



République Algérienne Démocratique et Populaire Ministère
de l'enseignement supérieur et de la recherche scientifique



كلية العلوم الدقيقة وعلوم الطبيعة والبيئة
FACULTÉ DES SCIENCES EXACTES
ET DES SCIENCES DE LA NATURE ET DE LA VIE

Faculté des Sciences Exactes et des Sciences de la Nature et de la Vie

Université Larbi Tébessi - Tébessa

Département : Mathématiques et Informatique

Mémoire de fin d'étude Pour l'obtention du diplôme *de MASTER*

Domaine : Mathématiques et Informatique

Filière : Informatique

Option : Systèmes d'information

Thème

*Un algorithme d'augmentation des données
appliqué sur une dataset de cancer du sein*

Présenté Par : Abaidia Faten

Devant le jury :

Ms. Amroune Mohamed Prof Université Larbi Tébessi, Tébessa **Encadreur**

Ms. Bendib Issam MCA Université Larbi Tébessi, Tébessa **Co-Encadreur**

Ms. Bendjenna Abdelhakim Prof Université Larbi Tébessi, Tébessa **Président**

Ms. Boualleg yaakoub MCB Université Larbi Tébessi, Tébessa **Examineur**

Date de soutenance : 30/06/2022

Résumé

Cancer du sein reste un réel problème de santé public et un sujet de recherche d'actualité très délicat à aborder, et La recherche dans le domaine de l'imagerie médicale utilisant des approches d'apprentissage profond est devenue progressivement contingente. Les découvertes scientifiques révèlent que les performances des méthodes d'apprentissage profond supervisé dépendent fortement de la taille de l'ensemble de formation, que les radiologues experts doivent annoter manuellement. Ce dernier est une tâche assez fatigante et chronophage. Par conséquent, la plupart des images biomédicales librement accessibles les ensembles de données sont de petite taille.

Notre projet vise à créer un model utilisant l'apprentissage en profondeur, en particulier dans le domaine des GANs (generative adversarial network), et de fournir la même précision que l'étude de la littérature menée. Notre contribution unique consiste à construire un model GAN à l'aide de techniques d'apprentissage supervisées pour la catégorisation des images histopathologies dans la prédiction du cancer du sein. Afin d'améliorer la précision du modèle et de rendre le modèle approprié pour l'apprentissage supervisé, nous modifierons également certaines limitations architecturales. Nous suggérons plus d'élan, ce qui a stabilisé la majorité de notre processus Apprentissage supervisées.

Les Mots clés : Cancer du sein, Apprentissage supervisées, l'apprentissage en profondeur, Gan, images histopathologies.

Abstract

Breast cancer remains a real public health problem and a topical research topic that is very delicate to address, and research in the field of medical imaging using deep learning approaches has gradually become contingent. Scientific findings reveal that the performance of supervised deep learning methods strongly depends on the size of the training set, which expert radiologists have to annotate manually. The latter is a rather tiring and time-consuming task. Therefore, most freely accessible biomedical image datasets are small.

Our project aims to create a model using deep learning, especially in the field of GANs, and to provide the same accuracy as the literature study conducted. Our unique contribution consists in building a generative adversarial network (Gan) model using supervised learning techniques for the categorization of histopathological images in the prediction of breast cancer. In order to improve the accuracy of the model and make the model suitable for supervised learning, we will also modify some architectural limitations. We suggest more momentum, which has stabilized the majority of our Supervised Learning process.

Keywords: Breast cancer, supervised learning, deep learning, Gan, histopathology images.

ملخص

يظل سرطان الثدي مشكلة صحية عامة حقيقية وموضوع بحث موضعي حساس للغاية لمعالجته، وأصبحت الأبحاث في مجال التصوير الطبي باستخدام مناهج التعلم العميق عرضية تدريجياً. تكشف النتائج العلمية أن أداء طرق التعلم العميق الخاضعة للإشراف يعتمد بشدة على حجم مجموعة التدريب، والتي يتعين على خبراء الأشعة أن يعلقوا عليها يدويًا. هذا الأخير هو مهمة متعبة إلى حد ما وتستغرق وقتًا طويلاً. لذلك، فإن معظم مجموعات بيانات الصور الطبية الحيوية التي يمكن الوصول إليها مجانًا يهدف مشروعنا إلى إنشاء نموذج باستخدام التعلم العميق، لا سيما في مجال شبكات. تكون صغيرة الحجم ، وتقديم نفس الدقة التي تم إجراؤها في دراسة الأدب. تتمثل مساهمتنا الفريدة في بناء نموذج GAN باستخدام تقنيات التعلم الخاضعة للإشراف لتصنيف الصور النسيجية المرضية في التنبؤ بسرطان GAN الثدي. من أجل تحسين دقة النموذج وجعل النموذج مناسبًا للتعلم الخاضع للإشراف، سنقوم أيضًا بتعديل بعض القيود المعمارية. نقترح مزيدًا من الزخم، والذي أدى إلى استقرار غالبية عملية التعلم الخاضع للإشراف لدينا

الكلمات المفتاحية: سرطان الثدي، التعلم تحت الإشراف، التعلم العميق، صور التشريح المرضي

.Gan

Remerciements

**On remercie dieu le tout puissant de nous avoir donné la
Santé et la volonté d'entamer et de terminer ce mémoire.**

**Tout d'abord, ce travail ne serait pas aussi riche et n'aurait
Pas pu avoir le jour sans l'aide et l'encadrement de Mr. Amroune Mohamed et Mr bendhib
Issam, on les remercie pour la qualité de l'encadrement
Exceptionnel, pour la patience, la rigueur et la disponibilité
Durant Mon préparation de ce mémoire.**

**Notre remerciement s'adresse également à tous nos professeurs
De département MI pour leurs générosités et la grande patience dont ils ont su
Faire preuve malgré leurs charges académiques et
Professionnelles.**



DEDICACE

A mon père : Abaidia Belgacem, que Dieu lui fasse miséricorde

Et lui accorde le paradis

Grâce à l'éducation rigoureuse que vous m'avez donnée, j'ai pu guider mes pas dans la vie. Je n'ai jamais oublié tes conseils, ton amour, ton soutien dans ma vie et dans mon parcours universitaire.

Merci mon père pour la confiance que tu m'as accordée.

Tu as été et tu es toujours le premier soutien dans toutes mes démarches.

A mon Mère chérie : Abaidia fatma

Vous avez tant souffert pour vos enfants, vos sacrifices en notre faveur sont inestimables.

Merci pour tous les plaisirs, la tendresse, la compréhension, les sourires et l'amour que vous nous avez toujours Donnés. Vous avez su nous aimer et lire sur nos visages, nos préoccupations tout en proposant des solutions. Vos conseils, Vos encouragements et vos bénédictions ne m'ont jamais fait défaut. Puisse ce travail vous

Réconfortez pour les efforts

Énormes fournis. Que Dieu vous garde longtemps près de nous

A mes frères et ma sœurs : Salah, Bilel, Abdel ghafour, Samir, Khaled, Mohamed, Hadia.

En témoignage de l'affection qui nous a toujours unis sous le toit paternel, je voudrais que vous Trouviez dans ce travail le fruit des efforts que vous avez consentis à mon égard. Ce travail est aussi le vôtre.

À tous mes amies

Plus que des amis, vous êtes des sœurs. Merci, Grâce à vous j'ai compris que la distance

N'efface pas l'amitié. Que Dieu vous bénisse et vous donne longue vie

À tous ma famille

Merci pour le respect et l'affection que vous me témoignés sans cesse.



Table de Matière

Introduction générale

1. Introduction.....	17
2. Problématique	17
3. Structure de mémoire.....	18
4. Contribution.....	19

Chapitre 01 : Contexte Médicale

1. Introduction.....	23
2. L'anatomie.....	23
3. Cancer du sein.....	23
3.1 Système lymphatique du sein.....	24
4. Facteurs de risque du cancer du sein.....	26
5. Symptômes du cancer du sein.....	27
6. Diagnostic du cancer du sein	28
6.1. Biopsie	28
6.2. Biopsie des ganglions lymphatiques	29
6.3. Analyse du statut des récepteurs hormonaux	29
6.4. Examen histologie	29
6.5. . Scintigraphie osseuse	30
6.6. . Mammographie diagnostique	30
6.7. Échographie.....	31
6.8. Radiographie	32
6.9. IRM	32
7. Classification histologique du cancer du sein.....	32
7.1. . Carcinome canalaire ou lobulaire infiltrant.....	33
7.2. Carcinome canalaire in situ (CCIS)	33

8. Conception assistée par ordinateur.....	34
Conclusion	35

Chapitre 02 : Intelligence artificielle

Intelligence artificielle	37
1. Introduction.....	39
2. Intelligence artificielle	39
3. Apprentissage automatique	39
3.1. Définition	39
3.2. Apprentissage supervisé.....	40
3.3. Apprentissage non supervisé	40
4. L'apprentissage en profondeur	41
4.1. Définition.....	41
4.2. Architecture L'apprentissage en profondeur.....	41
4.3. Deep Learning vs Machine Learning.....	42
4.4. Domaine d'application.....	43
4.4. Les techniques d'apprentissage en profondeur	44
4.4.1. Réseau de neurones convolutifs (CNN)	45
4.4.2. CNN Architectures : LeNet, AlexNet, VGG, GoogleNet, ResNet	48
4.4.2.1. LeNet-5	48
4.4.2.2. AlexNet	48
4.4.2.3. VGGNet.....	49
4.4.2.4. Vgg16	49
4.4.3. Réseau neuronal récurrent (RNN)	49
4.4.4. Generative Adversarial Networks(Gan)	50
4.4.5. Transferlearning.....	51
Conclusion	51

Chapitre 03 : Augmentation des données Concepts, méthodes et outils.

