

République Algérienne Démocratique et Populaire
Universit Abou Bakr Belkaid– Tlemcen
Faculté des Sciences
Département d'Informatique

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

Option : Modèle intelligent et de décision (MID)

Thème

Apprentissage profond pour une classification histopathologique précise dans le cancer du sein

Réalisé par :

- GHENNANI Hind Selma
- GHENNANI Nihel Loubna

Présenté le 27 Juin 2024 devant la commission composée de MM.

- Président : - CHOUITI Sidi Mohammed
- Encadrant: - BENAZZOUZ Mourtada
- Examinatrice: - AMGHAR Djazia

Année universitaire: 2023-2024

Remerciement

Nous tenons tout d'abord à remercier Dieu le tout puissant, nous rendons grâce pour nous avoir donné santé, patience, volonté et surtout raison.

Nos vifs remerciements vont également aux membres du jury pour l'intérêt qu'ils ont porté à notre recherche en acceptant d'examiner notre travail et de l'enrichir par leurs propositions.

Nous tenons à remercier infiniment nos chers parents pour leur contribution, leur soutien et leur patience tout au long de nos études. Nous exprimons également notre profonde gratitude à tous ceux qui ont contribué, de près ou de loin, à l'élaboration de ce mémoire de fin d'étude en particulier le professeur Benazzouz que nous remercions pour ses conseils et ses orientations.



Dédicace

Nous dédions ce modeste travail à nos parents, symboles de tendresse. Que Dieu les protège et les garde.

À notre chère sœur Wassila et son mari Samir, ainsi qu'à notre nièce Alaa et notre neveu Youcef.

À la mémoire de nos grands-parents et de nos oncles, Bouziane et Mohammed. Le destin ne nous a pas laissé le temps de partager ce bonheur ensemble. Puisse Dieu, le Tout-Puissant, leur accorder sa clémence, sa miséricorde et les accueillir dans son saint paradis.

A mama Téma, Grand-Mère maternelle symbole du respect et d'amour. Que ce modeste travail, soit l'expression des vœux que vous n'avez cessé de formuler dans vos prières. Que Dieu vous préserve santé et longue vie.

À nos chers frères et sœurs, qui sont ce que nous avons de plus cher et qui ont toujours été là pour nous.

À notre famille et à tous nos amis qui nous ont aidés et accompagnés notamment Abdelkader Sahraoui, nous dédions ce modeste travail qui résumera un long, riche et instructif cursus.

Nihel et Hind

Dédicace

Je tiens à exprimer ma reconnaissance à mes beaux-parents, Sahraoui Abdelkader et Ould Kaddour Nacera, pour leur soutien constant et leur amour. Que Dieu veille sur eux et les protège.

À mon très cher mari SAHRAOUI Youcef, je tiens à te remercier du fond du cœur pour ton soutien, ta patience et ton encouragement. Merci pour tout et merci d'être toujours à mes côtés.

À mon binôme, ma très chère sœur Nihel, à qui je souhaite beaucoup de joie et de bonheur.

Hind Selma

Table des matières

Remerciement.....	2
Dédicace	3
Liste des figures.....	8
Liste des tableaux.....	10
Liste des abréviations.....	11
Introduction Générale.....	13
I. Chapitre I : Cancer du sein et classification.....	16
I.1 Introduction	16
I.2 Définitions des concepts	16
I.2.1 Cancer.....	16
I.2.2 Cancer du sein	16
I.3 Anatomie et Physiologie du sein	17
I.3.1 Disposition des principaux ganglions lymphatiques axillaires	17
I.3.2 Approvisionnement vasculaire.....	18
I.4 Images Histopathologiques du Cancer du Sein.....	19
I.4.1 L'examen histologique	19
I.4.2 Collecte d'échantillons histopathologiques	19
I.4.3 Préparation des échantillons.....	20
I.5 Classification histopathologique du cancer du sein.....	21
I.5.1 Carcinome Canalaire Infiltrant (CCI).....	21
I.5.2 Carcinome Lobulaire Infiltrant (CLI)	22
I.6 Classification moléculaire.....	23
I.6.1 Le cancer du sein LUMINAL A OU B	24
I.6.2 Le cancer du sein HER2+	24
I.7 Traitements du cancer du sein.....	24
I.8 Quel traitement en cas de cancer du sein métastatique ?	24
I.9 Conclusion	25
II. CHAPITRE II : Apprentissage profond.....	27
II.1 Introduction	27
II.2 Apprentissage automatique.....	27
II.3 Apprentissage profond.....	27

II.3.1	Définition	27
II.3.1	Historique	28
II.3.2	Domaines d'application de l'apprentissage profond dans le cancer du sein	29
II.4	Les réseaux de neurones	30
II.4.1	Neurone biologique	30
II.4.2	Neurone formel	31
II.5	Architecture des réseaux de neurones artificiels	31
II.6	Les fonctions d'activations	32
II.6.1	Fonction d'activation linéaire	32
II.6.2	Fonction d'activation sigmoïde	33
II.6.3	Fonction d'activation ReLU	33
II.7	Les réseaux de neurones convolutifs (CNN)	34
II.7.1	Définition	34
II.7.2	Les couches de CNN	35
II.7.2.1	Couche de Convolution (Convo + ReLU)	35
II.7.2.2	Couche de pooling	36
II.7.2.3	Couche entièrement Connectée	36
II.7.3	Les différentes architectures du CNN	36
II.7.3.1	Inception-V3	37
II.7.3.2	ResNet-50	37
II.7.3.3	Inception-Resnet-V2	38
II.7.3.4	Xception (Extreme Inception)	39
II.7.3.5	Mobilenet-V1	39
II.8	Conclusion	40
III.	Chapitre III : Expérimentations, résultats et discussions	43
III.1	Introduction	43
III.2	Outils Utilisés	43
III.2.1	Les bibliothèques et le Framework Utilisés	43
III.2.2	Langage de programmation de haut niveau	45
III.2.3	Les clouds	46
	• Kaggle notebook	46
	• Google Colab	46

III.3	Ensemble de données d'images : Présentation et Caractéristiques	47
III.4	La validation croisée k-fold	50
III.5	Workflow du travail proposé	50
a.	Collection de Données	51
b.	Prétraitement des Données	51
c.	Traitement de données	55
III.6	Modèles CNN Utilisés dans l'Étude Comparative.....	58
III.7	Discussion des Résultats Obtenus	58
•	Modèle ResNet50.....	59
•	Modèle inceptionv3	60
•	Modèle inceptionresnetV2.....	60
•	Modèle Xception	61
•	Modèle MobilenetV1	61
III.8	Résultats de prédiction sur l'ensemble de test.....	61
III.9	Comparaison entre les performances de modèles	62
III.10	Déploiement de l'Application Web	63
III.11	Conclusion	65
RÉFÉRENCES BIBLIOGRAPHIQUES		68
Résumé.....		73
Abstract		73
ملخص.....		73

Liste des figures

Figure I.1:Disposition des principaux ganglions lymphatiques axillaires	17
Figure I.2:Approvisionnement vasculaire du sein	19
Figure I.3:Types de tissus mammaires basés sur la coloration à l'H&E	21
Figure I.4:Carcinome canalaire infiltrant de grade III.	22
Figure I.5:Carcinome lobulaire infiltrant.	23
Figure II.1:Apprentissage Profond une partie de l'apprentissage	28
Figure II.2:Application de l'apprentissage profond dans le cancer du sein.....	29
Figure II.3:Représentation d'un neurone biologique	30
Figure II.4:Structure générale d'un neurone formel	31
Figure II.5:Réseau de neurones comportant deux couches cachées	31
Figure II.6:Graph de la fonction d'activation linéaire.....	33
Figure II.7: Graph de la fonction d'activation Sigmoidé.....	33
Figure II.8: Graph de la fonction d'activation ReLU.	34
Figure II.9:Modèle d'architecture de CNN	34
Figure II.10:Exemple d'opération de convolution.	35
Figure II.11:Les trois types d'opérations de pooling.....	36
Figure II.12:L'évolution des réseaux de neurones convolutifs.....	37
Figure II.13:Architecture Inception-V3	37
Figure II.14: L'architecture du ResNet50	38
Figure II.15:Architecture InceptionResNetV2.....	39
Figure II.16:Structure du module Xception	39
Figure II.17: Architecture MobileNet-V1.....	40
Figure III.1:Le logo de Python	46
Figure III.2:Interface de notebook Kaggle.....	46
Figure III.3:Interface de notebook Google Colab.....	47
Figure III.4 : Répartition des tumeurs en tumeurs bénignes et malignes.....	48
Figure III.5:Sous-types de tumeurs bénignes.....	48
Figure III.6 Sous-types de tumeurs malignes.....	49
Figure III.7:Analyse de la répartition des données d'entraînement et de test par pli.....	50
Figure III.8:Workflow du travail proposé.....	51
Figure III.9 : BreakHis sur Kaggle	51
Figure III.10: Valeurs Manquantes.....	52
Figure III.11:Aperçu de CleanVision	52
Figure III.12: Détection des problèmes avec CleanVision	53
Figure III.13: Rapport après suppression de problèmes	54
Figure III.14:Application d'une inversion horizontale et une inversion verticale.....	54
Figure III.15:Aperçu d'apprentissage par transfert.....	55
Figure III.16:Comment fonctionne l'apprentissage par transfert.....	56
Figure III.17:Taux de VP par rapport aux FP au niveau de différents seuils.....	57
Figure III.18:AUC (aire sous la courbe ROC)	58

Figure III.19: Courbes du processus d'entraînement du CNN pour le modèle ResNet50.	59
Figure III.20: Courbes du processus d'entraînement du CNN pour le modèle InceptionV3. ...	60
Figure III.21: Courbes du processus d'entraînement du CNN pour le modèle InceptionResNetV2.....	60
Figure III.22: Courbes du processus d'entraînement du CNN pour le modèle Xception.	61
Figure III.23: Courbes du processus d'entraînement du CNN pour le modèle MobileNetV1. .	61
Figure III.24: Comparaison des indicateurs d'évaluation pour les modèles CNN.....	62
Figure III.25: La première interface de l'application.	64
Figure III.26: La deuxième interface de l'application.	64
Figure III.27: La troisième interface de l'application.	64
Figure III.28: La quatrième interface de l'application.	65
Figure III.29: La cinquième interface de l'application.	65

Liste des tableaux

Tableau I-1: Artères mammaires et leurs zones de vascularisation	19
Tableau I-2: Types de biopsies du sein	20
Tableau I-3: Options de traitement pour le cancer du sein : un aperçu	24
Tableau II-1: Historique d'apprentissage profond	29
Tableau III-1: Les bibliothèques et le Framework utilisées	45
Tableau III-2: Répartition des images par facteurs de grossissement et classe	47
Tableau III-3: Distribution des images bénignes par facteur de	49
Tableau III-4: Distribution des images malignes par facteur de	50
Tableau III-5: Aperçu des 5 modèles Utilisés	58
Tableau III-6: Résultats de prédiction pour les modèles CNN	62

Liste des abréviations

OMS : Organisation Mondiale de la Santé

CCI : Carcinome Canalaire Infiltrant

CLI : Carcinome lobulaire Infiltrant

SAI : Sans Autre Indication

TNS : Type Non Spécifique

HER : récepteur 2 du facteur de croissance épidermique humain

IA : Intelligence Artificielle

TDM : Tomodensitométrie

IRM : Imagerie par Résonance Magnétique

CADx: Computer Aided Diagnostic

ML: Machine Learning

DL: Deep Learning

ReLU: Rectified Linear Unit

CNN : Réseau de Neurones à Convolution

GAP: Global Average Pooling

FC: Fully Connected

ResNet: Residual Network

ILSVRC: ImageNet Large Scale Visual Recognition Challenge

DC: Deeper Convolutional layer

HC: Higher-level Convolutional layer

UC: Ultimate Convolutional layer

VC: Very deep Convolutional layer

TN : Vrai Négatif

FP : Faux Positif

FN : Faux Négatif

TP : Vrai Positif

ROC: Receiver Operating Characteristic

GPU: Graphics Processing Unit

TPU: Tensor Processing Unit

TPR: The true positive Rate

AUC: Area Under the ROC Curve

TVP : Taux Vrai Positif

PPV : Positive Predictive Value

A : Adenosis

F : Fibroadenoma

TA :Tubular Adenoma

PT : Phyllodes Tumor

DC : Ductal Carcinoma

LC : Lobular Carcinoma

MC : Mucinous Carcinoma

PC : Papillary Carcinoma

Introduction Générale

L'intelligence artificielle (IA) transforme rapidement le paysage de la médecine moderne, apportant des innovations dans diverses disciplines, y compris la radiologie, la pathologie et la génomique. Les algorithmes d'apprentissage profond, en particulier les réseaux neuronaux convolutifs (CNN), ont démontré des capacités remarquables pour analyser des volumes massifs de données médicales et extraire des informations cliniquement pertinentes. Ces avancées offrent des perspectives significatives pour des maladies complexes telles que le cancer du sein.

Le cancer du sein demeure une priorité de santé publique en raison de son incidence élevée et de son impact considérable sur la vie des patientes. Touchant des millions de femmes à travers le monde chaque année, sa complexité réside dans sa variabilité histologique et moléculaire, ce qui nécessite une compréhension approfondie pour des prises de décision thérapeutiques optimales.

