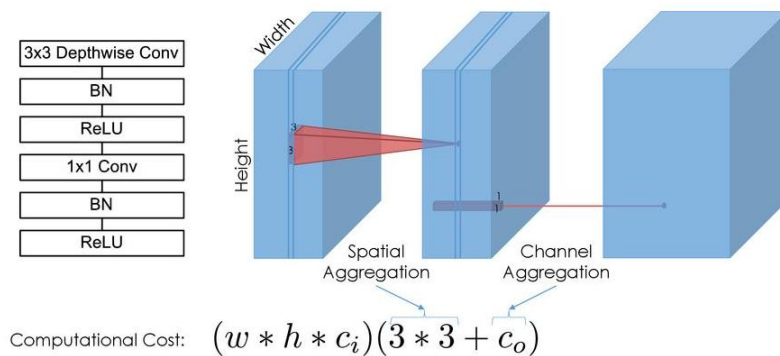


Figure 2.13 MobileNets

- GoogLeNet_DeepDream** : GoogLeNet_DeepDream est une architecture CNN de rêve profond qui a été développée par Alexander Mordvintsev, Christopher Olah, et al.. Elle utilise le réseau Inception pour générer des images basées sur les fonctionnalités CNN. L'architecture est souvent utilisée avec l'ensemble de données ImageNet pour générer des images psychédéliques ou créer des œuvres d'art abstraites en utilisant l'imagination humaine lors de l'atelier ICLR 2017 de David Ha, et al.

5. Travaux connexes

Voici un tableau résumant les travaux liés à l'apprentissage profond et à la détection du cancer du sein : (voir table 2.3)


Titre	Résumé
"Layered Deep learning for Improved Breast Cancer Detection" [41].	Propose un modèle d'apprentissage en profondeur en couches pour le diagnostic précoce du cancer du sein. Évalue l'efficacité de l'approche proposée à l'aide de plusieurs métriques d'évaluation liées à l'apprentissage automatique. Les résultats suggèrent que la précision du modèle proposé est supérieure à 96% pour l'entraînement et la validation du modèle.
"Review methods for breast cancer detection using artificial intelligence and deep learning methods" [42]	Compare les méthodes existantes pour la détection du cancer du sein en utilisant des algorithmes d'apprentissage en profondeur. Propose une nouvelle approche et l'utilisation de l'autoencodeur convolutionnel, qui a montré des performances élevées avec une sensibilité, une précision et une précision de 93,50%, 91,60% et 9%, respectivement.
"Breast Cancer Dataset, Classification and Detection Using Deep Learning" [43]	Passe en revue les méthodes existantes de pathologie computationnelle et numérique pour le diagnostic du cancer du sein, en mettant l'accent sur l'apprentissage en profondeur. Passe en revue les ensembles de données publics liés au diagnostic du cancer du sein et les méthodes d'apprentissage en profondeur existantes pour le diagnostic du cancer du sein.
"Efficient, Ultra-facile Breast Cancer Histopathological Images Classification Approach	Propose un modèle de réseau de neurones convolutifs simple entraîné à partir de zéro pour discriminer les tumeurs bénignes et malignes du cancer du sein dans les images histopathologiques. Quatre algorithmes

<p>Utilizing Deep Learning Optimizers" [44]</p>	<p>d'optimisation d'apprentissage en profondeur sont utilisés pour trouver de bons ensembles de paramètres qui aident à minimiser la perte et à augmenter la précision globale de la classification.</p>
<p>"A Systematic Review of Breast Cancer Detection Using Thermography and Neural Networks" [45]</p>	<p>Passe en revue systématiquement les travaux liés à la thermographie avec l'IA en mettant en évidence leurs contributions et leurs limites et en proposant des pistes de recherche ouvertes. Plusieurs types différents de réseaux de neurones artificiels (RNA) et de modèles d'apprentissage en profondeur ont été utilisés dans la littérature pour traiter les images thermographiques du cancer du sein.</p>
<p>"Deep Learning on Histopathology Images for Breast Cancer Classification: A Bibliometric Analysis" [46]</p>	<p>Explore l'état de la recherche et les tendances de développement de l'apprentissage en profondeur sur la classification des images de cancer du sein à l'aide d'une analyse bibliométrique. Les travaux pertinents de la littérature ont été obtenus à partir de la base de données Scopus entre 2014 et 2021. Le réseau de co-occurrence des mots-clés des auteurs a été analysé pour des orientations futures potentielles du domaine.</p>

Table 2.3: Travaux Connexes

6. Conclusion

Dans ce chapitre, nous avons étudié les réseaux de neurones artificiels, qui sont des modèles de calcul inspirés du fonctionnement des neurones biologiques. Nous avons également introduit la notion de Deep Learning, qui est un sous-ensemble de l'intelligence artificielle. Dans le prochain chapitre, nous nous concentrerons sur la conception et l'implémentation de notre projet, nous verrons comment mettre en pratique les notions que nous avons étudiées dans ce chapitre pour réaliser notre projet.



Chapitre 3

Conception
&
Réalisation

1. Introduction

Ce chapitre se concentre sur le modèle spécifique utilisé dans notre application, l'architecture générale du système et sa mise en œuvre. Nous analysons les besoins fonctionnels et non fonctionnels, concevons l'architecture de l'application et prenons en compte les choix de mise en œuvre nécessaires pour créer une application bien structurée et efficace.

2. Architecture générale du système de détection du cancer basée Deep learning

L'architecture générale de notre système de détection du cancer du sein basée sur le Deep Learning peut comprendre les étapes suivantes collecte de donnée, prétraitement des données, extraction de caractéristiques, entraînement du modèle, déploiement, maintenance et mise à jour (voir figure 3.1):

1. **Collecte de données** : La première étape consiste à collecter des données d'images médicales de haute qualité de tumeurs du sein. Ces images peuvent être obtenues à partir de diverses sources, telles que des scanners, des IRM, des mammographies, etc.
 2. **Prétraitement des données** : Les images collectées doivent être prétraitées pour éliminer le bruit et les artefacts. Cela peut inclure des étapes telles que la normalisation de l'intensité, la segmentation de la région d'intérêt, la correction de la distorsion, etc.
 3. **Extraction de caractéristiques** : Les caractéristiques pertinentes doivent être extraites à partir des images prétraitées. Les réseaux de neurones convolutifs peuvent être utilisés pour extraire automatiquement les caractéristiques pertinentes à partir des images.
 4. **Entraînement du modèle** : Les caractéristiques extraites doivent être utilisées pour entraîner un modèle de réseau de neurones convolutifs. Les modèles de réseaux de neurones convolutifs peuvent être entraînés à l'aide de techniques telles que la rétropropagation du gradient, le transfert de connaissances, etc.
 5. **Validation et évaluation** : Le modèle entraîné doit être validé et évalué à l'aide de données de test. Les métriques d'évaluation telles que la précision, le rappel, la F-mesure, etc. peuvent être utilisées pour évaluer les performances du modèle.
- **Déploiement** : Le modèle entraîné peut être déployé dans un environnement clinique pour la détection et la prévention du cancer du sein. Cela peut inclure des étapes telles que l'intégration avec des systèmes d'information médicale, la mise en œuvre de mécanismes de sécurité, etc. (voir figure 3.1)