1.	Introduction.....	54
2.	Techniques de base d'augmentation d'image.....	54
	2.1.Transformationgéométrique	54
	2.2. Augmentation du niveau de pixel.....	56
	2.3. Augmentation de pseudo-couleur	56
	2.4. Random Erasing (Effacement aléatoire).....	57
	2.5. Kernel Filters (Filtres du noyau).....	57
3.	Techniques d'augmentation avancées.....	58
	3.1. Augmentation basée sur le GAN	58
	3.1.1. Présentation de la structure du Gan	59
	3.2. Neural Style Transfer (NST)	60
4.	Etat de l'art.....	61
	4.1.Image Augmentation Techniques for Mammogram Analyse	61
	4.2. Techniques d'augmentation d'image pour le cancer du sein ensemble de données d'images échographiques.....	64
	4.3.Techniques d'augmentation d'image pour le cancer du sein Ensemble de données d'image d'histologie.....	65
	Conclusion	65

Chapitre 04 : Un algorithme d'augmentation des données appliqué sur une dataset de cancer du sein Contribution & Implémentation

1.	Introduction.....	68
2.	Contribution.....	68
3.	Dataset	68
4.	Création de modèle	68
	4.1. Création de générateur (G).....	68
	4.2. Création de discriminateur (D)	69
5.	Environnement de développement	70
6.	Etapes d'implémentation	71
7.	Résultats et discussion	77
	7.1. Les matrice d'évaluation	77

7.2. Les résultats obtenus	78
---	-----------

Liste des Figures

Chapitre 01 : Contexte Médicale

Figure1.1 : L'ANATOMIE DU SEIN.	23
Figure1.2 : Schéma d'une vue latérale du sein.	24
Figure1.3 : Schéma des ganglions lymphatiques du sein.	25
Figure 1.4 : Système lymphatique du sein.	26
Figure1.5 : Schéma des ganglions axillaires	27
Figure1.6 : Carcinome lobulaire	27
Figure1.7 : Carcinome canalaire.	29
Figure1.8 : microscopique.	29
Figure1.9 : Cancer du sien microscopie.	30
Figure 1.10 : les macrobiopsies par mammotome : A) la mammotome B) les pièces prélevées C) l'image radiographique	31
Figure1.11 : Mammographie Clé de radiologie	31
Figure1.12 : Les mammographies 3D peuvent améliorer la précision du dépistage du cancer du sein	31
Figure1.13 : Échographie du cancer du sein	32
Figure1.14 : une image d'une IRM	39

Chapitre 02 : Intelligence Artificielle

Figure 2.1 : le contexte de deep learning	41
--	-----------

Figure2.2 : Architecture L'apprentissage en profondeur	42
Figure 2.3 : structure d'un hypothétique réseau de neurones profonds à réaction directe	
Figure2.4 : ML VERS DL	43
Figure2.5 : Architecture standard d'un réseau à convolutions	45
Figure2.6 : représentation d'une image RGB	45
Figure2.7 : le fonctionnement des CNN	45
Figure2.8 : la fonction convoluée	46
Figure 2.9 : la fonction convoluée le cas de la couleur RGB	46
Figure2.10 : Couche convolution	47
Figure2.11 : Couche de pooling	47
Figure 2.12 : architecture de VGGNet	49
Figure 2.13 : architecture de VGG16	49
Figure 2.14 : architecture de RNN	50
Figure2.15 : architecture de Gan	51

Chapitre 03 : Augmentation des données concepts, méthodes et outils

Figure 3.1 : augmentation des données	53
Figure 3.2 : Méthode d'augmentation le schéma de méta-apprentissage	55
Figure 3.3 : Exemple d'images après application de la transformation géométrique	55
Figure 3.4 : Exemple d'images après application de la transformation géométrique	56
Figure 3.5 : Mammographies après application d'un effacement aléatoire	57
Figure 3.6 : Exemples of applying the PatchShuffle régularisation technique	57
Figure 3.7 : Illustration du concept GAN fourni par Mikolajczyk et Grochowski	57
Figure 3.8 : Backpropagation in generator training	58
Figure 3.9 : Backpropagation in generator training	59
Figure 3.10 : Illustration of style and content reconstructions in Neural Style Transfer	60
Figure 3.11 : Illustration of the Fast neural style algorithm by Johnson et al	60

Chapitre 04 :

Figure 4. 1 : generator model	68
Figure 4. 2 : modèle discriminateur	69
Figure 4. 3 : outils de développements	70
Figure 4. 4 : Importation de données à partir de drive	70
Figure 4. 5 : Unzip le fichier de données	70
Figure 4. 6 : Importation des bibliographies nécessaire	70
Figure 4. 7 : fonction de chargement de dataset	71
Figure 4. 8 : Définition des hyperparamètres	72
Figure 4. 9 : Fonction de création de model Génération	72
Figure 4. 10 : Fonction de création de model discriminateur	73
Figure 4. 11 : Lancement le discriminateur et le générateur	73
Figure 4. 12 : fonction de génération des images avec le générateur	74
Figure 4. 13 : Sauvegarde les images de génération	74
Figure 4. 14 : Evaluation de discriminateur	75
Figure 4. 15 : Test de prédiction	75
Figure 4. 16 : Lancement de code	76
Figure 4. 17 : Résultats de générateur	76
Figure 4. 18 : Matrice de confusion	77
Figure 4. 19 : Acc et loss de D et G	78
Figure 4. 20 : rapport de classification	78
Figure 4. 21 : Matrice de confusion	79

Liste des Tableaux

page

Tableau 1.1 : le score de caractéristique pathologiste	33
Tableau 2 : Description Le grade du CCIS	34
Tableau 2.1 : Différence entre l'apprentissage supervisées et non supervisées	41
Tableau 2.2 : L'apprentissage automatique VERS L'apprentissage profond.	43
Tableau3.1 : Résumé des techniques d'augmentation d'image de base et avancées.	61
Tableau 3.2 : Résumé des articles utilisant l'augmentation d'image	63
Tableau 3.3 : Résumé des articles utilisant l'augmentation d'image	64
Tableau 3.4 : Comparaison de la précision de différente méthode lors de test sur un jeu des données unique et combinées.	65
Tableau 3.5 : Compare les performances de classification du cancer du sein avant et après l'augmentation des données avec la synthèse images. Précision du classement	65

Introduction Générale

1. Introduction

La recherche dans le domaine de l'imagerie médicale utilisant des approches d'apprentissage profond est devenue progressivement contingente. Les découvertes scientifiques révèlent que les performances des méthodes d'apprentissage profond supervisé dépendent fortement de la taille de l'ensemble de formation, que les radiologues experts doivent annoter manuellement. Ce dernier est une tâche assez fatigante et chronophage. Par conséquent, la plupart des images biomédicales librement accessibles les ensembles de données sont de petite taille. De plus, il est difficile d'avoir des ensembles de données d'images médicales de grande taille en raison de problèmes de confidentialité et juridiques. Par conséquent, pas un petit nombre d'apprentissage profond supervisé les modèles sont sujets au surajustement et ne peuvent pas produire de sortie généralisée. L'un des plus populaires Les méthodes pour atténuer le problème ci-dessus portent le nom d'augmentation des données. Cette technique aide augmenter la taille de l'ensemble de formation en utilisant diverses transformations et a été annoncé pour améliorer la performance du modèle lorsqu'il est testé sur de nouvelles données. Ce projet a étudié différentes augmentations de données techniques employées sur les images médicales du cancer du sein. Le projet vise à donner un aperçu des connaissances de base et techniques d'augmentation basées sur l'apprentissage profond.

2. Problématique

Parmi les différents domaines de l'intelligence artificielle, le Deep Learning (DL) est largement adopté pour le traitement et l'analyse du cancer du sein. DL a été appliqué avec succès à plusieurs tâches de vision par ordinateur telles que la segmentation, la détection et la classification d'objets, principalement grâce aux taux de précision atteints par les réseaux de neurones convolutifs (CNN). CNN ont les capacités d'apprendre automatiquement les fonctionnalités à travers plusieurs couches de réseau à partir d'un grand ensemble d'ensembles de données étiquetés [1]. Concernant le thème de l'analyse d'images biomédicales, les CNN ont été utilisés avec succès pour diverses tâches telles que la classification des lésions ou des tumeurs, détection des régions suspectes et détection des anomalies [2–4]. Les solutions basées sur DL servent comme outil de contre-expertise pour les radiologues experts et les aide à la prise de décision, et une bonne planification du traitement [5]. Cependant, il doit y avoir une grande quantité de vérité terrain construire un modèle DL capable d'inférer des connaissances à partir de données et d'éviter le modèle étant très précis uniquement sur les images du jeu de données d'entraînement. Ce dernier porte le nom de surajustement [6,7] et représente un problème critique à surmonter pour avoir un modèle capable de fournir des capacités d'inférence de connaissances appropriées sur un domaine d'application donné. De plus, avoir des données de haute qualité et annotées manuellement est une tâche qui prend du temps et tâche dépendante de l'expert. Malheureusement, c'est assez courant dans le cadre l'analyse du cancer du sien [8–10]. L'une des tâches les plus difficiles pour les modèles DL est la généralisation, avec la généralisation étant la capacité des modèles à reconnaître les catégories pour lesquelles ils ont été entraînés pour de nouvelles données [11,12]. Le modèle avec une mauvaise généralisation ne fonctionne généralement pas bien en raison d'un

surajustement élevé sur l'ensemble d'entraînement. Le surajustement peut être observé d'une manière ou d'une autre dans le graphique montrant la précision de la validation à chaque époque de la phase d'entraînement [1]. Montre la représentation picturale des modèles avec et sans surajustement. La formation et la courbe de perte de validation diminue progressivement et simultanément, ce qui est parfait circonstance, comme indiqué dans. Le côté droit de la figure montre le surajustement, dans lequel la perte de validation commence à croître après un certain nombre d'époques. En revanche, la perte d'entraînement ne cesse de diminuer. Cela est dû à l'incapacité du modèle à fonctionner efficacement avec des données inconnues ou nouvelles. L'une des raisons de ce phénomène pourrait être le manque de suffisamment d'échantillons d'entraînement. L'erreur de validation des modèles DL appropriés devrait continuer à diminuer avec l'erreur d'apprentissage. Les méthodes d'augmentation des données peuvent aider à atteindre cet objectif tâche. Les données augmentées peuvent caractériser l'ensemble inclusif de points de données d'entrée et minimiser la distance entre les données de validation et de formation. Les techniques d'augmentation des données s'appliquent modifications des ensembles de données de formation pour produire plus d'échantillons. De plus, cette technique aide le modèle évite d'apprendre des caractéristiques trop spécifiques aux données d'origine, ce qui se traduit par une modèle généralisé avec des performances améliorées sur le jeu de données de test. Répartition des classes le déséquilibre dans les ensembles de données est un autre défi commun. Par exemple, la classification binaire des problèmes survient lorsqu'une classe (la classe minoritaire) détient considérablement moins d'échantillons que l'autre classe (la classe majoritaire). De ce fait, le modèle peut être biaisé vers la classe majoritaire, ce qui peut entraîner une erreur de classification. Augmenter la classe minoritaire des images peut être utilisées pour atténuer le problème de déséquilibre. L'augmentation des données n'est pas la seule approche pour réduire l'effet du surajustement et du déséquilibre de classe. Autres options pour éviter le surajustement dans les modèles DL est également exploré.

3. Structure de mémoire

La Structure de mémoire est composée d'une introduction générale et conclusion générale et quatre chapitres.

Le premier chapitre. Nous présenterons brièvement l'anatomie du sein chez la femme, ce qui va nous permettre d'aborder la notion du cancer du sein. Ensuite, nous exposerons la procédure du les outils dépistage du cancer du sein et le système lymphatique et quelque Classification histologique.

Dans le deuxième chapitre, une éducation sur l'IA et on déterminer les différentes techniques Et ces architectures.

Le troisième chapitre c'est une éducation colabe sur augmentation des données, Concepts, méthodes et outils. Et déterminer avec un 'état de l'art des techniques utilisées pour l'augmentation des données utilises pour la classification du cancer du sien.

Le quatrième chapitre nous présentons notre travail d'augmentation de dataset de cancer de sein base sur l'algorithme de GAN.