La détection précoce et le traitement approprié sont essentiels pour améliorer les taux de survie et la qualité de vie. Cependant, la nature hétérogène du cancer du sein pose des défis importants pour le diagnostic et la gestion de la maladie. La problématique principale réside dans la classification des images histopathologiques du cancer du sein, qui est confrontée à plusieurs défis majeurs comme la variabilité des sous- types histopathologiques et moléculaires qui nécessite des approches de traitement individualisées, rendant crucial le développement de techniques avancées pour une évaluation précise.

Le chapitre 1 vise à fournir un aperçu complet du cancer du sein, en mettant en lumière sa classification, ses traitements traditionnels et les avancées récentes dans le domaine de l'apprentissage profond pour une meilleure détection et prise en charge.

Nous débutons par une exploration des fondements du cancer du sein, en définissant ses concepts clés et en examinant son anatomie et sa physiologie. Comprendre la disposition des ganglions lymphatiques axillaires et l'approvisionnement vasculaire du sein est crucial pour évaluer la progression de la maladie et guider les interventions thérapeutiques. Ensuite, nous plongeons dans le monde des images histopathologiques du cancer du sein, en détaillant les processus d'examen, de collecte et de préparation des échantillons.

La classification histopathologique, notamment les sous-types tels que le carcinome canalaire infiltrant (CCI) et le carcinome lobulaire infiltrant (CLI), est essentielle pour évaluer le pronostic et orienter le traitement. Nous abordons également la classification moléculaire du cancer du sein, en mettant en évidence les sous-types moléculaires et leurs implications thérapeutiques.

Les traitements traditionnels, y compris la chirurgie, la chimiothérapie et l'hormonothérapie, sont discutés en détail, ainsi que les approches de traitement pour les cas de cancer du sein métastatique.

Dans le chapitre 2, nous explorerons les avancées de l'apprentissage profond, en mettant en évidence son application dans le domaine de la détection du cancer du sein. L'apprentissage profond, une sous-branche de l'intelligence artificielle (IA), utilise des réseaux de neurones artificiels pour modéliser des données complexes.

Les progrès récents dans ce domaine ont permis des avancées significatives dans de nombreux secteurs, notamment la reconnaissance d'image et la détection de maladies. Inspirés par la structure du cerveau humain, les réseaux de neurones apprennent à partir de grandes quantités de données et améliorent leur performance au fil du temps.

L'apprentissage profond trouve plusieurs applications cruciales dans le domaine du cancer du sein, notamment l'analyse d'imagerie médicale et la pathomique. Nous aborderons en détail l'architecture des réseaux neuronaux convolutifs (CNN) tels que ResNet50, Xception, InceptionV3, MobileNetV1 et InceptionResNetV2, et leurs techniques dans la détection et la classification des anomalies mammaires. Ce chapitre vise à fournir une compréhension approfondie des bases et des applications avancées de l'apprentissage profond dans la lutte contre le cancer du sein.

Enfin, le chapitre 3 vise à offrir une vue détaillée des méthodes expérimentales, des outils et des techniques utilisés, ainsi que des résultats obtenus, fournissant ainsi une compréhension complète des efforts déployés pour améliorer la détection du cancer du sein à travers l'apprentissage profond.

Nous discuterons également du déploiement des modèles, une étape essentielle pour rendre ces avancées accessibles et utilisables en milieu clinique. Le déploiement comprend la mise en production des modèles, leur intégration dans des systèmes existants, et la gestion continue de leur performance.

Enfin, la conclusion générale présente une synthèse de ce travail et les perspectives qui en découlent.

CHAPITRE I :

Cancer du sein et classification



I. Chapitre I : Cancer du sein et classification

I.1 Introduction

Selon l'Organisation mondiale de la santé (OMS) [1], le cancer du sein est le cancer le plus courant chez les femmes à l'échelle mondiale. Une femme sur trois atteintes en mourra. Plusieurs méthodes, dont la mammographie, l'imagerie par résonance magnétique (IRM) et les tests pathologiques, sont les modalités d'investigation actuelles du cancer du sein.

Parmi ces méthodes, les images histopathologiques sont considérées comme la référence pour améliorer la précision du diagnostic chez les patientes ayant déjà subi d'autres investigations telles que des mammographies [2]. Les images histopathologiques fournissent une visualisation détaillée des tissus biologiques, obtenue à partir d'échantillons prélevés lors de biopsies ou de chirurgies. Ces images permettent aux pathologistes d'observer minutieusement les caractéristiques microscopiques des cellules et des tissus, ce qui est crucial pour détecter et identifier les anomalies associées au cancer.

La classification précise des images histopathologiques joue donc un rôle primordial dans le processus de diagnostic, en permettant de distinguer les tissus sains des tissus cancéreux et en caractérisant la nature ainsi que la progression de la maladie.

Dans ce contexte, ce chapitre vise à explorer en profondeur le rôle critique des images histopathologiques dans le diagnostic du cancer du sein. Nous examinerons les défis techniques rencontrés lors de l'acquisition et de l'interprétation de ces images, ainsi que les stratégies potentielles pour les surmonter.

I.2 Définitions des concepts

I.2.1 Cancer

Ensemble de cellule indifférenciée qui, échappant au contrôle de l'organisme, se multiplie indéfiniment, envahissent les tissus voisins en les détruisant, et se répandent dans l'organisme en métastase (tumeur maligne) [10].

Le cancer peut atteindre tous les organes et tous les tissus. Quelle qu'en soit la localisation, la cellule cancéreuse présente des anomalies caractéristique, reconnaissable au microscope. Le tissu cancéreux a une structure anarchique profondément modifiée par rapport au tissu d'origine et il envahit les tissus voisins. Il se dissémine à distance par voie sanguine ou lymphatique (métastases) [10].

I.2.2 Cancer du sein

La notion de « cancer du sein » relève d'une nomenclature générique qui fait référence à tout un ensemble de prolifération néoplasique de la glande mammaire qui diffère tant du point de vue histologique qu'en ce qui concerne leur comportement évolutif [11]

Le terme de cancer du sein ne désigne que les tumeurs malignes potentiellement agressives du sein tandis que le terme de « tumeur du sein » design à la fois les tumeurs malignes et les tumeurs bénignes [11].

I.3 Anatomie et Physiologie du sein

I.3.1 Disposition des principaux ganglions lymphatiques axillaires

Il existe cinq groupes de ganglions lymphatiques axillaires, à savoir les ganglions lymphatiques latéraux (huméraux), antérieurs (pectoraux), postérieurs (subscapulaires), centraux et apicaux. Les ganglions lymphatiques apicaux constituent la voie finale commune pour tous les ganglions lymphatiques axillaires [3] comme représente la Figure I.1 ci-dessous




Figure I.1:Disposition des principaux ganglions lymphatiques axillaires [3].

Groupe latéral

- Quatre à six ganglions
- Postérieur et médial par rapport à la veine axillaire

Groupe antérieur (pectoral)

- Généralement quatre à cinq ganglions
- Le long de la bordure inférieure du muscle petit pectoral, adjacent aux vaisseaux thoraciques latéraux

Groupe postérieur (subscapulaire)

- Six à sept ganglions
- Le long des vaisseaux subscapulaires

Groupe central

- Trois ou quatre gros ganglions
- Dans le coussinet adipeux axillaire
- Reçoivent les lymphatiques efférents des trois premiers groupes de ganglions
- Se drainent dans les ganglions apicaux

Groupe apical

- Six à douze ganglions
- Postérieur et au-dessus du muscle petit pectoral, le long de l'aspect médial de la veine axillaire
- Reçoivent les efférents des autres groupes de ganglions lymphatiques, les lymphatiques longeant la veine céphalique, et certains drainages directs de la périphérie supérieure du sein [3].

I.3.2 Approvisionnement vasculaire

Le sein bénéficie d'un réseau sanguin riche, ce qui permet une division et une excision sécurisées des tissus mammaires, par exemple lors d'une chirurgie de réduction mammaire. Cependant, la viabilité du complexe aréolo-mamelonnaire dépend des vaisseaux sanguins qui traversent la glande, et qui doivent donc être préservés [4] ce qui est montré dans la Figure I.2 ci-dessous




Figure I.2: Approvisionnement vasculaire du sein [4].

Il existe trois principaux systèmes artériels :

Artère	Origine	Vascularisation
Artère thoracique interne (mammaire)	Artère sous-clavière	Moitié médiale du sein
Artère thoracique latérale	Artère axillaire	Quadrant supéro-externe du sein
Artères intercostales postérieures (branches antérieures)	Espaces intercostaux 3 à 6	Partie latérale du sein et peau surplombante

Tableau I-1: Artères mammaires et leurs zones de vascularisation [4].

I.4 Images Histopathologiques du Cancer du Sein

I.4.1 L'examen histologique

Le diagnostic de cancer du sein ne peut être confirmé que par l'examen histologique. Ce dernier est fait sur les tissus prélevés par ponction cytologique ou biopsie.

- ❖ Si la lésion est palpable : une ponction cytologique ou une biopsie peut être faite avec le repère de la palpation.
- ❖ Si la lésion est non palpable : la ponction ou la biopsie sera faite sous repérage soit par échographie, soit par mammographie.
- ❖ S'il s'agit de microcalcifications : la biopsie sera faite sous repérage mammographique (macro biopsie stéréotaxique) [5].

I.4.2 Collecte d'échantillons histopathologiques

La collecte d'échantillons histopathologiques est une étape essentielle dans le processus de diagnostic médical, permettant aux médecins de visualiser et d'analyser les

tissus prélevés pour identifier d'éventuelles anomalies, telles que des cellules cancéreuses ou des infections.

Une biopsie est une intervention lors de laquelle on prélève un échantillon de tissu ou de tumeur afin de l'examiner au microscope. La biopsie est employée pour diagnostiquer le cancer ou pour déterminer si une anomalie est cancéreuse ou non [6].

Cette collecte peut être réalisée à l'aide de différentes techniques de biopsie, chacune ayant ses propres spécificités. Voici une présentation détaillée des principales techniques de biopsie :

Type	Description	Avantages	Inconvénients
Aspiration cytologique	Utilise une mince aiguille pour aspirer du liquide ou des cellules provenant de la lésion suspecte	Rapide	Peut-être inconfortable
La biopsie à l'aiguille	Microbiopsie Utilise une aiguille pour prélever un petit échantillon de tissu sous échographie ou mammographie.	Rapide, ne nécessite pas d'hospitalisation	Peut ne pas fournir suffisamment d'informations pour un diagnostic définitif
	Macrobiopsie Utilise une aiguille plus large pour prélever un échantillon de tissu plus important sous mammographie.	Fournit plus d'informations qu'une microbiopsie	Plus longue que la microbiopsie, nécessite une anesthésie locale
Biopsie chirurgicale	Une biopsie peut être faite au bloc opératoire par un chirurgien sous anesthésie locale ou générale. Cela permet d'enlever toute la lésion suspecte palpée ou identifiée à la mammographie ou à l'échographie.	Permet de confirmer le diagnostic de cancer et de retirer la tumeur	Plus invasive que les autres types de biopsie, nécessite une anesthésie

Tableau I-2: Types de biopsies du sein [5].

I.4.3 Préparation des échantillons

Le diagnostic histopathologique est généralement considéré comme la "norme de référence" [7]. Les pathologistes observent les lésions tissulaires sous un microscope pour déterminer la zone cancéreuse et le degré de malignité en se basant sur la structure tissulaire, le noyau et le cytoplasme, ainsi que les motifs de croissance des cellules. Le tissu est généralement coloré pour faciliter l'analyse de ses différents composants sous le microscope. La coloration à l'hématoxyline et à l'éosine (H&E) est utilisée depuis plus d'un siècle [8]. La Figure I.3 montre des images de différents types de tissus mammaires colorés à l'H&E




Figure I.3: Types de tissus mammaires basés sur la coloration à l'H&E [9].

Le bleu indique les noyaux cellulaires dans les tissus excisés colorés à l'hématoxyline, tandis que d'autres structures (cytoplasme, matrice, etc.) sont colorées en rose avec l'éosine. Selon leurs comportements biologiques, les lésions mammaires peuvent être classées en lésions bénignes (Figure I.1(b)) et en lésions malignes (Figure I.1(c)(d)). Les lésions bénignes ont généralement une croissance lente et n'ont pas de motif de croissance invasif, tandis que les tumeurs malignes ont tendance à métastaser vers les ganglions lymphatiques et les organes distants [9].

I.5 Classification histopathologique du cancer du sein

La classification histopathologique du carcinome mammaire est généralement basée sur la diversité des caractéristiques morphologiques des tumeurs, comprenant 20 types de tumeurs majeurs et 18 sous-types mineurs [12].

Environ 70 à 80 % de tous les cancers du sein appartiennent à l'une des deux classes histopathologiques majeures, à savoir le carcinome canalaire infiltrant (CCI) et le carcinome lobulaire infiltrant (CLI) [13].