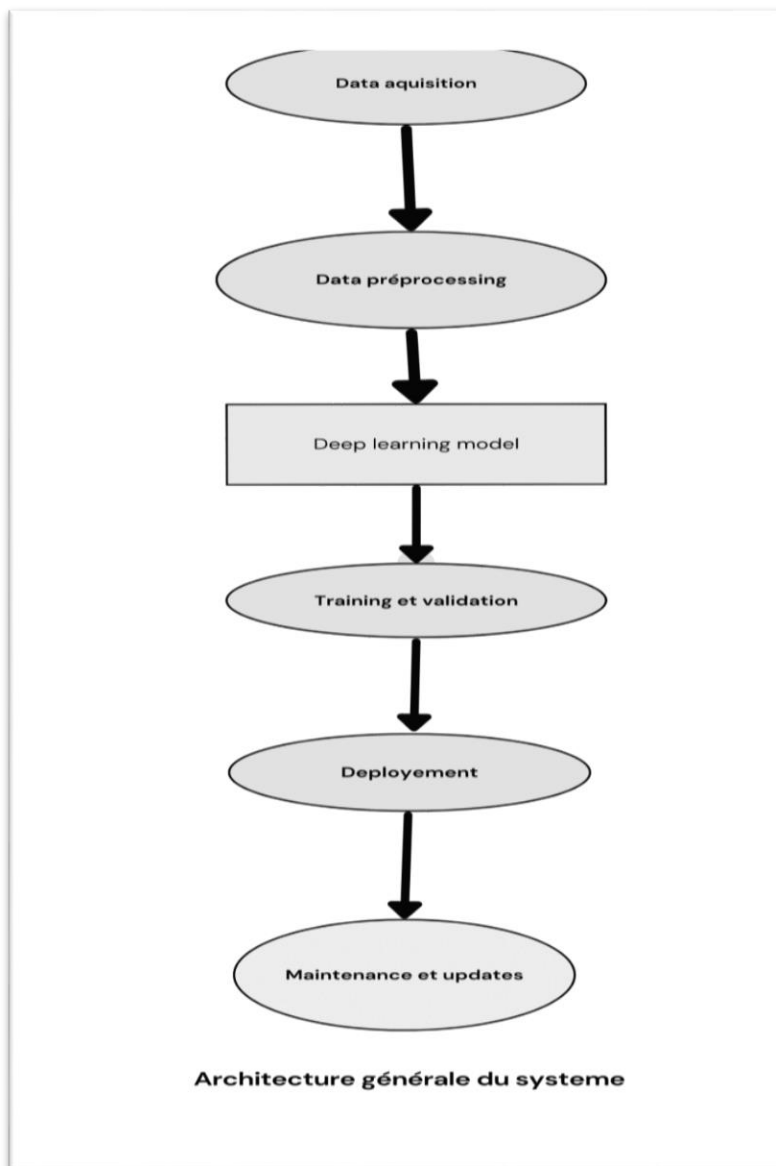


Figure 3.1: Architecture générale du système

3. Environnement de développement de système

Le projet a été développé avec la configuration matérielle suivante :

3.1. Environnement matériel :

- Plateforme : Google Colab et un ordinateur portable.
- Processeur (CPU) : Intel Core i5 5300U CPU
- Mémoire vive (RAM) : 4 Go de mémoire DDR3.
- Carte graphique : Intégrée.

Ces informations donnent un aperçu de la configuration matérielle utilisée dans le projet.

3.2. Environnement logiciel et langages de programmation

Le système d'exploitation installé est windows 10 professional 64 bits, et les langages et les frameworks utilisés sont les suivants

3.2.1. Langage Python



Python [47] est un langage de programmation interprété, orienté objet et de haut niveau avec une sémantique dynamique. Il est largement utilisé dans différents domaines tels que le développement web, l'analyse de données, l'intelligence artificielle et l'automatisation des tâches. Python est réputé pour sa syntaxe simple et lisible, ce qui facilite la maintenance du code. Il prend en charge les structures de données de haut niveau et offre une liaison dynamique, ce qui le rend attrayant pour le développement rapide d'applications.

Python est utilisé dans divers domaines, notamment le développement web. Il est également utilisé dans l'analyse de données, l'apprentissage automatique (machine learning) et l'intelligence artificielle grâce à des bibliothèques populaires comme NumPy[48], Pandas [49], et TensorFlow [50]

3.2.2. Keras



L'API Keras [51] est un framework d'apprentissage en profondeur écrit en Python, qui s'exécute sur la plate-forme d'apprentissage automatique TensorFlow [50]. Son objectif principal est de permettre aux développeurs de transformer leurs idées en résultats concrets le plus rapidement possible, en offrant un avantage inégalé à ceux qui cherchent à créer des applications basées sur l'apprentissage automatique. Keras se distingue par sa simplicité, sa flexibilité et sa puissance. Il met l'accent sur des aspects essentiels tels que la rapidité de débogage, l'élégance et la concision du code, ainsi que la facilité de maintenance et de déploiement [4]. Utilisé par des institutions renommées telles que le CERN, la NASA, et de nombreuses autres organisations scientifiques à travers le monde.

3.2.3. TensorFlow



TensorFlow [50] est une plate-forme open source complète qui met à disposition un large éventail d'outils pour gérer tous les aspects d'un système d'apprentissage automatique. Les API TensorFlow sont structurées de manière hiérarchique, comprenant des API de haut niveau qui reposent sur des API de bas niveau. Les chercheurs en apprentissage automatique exploitent les API de bas niveau de TensorFlow afin de concevoir et d'explorer de nouveaux algorithmes pour l'apprentissage automatique, son objectif est de simplifier le processus de développement et d'exécution d'applications d'analyse avancées pour les utilisateurs tels que les scientifiques des données, les statisticiens et les modélisateurs prédictifs.

3.2.4. PyQt5



PyQt5 [52] se réfère à la version la plus récente de la bibliothèque Qt. Cette bibliothèque permet d'utiliser le framework GUI Qt avec Python. Qt lui-même est implémenté en C++. En utilisant Qt avec Python, vous pouvez développer des applications plus rapidement sans compromettre les performances optimales du langage C++.

Qt est une collection de bibliothèques multiplateformes écrites en C++, offrant des API de haut niveau pour accéder à divers aspects des systèmes de bureau et mobiles modernes. Ces fonctionnalités incluent les services de localisation et de positionnement, le multimédia, ...etc, ainsi que le développement d'interfaces utilisateur traditionnelles.

3.2.5. Google colab



Colaboratory [53], souvent raccourci en "Colab", est un produit de Google Research. Colab permet à n'importe qui d'écrire et d'exécuter le code Python de son choix par le biais du navigateur. C'est un environnement particulièrement adapté au machine learning, à l'analyse de données et à l'éducation. En termes plus techniques, Colab est un service hébergé de notebooks Jupyter [54] qui ne nécessite aucune configuration et permet d'accéder sans frais à des ressources informatiques, dont des GPU.

4. Le dataset utilisé

Le cancer du sein est la forme la plus répandue de cancer chez les femmes, et le carcinome canalaire invasif (IDC)[55] en est la forme la plus courante. L'identification et la catégorisation précises des sous-types de cancer du sein sont des tâches cliniques importantes, et l'utilisation de méthodes automatisées peut permettre de gagner du temps et de réduire les erreurs.

Le carcinome canalaire infiltrant en anglais Invasive Ductal Carcinoma (IDC) [55] est le sous-type le plus courant de tous les cancers du sein. Afin d'évaluer l'agressivité d'un échantillon de tissu complet, les pathologistes se concentrent généralement sur les régions contenant le IDC. Ainsi, une des étapes couramment réalisées lors du prétraitement pour l'évaluation automatisée de l'agressivité consiste à délimiter précisément les régions de IDC à l'intérieur de l'échantillon complet .