4. Contribution

L'objectif principale derrière ce projet est de créer un modèle utilisant l'apprentissage en profondeur, en particulier dans le domaine des GAN, et de fournir la même précision que l'étude de la littérature menée. Notre contribution unique consiste à construire un modèle GAN à l'aide de techniques d'apprentissage supervisées pour la catégorisation des images histopathologiques dans la prédiction du cancer du sein. Afin d'améliorer la précision du modèle et de rendre le modèle approprié pour l'apprentissage supervisé, nous modifierons également certaines limitations architecturales. Nous suggérons plus d'élan, ce qui a stabilisé la majorité de notre processus d'apprentissage.

Il est à noter que les performances de notre modèle GAN montrent que le système distingue précisément les deux classes (97% pour la Classe 0 et 92% pour la Classe 1) car les valeurs hors diamètre sont très faibles et équilibrées. La précision globale de la classification pour D sur 1 000 tests était de 94,700 000 %.

Chapitre : 01

Contexte Médical

1. Introduction

Cancer du sein reste un réel problème de santé public et un sujet de recherche d'actualité très délicat à aborder. Dans ce chapitre, nous présenterons brièvement l'anatomie du sein chez la femme, ce qui va nous permettre d'aborder la notion du cancer du sein. Ensuite, nous exposerons la procédure du les outils dépistage du cancer du sein et le système lymphatique et quelque Classification histologique

2. L'anatomie

Chaque sein à 15 à 20 sections, appelées lobes. Ils sont disposés comme les pétales d'une marguerite. Chaque lobe a de nombreuses structures plus petites appelées lobules. Ceux-ci se terminent par des dizaines de minuscules bulbes qui peuvent produire du lait. Les lobes, les lobules et les bulbes sont tous reliés par de minces tubes appelés conduits. Ces conduits mènent au mamelon au centre d'une zone sombre de la peau appelée l'aréole. Illustration de l'anatomie du sein féminin, vue de face Illustration de l'anatomie du sein féminin, vue de côté La graisse remplit les espaces entre les lobules et les conduits. Il n'y a pas de muscles dans le sein, mais des muscles se trouvent sous chaque sein et recouvrent les côtes.

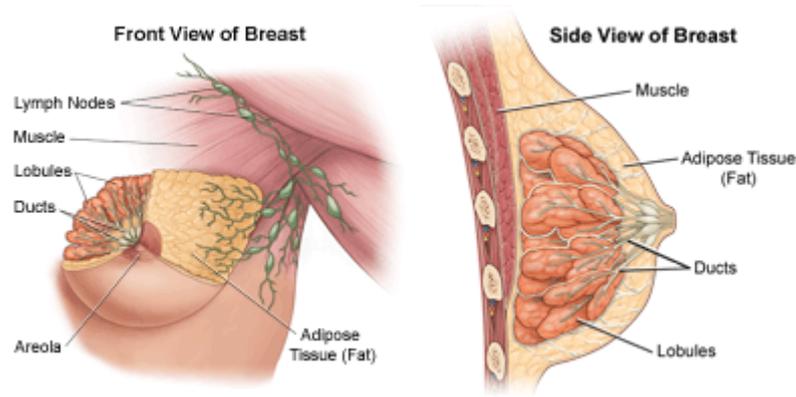


FIGURE 1.1 : L'ANATOMIE DU SEIN

Chaque sein contient également des vaisseaux sanguins et des vaisseaux qui transportent la lymphe. Les vaisseaux lymphatiques conduisent à de petits organes en forme de haricot appelés ganglions lymphatiques. Ces ganglions lymphatiques se trouvent en grappes sous le bras, au-dessus de la clavicule et dans la poitrine. Ils sont également dans de nombreuses

3. Cancer du sien

Le cancer du sein prend naissance dans les cellules du sein [13]. La tumeur cancéreuse (maligne) est un groupe de cellules cancéreuses qui peuvent envahir les tissus voisins et les détruire. Elle peut également se propager (métastases) à d'autres parties du corps.

Les cellules du sein subissent parfois des changements qui rendent leur mode de croissance ou leur comportement anormal. Ces changements peuvent engendrer des affections non cancéreuses (bénignes) du sein, comme l'hyperplasie atypique et des kystes [14]. Ils peuvent aussi entraîner la formation de tumeurs non cancéreuses, dont les papillomes intra canaux.

Dans certains cas, cependant, des modifications dans les cellules mammaires peuvent causer un cancer du sein. Le cancer du sein apparaît le plus souvent dans les cellules tapissant les canaux, qui sont des tubes qui transportent le lait des glandes au mamelon. Ce type de cancer du sein est appelé carcinome canalaire [15]. Le cancer peut aussi se former dans les cellules des lobules, qui sont les groupes de glandes productrices de lait. Ce type de cancer porte le nom de carcinome lobulaire [16]. Le carcinome canalaire et le carcinome lobulaire peuvent être in situ, c'est-à-dire que le cancer reste dans son emplacement d'origine et qu'il n'a pas envahi les tissus voisins. Ils peuvent également être infiltrant, ou invasifs, c'est-à-dire qu'ils ont envahi les tissus voisins.

Des types de cancer du sein moins fréquents peuvent aussi se manifester [17]. Le cancer inflammatoire du sein, la maladie de Paget du sein et le cancer du sein triple négatif en sont des exemples. Des types rares de cancer du sein sont entre autres le lymphome non hodgkinien et le sarcome des tissus mous.

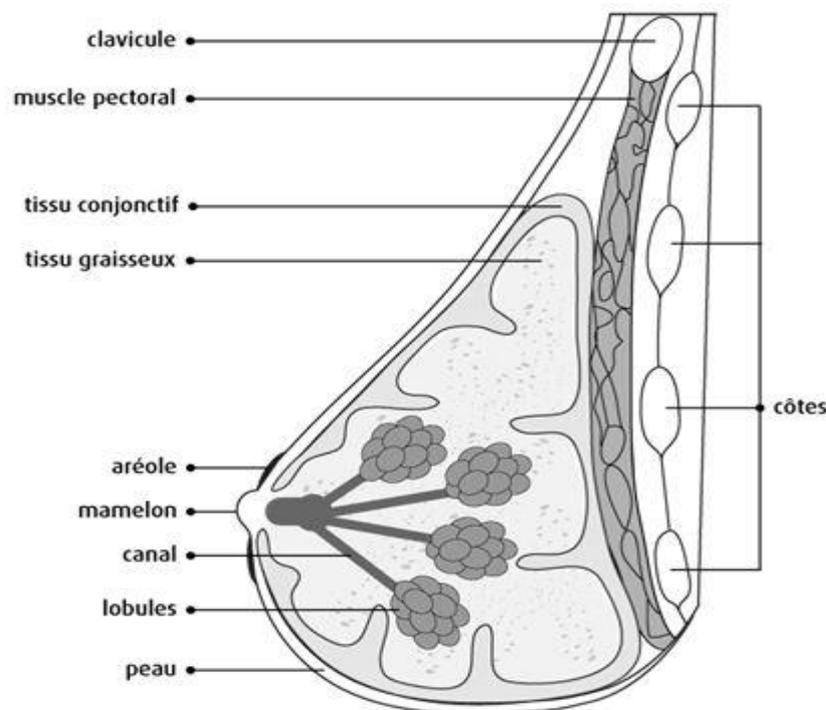


Figure1.2 : Schéma d'une vue latérale du sein [17]

3.1 Système lymphatique du sein

Le sein contient de nombreux vaisseaux sanguins et lymphatiques [18]. Les vaisseaux lymphatiques sont des tubes minces semblables aux vaisseaux sanguins. Ils recueillent et transportent la lymphe loin du sein jusqu'à de petites masses de tissu lymphatique en forme de haricot appelées ganglions lymphatiques, qui entourent la région mammaire. Les vaisseaux et les ganglions lymphatiques font partie du système lymphatique, qui aide à combattre les infections.

Plusieurs groupes de ganglions lymphatiques évacuent la lymphe de chaque sein. On les trouve des deux côtés du corps.

Les **ganglions sus-claviculaires** se trouvent au-dessus de la clavicule.

Les **ganglions infra-claviculaires**, ou **sous-claviculaires**, se trouvent sous la clavicule.

Les **ganglions mammaires internes** se trouvent à l'intérieur du thorax, autour du sternum.

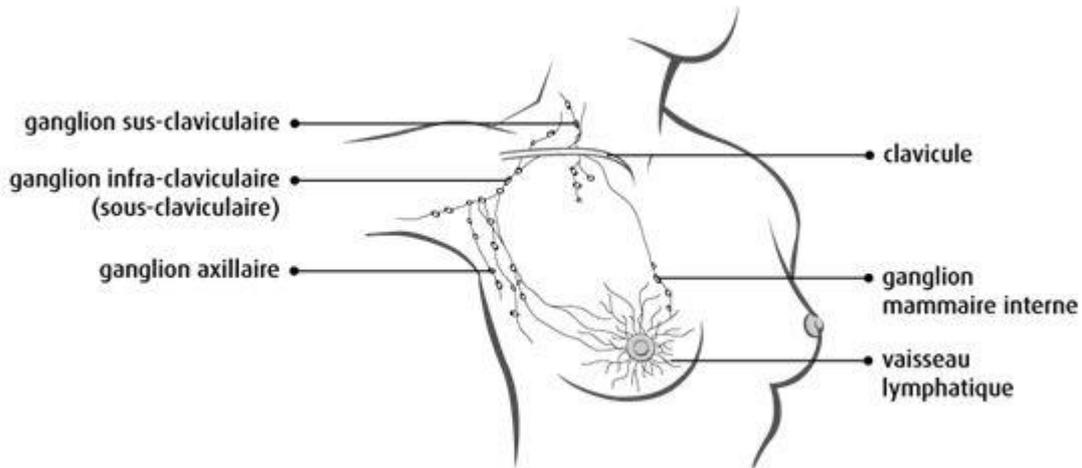


Figure1.3. Schéma des ganglions lymphatiques du sein [18]

Les **ganglions lymphatiques axillaires** se trouvent à l'aisselle (creux axillaire). On en compte de 30 à 50 par aisselle. Ils sont répartis en 3 niveaux selon leur proximité au large muscle du thorax appelé grand pectoral. Quand le cancer du sein se propage, il le fait habituellement aux ganglions de niveau I, puis aux ganglions de niveau II et ensuite aux ganglions de niveau III.

- Les ganglions de niveau I (région axillaire inférieure) longent le bord externe du muscle situé sous le grand pectoral appelé petit pectoral.
- Les ganglions de niveau II (région axillaire centrale) se trouvent sous le muscle petit pectoral.
- Les ganglions de niveau III (région axillaire supérieure) longent le bord interne du petit pectoral.