I.5.1 Carcinome Canalaire Infiltrant (CCI)

Le terme "carcinome canalaire infiltrant" (CCI) désigne les tumeurs du sein caractérisées par l'invasion des cellules cancéreuses dans les tissus adjacents comme les canaux mammaires ou les ganglions lymphatiques proches. Cette condition se manifeste généralement par la présence d'une masse ou d'un épaissement dans la glande mammaire [14].

L'adénocarcinome canalaire du sein peut être métastatique, ce qui signifie qu'il a la capacité de se propager à d'autres parties du corps et de causer des lésions secondaires à distance du site initial de la tumeur. En conséquence, des métastases peuvent se former dans diverses zones du corps humain [14].




Figure I.4: Carcinome canalaire infiltrant de grade III [65].

a : mammographie : masse ronde, de contour circonscrit.

b : histologie : prolifération carcinomateuse peu différenciée avec faible réaction stromale périphérique.

Le carcinome canalaire infiltrant peut se présenter sous différentes formes, en fonction des caractéristiques des cellules tumorales. Ces variations comprennent :

- Carcinome canalaire infiltrant papillaire
- Carcinome canalaire infiltrant médullaire
- Carcinome canalaire infiltrant mucineux
- Carcinome canalaire infiltrant tubulaire
- Carcinome canalaire infiltrant squameux
- Carcinome canalaire infiltrant sans autre indication (SAI)
- Carcinome canalaire infiltrant de type non spécifique (TNS)
- Carcinome canalaire infiltrant à prédominance intra canalaire

Chaque type présente des caractéristiques distinctes en termes de croissance et de comportement tumoral.

Les tumeurs papillaires, médullaires et mucineuses évoluent lentement, permettant souvent un diagnostic précoce avant toute extension aux ganglions lymphatiques. En revanche, les tumeurs squirrheuses progressent rapidement. Pour ce qui est du CCI tubulaire, il présente généralement un faible risque de récurrence de la maladie [14].

I.5.2 Carcinome Lobulaire Infiltrant (CLI)

Le carcinome lobulaire infiltrant (CLI) du sein représente 10 à 15% des cancers du sein [15], Il est classé comme le deuxième type le plus courant de cancer infiltrant du sein, comptant pour environ 8 % de tous les cancers infiltrants. Le CLI peut affecter plus fréquemment les deux seins [16].




Figure I.5: Carcinome lobulaire infiltrant [66].

a : mammographie : masse irrégulière de contour spiculé

b : histologie : longs spicules fibreux de richesse cellulaire variable (HES)

c : histologie : prolifération de cellules peu cohésives infiltrant la graisse et d

Le carcinome lobulaire infiltrant (CLI) se développe généralement selon un schéma linéaire dans le sein sans altérer les structures environnantes ni former de masse, ce qui le rend plus difficile à détecter que le carcinome canalaire infiltrant (CCI) à la mammographie et à l'échographie. Il est également plus difficile à visualiser dans sa forme métastatique. Souvent, le CLI n'est pas détecté lors des dépistages systématiques, ce qui entraîne une détection tardive et un diagnostic à un stade avancé, avec des tumeurs plus volumineuses lorsqu'elles sont finalement détectées et diagnostiquées [17].

I.6 Classification moléculaire

Les études sur les cancers du sein utilisant le profilage de l'expression génique ont identifié plusieurs grands sous-types de cancer du sein au-delà des types traditionnels positifs aux récepteurs hormonaux et négatifs aux récepteurs hormonaux. Les sous-types moléculaires les plus reproductibles parmi les cancers positifs aux récepteurs hormonaux sont les groupes luminal A et luminal B. Les groupes HER2 et basal-like sont les principaux sous-types moléculaires identifiés parmi les cancers du sein négatifs aux récepteurs hormonaux. D'autres sous-types moléculaires tels que les groupes luminal C et normal-like ont également été identifiés dans certaines études, mais ils sont moins bien caractérisés que les types luminal A, luminal B, HER2 et basal-like. Ces sous-types de

cancer du sein diffèrent par leurs schémas d'expression génique, leurs caractéristiques cliniques, leur réponse au traitement et leur pronostic [18].

I.6.1 Le cancer du sein LUMINAL A OU B

Ces tumeurs se développent à partir des cellules épithéliales des canaux et lobules du sein, représentant ainsi les cancers les plus courants, comptant pour environ 75 à 80 % des cas de cancer du sein. Elles expriment les récepteurs hormonaux à l'œstrogène et à la progestérone (RH+), ce qui les classe comme des cancers hormono-sensibles.

Les récepteurs hormonaux des cancers du type luminal A sont habituellement plus présents que dans le type luminal B. ils sont souvent caractérisés par un grade histologique plus faible que les cancers luminal B et sont associés à un pronostic moins sévère [19].

I.6.2 Le cancer du sein HER2+

Environ 15 % des tumeurs mammaires présentent une surexpression du récepteur HER2 (HER2+), ce qui conduit à une prolifération accrue des cellules cancéreuses [19].

I.7 Traitements du cancer du sein

Le traitement d'un cancer du sein localisé comprend en principe au minimum une chirurgie, généralement complétée parfois par un ou plusieurs traitements systémiques (chimiothérapie, hormonothérapie, immunothérapie, thérapies ciblées), et d'une radiothérapie [20]. Le tableau ci-dessus contient du détaille sur chaque traitement

Traitement	Description	Objectif	Bénéfice
Chirurgie	Ablation totale ou partielle du sein	Éliminer le cancer	Soigne le cancer du sein localisé
Chimiothérapie	Administration de médicaments par voie intraveineuse ou orale	Tuer les cellules cancéreuses résiduelles	Réduit le risque de récurrence de 5 à plus de 50%
Hormonothérapie	Blocage de la production d'hormones ou de leur action	Empêcher la prolifération des cellules cancéreuses	Réduit le risque de récurrence de 30 à 60%
Thérapies ciblées	Utilisation de médicaments qui attaquent spécifiquement les cellules cancéreuses	Attaquer les cellules cancéreuses en ciblant des anomalies spécifiques	Traitement efficace du cancer du sein HER2-positif
Radiothérapie	Utilisation de rayonnements ionisants pour tuer les cellules cancéreuses	Réduire le risque de récurrence locale et/ou régionale du cancer du sein	

Tableau I-3: Options de traitement pour le cancer du sein : un aperçu [20].

I.8 Quel traitement en cas de cancer du sein métastatique ?

Les métastases à distance surviennent lorsque des cellules tumorales du cancer du sein se propagent vers un autre organe que le sein et les ganglions lymphatiques adjacents. Elles sont souvent sensibles à de nombreux traitements. Néanmoins, sauf cas

exceptionnel, une guérison définitive ne peut pas être obtenue : la maladie passe dans une phase "chronique" avec des traitements au long cours. Le suivi sera plus rapproché, avec des examens réguliers visant à évaluer la tolérance et l'efficacité des traitements prescrits [20].

Les traitements sont nombreux et adaptés à chaque cas. Ils reposent sur des chimiothérapies, une hormonothérapie lorsque le cancer du sein a des caractéristiques de sensibilité potentielle, des thérapies ciblées (anticorps monoclonaux et conjugués, inhibiteurs du cycle cellulaire, inhibiteur d'une enzyme de réparation de l'ADN), la radiothérapie focalisée sur une lésion spécifique, la chirurgie dans des situations particulières en cas de métastases osseuses. Dans de nombreuses situations, des essais cliniques sont disponibles visant à proposer de nouveaux traitements alternatifs pour plus d'efficacité à long terme [20].

I.9 Conclusion


Le cancer du sein, le plus fréquent chez les femmes dans le monde, nécessite une classification précise pour orienter les décisions thérapeutiques et pronostiques. Les images histopathologiques sont essentielles pour identifier les caractéristiques microscopiques des cellules cancéreuses.

Les principaux types histopathologiques sont le carcinome canalaire infiltrant (CCI), représentant 70 à 80 % des cas, et le carcinome lobulaire infiltrant (CLI), représentant 10 à 15 % des cas. Le pronostic et le traitement dépendent du stade du cancer, des récepteurs hormonaux (œstrogène, progestérone, HER2), et des caractéristiques génétiques (mutations BRCA1 et BRCA2).

Les traitements incluent la chirurgie, la chimiothérapie, l'hormonothérapie, les thérapies ciblées et la radiothérapie. Les avancées en recherche et en intelligence artificielle promettent d'améliorer le diagnostic et le traitement.

CHAPITRE II :

Apprentissage profond



II. CHAPITRE II : Apprentissage profond

II.1 Introduction

L'apprentissage profond est une technologie qui tente d'imiter les secrets du fonctionnement neuronal du cerveau humain dans l'espoir qu'un jour il puisse le reproduire virtuellement et le transposer sur des machines qui deviendraient aussi intelligentes et autonomes que les humains. Cette technologie a permis aux scientifiques de faire des progrès considérables dans la reconnaissance et la classification des données [21].

L'apprentissage profond est une branche de l'intelligence artificielle. Il utilise des réseaux de neurones artificiels, constitués de plusieurs couches qui analysent les données de manière progressive, pour apprendre et accomplir des tâches complexes.

L'apprentissage profond a révolutionné de nombreux domaines, tels que la reconnaissance faciale, la traduction automatique, le traitement du langage naturel et la robotique. Il permet aux ordinateurs d'accomplir des tâches qui étaient autrefois considérées comme impossibles, et ouvre la voie à de nombreuses innovations futures.

II.2 Apprentissage automatique

L'apprentissage automatique, une sous-catégorie de l'intelligence artificielle (IA) qui entraîne les ordinateurs à penser comme les humains en apprenant et en s'appuyant sur des expériences antérieures. Il utilise une intervention humaine minimale pour analyser les données et repérer les tendances machine. L'apprentissage a un large éventail d'effets sur la société, notamment sur les chaînes de production, les soins de santé, l'éducation, les transports, et la nourriture [22].

II.3 Apprentissage profond

II.3.1 Définition

L'apprentissage profond « Deep Learning » est un ensemble de techniques d'apprentissage automatique qui a permis des avancées importantes en intelligence artificielle dans les dernières années. L'apprentissage profond est basé sur ce qui a été appelé, par analogie, des « réseaux de neurones artificiels », composés de milliers d'unités qui effectuent chacune de petites opérations simples. Les résultats d'une première couche de « neurones » servent d'entrée aux calculs d'une deuxième couche et ainsi de suite [23].

Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données (« big data ») [23].




Figure II.1: Apprentissage Profond une partie de l'apprentissage automatique et de l'IA

II.3.1 Historique

L'apprentissage profond a une histoire riche et variée, ponctuée par des événements significatifs qui ont façonné son développement. Depuis ses modestes débuts dans les années 1940 jusqu'à son triomphe au concours ImageNet en 2012, cette discipline a connu des avancées remarquables ainsi que des périodes de stagnation [24] comme le montre le tableau ci-dessous.

Année	Événement	Description
1943	Introduction du "neurone formel"	Warren McCulloch et Walter Pitts introduisent le concept de neurone binaire, simulant le cerveau humain.
1957	Développement du perceptron	Le perceptron élargit les horizons avec les "réseaux de neurones artificiels".
1960-1970	L'hiver de l'IA	Le développement des réseaux de neurones subit un ralentissement temporaire.
1980	Introduction du perceptron multicouche	Les réseaux de neurones connaissent un renouveau avec des architectures plus sophistiquées.
Années 80	Émergence du Deep Learning	Yann LeCun et ses réseaux de neurones convolutifs inspirent le deep learning, mais la puissance de calcul est un obstacle.

2012	Victoire du deep learning au concours ImageNet	Un programme utilisant le deep learning remporte le concours ImageNet, suscitant un regain d'intérêt.
------	--	---

Tableau II-1: Historique d'apprentissage profond [24].

II.3.2 Domaines d'application de l'apprentissage profond dans le cancer du sein

Le cancer du sein reste un problème de santé important à l'échelle mondiale, et l'apprentissage profond est devenu un outil précieux pour améliorer les résultats de la détection, du diagnostic et du traitement dans ce domaine. Nous explorons ici les applications spécifiques de l'apprentissage profond dans les soins de santé contre le cancer du sein :




Figure II.2: Application de l'apprentissage profond dans le cancer du sein.

- **Analyse d'imagerie médicale :**

L'apprentissage profond en général, mais particulièrement en imagerie médicale, nécessite un grand nombre de données d'entraînement afin d'obtenir une bonne performance et d'éviter le sur-apprentissage (en anglais overfitting). Pour répondre à ces enjeux, l'augmentation des données d'entraînement est une solution courante. Elle permet de rééquilibrer ou d'enrichir un jeu de données trop petit quelle qu'en soit la raison (annotations manuelles chronophages, manque de données accessibles dans le domaine de l'imagerie médicale...) [25].

Les techniques d'augmentation des données doivent être pertinentes par rapport au type d'analyse souhaitée et contribuer positivement aux performances du modèle lors de la phase d'apprentissage. Une augmentation excessive des données n'entraîne pas nécessairement une amélioration des performances. Il existe différentes transformations applicables aux images médicales obtenues par tomodensitométrie (TDM) ou par résonance magnétique (IRM). Ces transformations peuvent être appliquées à l'ensemble du jeu de données ou être sélectionnées avec certaines probabilités d'occurrence [25].