- Le dataset Breast Cancer Dataset [56] utilisé dans cette recherche est une base de données open source accessible au public sur le web. Cette base de données se compose de 162 images de diapositives entières de spécimens de cancer du sein (BCa) numérisées à 40x. À partir de cela, 277 524 patches de taille 50 x 50 ont été extraits, dont 198 738 IDC négatifs et 78 786 IDC positifs. Le nom de fichier de chaque patch est au format : u_xX_yY_classC.png, où u est l'ID du patient (10253_idx5), X est la coordonnée x d'où ce patch a été recadré, Y est la coordonnée y d'où ce patch a été recadré, et C indique la classe où 0 est non-IDC et 1 est IDC. Le tableau ci-dessous résume les caractéristiques de ce dataset utilisé pour l'entraînement et la recherche des hyperparamètres optimaux du réseau de convolution. (voir table 3.1)

Caractéristiques du dataset	Valeurs
Nombre d'images	162
Taille des images	50 x 50
Nombre de patches	277 524
Nombre de patches IDC positifs	78 786
Nombre de patches IDC négatifs	198 738

Table 1.1: Caractéristique du dataset

Ce dataset est largement utilisé dans la recherche sur les réseaux de neurones convolutifs pour la classification et la détection de tumeurs du sein, y compris le carcinome canalaire invasif (IDC), qui est la forme la plus courante de cancer du sein. Les réseaux de neurones convolutifs ont montré des performances élevées dans la classification des images de tumeurs du sein, ce qui peut aider les pathologistes à identifier et à catégoriser précisément les sous-types de cancer du sein. Cela peut conduire à des traitements plus efficaces et à de meilleurs résultats pour les patients.

La figure 3.2 et 3.3 illustrent des exemples extraits du dataset de la classe bénigne et maligne respectivement.



Figure 3.2: Exemple de la classe bénigne



Figure 3.3 : Exemple de la classe maligne

- En raison de la contrainte de manque d'espace mémoire dans Google Colab (12.7 Gb), on a dû travailler avec une base de données plus petite. La table 2 résume les caractéristiques de le sous dataset ; nous l'avons pris pour l'entraînement et la recherche des hyperparamètres optimaux de notre réseau de convolution. (voir figure 3.2)

Class/caractéristique	Size(pixel)	Total
Bénigne	50*50	54048
Maligne	50*50	30000

Table 3.2: Caractéristique du sous dataset

5. Les étapes de réalisation du système :

- La réalisation de notre travail englobe trois phases principales : préparation des images d'entraînement, sélection des valeurs des hyper paramètres des réseaux de convolution à

l'aide de la bibliothèque Keras, et développement d'une application desktop avec PyQt5 pour prédire la classe d'une image. (voir figure 3.4)

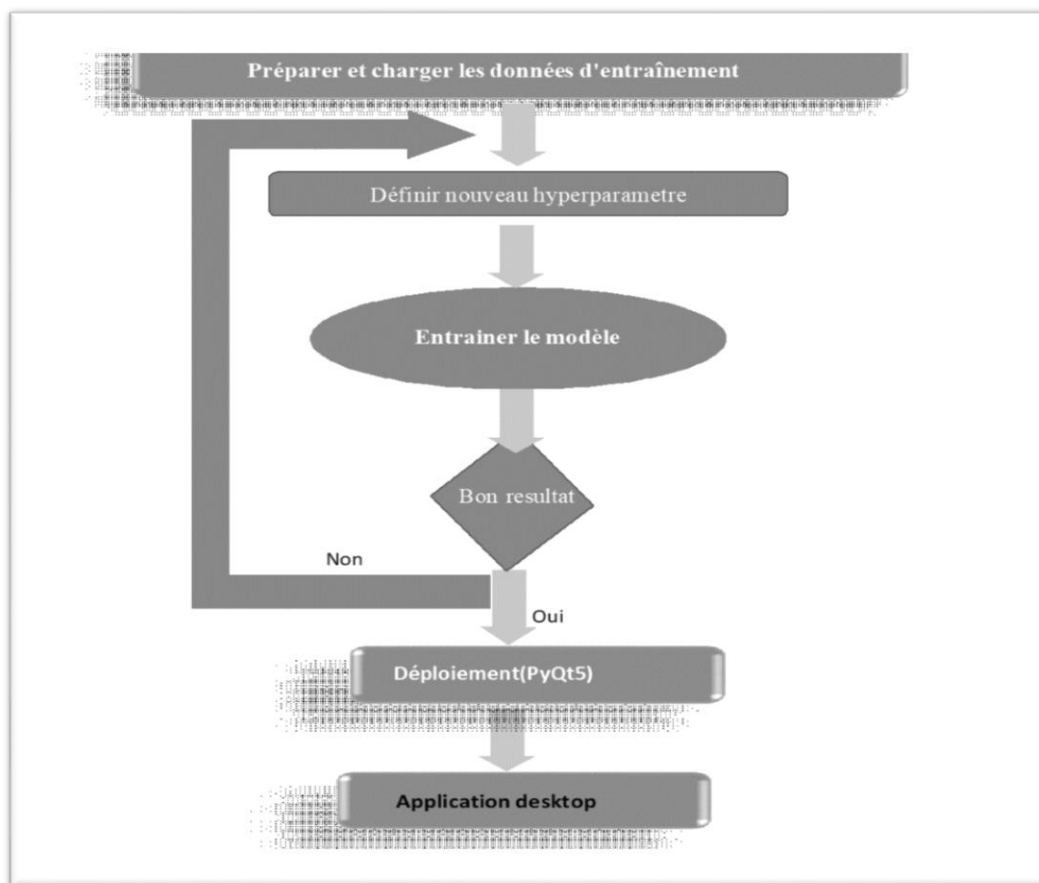


Figure 3.4: Les étapes de réalisation du système

Les trois phases principales de réalisation de notre travail sont les suivantes :

1. **Préparation des images d'entraînement** : Dans cette première étape, nous nous chargeons de préparer les images qui seront utilisées pour l'entraînement de notre modèle. Voici les principales étapes du processus :
 - a. **Chargement et division des données** : L'ensemble de données, généralement composé d'images et de leurs étiquettes correspondantes, est chargé. Ensuite, l'ensemble de données est divisé en ensembles d'entraînement, de validation et de test. L'ensemble d'entraînement est utilisé pour entraîner le modèle, l'ensemble de validation permet de régler les hyperparamètres et de surveiller les performances du modèle, et l'ensemble de test est utilisé pour l'évaluation finale [57].
 - b. **Redimensionnement et mise à l'échelle des images** : Toutes les images sont redimensionnées pour avoir une taille cohérente correspondant à la taille d'entrée du

modèle CNN (Convolutional Neural Network). Cette étape garantit que toutes les images ont les mêmes dimensions. De plus, les valeurs des pixels des images sont remises à l'échelle dans une plage spécifique, comme $[0, 1]$ ou $[-1, 1]$. La remise à l'échelle des valeurs de pixel aide à normaliser les données et facilite l'apprentissage du modèle [57].