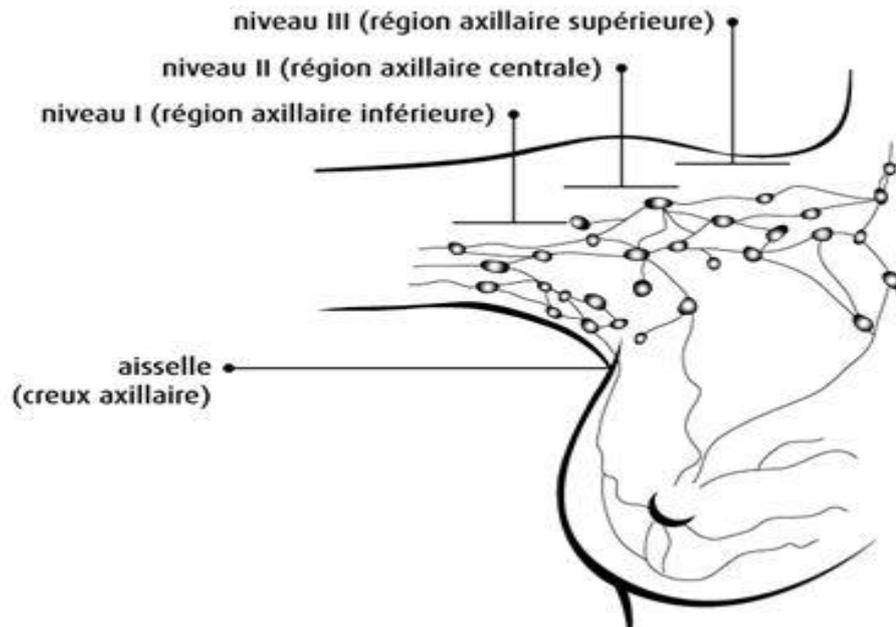


Figure1.5. Schéma des ganglions axillaires [18]

4. Facteurs de risque du cancer du sein

Un facteur de risque est quelque chose, comme un comportement, une substance ou un état, qui accroît le risque d'apparition d'un cancer [19]. La plupart des cancers sont attribuables à de nombreux facteurs de risque, mais il arrive que le cancer du sein apparaisse chez des femmes qui ne présentent aucun des facteurs de risque décrits ci-dessous [20]. La plupart des cancers du sein affectent la femme [21]. C'est surtout parce que leurs cellules mammaires sont exposées aux hormones femelles appelées œstrogène et progestérone. Ces hormones, en particulier l'œstrogène, sont liées au cancer du sein et elles favorisent la croissance de certains de ces cancers

- Antécédents personnels de cancer du sein [22].
- Antécédents familiaux de cancer du sein et d'autres cancers
- Mutations des gènes BRCA [23].
- Seins denses.
- Certains troubles génétiques [24].
- Autres mutations génétiques [25].
- Descendance juive ashkénaze [26].
- Antécédents de reproduction [27].
- Exposition à des rayonnements ionisants
- Hormonothérapie substitutive [28].
- Contraceptifs oraux.
- Hyperplasie atypique [29].
- Alcool [30].
- Obésité [31].
- Inactivité physique.

- Statut socio-économique élevé.
- Grande taille à l'âge adulte.

Des preuves convaincantes permettent d'affirmer que les facteurs suivants font augmenter votre risque de cancer du sein.

5. Symptômes du cancer du sein

Il est possible que le cancer du sein ne cause aucun signe ni symptôme aux tout premiers stades de la maladie. Les symptômes apparaissent quand la tumeur au sein est suffisamment grosse pour qu'on sente la masse au toucher ou quand le cancer s'est propagé aux tissus et organes voisins. D'autres affections médicales peuvent causer les mêmes symptômes que le cancer du sein [32].

Le symptôme le plus fréquent du carcinome canalaire est une masse ferme ou dure qui est très différente du reste du tissu mammaire. Elle peut sembler fixée à la peau ou au tissu mammaire voisin. La masse ne rétrécit pas ou ne disparaît pas et ne réapparaît pas au cours du cycle menstruel. Elle peut être sensible mais n'est généralement pas douloureuse. (La douleur est plus souvent le symptôme d'une affection non cancéreuse.)

Il arrive souvent que le carcinome lobulaire ne forme pas de masse. On a plus l'impression que le tissu mammaire s'épaissit ou durcit.

Les autres symptômes du cancer du sein canalaire ou lobulaire peuvent être ceux-ci :

Masse à l'aisselle (creux axillaire) ; changement de la taille ou de la forme du sein ;

Changements mamelonnaires, comme un mamelon qui commence soudainement à pointer vers l'intérieur (mamelon inversé) ; écoulement du mamelon sans qu'on le comprime ou qui est teinté de sang [33].

Les signes et symptômes tardifs se manifestent quand la masse cancéreuse grossit ou se propage à d'autres parties du corps, dont d'autres organes : Les symptômes tardifs du cancer du sein comprennent les suivants [34] :

douleur osseuse; perte de poids; nausées; perte d'appétit; jaunisse; essoufflement; toux; maux de tête; vision double; faiblesse musculaire.

Le cancer inflammatoire du sein et la maladie de Paget du sein causent des symptômes différents [35].

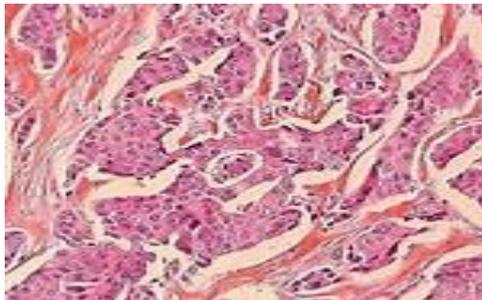


Figure1.6 Carcinome lobulaire [35]

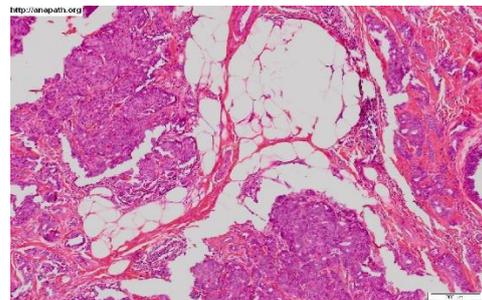


Figure1.7 Carcinome canalaire [35]

6. Diagnostic du cancer du sein

On a habituellement recours aux tests qui suivent pour éliminer ou diagnostiquer le cancer du sein. Bien des tests permettant de poser le diagnostic de cancer sont également employés pour en déterminer le stade, c'est-à-dire jusqu'où la maladie a progressé. Votre médecin pourrait aussi vous faire passer d'autres examens afin de vérifier votre état général de santé et d'aider à planifier votre traitement.

6.1. Biopsie

La biopsie est le seul moyen de diagnostiquer avec certitude le cancer du sein. Lors d'une biopsie, le médecin prélève des tissus ou des cellules du corps afin qu'ils soient analysés en laboratoire. Le rapport du pathologiste indiquera s'il y a ou non des cellules cancéreuses dans l'échantillon.

Le type de biopsie sera choisi en fonction de la masse, à savoir si elle est palpable, ce qui signifie qu'on peut la sentir au toucher, ou non palpable, c'est-à-dire qu'on ne peut pas la sentir au toucher. Le médecin peut avoir recours à la mammographie ou à l'échographie pour aider à trouver la région à analyser. On fait la plupart des biopsies à l'hôpital, et vous pouvez retourner à la maison une fois qu'elle est terminée.

Lors de la biopsie à l'aiguille fine (BAF), on utilise une aiguille très fine et une seringue pour prélever une petite quantité de tissu dans la masse. Les médecins y ont recours pour savoir si la masse est un kyste ou une tumeur solide. La BAF ne permet pas de déterminer si le cancer est non infiltrant ou infiltrant. Apprenez-en davantage sur la biopsie à l'aiguille fine (BAF).

Lors de la biopsie par forage, on utilise une aiguille creuse particulière pour prélever du tissu dans le corps. Les médecins y ont recours pour prendre un échantillon dans une région suspecte du sein. Ils peuvent faire plusieurs prélèvements dans la région lors de l'intervention. Il arrive que les médecins aient recours à un dispositif d'aspiration spécial pour retirer plus de tissu avec l'aiguille creuse. Cette technique est appelée biopsie par aspiration. Apprenez-en davantage sur la biopsie par forage.

Une biopsie par forage sous guidage stéréotaxique est un type de biopsie lors de laquelle on utilise des images tridimensionnelles (stéréotaxiques) pour trouver la position exacte d'une tumeur ou d'une anomalie dans le sein. Le médecin se sert de ces images pour guider l'aiguille lors de la biopsie. On a recours à la biopsie par forage sous guidage stéréotaxique pour faire des prélèvements dans une masse qu'on peut observer sur les clichés d'imagerie mais qu'on ne peut pas sentir au toucher. Apprenez-en davantage sur la biopsie par forage sous guidage stéréotaxique.

Lors de la biopsie à l'emporte-pièce, on se sert d'un instrument creux et tranchant pour enlever une région de peau et le tissu sous-jacent. On y a recours pour diagnostiquer le cancer inflammatoire du sein, c'est-à-dire dont les cellules cancéreuses sont présentes dans les vaisseaux lymphatiques de la peau. Apprenez-en davantage sur la biopsie à l'emporte-pièce.

6.2. Biopsie des ganglions lymphatiques

La biopsie des ganglions lymphatiques est une intervention chirurgicale au cours de laquelle on enlève des ganglions en vue d'un examen microscopique afin de savoir s'ils sont atteints par le cancer.



Figure 1.8 microscopique

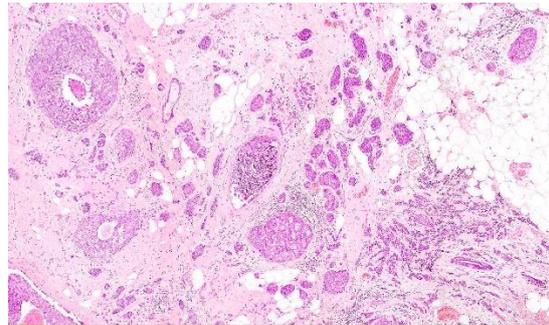


Figure 1.9 cancer du sien microscopie

Les cellules du cancer du sein peuvent se détacher de la tumeur et circuler dans le système lymphatique. Elles peuvent d'abord se propager jusqu'aux ganglions lymphatiques de l'aisselle (ganglions axillaires). Le médecin utilise le nombre de ganglions lymphatiques atteints par le cancer pour l'aider à établir le stade du cancer du sein.

La **biopsie du ganglion sentinelle (BGS)** permet d'identifier et d'enlever le ganglion sentinelle afin de savoir s'il contient des cellules cancéreuses. Le ganglion sentinelle est le premier ganglion lymphatique d'une chaîne ou d'un groupe ganglionnaire qui reçoit la lymphe provenant de la région qui entoure la tumeur. Le médecin enlèvera d'autres ganglions lymphatiques seulement si le ganglion sentinelle est atteint par le cancer. On propose une BGS si la tumeur au sein mesure moins de 5 cm et si les ganglions axillaires ne peuvent pas être sentis au toucher lors de l'examen physique. Apprenez-en davantage sur la biopsie du ganglion sentinelle.

L'**évidement ganglionnaire axillaire** permet d'enlever les ganglions lymphatiques de l'aisselle. L'évidement ganglionnaire axillaire est la méthode standard d'examen des ganglions lymphatiques employée par les médecins dans la plupart des centres au Canada.