- **Diagnostic assisté par ordinateur (CADx) :**

Les applications principales du CADx impliquent la distinction entre les lésions malignes et bénignes, ainsi que l'identification de certaines maladies à partir d'une ou de plusieurs images. Traditionnellement, la plupart des systèmes CADx ont été développés pour utiliser des descripteurs conçus par des experts du domaine. En effet, un algorithme ML ou DL agit souvent comme un classifieur d'objets, comme les lésions dans les images médicales. La sélection des caractéristiques est une étape cruciale dans le traitement de l'image médicale, permettant de déterminer quels descripteurs sont pertinents pour le problème de classification. Cela contribue également à améliorer les taux de précision [26].

- **Radiomique :**

La radiomique, une forme d'analyse informatique des images médicales, vise à convertir les données d'imagerie en données quantitatives objectives à haute dimension. Cette approche permet de développer des biomarqueurs d'imagerie grâce à des techniques d'apprentissage automatique [27].

- **Pathomique :**

La pathomique implique l'analyse mathématique et informatique de données histopathologiques pour le diagnostic assisté par ordinateur, la prédiction des anomalies moléculaires, la caractérisation et l'identification des facteurs pronostiques, ainsi que l'évolution des maladies ou la réponse au traitement [28].

II.4 Les réseaux de neurones

II.4.1 Neurone biologique

Un neurone biologique est constitué d'un corps cellulaire contenant le noyau et la majorité des composants cellulaires complexes. Il possède également de multiples prolongements appelés dendrites et un long prolongement appelé axone. À l'extrémité de l'axone, celui-ci se divise en plusieurs ramifications appelées télodendrons, qui se terminent par de petites structures appelées synapses. Ces synapses sont directement reliées aux dendrites d'autres neurones ou directement au corps cellulaire [29].

La figure ci-dessous représente une illustration schématique d'un neurone biologique.




Figure II.3: Représentation d'un neurone biologique [29].

II.4.2 Neurone formel

Un neurone formel dit aussi artificiel est un modèle mathématique et informatique simplifié d'un neurone biologique. Il possède plusieurs entrées et une sortie. Il calcule la somme pondérée des signaux reçus en fonction des poids synaptiques, qui représentent la force des connexions entre les neurones. Cette somme est ensuite passée à une fonction d'activation non linéaire pour générer la sortie du neurone. L'apprentissage d'un réseau neuronal consiste à ajuster les poids synaptiques des neurones afin d'optimiser la performance du réseau et d'atteindre un objectif d'apprentissage [30]. La figure ci-dessous décrit la structure d'un neurone au sein d'un réseau neuronal artificiel.




Figure II.4: Structure générale d'un neurone formel

II.5 Architecture des réseaux de neurones artificiels

Comme illustré dans la figure ci-dessus, un réseau de neurones artificiels est composé de couches et de poids de connexion. Le fonctionnement du réseau est également influencé par les interactions entre les neurones [31].




Figure II.5: Réseau de neurones comportant deux couches cachées [31].

- ❖ **La couche d'entrée** : Recevant les données du programme pour le réseau à partir d'une source externe, cette couche ne comporte pas de fonctions d'activation et ne réalise pas de calculs.
- ❖ **La couche cachée** : Intermédiaire, cette couche reçoit les entrées des neurones précédents et les transmet aux neurones suivants. Elle effectue l'ensemble des calculs et extrait les caractéristiques des données. Il peut y avoir plusieurs couches cachées interconnectées.
- ❖ **La couche de sortie** : Joue un rôle crucial en fournissant les résultats du traitement effectué par les neurones. Elle prend en compte les entrées des couches cachées précédentes pour parvenir à une prédiction finale, basée sur les apprentissages du modèle [32].

Les réseaux de neurones se structurent avec une couche d'entrée unique, une ou plusieurs couches cachées, et une couche de sortie. Conformément à la Figure I.4, chaque entrée X_i est associée à un poids P_i . La fonction de combinaison calcule la somme des produits $X_i * P_i$, suivi de l'application d'une fonction d'activation pour obtenir la sortie Y [31].

$$y = \sigma \left(w_0 + \sum_{j=0}^p w_j x_j \right)$$

II.6 Les fonctions d'activations

Une fonction d'activation est une fonction mathématique utilisée sur un signal. Elle va reproduire le potentiel d'activation que l'on retrouve dans le domaine de la biologie du cerveau humain [33].

Les fonctions d'activation sont spécialement utilisées dans les réseaux neuronaux artificiels pour transformer un signal d'entrée en un signal de sortie qui est ensuite alimenté en tant qu'entrée à la couche suivante. Dans un réseau neuronal artificiel, nous calculons la somme des produits des entrées et de leurs poids correspondants, puis nous appliquons enfin une fonction d'activation pour obtenir la sortie de cette couche particulière et la fournir en tant qu'entrée à la couche suivante [34].

II.6.1 Fonction d'activation linéaire

La fonction d'activation linéaire est couramment utilisée en tant que couche de sortie pour les tâches de régression. Elle conserve les valeurs d'entrée telles quelles, ce qui signifie que les unités de sortie sont identiques à leurs entrées correspondantes. Son intervalle de sortie s'étend de moins l'infini à plus l'infini [33].




Figure II.6: Graph de la fonction d'activation linéaire.

II.6.2 Fonction d'activation sigmoïde

C'est la fonction d'activation la plus largement utilisée car c'est une fonction non linéaire. La fonction sigmoïde transforme les valeurs dans la plage de 0 à 1. Elle peut être définie comme suit :

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




Figure II.7: Graph de la fonction d'activation Sigmoïde.

II.6.3 Fonction d'activation ReLU

ReLU signifie "rectified linear unit" et est une fonction d'activation non linéaire largement utilisée dans les réseaux neuronaux. L'avantage principal de l'utilisation de la fonction ReLU est que tous les neurones ne sont pas activés en même temps. Cela signifie qu'un

neurone ne sera désactivé que lorsque la sortie de la transformation linéaire est nulle. [34]
Mathématiquement, elle peut être définie comme suit : $f(x) = \max(0, x)$

Les valeurs sont comprises entre 0 et $+\infty$




Figure II.8: Graph de la fonction d'activation ReLU.

II.7 Les réseaux de neurones convolutifs (CNN)

II.7.1 Définition

Le CNN, ou réseau de neurones à convolution, est une technique fondamentale du DL qui se compose de plusieurs couches. Chaque couche de convolution est appelée une carte de caractéristiques. Les CNN sont les algorithmes les plus populaires en DL, car ils apprennent directement à partir des données d'entrée sans nécessiter une extraction préalable des caractéristiques par des humains. Inspirée par le fonctionnement des neurones dans le cerveau humain et animal, la structure des CNN utilise un nombre réduit de paramètres, simplifiant ainsi le processus d'apprentissage et accélérant le réseau [31].




Figure II.9:Modèle d'architecture de CNN [36].

II.7.2 Les couches de CNN

II.7.2.1 Couche de Convolution (Convo + ReLU)

Une couche de convolution est un composant fondamental de l'architecture des CNN qui effectue l'extraction des caractéristiques. Cette opération consiste généralement en une combinaison d'opérations linéaires et non linéaires, c'est-à-dire une opération de convolution et une fonction d'activation [35].

La convolution est une opération linéaire qui applique un tableau de nombres appelé noyau à un tableau d'entrée appelé tenseur. À chaque emplacement du tenseur, un produit élément par élément entre chaque élément du noyau et du tenseur d'entrée est calculé, puis sommé pour obtenir la valeur de sortie dans la position correspondante du tenseur de sortie, appelée carte de caractéristiques. Ce processus est répété en appliquant plusieurs noyaux pour former un nombre variable de cartes de caractéristiques, représentant ainsi différentes caractéristiques des tenseurs d'entrée ; les différents noyaux agissent comme des extracteurs de caractéristiques distincts. Deux hyperparamètres clés définissent l'opération de convolution : la taille du noyau (3×3 , 5×5 ou 7×7) et le nombre de noyaux, qui déterminent la profondeur des cartes de caractéristiques de sortie. [35]

La figure ci-dessus illustre un exemple d'opération de convolution avec un noyau de taille 3×3 sans padding. Cette opération de convolution est effectuée avec un stride habituel de 1, où la distance entre deux positions consécutives du noyau est de 1.




Figure II.10: Exemple d'opération de convolution.

Le padding est une technique qui implique l'ajout de lignes et de colonnes de zéros de chaque côté du tenseur d'entrée. Son but est de permettre au centre d'un noyau de se positionner sur l'élément le plus extérieur du tenseur tout en maintenant les dimensions dans le plan constantes pendant toute l'opération de convolution.

Après la convolution, la sortie est ensuite soumise à une fonction d'activation non linéaire, avec ReLU étant la plus couramment utilisée actuellement [35].

II.7.2.2 Couche de pooling

La fonction principale de la couche de pooling est de réduire la taille des cartes de caractéristiques par sous-échantillonnage. Ce processus crée des cartes plus petites tout en préservant la majorité des informations dominantes à chaque étape. Les paramètres tels que la taille du filtre, le pas et le padding sont des hyperparamètres dans les opérations de pooling, similaires à ceux des opérations de convolution. Il existe plusieurs types de méthodes de pooling disponibles, notamment le pooling en arbre, le pooling en porte, le pooling moyen, le pooling minimum, le pooling maximum, le pooling moyen global (GAP) et le pooling maximum global. Les méthodes de pooling les plus familières et les plus couramment utilisées sont le pooling maximum, minimum et GAP [36]. La figure ci-dessous illustre ces trois opérations de pooling.




Figure II.11: Les trois types d'opérations de pooling.

II.7.2.3 Couche entièrement Connectée

À l'intérieur de cette couche, chaque neurone est connecté à tous les neurones de la couche précédente, suivant ainsi l'approche entièrement connectée (FC). Elle sert de classificateur CNN et adopte la méthode de base du réseau neuronal perceptron multicouche conventionnel, agissant comme un type de réseau neuronal à propagation avant. L'entrée de la couche FC provient de la dernière couche de pooling ou de convolution, sous forme de vecteur créé à partir des cartes de caractéristiques après aplatissage. La sortie de la couche FC représente la sortie finale du CNN [36].

II.7.3 Les différentes architectures du CNN

La figure ci-dessous illustre l'évolution des réseaux de neurones convolutifs (CNN) au fil du temps.




Figure II.12:L'évolution des réseaux de neurones convolutifs.

II.7.3.1 Inception-V3

Inception v3 est un modèle de reconnaissance d'image avec une précision supérieure à 78,1 % sur l'ensemble de données ImageNet. Il est le résultat de nombreuses contributions de chercheurs. Le modèle comprend des composants symétriques et asymétriques tels que des convolutions, des pooling moyen et maximal, des concaténations, des abandons et des couches entièrement connectées. La normalisation par lots est largement utilisée et appliquée aux entrées d'activation, avec une perte calculée à l'aide de Softmax [37].

La figure ci-dessous illustre la structure du réseau Inception-V3.




Figure II.13:Architecture Inception-V3 [38].

II.7.3.2 ResNet-50

ResNet50 est un modèle de réseau neuronal convolutif (CNN) développé par Microsoft Research en 2015 caractérisée par ses 50 couches en profondeur. ResNet50 est un puissant modèle de classification d'images qui peut être entraîné sur de grands ensembles de données et obtenir des résultats de pointe. Une de ses principales innovations est l'utilisation de connexions résiduelles, 42 qui permettent au réseau d'apprendre un ensemble de fonctions résiduelles qui cartographient l'entrée vers la sortie désirée. Ces connexions résiduelles permettent au réseau

d'apprendre des architectures beaucoup plus profondes qu'auparavant, sans souffrir du problème des gradients disparus.

L'architecture de ResNet50 comprend des couches convolutionnelles pour l'extraction des caractéristiques de l'image, suivies de blocs d'identité et de blocs convolutionnelles pour le traitement de ces cartes de caractéristiques. Les couches entièrement connectées sont ensuite utilisées pour la classification finale [39].




Figure II.14: L'architecture du ResNet50 [40].

ResNet50 utilise des connexions résiduelles pour faciliter l'apprentissage profond. Ces connexions permettent au réseau d'apprendre des fonctions résiduelles, ce qui est crucial pour maintenir un bon flux d'informations à travers les couches.

Les couches convolutionnelles sont suivies de couches de pooling pour réduire les dimensions spatiales des caractéristiques tout en préservant les informations importantes. Les blocs d'identité et de convolution jouent un rôle clé dans la création de cette architecture. Enfin, les couches entièrement connectées sont utilisées pour la classification finale, en utilisant une fonction d'activation Softmax pour obtenir les probabilités de classe [39].

II.7.3.3 Inception-Resnet-V2

Inception-Resnet-V2 est formulé sur la base d'une combinaison de la structure Inception et de la connexion résiduelle. Dans le bloc Inception-ResNet [41], des filtres de convolution de tailles multiples sont combinés par des connexions résiduelles. L'utilisation de connexions résiduelles évite non seulement le problème de dégradation causé par des structures profondes, mais réduit également le temps d'entraînement [42].

La figure ci-dessous illustre la structure du réseau InceptionResNetV2.