- c. **Regroupement et brassage des données** : Les données sont préparées pour un entraînement efficace en créant des lots d'échantillons. Le traitement par lot consiste à regrouper plusieurs échantillons, ce qui réduit le nombre de mises à jour de poids par itération. De plus, les données sont mélangées au sein de chaque époque pour introduire un caractère aléatoire et éviter tout biais dans le processus d'entraînement [57]
- d. **Normalisation des données** : Les données d'entrée sont normalisées pour avoir une moyenne nulle et une variance unitaire, généralement sur une base par canal. La normalisation aide à stabiliser le processus d'apprentissage et à garantir que le modèle n'est pas sensible à l'échelle des valeurs d'entrée [57].

Ces étapes de préparation des données sont essentielles pour obtenir de bons résultats lors de la classification automatique. Elles permettent de rendre les images d'apprentissage adaptées à l'entraînement du modèle et de faciliter le processus d'apprentissage en normalisant les données, en les redimensionnant et en les regroupant de manière appropriée [57].

2. Sélection des valeurs des hyperparamètres des réseaux de convolution à l'aide de la bibliothèque Keras : Dans cette deuxième étape, nous utilisons la bibliothèque Keras pour sélectionner les valeurs des hyperparamètres des réseaux de convolution pour chaque expérimentation. Keras est une bibliothèque très intuitive de Deep Learning en Python. Nous pouvons utiliser les couches de convolution fournies par Keras, telles que la classe Conv2D [58]. La classe Conv2D permet de créer une couche de convolution 2D qui utilise des filtres pour traiter les entrées et produire une sortie de tenseur [59]. Nous ajustons les valeurs des hyperparamètres tels que le nombre de filtres, la taille du noyau, les pas de déplacement (strides), le type de padding, etc., en fonction des besoins de notre expérimentation. Pour effectuer une recherche systématique des hyperparamètres optimaux, nous pouvons utiliser des techniques telles que la recherche en grille (grid search) ou le réglage d'hyperparamètres (hyperparameter tuning). Ces techniques nous permettent d'explorer différentes combinaisons d'hyperparamètres pour trouver celles qui donnent les meilleures performances de notre modèle.

Pour initialiser le mécanisme de recherche en utilisant l'API Keras, nous devons fournir l'hypermodèle, l'objectif à optimiser et le nombre d'essais à spécifier via le paramètre correspondant (voir tableau 3.3).

	Hyperparamètre	Hyper1	Hyper2	Hyper3	Hyper4
Convolution N°1	Nombre de filtres	16	16	16	16
	Taille du masque	3*3	3*3	3*3	3*3
	Fonction d'activation	Relu	Relu	Relu	Relu
Convolution N°2	Nombre de filtres	32	32	32	32
	Taille du masque	3*3	3*3	3*3	3*3
	Fonction d'activation	Relu	relu	relu	Relu
Convolution N°3	Nombre de filtres	64	64	64	64
	Taille du masque	3*3	3*3	3*3	3*3
	Fonction d'activation	Relu	relu	relu	Relu
Couche caché 01	Nombre de neurones	256	512	/	128
	Fonction d'activation	Relu	relu	/	Relu
Couche caché 02	Nombre de neurones	64	256	256	/
	Fonction d'activation	Relu	relu	sigmoid	/
Couche caché 03	Nombre de neurones		128	128	/
	Fonction d'activation		Relu	sigmoid	/
Couche caché 04	Nombre de neurones		32	32	/
	Fonction d'activation		relu	sigmoid	/
Couche de Sortie	Nombre de neurones	2	1	1	2
	Fonction d'activation	Softmax	sigmoid	sigmoid	Softmax

Table 3.3: Les hyper paramètre proposés

- Nous allons procéder à l'entraînement dans google colab avec les hyperparamètre proposés auparavant, les résultats obtenus sont les suivants : (voir table 3.4, 3.5, 3.6, 3.7)

Optimazer	Adam	Adam	Adam
Fonction d'erreur	sparse_categorical_crossentropy	sparse_categorical_crossentropy	sparse_categorical_crossentropy
Taux d'apprentiss	0.001	0.0001	0.00001
Nbr etération	100	100	100
Accuracy	0.8625	0.8788	0.8342
Taux d'erreur	0.3555	0.3339	0.3982
Val-accuracy	0.8474	0.8641	0.8342
Val-erreur	0.3939	0.3542	0.3972
Regularisatio n L1	0.3/0.1	0.3/0.1	0.3/0.1
Regularisatio n L2	1.5/1.5	1.5/1.5	1/1
Temp d'execution	1564	1638	1578

Table 3.4: Résultat avec hyper1

Optimazer	Adam	Adam	Adam
Fonction d'erreur	binary_crossentropy	binary_crossentropy	binary_crossentropy
Taux d'apprentiss	0.001	0.0001	0.00001
Nbr etération	50	50	100
Accuracy	0.8262	0.8106	0.8095
Taux d'erreur	0.5159	0.4703	0.4707
Val-accuracy	0.8410	0.8137	0.8169
Val-erreur	0.5012	0.4495	0.4580
Regularisation L1	0.5/0.4/0.3/0.3	0.5/0.4/0.3/0.3	0.5/0.4/0.3/0.3
Regularisation L2	0.5/0.5/0.5/0.5	1/1/1/1	0.5/0.5/0.5/0.5
Temp d'execution	864	835	1590

Table 3.5: Résultat avec hyper2

Optimazer	Adam	Adam	Adam
Fonction d'erreur	binary_crossentropy	binary_crossentropy	binary_crossentropy
Taux d'apprentiss	0.00005	0.00001	0.0001
Nbr etération	50	50	50
Accuracy	0.9612	0.8341	0.9835
Taux d'erreur	0.1051	0.3840	0.0464
Val-accuracy	0.8274	0.8282	0.8210
Val-erreur	0.5783	0.3916	0.7372
Regularisation L1	0.4,0.3,0.2	0.4,0.3,0.2	/
Regularisation L2	////////	////	/
Temp d'execution	756	742	779

Table 3.6 Résultat avec hyper 3

Optimazer	Adam	Adam	adam
Fonction d'erreur	sparse_categorical_crossentropy	sparse_categorical_crossentropy	sparse_categorical_crossentropy
Taux d'apprentiss	0.0005	0.001	0.0001
Nbr etération	60	50	80
Accuracy	0.8886	87	0.9046
Taux d'erreur	0.2817	0.3031	0.2617
Val-accuracy	0.8588	0.85	0.8473
Val-erreur	0.3513	0.3533	0.3896
Regularisation L1	////	////	/
Regularisation L2	1	0.2	1
Temp d'execution	934	687	1167

Table 3.7 Résultat avec hyper 4

- Après l'exécution du processus de recherche des hyperparamètres (trouver les valeurs optimales des hyperparamètres en minimisant une fonction de perte sur un ensemble de données de test), les meilleurs résultats obtenus des expérimentations est la configuration des hyperparametre hyper 1 avec un taux d'apprentissage 0.0001. (voir figure 3.5)

La figure présente l'architecture du modèle.

```

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
conv2d (Conv2D)             (None, 50, 50, 16)         448
max_pooling2d (MaxPooling2D) (None, 25, 25, 16)         0
conv2d_1 (Conv2D)           (None, 25, 25, 32)         4640
max_pooling2d_1 (MaxPooling2D) (None, 12, 12, 32)         0
conv2d_2 (Conv2D)           (None, 12, 12, 64)         18496
max_pooling2d_2 (MaxPooling2D) (None, 6, 6, 64)          0
flatten (Flatten)           (None, 2304)                0
dense (Dense)                (None, 256)                 590080
dropout (Dropout)           (None, 256)                 0
dense_1 (Dense)              (None, 64)                  16448
dropout_1 (Dropout)         (None, 64)                  0
dense_2 (Dense)              (None, 2)                   130
-----
Total params: 630,242
Trainable params: 630,242
Non-trainable params: 0

```

Figure 3.5: La meilleure configuration du réseau proposée pour l'entraînement

- 3. Développement d'une application desktop avec PyQt5 pour prédire la classe d'une image :** Dans cette troisième et dernière étape, nous développons une application desktop à l'aide de la bibliothèque PyQt5, ce qui permet le déploiement de l'application. Cette application comprend une interface graphique qui permet de sélectionner une image, puis de prédire sa classe à l'aide du modèle entraîné (voir figure 3.6). PyQt5 est une bibliothèque populaire pour le développement d'interfaces graphiques en Python, et elle offre des fonctionnalités permettant de créer des fenêtres, des boutons, des boîtes de dialogue, etc., pour interagir avec l'utilisateur.