6.3. Analyse du statut des récepteurs hormonaux

L'œstrogène et la progestérone sont des hormones qui peuvent stimuler la croissance des cellules du cancer du sein. L'analyse du statut des récepteurs hormonaux sert à vérifier s'il y a des récepteurs d'œstrogènes (ER) et de progestérone (PR) dans les cellules cancéreuses du sein. Ces renseignements aideront votre équipe de soins à déterminer quels traitements seront les plus efficaces pour vous.

6.4. Examen histologie

Certaines anomalies indéterminées ou suspectes nécessitent des examens plus poussés. Pour faire face aux mammographies douteuses ou aux échographies ambiguës un examen histologique est recommandé. Ce dernier est pratiqué sur les tissus prélevés par ponction cytologique ou biopsie. L'aspiration ou la ponction à l'aiguille utilise une fine aiguille pour aspirer du liquide ou des cellules provenant de la lésion suspecte.[16]

L'intervention est rapide, mais peut être inconfortable à cause de la sensibilité des seins. Cependant les microbiopsies sont indiquées pour explorer les anomalies de type masses ou opacités, visibles. Elles sont faites sous échographie à l'aide d'un pistolet automatique muni d'une aiguille.

Les macrobiopsies par mammotome (figure 1.8) sont indiquées pour explorer les foyers de MCS. Après une anesthésie locale et une petite incision de 3-4 mm, la sonde (aiguille creuse) est introduite dans la zone choisie (le tissu suspect), creusée par un petit couteau cylindrique rotatif, puis aspirer.[17]

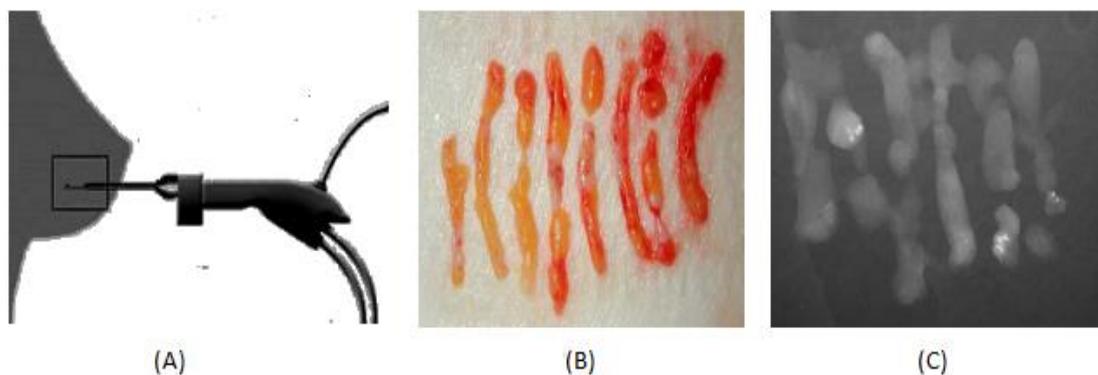


FIGURE 1.10 : LA MACROBIOPSIE PAR MAMMOTOME : A) LA MAMMOTOME B) LES PIÈCES PRÉLEVÉES C) L'IMAGE RADIOGRAPHIQUE.

6.5. . Scintigraphie osseuse

Lors d'une scintigraphie osseuse, on emploie des matières radioactives qui se fixent sur les os (produits radio pharmaceutiques) et un ordinateur pour créer une image des os. La scintigraphie osseuse permet de savoir si le cancer du sein s'est propagé aux os (métastases osseuses).

On a recours à la scintigraphie osseuse si la femme éprouve de la douleur osseuse ou si le taux de phosphatase alcaline est plus élevé que la normale. Le médecin peut aussi prescrire une scintigraphie osseuse si la tumeur au sein mesure plus de 5 cm ou s'il peut sentir au toucher les ganglions lymphatiques à l'aisselle (ganglions axillaires). On ne fait pas de scintigraphie osseuse chez la femme atteinte d'un cancer du sein de stade I.

6.6. . Mammographie diagnostique

La mammographie diagnostique est une radiographie qui emploie des radiations de faible dose pour produire des images du sein. On y a recours pour faire le suivi de résultats anormaux observés lors d'une mammographie de dépistage ou d'un examen clinique des seins.

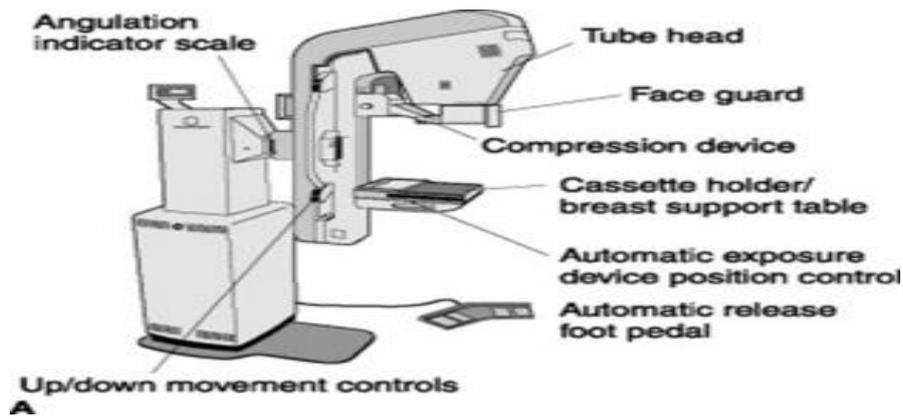


Figure1.11. Mammographie | Clé de radiologie

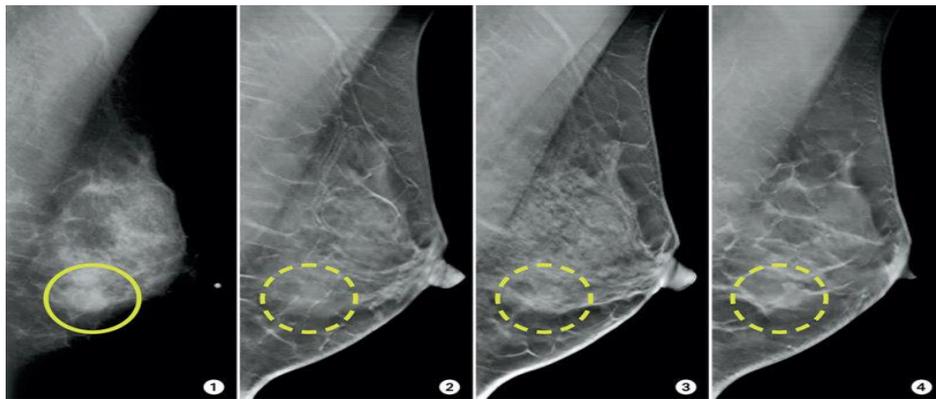


Figure1.12 : Les mammographies 3D peuvent améliorer la précision du dépistage du cancer du sein

La mammographie permet aussi de trouver une région anormale lors d'une biopsie.

6.7. Échographie

Lors d'une échographie, on a recours à des ondes sonores de haute fréquence pour produire des images de parties du corps. Elle permet de savoir si une masse au sein est une tumeur solide ou un kyste. Les médecins peuvent aussi se servir de l'échographie pour guider l'aiguille à biopsie vers la région à analyser. La femme atteinte d'un cancer du sein de stade avancé pourrait passer une échographie afin de savoir si le cancer s'est propagé au foie (métastases hépatiques).



Figure1.13 : Échographie du cancer du sein

6.8. Radiographie

Lors d'une radiographie, on emploie des radiations de faible dose pour produire des images des structures du corps sur film. On y a recours pour savoir si le cancer du sein s'est propagé aux poumons.

6.9. IRM

En imagerie par résonance magnétique (IRM), on a recours à de puissantes forces magnétiques et à des ondes radioélectriques pour produire des images en coupes des organes, tissus, os et vaisseaux sanguins du corps. Un ordinateur assemble les images en clichés à 3 dimensions.

L'IRM n'est pas régulièrement employée pour diagnostiquer le cancer du sein. Le médecin peut y avoir recours pour mieux examiner une anomalie observée lors de la mammographie s'il ne parvient pas à l'identifier à l'aide d'autres examens ou si les résultats d'autres tests ne sont pas clairs.

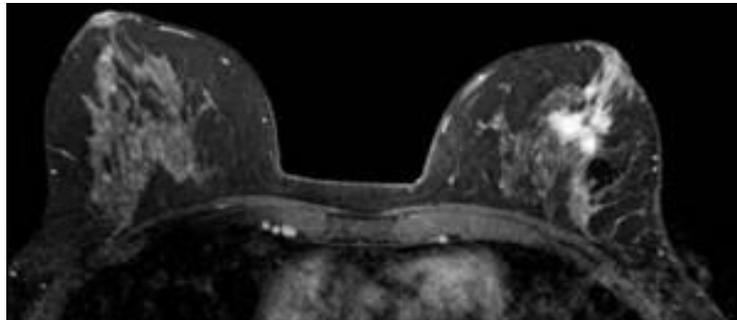


Figure1.14 : une image d'une IRM.

7. Classification histologique du cancer du sein

Le grade est défini par l'apparence des cellules cancéreuses qu'on compare à celle des cellules normales. Pour établir le grade du cancer du sein, le pathologiste examine au microscope un échantillon de tissu prélevé dans la tumeur. Le pathologiste évalue également certaines caractéristiques particulières des cellules cancéreuses afin d'assigner un grade de 1 à 3 au cancer du sein. Plus ce nombre est bas, plus le grade l'est aussi.

On utilise le mot différenciation pour désigner à quel point les cellules cancéreuses sont différentes.

Les cellules cancéreuses de bas grade sont bien différenciées. Elles ont presque l'air de cellules normales. Elles ont tendance à se développer lentement et risquent moins de se propager.

Les cellules cancéreuses de haut grade sont peu différenciées ou indifférenciées. Leur apparence est moins normale, ou plus anormale. Elles ont tendance à se développer plus rapidement et sont plus susceptibles de se propager que les cellules cancéreuses de bas grade.

Connaître le grade donne à votre équipe de soins une idée de la rapidité à laquelle le cancer peut se développer et de sa probabilité de propagation. Cela l'aide à planifier votre traitement. Le grade peut aussi aider l'équipe de soins à établir votre pronostic et à prévoir comment le cancer pourrait réagir au traitement.

7.1. . Carcinome canalaire ou lobulaire infiltrant

Le système de classification histologique le plus souvent employé pour les cancers du sein qui se sont propagés aux tissus voisins, soit des cancers infiltrant, se base sur 3 caractéristiques des cellules de la tumeur qui les différencient des cellules saines :

La formation de tubules, qui indique le pourcentage des cellules tumorales qui contiennent des structures en forme de tubes appelées tubules

Le pléomorphisme nucléaire, qui indique jusqu'à quel point le noyau

De chaque cellule cancéreuse diffère de celui des cellules normales

La fréquence des mitoses, qui indique le nombre de cellules qui se divisent activement dans la tumeur

Le pathologiste assigne à chaque caractéristique un score de 1 à 3 avant de les additionner pour établir le grade.

Tableau 1.1 : le score de caractéristique pathologiste [17].