Figure II.15: Architecture InceptionResNetV2[43].

II.7.3.4 Xception (Extreme Inception)

François Chollet de Google [44] a proposé l'architecture extrême Inception nommée Xception, où les modules Inception ont été remplacés par des modules modifiés "depthwise separable convolutions." qui ont été proposé par Laurent Siphre en 2014 [45].

La figure ci-dessous illustre la structure du réseau Xception.




Figure II.16: Structure du module Xception [46].

L'architecture du réseau Xception est basée sur des couches de convolution séparables en profondeur modifiées. L'entrée doit passer par trois flux, c'est-à-dire le flux d'entrée, le flux moyen (qui se répète huit fois) et le flux de sortie. Chacune des couches de convolution et de convolution séparables est suivie d'une normalisation par lots. Le flux intermédiaire est la partie structurelle centrale du réseau Xception, comprenant une structure de neuf couches qui se répète huit fois. Chacune des neuf couches de la structure contient trois combinaisons de couches ReLU, Conv2D séparables et de normalisation par lots [46].

II.7.3.5 Mobilenet-V1

MobileNet est un modèle léger avec 4 253 864 paramètres. Il prend des images de taille 224x224x3 en entrée et utilise un bloc de convolution séparables en profondeur plutôt qu'un bloc de convolution standard pour extraire les caractéristiques [47].

La figure ci-dessous illustre la structure du réseau MobileNet-V1.




Figure II.17: Architecture MobileNet-V1[48].

La convolution en profondeur utilise un filtre pour chaque canal pendant la convolution. La convolution ponctuelle est une convolution 1x1. La convolution ponctuelle fusionne la sortie de la convolution en profondeur. La convolution séparable en profondeur contient un nombre plus petit de paramètres que la convolution standard traditionnelle. La convolution en profondeur est utilisée pour extraire les caractéristiques des images et la convolution ponctuelle est utilisée pour combiner les caractéristiques. Ces couches ont également une couche d'activation ReLU et une couche de normalisation par lots. Mais dans la convolution standard, le filtrage de l'image et la combinaison de la sortie sont effectués par une seule couche [49], ce qui est plus coûteux en termes de calcul. Ainsi, la convolution séparable en profondeur est plus efficace que la couche de convolution standard. [50]

II.8 Conclusion

L'apprentissage profond a révolutionné le domaine de l'intelligence artificielle, offrant des avancées significatives dans la reconnaissance d'images, la compréhension du langage naturel, et de nombreux autres domaines. En particulier, l'application de l'apprentissage profond dans la détection et le traitement du cancer du sein a montré un potentiel énorme pour améliorer les diagnostics et les traitements.

Les réseaux de neurones, inspirés des neurones biologiques, constituent la base de l'apprentissage profond. Avec des structures complexes et des fonctions d'activation sophistiquées, ces réseaux sont capables d'apprendre et de modéliser des relations complexes dans les données. Parmi les différentes architectures de réseaux de neurones, les réseaux de neurones convolutifs (CNN) se sont avérés particulièrement efficaces pour la reconnaissance d'images. Les CNN intègrent des couches de convolution, de pooling et entièrement connectées, chacune jouant un rôle crucial dans l'extraction des caractéristiques et la classification des images.

Les différentes architectures de CNN, telles que ResNet, Xception, Inception-Resnet-V2, Mobilenet-V1 et Inception-V3, ont poussé les limites de la performance en introduisant des innovations dans la conception des réseaux. En particulier, Inception-V3, avec sa combinaison

de convolutions symétriques et asymétriques et sa normalisation par lots, a démontré une précision impressionnante sur des ensembles de données complexes comme ImageNet.

L'impact de ces technologies est particulièrement pertinent dans le domaine médical, où des modèles comme InceptionResNetV2 sont utilisés pour l'analyse histopathologique des tissus mammaires, aidant ainsi à identifier les caractéristiques microscopiques des cellules cancéreuses. Cela permet aux professionnels de santé de prendre des décisions plus éclairées et de personnaliser les traitements pour chaque patient.

En conclusion, l'apprentissage profond et les réseaux de neurones convolutifs représentent des outils puissants dans la lutte contre le cancer du sein. Les avancées dans ces technologies continueront à améliorer les capacités de diagnostic et de traitement, offrant de nouvelles perspectives pour améliorer les résultats des patients. Pour rester à la pointe de ces développements, il est essentiel de suivre les recherches et les innovations dans ce domaine dynamique.

CHAPITRE III :

Expérimentations, résultats et discussions



III. Chapitre III : Expérimentations, résultats et discussions

III.1 Introduction

L'analyse histopathologique des images des biopsies est essentielle pour le diagnostic et le pronostic de la maladie. Cependant, ce processus manuel peut être fastidieux, subjectif et sujette à des erreurs. L'intelligence artificielle, et plus particulièrement l'apprentissage profond, offre une alternative prometteuse pour automatiser et améliorer la précision de cette tâche cruciale.

Dans ce chapitre, nous explorons l'application de cinq modèles d'apprentissage profond convolutifs (CNN) à la classification des images histopathologiques du cancer du sein. Ces modèles, ResNet50, InceptionV3, InceptionResNetV2, Xception et MobileNetV1, ont été évalués sur l'ensemble de données BreakHis, comprenant 7 909 images provenant de 82 patients. L'objectif est de déterminer le modèle le plus performant pour distinguer les images de tumeurs bénignes de celles de tumeurs malignes.

Ce chapitre contribue à l'avancement de la recherche dans le domaine de l'intelligence artificielle appliquée à la médecine, en particulier dans la lutte contre le cancer du sein. Les résultats présentés ouvrent la voie à l'exploration d'architectures de réseaux neuronaux et à l'intégration de ces modèles dans des systèmes d'aide à la décision clinique.

III.2 Outils Utilisés

III.2.1 Les bibliothèques et le Framework Utilisés

Il existe de nombreuses bibliothèques utilisées dans le domaine de l'apprentissage profond. Le tableau III-1 répertorie toutes les bibliothèques utilisées dans notre projet

Bibliothèques	Description	Logo
Keras	Une bibliothèque de haut niveau permettant de créer et de manipuler des réseaux de neurones. Elle est capable d'utiliser TensorFlow (des bibliothèques de bas niveau permettant de créer et de manipuler des réseaux de neurones). Son objectif est de permettre des expérimentations rapides modèles [51]	

Tensorflow	Tensorflow est un Framework de programmation pour le calcul numérique créé par Google et devenu un Framework Open Source en novembre 2015. Depuis, TensorFlow a continué à gagner une grande importance et popularité et rapidement devenu l'un des Frameworks les plus utilisés pour le Deep Learning. Son nom s'inspire notamment du fait que les opérations actuelles des réseaux de neurones s'effectuent principalement via une table multidimensionnelle de données, appelée Tenseurs qui est l'équivalent d'une matrice [52].	
Pandas	Pandas est une bibliothèque Python utilisée pour travailler avec des ensembles de données. Elle propose des fonctions pour analyser, nettoyer, explorer et manipuler des données. Le nom "Pandas" fait référence à la fois aux "données de panel" et à "l'analyse des données en Python" et a été créé par Wes McKinney en 2008 [53].	
CleanVision	CleanVision est une bibliothèque qui détecte automatiquement les problèmes potentiels dans les ensembles de données d'images, tels que les images floues, sous exposées, les doublons (presque) et autres. Ce package d'intelligence artificielle centré sur les données est une première étape rapide pour tout projet de vision par ordinateur afin de repérer les problèmes dans l'ensemble de données, que vous souhaitez traiter avant d'appliquer l'apprentissage automatique [54].	
Matplotlib	Matplotlib est une bibliothèque complète pour créer des visualisations statiques, animées et interactives en Python. Matplotlib rend les tâches simples faciles et les tâches complexes possibles [55].	
Seaborn	Seaborn est une bibliothèque de visualisation de données en Python basée sur matplotlib. Il offre une interface de haut niveau pour dessiner des graphiques statistiques attrayants et informatifs [56].	

NumPy	NumPy est le package fondamental pour le calcul scientifique en Python. C'est une bibliothèque Python qui fournit un objet de tableau multidimensionnel, divers objets dérivés et un assortiment de routines pour des opérations rapides sur les tableaux, comprenant des opérations mathématiques, logiques, de manipulation de forme, de tri, de sélection, de transformations de Fourier discrètes, d'algèbre linéaire et bien plus encore [57].	
PIL	La bibliothèque Python Imaging Library ajoute des capacités de traitement d'image à votre interpréteur Python. Cette bibliothèque offre une prise en charge étendue des formats de fichier, une représentation interne efficace et des capacités de traitement d'image assez puissantes. La bibliothèque d'image de base est conçue pour un accès rapide aux données stockées dans quelques formats de pixel de base [58].	
Scikit-learn	C'est une bibliothèque open source d'apprentissage automatique qui prend en charge l'apprentissage supervisé et non supervisé. Elle fournit également divers outils pour l'ajustement de modèle, le prétraitement des données, la sélection de modèle, l'évaluation de modèle et de nombreuses autres utilités [59].	
Streamlit	Streamlit est un Framework Python open source destiné aux data scientists et aux ingénieurs IA/ML afin de fournir des applications de données dynamiques avec seulement quelques lignes de code. [60]	

Tableau III-1:Les bibliothèques et le Framework utilisées

III.2.2 Langage de programmation de haut niveau

Python est un langage de programmation puissant et facile à apprendre. Il dispose de structures de données de haut niveau et permet une approche simple mais efficace de la programmation orientée objet. Parce que sa syntaxe est élégante, que son typage est dynamique et qu'il est interprété, Python est un langage idéal pour l'écriture de scripts et le développement rapide d'applications dans de nombreux domaines et sur la plupart des plateformes [61].



Figure III.1:Le logo de Python

III.2.3 Les clouds

- **Kaggle notebook**

Un notebook informatisé en nuage (cloud computed notebook), où tout votre code/vos processus sont calculés sur leurs serveurs en nuage. Ce type de notebook offre plusieurs avantages, notamment la possibilité d'utiliser des accélérateurs matériels pour améliorer les performances de calcul.

Parmi ces accélérateurs, on trouve les processeurs centraux (CPU), GPU P100 qu'on a utilisé dans notre travail ,2xGPU T4 et TPU VM v3-8

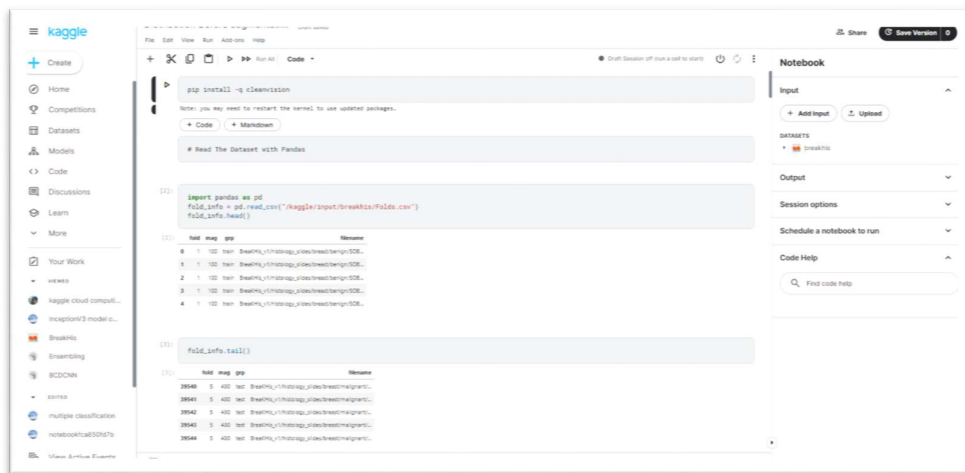


Figure III.2:Interface de notebook Kaggle

- **Google Colab**

Colab est un service de notebook Jupiter hébergé qui ne nécessite aucune configuration pour être utilisé et offre un accès gratuit à des ressources informatiques, y compris CPU, GPU comme GPU T4 qu'on a utilisé et des TPU comme TPU v2.

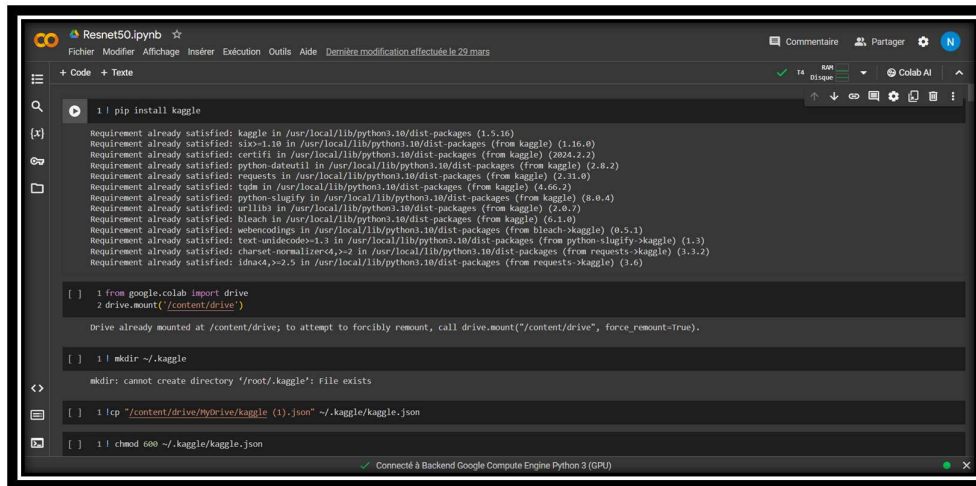


Figure III.3: Interface de notebook Google Colab

III.3 Ensemble de données d'images : Présentation et Caractéristiques

La classification des images histopathologiques du cancer du sein (BreakHis) est un ensemble de données de pathologie comprenant 7 909 images histopathologiques du cancer du sein provenant de 82 patients avec différents facteurs de grossissement, notamment 40×, 100×, 200× et 400× comme représenter dans le tableau III-2 ci-dessus.