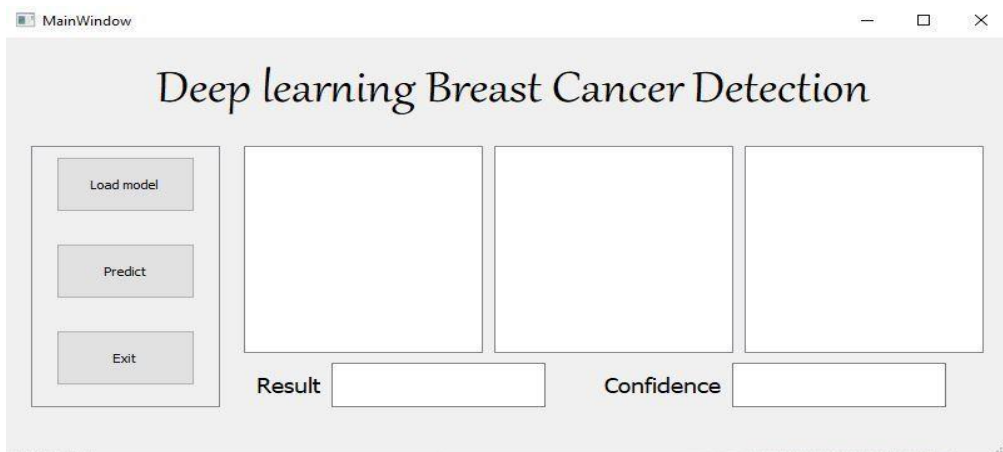


Figure 3.6 Interface graphique principale de notre application

Cette interface graphique permet de :

- Charger les images,
- Prédire la classe du cancer après entrainement du réseau,
- Afficher le résultat de la classification. (voir figure 3.7)

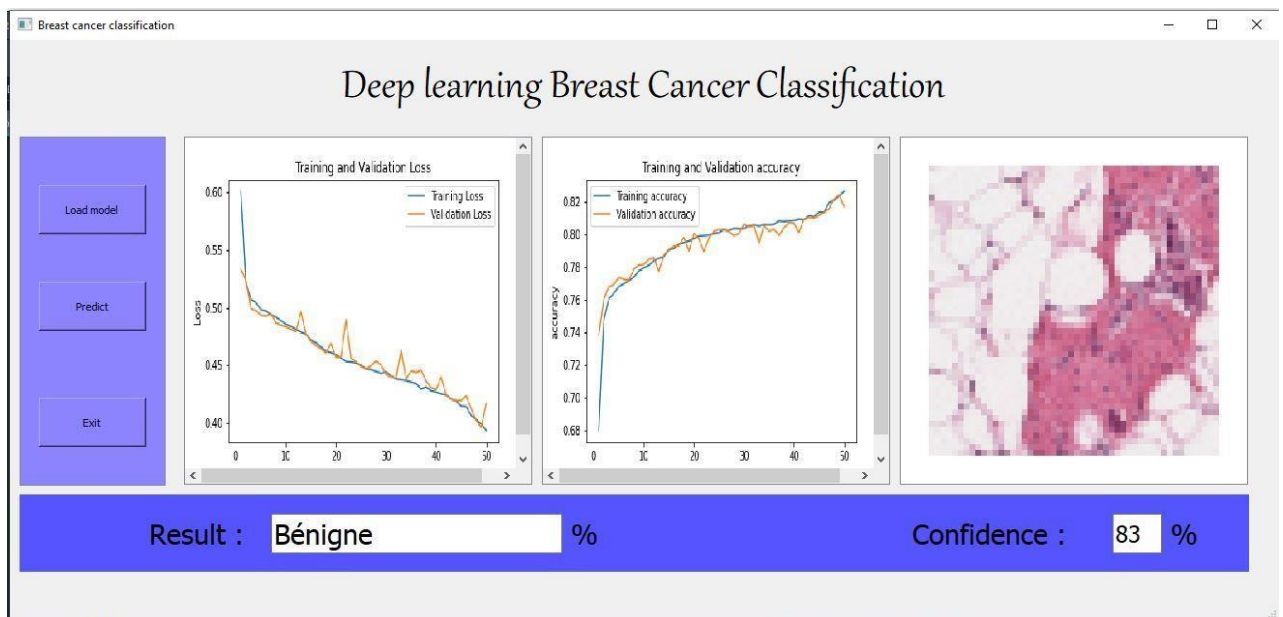


Figure 3.7: interface graphique principale de notre application d'affichage de résultats

- **Le bouton Load model** : permet de charger un modèle préalablement entraîné et l'utiliser pour prédire de nouvelles images. Après le chargement, les performances du modèle seront affichées dans les zones spécifiques.
- **Le bouton Prédicat** : permet de sélectionner une nouvelle image et de prédire sa classe. Le résultat de la prédiction sera affiché dans la zone Résultat, tandis que la confiance associée à la prédiction sera affichée dans la zone Confiance.

6. Évaluation de la performance

Pour évaluer les performances de notre système de classification d'images d'histopathologie mammaire (bénignes/malignes), il est nécessaire de mesurer la performance de la classification binaire.

La performance du modèle est évaluée à l'aide de quatre mesures largement répandues: la spécificité, la sensibilité, la précision et le taux de faux négatifs : La spécificité, la sensibilité, la précision et le taux de faux négatifs.

- **Spécificité** : Cet indicateur mesure la capacité d'un modèle à identifier correctement les négatifs, c'est-à-dire la proportion de négatifs réels qui sont correctement identifiés comme négatifs.

$$\text{Spécificité} = \text{vrai négatif} / (\text{vrai négatif} + \text{faux positif})$$

$$\text{Spécificité} = 4912 / (4912 + 1254) = 79.6\%$$

- **Sensibilité** : Cet indicateur mesure la capacité d'un modèle à identifier correctement les positifs, c'est-à-dire la proportion de positifs réels qui sont correctement identifiés comme positifs.

$$\text{Sensibilité} = \text{vrai positif} / (\text{vrai positif} + \text{faux négatif})$$

$$\text{La sensibilité} = 9653 / (9653 + 990) = 90.7\%$$

- **Précision** : Cet indicateur mesure la fréquence à laquelle le modèle prédit le bon résultat, c'est-à-dire la proportion de prédictions correctes, qu'il s'agisse de vrais positifs ou de vrais négatifs. (voir table 3.8)

$$\text{Précision} = (\text{vrai positif} + \text{vrai négatif}) / (\text{vrai positif} + \text{vrai négatif} + \text{faux positif} + \text{faux négatif})$$

$$\text{Précision} = (9653 + 4912) / (4912 + 9653 + 1254 + 990) = 86.6\%$$

- **Taux de faux négatifs** : Cet indicateur mesure la proportion de positifs réels qui sont classés à tort comme négatifs.