Grade	Score total	Description
1 (bas)	3 à 5	Les cellules cancéreuses sont bien différenciées. Elles ont presque l'air de cellules normales.
2(intermédiaire)	6 ou 7	Les cellules cancéreuses sont modérément différenciées. Elles se classent entre le grade 1 et le grade 3.
3 (haut)	8 ou 9	Les cellules cancéreuses sont peu différenciées ou indifférenciées. Leur apparence est moins normale, ou plus anormale, que celle des cellules saines.

7.2. Carcinome canalaire in situ (CCIS)

Le grade du CCIS se base sur la différenciation des cellules cancéreuses, l'apparence du noyau de chaque cellule cancéreuse et la présence de cellules cancéreuses mortes ou mourantes (nécrose) dans un échantillon de la tumeur.

Tableau 02 : Description Le grade du CCIS [17].

Grade	Description
1 (bas)	Le noyau de chaque cellule cancéreuse est de taille petite à moyenne et les noyaux de toutes les cellules cancéreuses ont la même forme. Il n'y a pas de nécrose dans l'échantillon.
2 (intermédiaire)	Le noyau de chaque cellule cancéreuse est de taille petite à moyenne et les noyaux de toutes les cellules cancéreuses ont la même forme. On observe quelques petites régions de nécrose dans l'échantillon.
3 (haut)	Le noyau de chaque cellule cancéreuse est de grande taille et les noyaux de toutes les cellules cancéreuses sont de forme inégale. On peut observer une nécrose dans l'échantillon.

8. Conception assistée par ordinateur

L'idée d'un logiciel de Conception Assistée par Ordinateur (CAO) en manipulation d'images médicales. L'étude aborde également le concept d'images matricielles et vectorielles, car les images médicales seront appelées graphiques matriciels et CAO sous forme de graphiques vectoriels. La vectorisation permet à une image d'être plus flexible et peut être manipulée afin que plus d'informations puissent y être chargées. En tant que tel, il n'est pas impossible que la méthode de vectorisation puisse également être effectuée sur des images médicales à l'aide de logiciels de CAO tels qu'AutoCAD, Solidworks et autres. Une image médicale au format médical est convertie au format JPEG à l'aide du logiciel Medweb. Ensuite, en utilisant le logiciel Image2CAD, l'image médicale est convertie au format DXF. Les résultats ont montré que l'image médicale du patient peut être manipulée à l'aide du logiciel AutoCAD. Une étude montre que la CAO n'est pas seulement utilisée dans le domaine de la fabrication, mais qu'elle peut également être utilisée dans le domaine médical.

- ✚ Traitement d'images médicales et CAO : une interface entre l'ingénierie et la science médicale L'expertise humaine est une ressource rare dont l'approvisionnement n'est jamais garanti L'humain se fatigue, oublie ou devient tout simplement indolent Les humains sont incohérents dans leurs décisions quotidiennes pour le même ensemble de données L'humain peut mentir, mourir et se cacher
- ✚ La CAO peut diagnostiquer moniteur analyser, interpréter planifier, motif, instruire clarifier Apprendre
- ✚ La CAO aide à Visualisation : amélioration de l'analyse visuelle Détection : Détecter la présence d'une manifestation de la maladie Localisation et segmentation : Localisez

ou segmentez les régions spatiales contenant la manifestation de la maladie D'autres utilitaires peuvent être utilisés pour mesurer diverses structures à partir d'images (longueur, volume, etc.

Conclusion

Dans ce chapitre ont été abordées des notions de généralité en rapport avec le cancer du sein. Après avoir présenté de façon concise l'anatomie du sein, en passant par le dépistage du cancer du sein, système lymphatique et classification histologique. L'objectif qui sous-tend la présentation de ces éléments, c'est de mettre en lumière les difficultés rencontrées par les radiologues dans l'analyse du cancer du sien. Notre travail va s'orienter vers Un algorithme d'augmentation de donnés appliqué sur dataset du cancer du sein à partir une éducation sur l'intelligence artificielle le sujet de notre suivant chapitre.

Chapitre 02 :

Intelligence artificielle

1. Introduction

L'intelligence artificielle, l'un des domaines les plus prometteurs de l'innovation en santé est l'application de l'intelligence artificielle (IA) à l'imagerie médicale, y compris, mais sans s'y limiter, le traitement et l'interprétation d'images. En effet, l'IA peut trouver de multiples applications, de l'acquisition et du traitement d'images au Reporting assisté, à la planification du suivi, au stockage de données, à l'exploration de données et bien d'autres. En raison de ce large éventail d'applications, l'IA devrait avoir un impact massif sur la vie quotidienne du radiologue.

2. Intelligence artificielle

Le terme IA est appliqué lorsqu'un appareil imite des fonctions cognitives, telles que l'apprentissage et la résolution de problèmes [36]. Plus généralement, l'IA fait référence à un domaine de l'informatique dédié à la création de systèmes effectuant des tâches qui nécessitent généralement l'intelligence humaine, se ramifiant en différentes techniques [37]. L'apprentissage automatique, un terme introduit par Arthur Samuel en 1959 pour décrire un sous-domaine de l'IA [38] qui comprend toutes les approches permettant aux ordinateurs d'apprendre à partir de données sans être explicitement programmé, a été largement appliqué à l'imagerie médicale [39]. Parmi les techniques qui relèvent du L'apprentissage automatique, l'apprentissage en profondeur est devenu l'une des plus prometteuses. En effet, DL est une technique appartenant à ML, qui à son tour fait référence à une famille d'IA plus large (Fig. 2.1). En particulier, les méthodes DL appartiennent aux méthodes d'apprentissage de la représentation à plusieurs niveaux de représentation, qui traitent des données brutes pour effectuer des tâches de classification ou de détection [40].

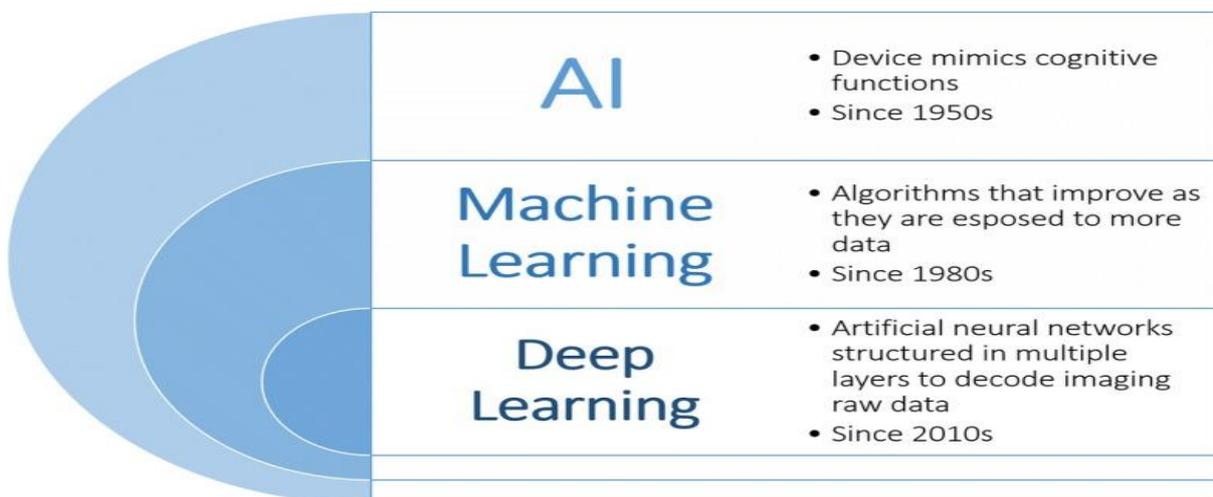


FIGURE 2.1 : LE CONTEXTE DE DEEP LEARNING.

3. Apprentissage automatique

3.1. Définition

Apprentissage automatique est un domaine d'investigation consacré à la compréhension et à la construction de méthodes qui "apprennent", c'est-à-dire des méthodes qui exploitent les

données pour améliorer les performances sur un ensemble de tâches. [36] Il est considéré comme faisant partie de l'intelligence artificielle. Les algorithmes d'apprentissage automatique construisent un modèle basé sur des données d'échantillon, appelées données d'apprentissage, afin de faire des prédictions ou des décisions sans être explicitement programmés pour le faire.

3.2. Apprentissage supervisé

Les algorithmes d'apprentissage supervisé construisent un modèle mathématique d'un ensemble de données qui contient à la fois les entrées et les sorties souhaitées [34].

Les données sont appelées données d'apprentissage et consistent en un ensemble d'exemples d'apprentissage. Chaque exemple de formation a une ou plusieurs entrées et la sortie souhaitée, également appelée signal de supervision. Dans le modèle mathématique, chaque exemple d'apprentissage est représenté par un tableau ou un vecteur, parfois appelé vecteur de caractéristiques, et les données d'apprentissage sont représentées par une matrice. Grâce à l'optimisation itérative d'une fonction objective, les algorithmes d'apprentissage supervisé apprennent une fonction qui peut être utilisée pour prédire la sortie associée à de nouvelles entrées. Une fonction optimale permettra à l'algorithme de déterminer correctement la sortie pour les entrées qui ne faisaient pas partie des données d'apprentissage.

3.3. Apprentissage non supervisé

Les algorithmes d'apprentissage non supervisé prennent un ensemble de données qui ne contient que des entrées et trouvent une structure dans les données, comme le regroupement ou le regroupement de points de données. Les algorithmes apprennent donc à partir

de données de test qui n'ont pas été étiquetées, classées ou catégorisées. Au lieu de répondre aux commentaires, les algorithmes d'apprentissage non supervisé identifient les points communs dans les données et réagissent en fonction de la présence ou de l'absence de ces points communs dans chaque nouvelle donnée. Une application centrale de l'apprentissage non supervisé se trouve dans le domaine de l'estimation de la densité dans les statistiques, comme la recherche de la fonction de densité de probabilité. Bien que l'apprentissage non supervisé englobe d'autres domaines impliquant la synthèse et l'explication des caractéristiques des données.

TABLEAU 2.1 : DIFFÉRENCES ENTRE L'APPRENTISSAGE SUPERVISÉ ET NON SUPERVISÉ.

Apprentissage supervisé	Apprentissage non supervisé
Données d'entrée sont étiquetées.	Données d'entrée sont non étiquetées.
Utilise le jeu de données d'apprentissage.	Utilise tout le jeu de données en entrée.
Utilisé pour la prédiction.	Utilisé pour l'analyse.
Classification et régression.	Regroupement, estimation de la densité, et réduction de la dimensionnalité.

4. L'apprentissage en profondeur

4.1. Définition

L'apprentissage en profondeur est une classe d'algorithmes d'apprentissage automatique qui [41] : 199–200 utilise plusieurs couches pour extraire progressivement des fonctionnalités de niveau supérieur à partir de l'entrée brute. Par exemple, dans le traitement d'images, les couches inférieures peuvent identifier les bords, tandis que les couches supérieures peuvent identifier les concepts pertinents pour un humain, tels que les chiffres, les lettres ou les visages.