Magnification	Benign	Malignant	Total
40×	625	1370	1995
100×	644	1437	2081
200×	623	1390	2013
400×	588	1232	1820
Total	2480	5429	7909
# Patients	24	58	82

Tableau III-2: Répartition des images par facteurs de grossissement et classe.

Les 7 909 images comprennent 2 480 images d'échantillons bénins et 5 429 images d'échantillons malins. Comme représenté dans la figure III-3 ci-dessous, l'ensemble de données open source BreakHis a été utilisé dans ce travail pour implémenter les modèles proposés.




Figure III.4 : Répartition des tumeurs en tumeurs bénignes et malignes

Les échantillons bénins et malins ont été divisés en différents sous-types. Les Figure III-5 et Figure III-6 présentent les quatre sous-types de tumeurs bénignes (adénose, fibroadénome, adénome tubulaire et tumeur phyllode) et les quatre sous-types de tumeurs malignes (carcinome canalaire, carcinome lobulaire, carcinome mucineux et carcinome papillaire).

La Figure III.5 ci-dessus montre les quatre sous-types de tumeurs bénignes.




Figure III.5: Sous-types de tumeurs bénignes

La Figure III.6 ci-dessus montre les quatre sous-types de tumeurs malignes.




Figure III.6 Sous-types de tumeurs malignes.

Les deux tableaux III-4 et III-5 ci-dessus décrivent la distribution des tumeurs bénignes et malignes parmi les différentes classes, offrant ainsi une exploration approfondie des sous-types de tumeurs.

Magnification	A	F	TA	PT	Total
40×	114	253	109	149	598
100×	113	260	121	150	614
200×	111	264	108	140	594
400×	106	237	115	130	562
Total	444	1,014	453	569	2,368
# Patients	4	10	3	7	24

Tableau III-3: Distribution des images bénignes par facteur de grossissement et sous-types histologiques.

Magnification	DC	LC	MC	PC	Total
40×	864	156	205	145	1,370
100×	903	170	222	142	1,437
200×	896	163	196	135	1,390
400×	788	137	169	138	1,232
Total	3,451	626	792	560	5,429
# Patients	38	5	9	6	58

Tableau III-4: Distribution des images malignes par facteur de grossissement et sous-types histologiques.

III.4 La validation croisée k-fold

La validation croisée k-fold est une technique d'évaluation des modèles prédictifs. Le jeu de données est divisé en k sous-ensembles ou plis. Cette méthode aide à l'évaluation, la sélection des modèles et l'ajustement des hyperparamètres, fournissant une mesure plus fiable de l'efficacité d'un modèle.

Dans notre ensemble de données nous avons une stratégie de validation croisée à 5 plis conçue de manière à ce que les images d'entraînement et de test proviennent de différentes personnes. Chaque pli contient les 7 909 images disponibles. Nous utiliserons le deuxième pli pour cette étude, car il contient la plus grande proportion d'images d'entraînement comme montré dans la figure III-7 ci-dessus.




Figure III.7: Analyse de la répartition des données d'entraînement et de test par pli.

III.5 Workflow du travail proposé

Dans le cadre de notre travail proposé, nous présentons un workflow complet qui englobe les étapes fondamentales du processus de fouille de données. Ce workflow est représenté dans la figure III-8 qui contient les étapes de la collecte des données, du

prétraitement des données, comprenant le nettoyage des données, la transformation des données, l'augmentation des données et la normalisation des données, puis la dernière étape du workflow qui est traitement qui concernent les algorithmes utilisés.




Figure III.8:Workflow du travail proposé.

a. Collection de Données

Le workflow proposé commence par la collecte des données, où les données brutes sont rassemblées à partir de diverses sources. L'installation se fait à partir de Kaggle, comme représenté dans la figure III-9 ci-dessous.




Figure III.9 : BreakHis sur Kaggle

b. Prétraitement des Données

La phase de prétraitement des données est peut-être la plus cruciale dans le processus de fouille de données. Cette phase commence après la collecte des données et comprend les étapes qui sont dans la figure III-8. Cette phase critique permet d'optimiser la qualité, la cohérence et la pertinence des données, ce qui influence directement les performances et la généralisation des modèles résultants.

b.1 Nettoyage de données

Une fois les données acquises, il est essentiel de les nettoyer en identifiant et en traitant les valeurs manquantes, les valeurs aberrantes et les données dupliquées. Ce processus garantit la qualité et l'intégrité des données avant de les utiliser pour l'apprentissage. Dans un autre ensemble de données, nous avons vérifié la présence de valeurs manquantes, mais aucune n'a été détectée comme présenté dans la figure III-10.

```
[4]: print("Le nombre de valeurs manquantes dans chaque colonne est : \n", fold_info.isnull().sum())

Le nombre de valeurs manquantes dans chaque colonne est :
fold      0
mag      0
grp      0
filename  0
dtype: int64
```

Figure III.10: Valeurs Manquantes

L'emploi de CleanVision, une bibliothèque spécialisée dans le prétraitement des données comme illustré dans la figure III-11 peut considérablement simplifier cette tâche.




Figure III.11: Aperçu de CleanVision [54].

L'application de CleanVision à notre ensemble de données BreakHis nous a donné les résultats présentés dans la figure III-12, accompagnés de quelques images illustrant chaque problème détecté.


```
Issue checks completed. 0 issues found in the dataset. To see a detailed report of issues found, use imagelab.report().
Issues found in images in order of severity in the dataset
```

	issue_type	num_images
0	dark	0
1	light	0
2	odd_aspect_ratio	0
3	low_information	0
4	blurry	0
5	grayscale	0
6	odd_size	0
7	exact_duplicates	0
8	near_duplicates	0

Figure III.13: Rapport après suppression de problèmes

b.2 Transformation de données

Le redimensionnement est appliqué par les chercheurs pour modifier les images d'entrée en tailles spécifiques adaptées aux modèles d'apprentissage profond. Bien que cette méthode soit souvent appliquée avant de fournir les images aux modèles. La taille d'image originale des images d'histopathologie dans l'ensemble de données BreakHis est de 700×460 pixels. Toutes les images sont redimensionnées en 224×224 pixels.

b.3 Augmentation de données

Les principaux défis rencontrés lors de l'entraînement des modèles d'apprentissage profond sont le manque de données étiquetées et le déséquilibre du nombre de classes. Le manque de données étiquetées entraîne des résultats biaisés des modèles, également connus sous le nom de problème d'overfitting. L'augmentation de données est utilisée pour augmenter la taille de l'ensemble de données.

Cependant, il y avait un déséquilibre significatif dans le nombre d'images dans les catégories des tumeurs bénignes (2 480) et malignes (5 429) Pour remédier à ce problème, des stratégies d'augmentation de données ont été appliquées aux échantillons de tumeurs bénignes dans tous les sous-ensembles, à savoir une inversion horizontale et une inversion verticale comme présentés dans la figure III-14.



Figure III.14: Application d'une inversion horizontale et une inversion verticale.

b.4 Normalisation de données

Comme la couleur dans les images histopathologiques est très intense, dans notre travail nous avons appliqué une normalisation pour mapper les nombres dans une plage entre zéro et un afin de diminuer la distribution et l'intensité des couleurs.

c. Traitement de données

c.1 Transfert d'apprentissage

En apprentissage par transfert, les connaissances d'un modèle d'apprentissage automatique déjà entraîné sont appliquées à un problème différent mais connexe. Par exemple, si vous avez entraîné un simple classificateur à prédire si une image contient un sac à dos, vous pourriez utiliser les connaissances acquises par le modèle lors de son entraînement pour reconnaître d'autres objets comme des lunettes de soleil.

Avec l'apprentissage par transfert, nous essayons essentiellement d'exploiter ce qui a été appris dans une tâche pour améliorer la généralisation dans une autre. Nous transférons les poids qu'un réseau a appris lors de la "tâche A" vers une nouvelle "tâche B" [62].

La Figure III.15 montre un aperçu d'apprentissage par transfert.



Figure III.15:Aperçu d'apprentissage par transfert.

L'idée générale est d'utiliser les connaissances qu'un modèle a acquises à partir d'une tâche disposant de beaucoup de données d'entraînement étiquetées pour une nouvelle tâche qui ne dispose pas de beaucoup de données. Au lieu de recommencer le processus d'apprentissage à partir de zéro, nous commençons avec les modèles appris lors de la résolution d'une tâche connexe [62] comme expliquer dans la figure III.16 ci-dessus.




Figure III.16: Comment fonctionne l'apprentissage par transfert.

c.2 Evaluation

L'évaluation des performances de n'importe quel système de classification est une étape très importante parce que ces performances reflètent la fiabilité du système proposé. Dans les applications médicales et plus particulièrement celle à deux classes, le taux de bonne classification et d'erreur globale ne suffisent pas pour juger les performances [63]. Les mesures adoptées sont définies comme suit :

- **Taux de bonne classification (Accuracy)**

Taux de bonne classification (Accuracy) est l'indicateur le plus naturel et le plus évident permettant d'évaluer les performances d'un système de classification. Cette valeur simple à calculer, détecte la fréquence à laquelle notre modèle est correct :

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

Où :

TN : Le modèle prédit bénin le cas est bénin.

FP : Le modèle prédit malin le cas est en fait bénin.

FN : Le modèle prédit bénin le cas est en fait malin.

TP : Le modèle prédit malin le cas est malin.

- **La sensibilité (le rappel) :**

C'est le nombre de vrais positifs divisé par le nombre de vrais positifs et le nombre de faux négatifs :

$$sensibilité = \frac{TP}{TP+FN}$$

- **La précision :**

C'est le nombre de vrais positifs divisé par le nombre de vrais positifs et de faux positifs

$$PPV = \frac{TP}{TP+FP}$$

- **F1-score :**

C'est une moyenne harmonique de précommeision et de rappel, elle est considérée comme parfaite à 1 et est une défaillance totale à 0

$$F1 - Score = \frac{2 * Precision * Recall}{Precision + Recall} = \frac{2 * TP}{2 * TP + FP + FN}$$

- **La courbe ROC (Receiver Operating Characteristic):**

Une **courbe ROC** est un graphique qui montre les performances d'un modèle de classification à tous les seuils de classification. Cette courbe représente deux paramètres :

Le **taux de vrais positifs (TPR)** est l'équivalent du rappel.

Le **taux de faux positifs (TFP)** est défini comme suit :

$$FPR = \frac{FP}{FP + TN}$$

Une courbe ROC représente les valeurs TVP et TFP pour différents seuils de classification. La diminution du seuil de classification permet de classer davantage d'éléments comme étant positifs, ce qui augmente le nombre de faux positifs et de vrais positifs. La figure suivante montre une courbe ROC typique [64].




Figure III.17:Taux de VP par rapport aux FP au niveau de différents seuils de classification [64]

- **AUC zone sous la courbe ROC :**

AUC (Area Under the ROC Curve) est un nombre compris entre 0,0 et 1,0 représentant la capacité d'un modèle de classification binaire à séparer les classes positives des classes négatives. Plus l'AUC se rapproche de 1,0, meilleure est la capacité du modèle à séparer les classes les unes des autres.




Figure III.18:AUC (aire sous la courbe ROC) [64].

III.6 Modèles CNN Utilisés dans l'Étude Comparative

Les Applications Keras sont des modèles d'apprentissage profond qui sont mis à disposition avec des poids pré-entraînés. Dans notre étude, nous avons utilisé cinq modèles d'apprentissage profond. Ces modèles peuvent être utilisés pour la prédiction, l'extraction de caractéristiques et le réglage fin le tableau III-6 représente un aperçu de ces 5 modèles.

Modèle	Taille (Mo)	Top-1 Accuracy	Top-5 Accuracy	Paramètres	Profondeur	Temps (ms) par pas d'inférence (CPU)	Temps (ms) par pas d'inférence (GPU)
Xception	88	79.0%	94.5%	22.9M	81	109.4	8.1
ResNet50	98	74.9%	92.1%	25.6M	107	58.2	4.6
InceptionV3	92	77.9%	93.7%	23.9M	189	42.2	6.9
MobileNet	16	70.4%	89.5%	4.3M	55	22.6	3.4
InceptionResNetV2	215	80.3%	95.3%	55.9M	449	130.2	10.0

Tableau III-5: Aperçu des 5 modèles Utilisés [24].