$$\text{Taux de faux négatifs} = \text{faux négatifs} / (\text{vrais positifs} + \text{faux négatifs})$$

$$\text{F1-score} = 2 * \text{précision} * \text{rappel} / (\text{précision} + \text{rappel})$$

$$\text{F1-score} = 2 * 0.866 * 0.907 / (0.866 + 0.907) = 88.5\%$$

Modèle	Spécificité (%)	Sensibilité (%)	Précision (%)	Faux négatif (%)
Notre modèle	79.6	90.7	86.60	35

Table 3.8: Évaluation de la performance du modèle

Les résultats démontrent que ce modèle présente une valeur élevée de précision et de sensibilité pour la détection des IDC positif, ce qui est remarquable compte tenu de la taille de notre base de données et des exigences des réseaux de neurones à convolution.

Ces résultats indiquent que le modèle a atteint une précision de 86.6%, ce qui signifie qu'il est capable de classer correctement 86.6% des exemples de test. Le rappel de 90.7% indique que le modèle a réussi à identifier 90.7% des exemples positifs réels. La mesure de 88.5% est une mesure combinée de la précision et du rappel qui donne une idée globale des performances du modèle.

Le taux d'erreur de 35% indique la proportion d'exemples mal classés par rapport au total des exemples. En d'autres termes, le modèle a commis des erreurs dans 35% des prédictions.

Le temps d'entraînement était de 27.3 minutes, ce qui peut varier en fonction de la taille du jeu de données et de la complexité du modèle. Le nombre total d'itérations était de 100, ce qui indique combien de fois le modèle a été mis à jour pendant l'entraînement. Il est important de noter que ces résultats sont spécifiques à l'entraînement effectué avec les hyperparamètres donnés. Les résultats peuvent varier en fonction des données, des hyperparamètres et d'autres facteurs. Nous avons également calculé la matrice de confusion en utilisant le sous dataset. La matrice de

confusion présentée dans le Tableau met en évidence la relation entre les différents indices de performance pour la classification des tissus mammaires.

Matrice de confusion		Classé	
		Positive (Bénigne)	Négative (Maligne)
Les donnée réelles	Positive (bénigne, IDC-)	Vrai positive (VP) 9653	Faux positive (FP) 1254
	Négative (maligne, IDC +)	Faux négative (FN) 990	Vrai négative (VN) 4912

Table 3.9: La matrice de confusion

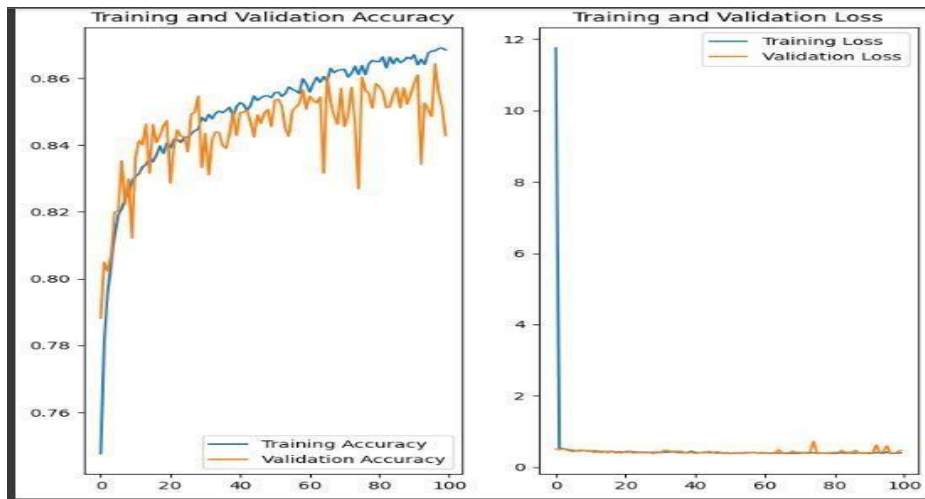


Figure 3.8: Évolution de l'apprentissage et l'erreur sur 100 itérations

La Figure 3.8 représente l'évolution du taux de reconnaissance et l'erreur sur la base d'apprentissage et de validation sur les 100 itérations.

Le modèle proposé est une approche prometteuse pour détecter le cancer du sein avec précision. Cependant, il présente quelques limites à savoir :

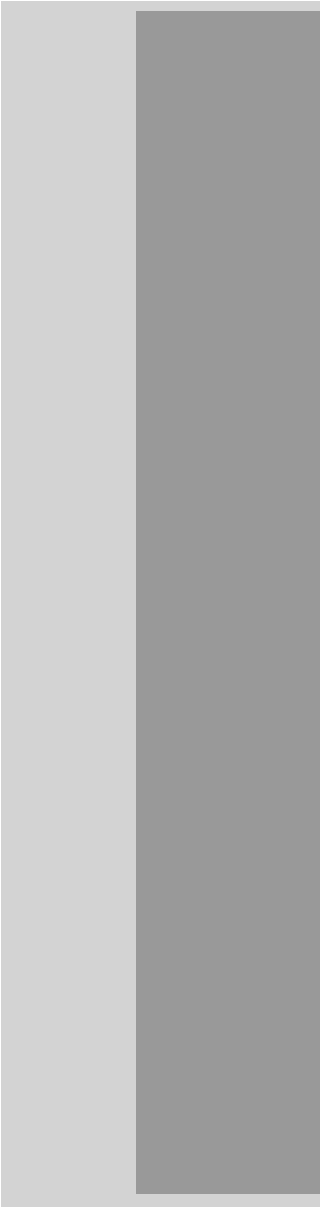
Premièrement, le modèle est limité par la taille de l'ensemble de données utilisé pour l'apprentissage ; plus l'ensemble de données est important, les images sont mieux classées.

Deuxièmement, le modèle est limité par les ressources informatiques disponibles ; il est très

gourmand en ressources informatiques et nécessite un matériel puissant pour classer les images.

7. Conclusion :

En conclusion, ce chapitre a présenté une approche complète pour la conception et la réalisation d'un système de détection du cancer du sein. Nous avons utilisé le langage Python, TensorFlow et PyQt5 pour mettre en œuvre l'architecture du système et réaliser une interface utilisateur conviviale. Les résultats obtenus sur le jeu de données "BreastCancer" démontrent le potentiel de cette approche pour aider à la détection précoce et précise du cancer du sein.



Conclusion Générale

Conclusion générale

La détection du cancer du sein à l'aide de l'apprentissage en profondeur (deep learning) est un sujet important dans le domaine de la recherche médicale.

Les systèmes d'aide à la décision pour le diagnostic du cancer sont devenus des outils essentiels dans le domaine médical, offrant un soutien précieux aux professionnels de la santé pour leurs décisions cliniques. Notre système vise à améliorer les capacités diagnostiques en fournissant une méthode rapide et précise pour détecter les tumeurs malignes et bénignes, contribuant ainsi à améliorer les chances de guérison grâce à un traitement précoce.