4.2. Architecture L'apprentissage en profondeur

L'IA est centrée sur une technique appelée apprentissage en profondeur, qui est alimentée par des réseaux de neurones artificiels. Voici une explication graphique de la façon dont ces réseaux de neurones sont structurés et entraînés.

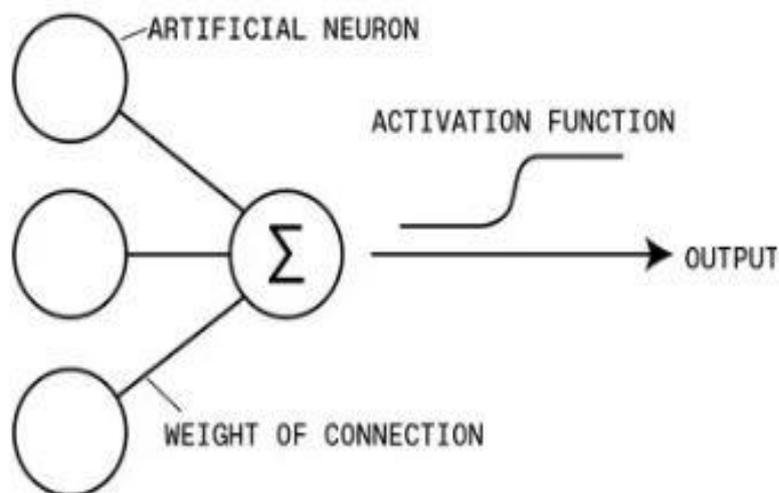


Figure2.2. Architecture L'apprentissage en profondeur

Chaque neurone d'un réseau neuronal artificiel additionne ses entrées et applique une fonction d'activation pour déterminer sa sortie. Cette architecture s'inspire de ce qui se passe dans le cerveau, où les neurones se transmettent des signaux entre eux via des synapses.

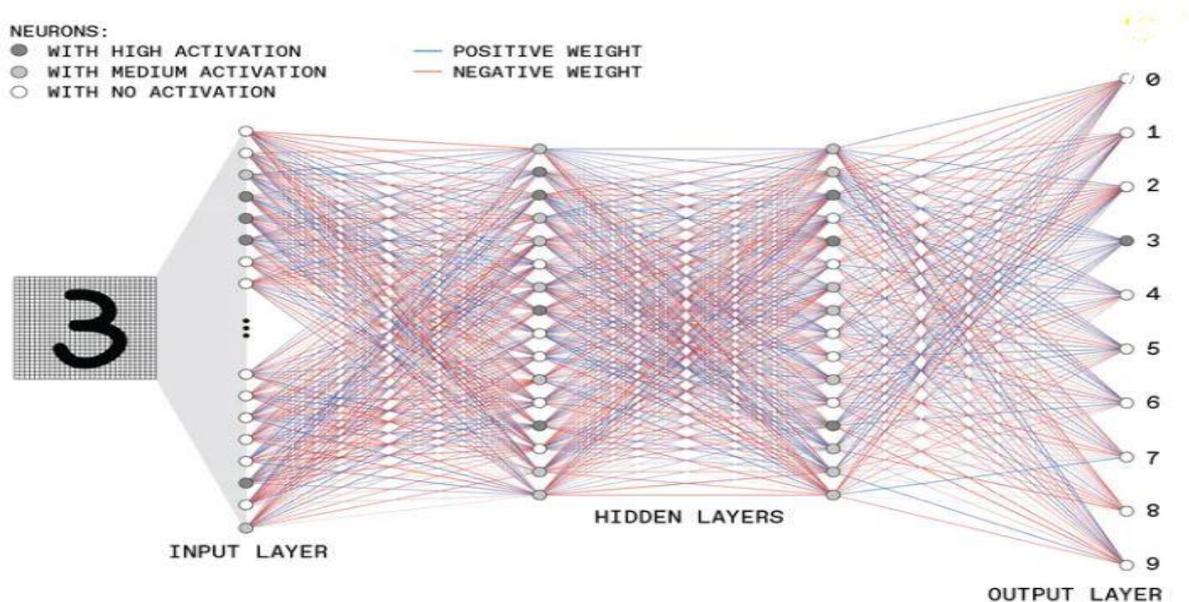


Figure 2.3 structure d'un hypothétique réseau de neurones profonds à réaction directe

4.3. Deep Learning vs Machine Learning

Le Deep learning (apprentissage profond) n'a pas besoin de données exprimées. Le système fonctionne à partir de plusieurs couches de réseaux neuronaux, qui combinent différents algorithmes en s'inspirant du cerveau humain. Ainsi, le système est capable de travailler à partir de données non modulées. Cette approche est particulièrement adaptée pour les tâches complexes, lorsque tous les aspects des objets à traiter ne peuvent pas être catégorisés en amont.

Le système du Deep learning identifie lui-même les caractéristiques discriminantes. Dans chaque couche, il recherche un nouveau critère spécifique de l'objet, qui sert de base pour décider de la classification retenue pour l'objet à la fin du processus. Important : avec le Deep learning, le système identifie lui-même les caractéristiques discriminantes des données, sans avoir besoin d'une catégorisation préalable. Le système n'a pas besoin d'être entraîné par un développeur. Il fournit lui-même le besoin de modifier le classement ou de créer des catégories inédites en fonction des nouvelles données.

Tandis que le Machine learning fonctionne à partir d'une base de données contrôlable, le Deep learning a besoin d'un volume de données bien plus considérable. Le système doit disposer de plus de 100 millions d'entrées pour donner des résultats fiables. Par ailleurs, la technologie

nécessaire pour le Deep learning est plus sophistiquée. Elle exige plus de ressources IT et s'avère nettement plus coûteuse que le Machine learning : elle n'est donc pas intéressante, du moins à l'heure actuelle, pour une utilisation de masse par les entreprises.

TABLEAU 2.2 : L'apprentissage automatique VERS L'apprentissage profond.

	L'apprentissage automatique	L'apprentissage profond
Type de données	Données structurées	Données non structurées
Base de données	Fournit une grande précision	Donne moins de précision
Entraînement	Contrôlable	< 1 million de données
Algorithme	Entraînement par l'humain nécessaire.	Système d'apprentissage autonome
Champ d'application	Actions simples de routine.	Tâches complexes

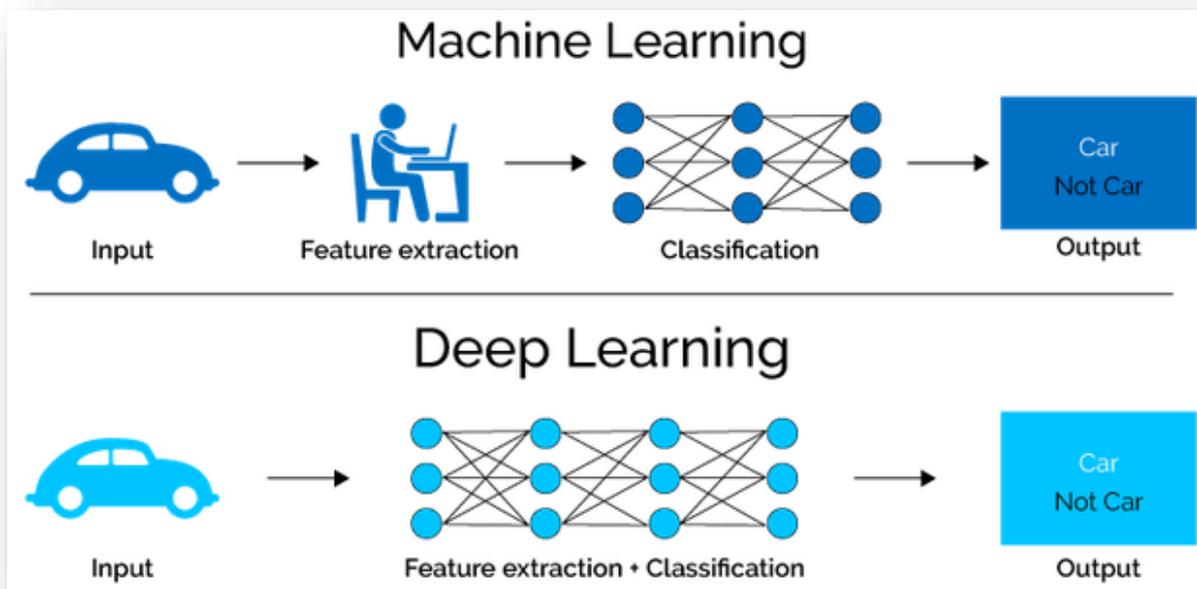


Figure2.4. L'apprentissage automatique VERS L'apprentissage profond.

4.4 Domaine d'application

L'apprentissage profond s'applique à divers secteurs des NTIC, notamment :

Un algorithme d'augmentation de données appliqué sur dataset du cancer du sein

- La reconnaissance visuelle par exemple, d'un panneau de signalisation par un robot ou une voiture autonome [46] et vocale [47] ;
- La robotique ;
- La bio-informatique [48] p. ex., pour l'étude de l'ADN [49] et des segments non codants du génome [50] ou encore la Cryométrie [51] ;
- La reconnaissance ou la comparaison de formes [52] ;
- La sécurité ;
- La santé [53] ;
- La pédagogie assistée par l'informatique [54].
- L'art ;
- L'intelligence artificielle en général.
- La traduction.

La méthode de l'apprentissage profond est aujourd'hui utilisée pour l'élaboration des moteurs de traduction automatique.

L'apprentissage profond peut, par exemple, aider à :

- Mieux reconnaître des objets hautement déformables [55].
- Analyser les émotions révélées par un visage photographié ou film [56].
- Analyser les mouvements et position des doigts d'une main, ce qui peut être utile pour traduire les langues signées [57].
- Améliorer le positionnement automatique d'une caméra, etc. [58].
- Poser, dans certains cas, un diagnostic médical (ex. : reconnaissance automatique d'un cancer en imagerie médicale [59], ou détection automatique de la maladie de Parkinson par la voix), ou de prospective ou de prédiction (ex. : prédiction des propriétés d'un sol filmé par un robot) ;
- Reproduire une œuvre artistique à partir d'une photo à l'ordinateur [59].

Une application du *deep learning* à la santé publique est le projet Horus de la société Eyra [60]. Il s'agit d'un appareil portable utilisant la plate-forme NVidia Jetson, qui aide les malvoyants ou les aveugles à s'orienter et à reconnaître des personnes ou des objets, en retranscrivant en audio une image captée par une caméra. Des liens entre l'apprentissage profond et la théorie de jeux ont été établis par Hamidou Tembine en utilisant notamment des jeux de type champ moyen [61].