III.7 Discussion des Résultats Obtenus

Dans cette section, nous examinerons cinq modèles en cours d'entraînement. Chaque modèle présente des compromis différents entre complexité, capacité de généralisation et performance. En choisissant le modèle approprié pour nos besoins

spécifiques, nous pouvons maximiser l'efficacité de nos solutions de vision par ordinateur.

Dans notre étude, nous avons opté pour un entraînement sur 35 époques. Cependant, l'entraînement s'arrête parfois plutôt en raison de l'utilisation de l'early stopping, un callback de Keras. De plus, pour les courbes de perte, nous avons utilisé le callback ReduceLROnPlateau de Keras, qui réduit le taux d'apprentissage lorsque la performance stagne.

Il est important de noter que les courbes présentent des tressautements, dus à une insuffisance des données de validation. Le ratio choisi dans notre étude est de 70 % pour l'entraînement, 20 % pour le test et 10 % pour la validation.

- **Modèle ResNet50**




Figure III.19: Courbes du processus d'entraînement du CNN pour le modèle ResNet50.

- **Modèle inceptionv3**




Figure III.20: Courbes du processus d'entraînement du CNN pour le modèle InceptionV3.

- **Modèle inceptionresnetV2**




Figure III.21: Courbes du processus d'entraînement du CNN pour le modèle InceptionResNetV2.

- **Modèle Xception**




Figure III.22: Courbes du processus d'entraînement du CNN pour le modèle Xception.

- **Modèle MobilenetV1**




Figure III.23: Courbes du processus d'entraînement du CNN pour le modèle MobileNetV1.

III.8 Résultats de prédiction sur l'ensemble de test

Les résultats de classification obtenus par les cinq CNN sont résumés dans le Tableau III.6 et pour une comparaison plus claire. La figure 24 ci-dessus représente les résultats obtenus pour les cinq modèles, en utilisant cinq métriques différentes : le ROC-AUC (en bleu), l'exactitude (en jaune), la précision (en vert), le rappel (en rouge) et le score F1 (en mauve).




Figure III.24: Comparaison des indicateurs d'évaluation pour les modèles CNN

Les résultats de classification obtenus par les cinq modèles CNN sont résumés dans le Tableau 10. Il est à noter que le modèle InceptionResNetV2 a obtenu les meilleurs résultats en termes d'exactitude (accuracy).

Modèles	Accuracy	Précision	Rappel	F1-score	Roc-Auc
ResNet50	0.989	0.986	0.963	0.974	0.962
InceptionV3	0.938	0.898	0.908	0.903	0.879
InceptionresnetV2	0.996	0.992	0.960	0.976	0.968
Xception	0.986	0.957	0.991	0.974	0.997
MobilenetV1	0.995	0.994	0.985	0.989	0.981

Tableau III-6: Résultats de prédiction pour les modèles CNN

III.9 Comparaison entre les performances de modèles

Sur le BreakHis dataset, la performance des différentes architectures peut varier en fonction de divers facteurs tels que la complexité des images histologiques, la taille de l'ensemble de données et les spécificités de la tâche de classification. Cependant, voici une comparaison générale basée sur les caractéristiques des architectures mentionnées avant :

InceptionResNetV2 : Cette architecture combine les idées des modules Inception avec les connexions résiduelles de ResNet. Ce modèle a eu le meilleur résultat en raison de sa

profondeur et de sa capacité à capturer des caractéristiques complexes à partir d'images. Il utilise des blocs résiduels pour améliorer l'entraînement en profondeur. Elle est souvent utilisée lorsque des performances élevées sont nécessaires dans des tâches de classification d'images complexes.

MobileNetV1 : Cette architecture est conçue pour être légère en termes de ressources. Il utilise des convolutions profondes mais étroites, ainsi que des convolutions séparables en profondeur pour réduire le nombre de paramètres et d'opérations de calcul. Cela le rend moins profond et moins complexe que InceptionResNetV2.

Xception : quant à lui, utilise des convolutions séparables en profondeur, une approche qui lui permet d'explorer les dépendances spatiales et chromatiques de manière plus efficace. Bien qu'elle soit profonde, Xception est moins complexe que InceptionResNetV2 en termes de nombre de paramètres.

ResNet50 : Bien qu'il s'agisse d'une architecture profonde, ResNet50 est moins complexe que InceptionResNetV2. Il est composé de blocs résiduels qui facilitent l'entraînement en profondeur, mais il n'utilise pas les modules Inception.

InceptionV3 : Cette architecture est moins profonde et moins complexe que des architectures comme InceptionResNetV2 et Xception. Il est moins efficace que InceptionResNetV2 dans la capture de caractéristiques discriminantes, en particulier dans des ensembles de données complexes comme le BreakHis dataset.

III.10 Déploiement de l'Application Web

Nous présentons dans cette section l'interface de l'application développée dans ce travail. Elle est destinée aux utilisateurs pour les aider à déterminer si une tumeur est maligne ou bénigne, ainsi qu'à tester notre travail.

- La première interface : cette interface permet aux utilisateurs d'accéder au reste de l'application.



Figure III.25: La première interface de l'application.

- La 2eme interface : cette interface démontre le rôle de l'IA, montrant qu'elle est plus performante qu'un pathologiste.




Figure III.26: La deuxième interface de l'application.

- La 3eme interface : cette interface est considérée comme interface principale de l'application.



Figure III.27: La troisième interface de l'application.

- La 4eme interface : cette interface est conçue pour présenter les différents traitements possibles pour le cancer.



Figure III.28: La quatrième interface de l'application.

- La 5ème interface : cette interface représente les statistiques mondiales de la santé selon l'OMS.



Figure III.29: La cinquième interface de l'application.

III.11 Conclusion

Ce chapitre a exploré l'application de cinq modèles d'apprentissage profond convolutifs (CNN) à la classification des images histopathologiques du cancer du sein. Les résultats obtenus ont démontré que les CNN peuvent être des outils puissants pour cette tâche, avec des performances atteignant jusqu'à 99,4% d'exactitude.

Parmi les modèles étudiés, InceptionResNetV2 s'est démarqué comme le plus performant, avec une précision de 99,4%, un rappel de 97,5%, un score F1 de 98,2% et une AUC de 0,978.

En plus de la performance des modèles, une application web a été développée pour permettre aux utilisateurs de télécharger une image histopathologique et d'obtenir une prédiction sur la nature de la tumeur (bénigne ou maligne). L'application fournit également des informations sur les différents traitements possibles pour le cancer du sein et les statistiques mondiales de la santé selon l'OMS.

Ces résultats suggèrent que les CNN ont le potentiel de révolutionner le diagnostic du cancer du sein en offrant une méthode automatisée, précise et accessible pour la classification des images histopathologiques. Les modèles présentés dans ce chapitre peuvent servir de base au développement de systèmes d'aide à la décision clinique qui peuvent aider les pathologistes à diagnostiquer le cancer du sein plus rapidement et plus précisément, contribuant ainsi à améliorer les résultats des patient

Conclusion générale

La santé est un domaine privilégié des recherches scientifiques dans le monde, notamment dans le domaine de l'informatique et de l'intelligence artificielle (IA). Ces dernières années, l'IA a montré un grand potentiel dans le développement de systèmes intelligents pour la classification et le diagnostic du cancer du sein. Les modèles de réseaux de neurones convolutifs (CNN) se sont avérés particulièrement efficaces dans cette tâche, offrant rapidité et fiabilité dans l'analyse d'images histopathologiques.

La classification d'image histopathologique est un domaine crucial de la vision par ordinateur, visant à donner aux machines la capacité de reconnaître des modèles complexes dans les tissus biologiques. Cette capacité est particulièrement précieuse dans le domaine du cancer du sein, une maladie répandue et potentiellement mortelle touchant des millions de femmes dans le monde.

Dans cette étude, nous avons exploré différentes architectures de CNN, notamment ResNet50, InceptionV3, InceptionResNetV2, Xception et MobileNetV1, pour classer les images histopathologiques du cancer du sein. À travers des expérimentations approfondies, nous avons évalué la performance de ces modèles dans la classification binaire du cancer du sein.

De plus, nous avons utilisé Clean Vision pour le prétraitement des données, ce qui a permis d'améliorer la qualité des images analysées. Pour le déploiement de notre application web, nous avons employé le Framework Streamlit, facilitant ainsi l'accès et l'utilisation de notre modèle par les professionnels de santé.

Nos résultats ont démontré que certaines architectures, telles que InceptionResNetV2, ResNet50 et MobilNetV1, ont obtenu des performances remarquables dans la classification du cancer du sein, surpassant d'autres modèles dans certains cas. Cependant, chaque modèle a ses propres forces et faiblesses, et des recherches supplémentaires sont nécessaires pour comprendre pleinement leur potentiel dans ce domaine.

Les avancées dans le domaine de l'IA et de la vision par ordinateur offrent des opportunités prometteuses pour améliorer la détection précoce et le diagnostic du cancer du sein. En combinant des techniques d'apprentissage profond avec des données médicales volumineuses, nous pouvons contribuer à améliorer les soins de santé et à sauver des vies.

EN guise de perspectives futures de ce travail, nous envisageons d'utiliser les transformers, et en particulier le Vision Transformer (ViT), offrent des performances exceptionnelles grâce à leur capacité à capturer des dépendances à long terme et à traiter des ensembles de données complexes. L'application des transformers ne se limite pas aux images histopathologiques du sein. Leur utilisation pourrait être étendue à d'autres types d'images microscopiques, telles que les images cervicales et gastriques, améliorant ainsi les capacités diagnostiques dans ces domaines également. Les transformers permettent une meilleure interprétation des images médicales, facilitant la détection précoce et le traitement des maladie .

RÉFÉRENCES BIBLIOGRAPHIQUES

- [1] (2018). WHO | Breast Cancer. Accessed: Feb. 15, 2019. [Online]. Available: <https://www.who.int/cancer/prevention/diagnosis-screening/breastcancer/en/>
- [2] M. Zeeshan, B. Salam, Q. S. B. Khalid, S. Alam, and R. Sayani, “Diagnostic accuracy of digital mammography in the detection of breast cancer,” *J. Cureus*, vol. 10, no. 4, p. e2448, Apr. 2018, doi: 10.7759/cureus.2448.
- [3] H. Ellis and V. Mahadevan, “Anatomy and physiology of the breast,” *Surg. (United Kingdom)*, vol. 31, no. 1, pp. 11–14, 2013, doi: 10.1016/j.mpsur.2012.10.018.
- [4] *Learnsurgeryonline.com*. (n.d.). The Breasts. Retrieved from <https://learnsurgeryonline.com/the-breasts/>
- [5] Haute Autorité de Santé. (2015). Référentiel de Cancer du Sein [Breast Cancer Guidelines]. Retrieved from https://www.has-sante.fr/upload/docs/application/pdf/2015-04/refces_k_du_sein_vf.pdf
- [6] *Cancer.ca*. (s. d.). Biopsie. Consulté à l'adresse https://cancer.ca/fr/treatments/tests-and-procedures/biopsy#ci_biopsy_89_3953_00.
- [7] De Matos J, Britto AdSJr, Oliveira LES, et al. Histopathologic image processing: a review. *arXiv preprint arXiv:190407900*2019.
- [8] Gurcan MN, Boucheron LE, Can A, et al. Histopathological image analysis: a review. *IEEE Rev Biomed Eng* 2009;2:147–71. doi:10.1109/RBME.2009.2034865
- [9] Y. Zheng et al., “Application of transfer learning and ensemble learning in image-level classification for breast histopathology,” *Intell. Med.*, vol. 3, no. 2, pp. 115–128, 2023, doi: 10.1016/j.imed.2022.05.004
- [10] LE PETIT LAROUSSE ILLUSTRÉ, 2013, P. 164
- [11] R. Sofiane, “Cancer du sein Suivi d’une population sous chimiothérapie”, mémoire de Master, Université Abdelhamid Ibn Badis Mostaganem, 2018.
- [12] W. H. Organization et al., “Tumours of the breast and female genital organs,” *World Health Organization Classification of Tumours: Pathology and Genetics of Tumours of the Breast and Female Genital Organs*. Lyon: International Agency for Research in Cancer, 2003
- [13] G. Viale, N. Rotmensz, P. Maisonneuve, E. Orvieto, E. Maiorano, V. Galimberti, A. Luini, M. Colleoni, A. Goldhirsch, and A. S. Coates, “Lack of prognostic significance of classic lobular breast carcinoma: a matched, single institution series,” *Breast cancer research and treatment*, vol. 117, no. 1, p. 211, 2009.