Notre mémoire a présenté la conception et la réalisation d'un système de détection du cancer du sein basé sur un modèle de réseau de neurones convolutifs (CNN). Les réseaux de neurones convolutifs (CNN) basés sur le deep learning ont montré une grande efficacité dans la détection de cette maladie ainsi ce système offre un moyen prometteur d'aider au diagnostic précoce de cette maladie grave en analysant les images médicales de mammographies et d'IRM du sein.

Les CNN sont particulièrement adaptés à la tâche de détection de cancer de sein, car ils sont capables d'apprendre des caractéristiques visuelles complexes à partir d'images histologiques du sein. Ces réseaux peuvent extraire automatiquement des informations pertinentes à partir des images et les utiliser pour prédire la présence de tumeurs cancéreuses.

Nous avons utilisé le langage Python, TensorFlow et PyQt5 pour mettre en œuvre l'architecture du système et réaliser une interface utilisateur conviviale. Les résultats obtenus sur le jeu de données "Breast Cancer Dataset" démontrent le potentiel de cette approche pour aider à la détection précoce et précise du cancer du sein.

L'importance du taux de cancer en Algérie et de sa véracité ne peut être sous-estimée, et il est crucial de disposer de systèmes de détection fiables et efficaces pour diagnostiquer la maladie avec précision. Notre système, bien qu'initialement développé en utilisant des données internationales, pourrait être adapté et validé pour une utilisation en Algérie, permettant ainsi aux professionnels de la santé de bénéficier d'un outil supplémentaire pour diagnostiquer le cancer du sein plus précisément et à un stade précoce.

Cependant, il est important de noter que l'adaptation de notre système aux spécificités du contexte algérien nécessiterait des études supplémentaires. Ces études devraient prendre en compte les variations dans les pratiques médicales, les ressources disponibles et les caractéristiques de la population algérienne. De telles enquêtes permettraient d'évaluer la

performance et l'adaptabilité du système, assurant ainsi sa pertinence et son utilité pour la population locale.

En résumé, notre mémoire représente une contribution significative dans le domaine de la détection du cancer du sein en proposant un système basé sur un modèle CNN. Ce système offre un potentiel considérable pour améliorer les capacités diagnostiques des professionnels de la santé et faciliter la prise de décisions éclairées. Nous encourageons donc la poursuite des recherches et des études pour adapter et valider ce système en tenant compte des caractéristiques spécifiques de l'Algérie, afin d'apporter une contribution concrète à la lutte contre le cancer du sein dans le pays. Cependant, il est important de noter que ces modèles doivent être validés cliniquement avant d'être utilisés en pratique médicale. Il est essentiel de travailler en collaboration avec des experts médicaux pour garantir la sécurité et l'efficacité de ces modèles.

Références bibliographiques

- [1] H. Rochefort, « Cancérogenèse hormonale chez la femme : des mécanismes à la prévention », *C. R. Biol.*, vol. 331, n° 2, p. 104-113, févr. 2008, doi: 10.1016/j.crvi.2006.07.009.
- [2] L. D. D. Communal, « Influence des hormones stéroïdes et potentiel préventif d'un antiprogestatif, l'ulpristal acétate, dans la tumorigenèse liée à la mutation du gène BRCA1 », 2011.
- [3] Gorins, A., & Denis, C., « Effets de la progestérone et des progestatifs sur la glande mammaire.. » 1995.
- [4] H. Bonsang-Kitzis, « Caractérisation moléculaire et immunité des cancers du sein triple-négatifs », Thèse de doctorat, Université Paris-Saclay (ComUE), 2018. Consulté le: 14 juin 2023. [En ligne]. Disponible sur: <https://www.theses.fr/2018SACLS162>
- [5] G. Schaller, « Composition destinée à la prévention et au traitement de maladies tumorales.]. » 2015.
- [6] Mahbouli, S. ., « Etude de l'impact de la leptine sur le statut oxydatif et inflammatoire du tissu mammaire : approche expérimentale in vitro et in vivo - Mise en oeuvre de la technique de détection par fluorescence native. » 2015.
- [7] (Malhotra et al., 2010.
- [8] Nakamura, Y., Katagiri, T., & Nakatsuru, S., « Methode de diagnostic du cancer du sein ». 2004.
- [9] Dabladji, R., « Classification du cancer du sein par des approches basées sur les systèmes immunitaires artificiels. »
- [10] Lamy, J., Sekar, B.D., Guézennec, G., Bouaud, J., & Séroussi, B., « Intelligence artificielle explicable pour le cancer du sein : Une approche visuelle de raisonnement à partir de cas. European Grid Conference. »
- [11] Heisey, R., & Carroll, J.C., « Identification et prise en charge des femmes ayant des antécédents familiaux de cancer du sein Guide pratique à l'intention des médecins. *Canadian Family Physician*, 62. »
- [12] Bao, H., Sun, X., Zhang, Y., Pang, B., Li, H., Zhou, L., Wu, F., Cao, D., Wang, J., Turic, B., & Wang, L., « The artificial intelligence-assisted cytology diagnostic system in large-scale cervical cancer screening: A population-based cohort study of 0.7 million women. *Cancer Medicine*, 9(18), 6896-6906. <https://doi.org/10.1002/cam4.3296> ». 2020.
- [13] Polyakova, M., & Krylov, V.N., « Data normalization methods to improve the quality of classification in the breast cancer diagnostic system. *Applied Aspects of Information Technology*. »
- [14] S, R., V. A., S., Kapoor, S., & J, N., « Deep Learning based Breast Cancer Diagnostic System using Medical Images. *Journal of Innovative Image Processing* ». 2023.
- [15] 4 Meldo, A.A., Utkin, L.V., Lukashin, A.A., Mulukha, V., & Zaborovsky, V.S., . « Database Acquisition for the Lung Cancer Computer Aided Diagnostic Systems. 2019 25th Conference of Open Innovations Association (FRUCT), 220-227. » 2019.