- [14] Bourgeois, D. (2023, 1 janvier). Le carcinome canalaire infiltrant : un type de cancer du sein particulier. Centre de Chirurgie de la Femme. <https://chirurgiefemme-paris.fr/cancer-sein/traitement-cancer-sein/carcinome-canalaire-infiltrant/>
- [15] McCart Reed AE, et al. Invasive lobular carcinoma of the breast: the increasing importance of this special subtype. *Breast Cancer Res.* 2021 Jan 7;23(1):6. PMID: 33413533
- [16] Carcinome infiltrant. (2023, 4 octobre). <http://www.depistagesein.ca/carcinome-infiltrant/>
- [17] “Fiche d’information Carcinome lobulaire infiltrant (CLI),” vol. 22, no. Cli, p. 32586354, 2022.
- [18] Schnitt SJ. Classification and prognosis of invasive breast cancer: from morphology to molecular taxonomy. *Mod Pathol.* 2010;23(560-564).
- [19] De L’ISHH, L. (2024, 20 février). Classification moléculaire cancer du sein - Ce qu’il faut retenir. ISHH. [https://ishh.fr/cancer-du-sein/classification-moleculaire-differents-cancer-sein/#:~:text=On%20parle%20de%20situation%20anatomopathologique,infiltrant%20\(ou%20cancer%20infiltrant\).](https://ishh.fr/cancer-du-sein/classification-moleculaire-differents-cancer-sein/#:~:text=On%20parle%20de%20situation%20anatomopathologique,infiltrant%20(ou%20cancer%20infiltrant).)
- [20] Gustave Roussy. (n.d.). Cancer du sein : Traitement. Retrieved from <https://www.gustaveroussy.fr/fr/cancer-du-sein-traitement#:~:text=Quel%20traitement%20en%20cas%20de,%2C%20hormonoth%C3%A9rapie%2C%20th%C3%A9rapies%20cibl%C3%A9es>
- [21] Deluzarche, Céline. 2021 (05). Deep Learning : qu’est-ce que c’est ?
- [22] S. V. Mahadevkar et al., “A Review on Machine Learning Styles in Computer Vision - Techniques and Future Directions,” *IEEE Access*, vol. 10, no. October, pp. 107293–107329, 2022, doi: 10.1109/ACCESS.2022.
- [23] M. Boughaba and B. Boukhris, “L’apprentissage profond (Deep Learning) pour la classification et la recherche d’images par le contenu,” p. 43, 2017.
- [24] Le Deep Learning : définition, histoire et cas d’usage. (s. d.). <https://www.sicara.fr/fr/parlons-data/deep-learning>
- [25] Desternes, J. (2024, 5 avril). Deep learning en imagerie médicale : augmentation des données. IMAIOS. <https://www.imaios.com/fr/ressources/blog/ia-pour-l-imagerie-medecale-augmentation-des-donnees>
- [26] D. Castillo, Vasudevan Lakshminarayanan, Maria J. Rodriguez-Alvarez. MRI Images, Brain Lesions and Deep Learning. arXiv:2101.05091 (2021).
- [27] Sun R, Limkin EJ, Dercle L, Reuzé S, Zacharaki EI, Chargari C, et al. Imagerie médicale computationnelle (radiomique) et potentiel en immuno-oncologie. *Cancer Radiother* 2017;21:648–54. <https://doi.org/10.1016/j.canrad.2017.07.035>.
- [28] Classe M, Lerousseau M, Scoazec J-Y, Deutsch É. Perspectives in pathomics in head and neck cancer. *Curr Opin Oncol* 2021;33:175–83. <https://doi.org/10.1097/CCO.0000000000000731>.

- [29] Dejasmin, J. (2021, 31 mai). Histoire du deep learning. Le Meilleur de la Technologie Au Service de la Biodiversité. <https://www.natural-solutions.eu/blog/histoire-du-deep-learning>
- [30] M. Boughaba and B. Boukhris, "L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu," p. 43, 2017.
- [31] F. Ouissal.(juin 2023), "Thème Combinaison de classifieurs pour la reconnaissance des anomalies mammaires Résumé."
- [32] Iglesias, L. L., Bellón, P. S., del Barrio, A. P., Fernández-Miranda, P. M., González, D. R., Vega, J. A., Mandly, A. A. G., & Blanco, J. A. P. (2021). A primer on deep learning and convolutional neural networks for clinicians. *Insights into Imaging*, 12(1), 117. <https://doi.org/10.1186/s13244-021-01052-z>
- [33] Maurice, B. (2018, 26 septembre). Fonction d'activation ; activation. Deeply Learning. <https://deeplylearning.fr/cours-theoriques-deep-learning/fonction-dactivation/>
- [34] S. Sharma, S. Sharma, and A. Athaiya, "Activation Functions in Neural Networks," *Int. J. Eng. Appl. Sci. Technol.*, vol. 04, no. 12, pp. 310–316, 2020, doi: 10.33564/ijeast.2020.v04i12.054.
- [35] Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks : An overview and application in radiology. *Insights into Imaging*, 9(4), 611-629. <https://doi.org/10.1007/s13244-018-0639-9>
- [36] Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning : Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1), 53. <https://doi.org/10.1186/s40537-021-00444-8>
- [37] Google Cloud. (n.d.). Inception v3 avancé. Retrieved from <https://cloud.google.com/tpu/docs/inception-v3-advanced?hl=fr>
- [38] S. P. Sonavane and S. Patankar, "Detection of Malaria Parasite Using Deep Learning," 2021. Available: https://www.researchgate.net/figure/The-architecture-of-Inception-V3-model_fig5_349717475.
- [39] Kundu, N. (2023, 23 janvier). Exploring ResNet50 : An In-Depth Look at the Model Architecture and Code Implementation. Medium. <https://medium.com/@nitishkundu1993/exploring-resnet50-an-in-depth-look-at-the-model-architecture-and-code-implementation-d8d8fa67e46f>
- [40] T. Zang, "The Annotated ResNet-50," *Towards Data Science*, July 3, 2019. Available: <https://towardsdatascience.com/the-annotated-resnet-50-a6c536034758>
- [41] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, "Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning". In *AAAI*, 2017, pp. 4278-4284.

- [42] L. D. Nguyen, D. Lin, Z. Lin, and J. Cao, "Deep CNNs for microscopic image classification by exploiting transfer learning and feature concatenation," Proc. - IEEE Int. Symp. Circuits Syst., vol. 2018-May, no. May, 2018, doi: 10.1109/ISCAS.2018.8351550.
- [43] ResearchGate. (n.d.). Inception ResNet V2 architecture designed for binary classification [Image]. Retrieved from https://www.researchgate.net/figure/nception-ResNet-V2-architecture-designed-for-binary-classification_fig1_353494880
- [44] CHOLLET et François., «Xception: Deep learning with depthwise separable convolutions,» in Proceedings of the IEEE conference on computer vision and pattern recognition, p. 1251–1258, 2017.
- [45] L.Sifre et S.Mallat, «Rigid-motion scattering for image classification,» arXiv 2014. arXiv preprint arXiv:1403.1687., 2014.
- [46] Mehmood A, Gulzar Y, Ilyas QM, Jabbari A, Ahmad M, Iqbal S. SBXception: A Shallower and Broader Xception Architecture for Efficient Classification of Skin Lesions. Cancers. 2023; 15(14):3604. <https://doi.org/10.3390/cancers15143604>
- [47] Andrew G. Howard, Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto, Hartwig Adam. "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications", arXiv preprint arXiv:1704.04861, 2017
- [48] Yu, A. (2023). MobileNet V1 architecture. ResearchGate. Retrieved from https://www.researchgate.net/figure/MobileNet-V1-architecture_fig3_376752661.
- [49] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-Based Learning Applied to Document Recognition," proc. IEEE, 1998.
- [50] T. Ghosh et al., "Bangla handwritten character recognition using mobilenet v1 architecture," Bull. Electr. Eng. Informatics, vol. 9, no. 6, pp. 2547–2554, 2020, doi: 10.11591/eei.v9i6.2234.
- [51] HOUAZENE Sabrina et MANSOUR Souad, « Détection des Scripts publicitaires à base d'apprentissage automatique profond », Université Mouloud Mammeri de Tizi Ouzou ,2019
- [52] Medjdoubi Abdelkader, « L'ANALYSE DU SENTIMENT UTILISANT LE DEEP LEARNING », Dr. TAHAR MOULAY SAIDA,2019
- [53] W3Schools. "Python Pandas - Introduction". Disponible sur : https://www.w3schools.com/python/pandas/pandas_intro.asp
- [54] GitHub. CleanVision. Disponible sur : <https://github.com/cleanlab/cleanvision>
- [55] Matplotlib. [En ligne]. Disponible sur : <https://matplotlib.org/>
- [56] Seaborn. [En ligne]. Disponible sur : <https://seaborn.pydata.org/>
- [57] NumPy. [En ligne]. Disponible sur : <https://numpy.org/doc/stable/>

- [58] Pillow. (s. d.). Pillow (PIL Fork) documentation. Récupéré sur <https://pillow.readthedocs.io/en/stable/>
- [59] scikit-learn. (n.d.). Getting Started — scikit-learn documentation. Retrieved from https://scikit-learn.org/stable/getting_started.html
- [60] Streamlit Docs. (s. d.). <https://docs.streamlit.io/>
- [61] Python Software Foundation. (n.d.). Tutoriel Python. Retrieved from <https://docs.python.org/fr/3/tutorial/>
- [62] Ellis, R. (2021, January 11). What Is Transfer Learning? Exploring the Popular Deep Learning Approach. Built In. <https://builtin.com/data-science/transfer-learning>
- [63] N.Dey, A.B. Roy , M.Pal, and A .Das. : “ FCM based bloodvessel segmentation method for retinal images”, arXiv:1209.1181, 2012.
- [64] Google. (n.d.). ROC (receiver operating characteristic) Curve. In Google Developers: Machine Learning Crash Course - Classification. Retrieved from <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc?hl=fr#:~:text=AUC%20represents%20the%20probability%20that,has%20an%20AUC%20of%201.0>
- [65] Camps, S. (2013). Carcinome canalaire infiltrant de grade III à mammographie: masse ronde de contour irrégulier, de forte densité, avec des fines spicules radiées à son bord [Figure]. Dans Détection de la tumeur en mammographie. https://www.researchgate.net/figure/Carcinome-canalaire-infiltrant-de-grade-III-a-mammographie-masse-ronde-de-contour_fig3_260113176
- [66] Camps, S. (2013). Carcinome lobulaire infiltrant à mammographie: masse irrégulière de contour spiculé [Figure]. Dans Détection de la tumeur en mammographie. https://www.researchgate.net/figure/Carcinome-lobulaire-infiltrant-a-mammographie-masse-irreguliere-de-contour-spicule_fig7_260113176

Résumé

Le cancer du sein est le cancer le plus fréquent chez la femme, et la détection précoce via la classification histopathologique joue un rôle crucial en augmentant les chances de guérison complète et permet dans certains cas un traitement moins invasif. Ces dernières années, l'intégration des techniques d'apprentissage profond (DL) ont montré des résultats prometteurs dans la classification du cancer du sein.

Les réseaux neuronaux convolutifs (CNN) sont une architecture d'apprentissage profond largement utilisée pour obtenir une classification précise des images histopathologiques du cancer du sein. Ce projet a combiné cinq modèles d'apprentissage par transfert (Xception, ResNet50, MobileNetV1, InceptionV3 et Inception ResNet-V2), évalués pour la classification binaire à partir de la dataset BreakHis.

L'architecture Inception ResNet-V2 a obtenu les meilleurs résultats pour la classification binaire. Nous avons également examiné quatre autres modèles dans notre étude afin de comparer les résultats.

Mots clés : Cancer du sein ,Classification d'images, Image histopathologique, Réseau de neurones convolutionnelles (CNN), Apprentissage par transfert

Abstract

Breast cancer is the most common cancer in women, and early detection through histopathological classification plays a crucial role in increasing the chances of complete recovery and, in some cases, allows for less invasive treatment. In recent years, the integration of deep learning techniques (DL) has shown promising results in breast cancer classification.

Convolutional Neural Networks (CNNs) are a widely used deep learning architecture for accurate classification of breast cancer histopathological images. This project combined five transfer learning models (Xception, ResNet50, MobileNetV1, InceptionV3, and Inception ResNet-V2), evaluated for binary classification using the BreakHis dataset.

The Inception-ResNet-V2 architecture achieved the best results for binary classification. We also examined four other models in our study to compare the results.

Keywords: Breast cancer, Image classification, Histopathological image, Convolutional neural network (CNN), Transfer learning

ملخص

سرطان الثدي هو السرطان الأكثر شيوعاً بين النساء، ويلعب الكشف المبكر من خلال التصنيف النسيجي الدور الرئيسي في زيادة فرص الشفاء الكامل وفي بعض الحالات يمكن أن يسمح بعلاج أقل تدخلاً. في السنوات الأخيرة، أظهرت تقنيات التعلم العميق (DL) نتائج واعدة في تصنيف سرطان الثدي.

الشبكات العصبية التصويرية التحويلية (CNNs) هي هندسة تعلم عميق مستخدمة على نطاق واسع للحصول على تصنيف دقيق للصور النسيجية لسرطان الثدي. جمع هذا المشروع بين خمس نماذج لتعلم النقل : Xception ، ResNet50 ، MobileNetV1 ، InceptionV3 و Inception-ResNet-V2 تم تقييمها للتصنيف الثنائي باستخدام مجموعة بيانات BreakHis

حققت هندسة Inception ResNet-V2 أفضل النتائج للتصنيف الثنائي. كما فحصنا أيضاً أربعة نماذج أخرى في دراستنا لمقارنة النتائج.

الكلمات المفتاحية: سرطان الثدي، تصنيف الصور، الصور النسيجية، الشبكات العصبية التلافيفية (CNN)، التعلم بالنقل