- [16] Meldo, A.A., Utkin, L.V., Lukashin, A.A., Mulukha, V., & Zaborovsky, V.S., . « Database Acquisition for the Lung Cancer Computer Aided Diagnostic Systems. 2019 25th Conference of Open Innovations Association (FRUCT), 220-227.] »:
- [17] Janghel, R.R., Shukla, A., Tiwari, R., & Kala, R., « Breast cancer diagnostic system using Symbiotic Adaptive Neuro-evolution (SANE). 2010 International Conference of Soft Computing and Pattern Recognition, 326-329. » 2010.
- [18] A. M. Turing, « Computing Machinery and Intelligence », in *Parsing the Turing Test: Philosophical and Methodological Issues in the Quest for the Thinking Computer*, R. Epstein, G. Roberts, et G. Beber, Éd., Dordrecht: Springer Netherlands, 2009, p. 23-65. doi: 10.1007/978-1-4020-6710-5_3.
- [19] C. Manning, « Computational Linguistics and Deep Learning », *Comput. Linguist.*, vol. 41, p. 699-705, sept. 2015, doi: 10.1162/COLI_a_00239.
- [20] Shu-Hsien Liao, « Expert system methodologies and applications – a decade review from 1995 to 2004 », *Expert Syst. Appl.*, vol. 28, n° 1, p. 93-103, janv. 2005, doi: 10.1016/j.eswa.2004.08.003.
- [21] *L'Intelligence Artificielle ou L'enjeu du siècle - Eric Sadin - Librairie Eyrolles*. Consulté le: 15 juin 2023. [En ligne]. Disponible sur: <https://www.eyrolles.com/Sciences/Livre/l-intelligence-artificielle-ou-l-enjeu-du-siecle-9782373090505/>
- [22] C. Thibout, « L'intelligence artificielle, une géopolitique des fantasmes », *Etudes Digit.*, vol. 5, n° 1, 2019, doi: 10.15122/isbn.978-2-406-09290-2.p.0105.
- [23] J.-B. Mateu et J.-J. Pluchart, « L'économie de l'intelligence artificielle », *Rev. Déconomie Financ.*, vol. 135, n° 3, p. 257-272, 2019, doi: 10.3917/ecofi.135.0257.
- [24] L. A. Wehenkel, *Automatic Learning Techniques in Power Systems*. Boston, MA: Springer US, 1998. doi: 10.1007/978-1-4615-5451-6.
- [25] A. Cornuéjols, L. Miclet, et V. Barra, *Apprentissage artificiel: Deep learning, concepts et algorithmes*. Eyrolles, 2018.
- [26] P. Shinde et S. Shah, « A review of machine learning and deep learning applications. In 2018 Fourth international conference on computing communication control and automation (ICCUBEA) ». IEEE, 2018.
- [27] E. Charniak, *Introduction au deep learning*. Dunod, 2021.
- [28] T. Masini et D. d'ingénieur de Polytech Nancy, « Etude des performances en généralisation des réseaux de neurones profonds. » 2021.
- [29] L. Vanni, M. Corneli, D. Longrée, D. Mayaffre, et F. Precioso, « Hyperdeep: deep learning descriptif pour l'analyse de données textuelles », 2020.
- [30] N. Granger, « Deep-learning for high dimensional sequential observations: application to continuous gesture recognition. (Modélisation par réseaux de neurones profonds pour l'apprentissage continu d'objets et de gestes par un robot). » 2019.

- [31] R. Neelapu, G. Lavanya Devi, et K. Srinivasa Rao, « Deep learning based conventional neural network architecture for medical image classification », *Trait. Signal*, vol. 35, n° 2, p. 169-182, juin 2018, doi: 10.3166/ts.35.169-182.
- [32] R. M. Turner, C. Loftin, A. Revello, L. R. Kline, M. A. Lewis, et S. Y. Sekeh, « Context-Dependent Deep Learning », *Modélisation Util. Contexte*, vol. 4, n° Special Issue, 2021, doi: 10.21494/ISTE.OP.2021.0690.
- [33] H. B. Braiek, « Towards Debugging and Testing Deep Learning Systems », 2019.
- [34] C. TOUZET, *Conscience, intelligence, libre-arbitre ? : Les réponses de la Théorie neuronale de la Cognition - Tome 1*. Editions la Machotte, 2010.
- [35] G. Laura et Y. A, « Algorithme de descente du gradient stochastique ». 2015.
- [36] I. K. M. Jais, A. R. Ismail, et S. Q. Nisa, « Adam Optimization Algorithm for Wide and Deep Neural Network », *Knowl. Eng. Data Sci.*, vol. 2, n° 1, p. 41, juin 2019, doi: 10.17977/um018v2i12019p41-46.
- [37] N. Zhang, D. Lei, et J. F. Zhao, « An Improved Adagrad Gradient Descent Optimization Algorithm », in *2018 Chinese Automation Congress (CAC)*, nov. 2018, p. 2359-2362. doi: 10.1109/CAC.2018.8623271.
- [38] Технология, « Réseau de Neurones Artificiels ». 2010.
- [39] B. Hakim et B. Sarouer, « Classification des images avec les réseaux de neurones convolutionnels. », Thèse de doctorat, Université Mouloud Mammeri, 2018.
- [40] S. Bédard-Ve, « MÉMO IRE PRÉSE TÉ COMME EXIGE CE PARTIELLE DE LA MAÎTRISE EN MATHÉMATIQUES », 2018.
- [41] B. Asadi et Q. A. Memon, « Layered Deep learning for Improved Breast Cancer Detection », in *2022 International Symposium on Intelligent Signal Processing and Communication Systems (ISPACS)*, nov. 2022, p. 1-4. doi: 10.1109/ISPACS57703.2022.10082840.
- [42] M. Naderan, « Review methods for breast cancer detection using artificial intelligence and deep learning methods. » *System research and information technologies* 1, 2021.
- [43] M. S. Iqbal, W. Ahmad, R. Alizadehsani, S. Hussain, et R. Rehman, « Breast Cancer Dataset, Classification and Detection Using Deep Learning », *Healthcare*, vol. 10, n° 12, Art. n° 12, déc. 2022, doi: 10.3390/healthcare10122395.
- [44] S. Asare, F. You, et O. Tettey, « Efficient, Ultra-facile Breast Cancer Histopathological Images Classification Approach Utilizing Deep Learning Optimizers », *Int. J. Comput. Appl.*, vol. 177, p. 1-9, févr. 2020, doi: 10.5120/ijca2020919875.
- [45] M. A. S. A. Husaini, M. H. Habaebi, S. A. Hameed, Md. R. Islam, et T. S. Gunawan, « A Systematic Review of Breast Cancer Detection Using Thermography and Neural Networks », *IEEE Access*, vol. 8, p. 208922-208937, 2020, doi: 10.1109/ACCESS.2020.3038817.
- [46] S. S. M. Khairi *et al.*, « Deep Learning on Histopathology Images for Breast Cancer Classification: A Bibliometric Analysis », *Healthcare*, vol. 10, n° 1, Art. n° 1, janv. 2022, doi: 10.3390/healthcare10010010.

- [47] Thanaki, J., « Python natural language processing. Packt Publishing Ltd ». 2017.
- [48] Oliphant, T. E., « A guide to NumPy (Vol. 1, p. 85). USA: Trelgol Publishing ». 2006.
- [49] Snider, L. A., & Swedo, S. E., « PANDAS: current status and directions for research. *Molecular psychiatry*, 9(10), 900-907 ». 2004.
- [50] Developers, T., « TensorFlow. Zenodo ». 2022.
- [51] Ketkar, N., & Ketkar, N., « Introduction to keras. *Deep learning with python: a hands-on introduction*, 97-111 ». 2017.
- [52] Fitzpatrick, M., « Create GUI Applications with Python & Qt5 (PyQt5 Edition): The hands-on guide to making apps with Python. Martin Fitzpatrick ». 2020.
- [53] Bisong, E., & Bisong, E., « Google colaboratory. *Building machine learning and deep learning models on google cloud platform: a comprehensive guide for beginners*, 59-64 ». 2019.
- [54] Kluyver, T., Ragan-Kelley, B., Pérez, F., Granger, B. E., Bussonnier, M., Frederic, J., ... & Willing, C., « Jupyter Notebooks-a publishing format for reproducible computational workflows (Vol. 2016, pp. 87-90) ». 2016.
- [55] Hennequin, C., Barillot, I., Azria, D., Belkacémi, Y., Bollet, M., Chauvet, B., ... & Mahé, M. A., « Radiothérapie du cancer du sein. *Cancer/Radiothérapie*, 20, S139-S146 ». 2016.
- [56] « <https://www.kaggle.com/datasets/yasserh/breast-cancer-dataset> ».
- [57] « <https://learn.microsoft.com/fr-fr/azure/purview/concept-best-practices-classification> ».
- [58] « <https://pyimagesearch.com/2021/05/31/hyperparameter-tuning-for-deep-learning-with-scikit-learn-keras-and-tensorflow/> ».
- [59] « https://www.tensorflow.org/tutorials/keras/keras_tuner ».