4.4. Les techniques d'apprentissage en profondeur

Les algorithmes d'apprentissage en profondeur traversent plusieurs couches de la ou des couches cachées ou des réseaux de neurones. Ainsi, ils apprennent profondément sur les images pour une prédiction précise. Chaque couche apprend et détecte les caractéristiques de bas niveau comme les bords et, par la suite, la nouvelle couche fusionne avec les caractéristiques de la couche précédente pour une meilleure représentation. Par exemple, une couche intermédiaire peut détecter n'importe quel bord de l'objet tandis que la couche masquée détectera l'intégralité de l'objet ou de l'image. Cette technique est efficace avec des données volumineuses et complexes. Si les données sont petites ou incomplètes, DL devient incapable de travailler avec de nouvelles données. Il existe certains réseaux d'apprentissage en profondeur comme suit :

4.4.1. Réseau de neurones convolutifs (CNN)

Dans l'apprentissage en profondeur, un réseau de neurones convolutifs (CNN/ConvNet) est une classe de réseaux de neurones profonds, le plus souvent appliqués pour analyser l'imagerie visuelle. Maintenant, quand nous pensons à un réseau de neurones, nous pensons aux multiplications matricielles, mais ce n'est pas le cas avec ConvNet. Il utilise une technique spéciale appelée convolution. Or, en mathématiques, la convolution est une opération mathématique sur deux fonctions qui produit une troisième fonction qui exprime comment la forme de l'une est modifiée par l'autre

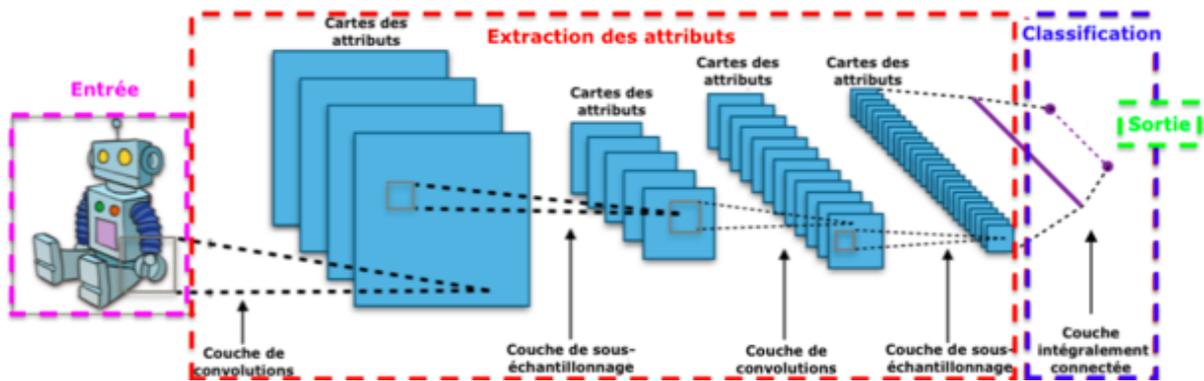


Figure2.5 Architecture standard d'un réseau à convolutions.

- Avant de passer au fonctionnement de CNN, couvrons les bases telles que ce qu'est une image et comment est-elle représentée. Une image RGB n'est rien d'autre qu'une matrice de valeurs de pixels ayant trois plans alors qu'une image en niveaux de gris est la même mais elle a un seul plan. Jetez un œil à cette image pour en savoir plus.

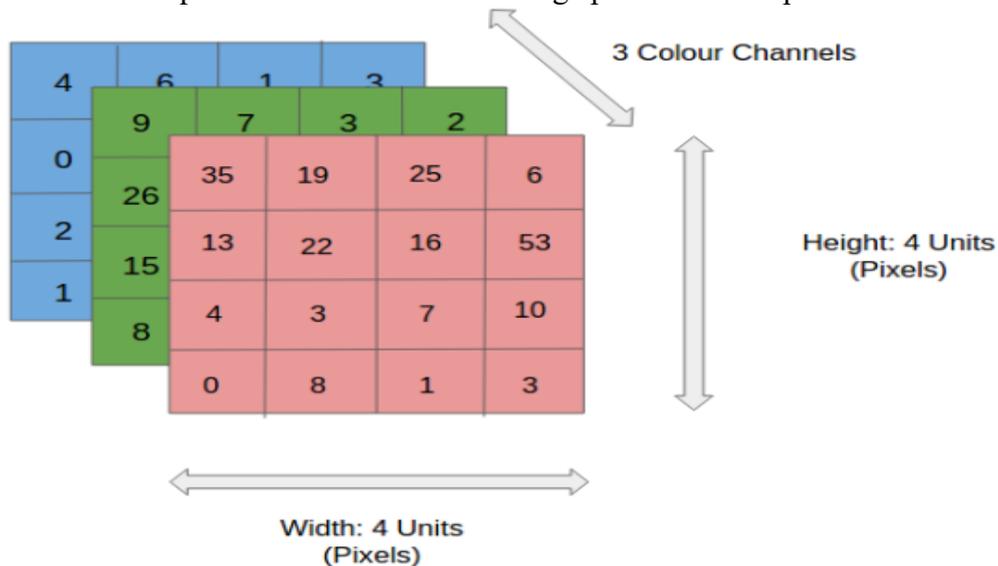


Figure2.6 représentation d'une image RGB.

- Pour plus de simplicité, restons-en aux images en niveaux de gris alors que nous essayons de comprendre le fonctionnement des CNN.

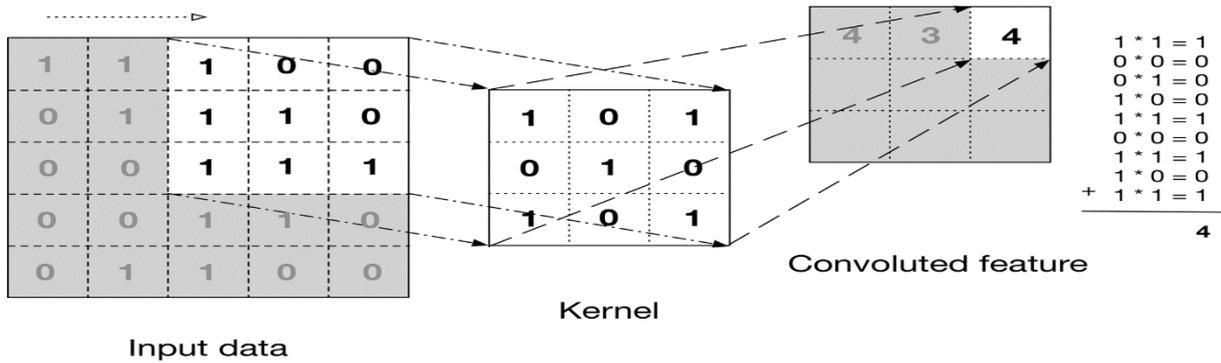


Figure2.7 le fonctionnement des CNN.

✚ L'image ci-dessus montre ce qu'est une convolution. Nous prenons un filtre/noyau (matrice 3 × 3) et l'appliquons à l'image d'entrée pour obtenir la fonction convoluée. Cette fonction convoluée est transmise à la couche suivante.

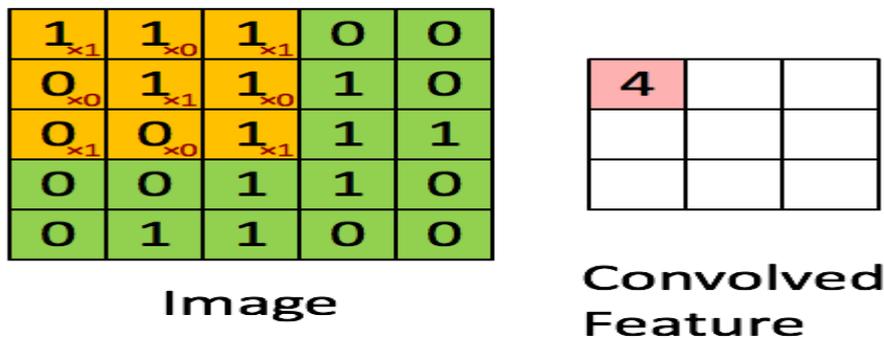


Figure2.8 la fonction convoluée.

✚ Dans le cas de la couleur RGB, le canal regarde cette animation pour comprendre son fonctionnement

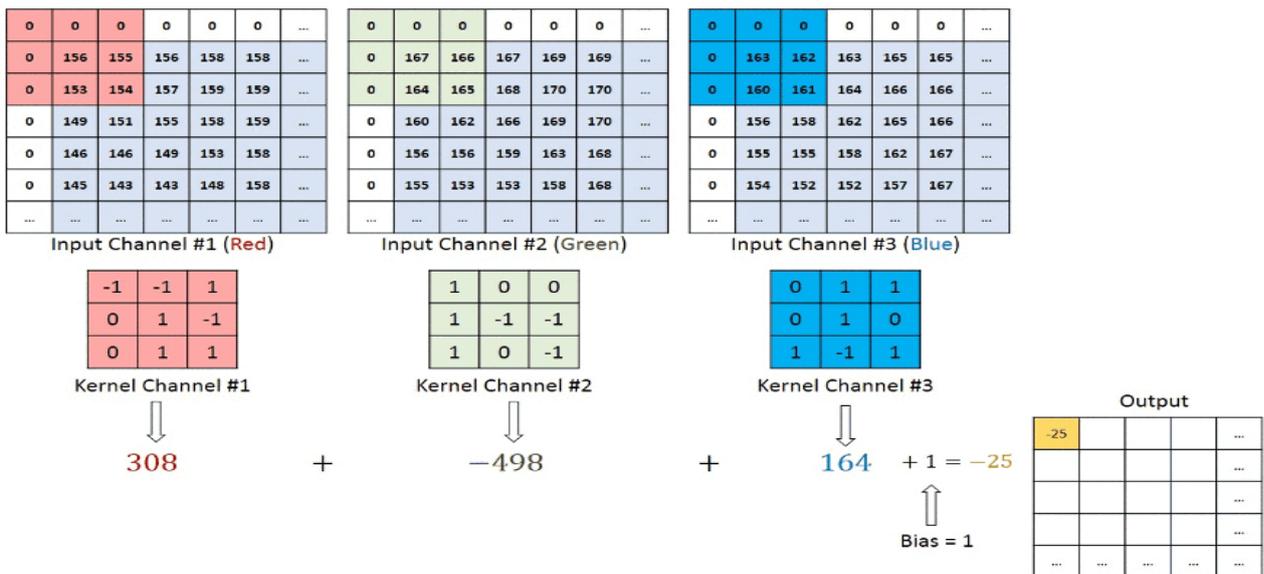


Figure 2.9 la fonction convoluée le cas de la couleur RGB.

- Les réseaux de neurones convolutifs sont composés de plusieurs couches de neurones artificiels. Les neurones artificiels, une imitation grossière de leurs homologues biologiques, sont des fonctions mathématiques qui calculent la somme pondérée de plusieurs entrées et sortent d'une valeur d'activation. Lorsque vous entrez une image dans un ConvNet, chaque couche génère plusieurs fonctions d'activation qui sont transmises à la couche suivante. La première couche extrait généralement les caractéristiques de base telles que les bords horizontaux ou diagonaux. Cette sortie est transmise à la couche suivante qui détecte des caractéristiques plus complexes telles que des coins ou des arêtes combinatoires. Au fur et à mesure que nous progressons dans le réseau, il peut identifier des caractéristiques encore plus complexes telles que des objets, des visages, etc.

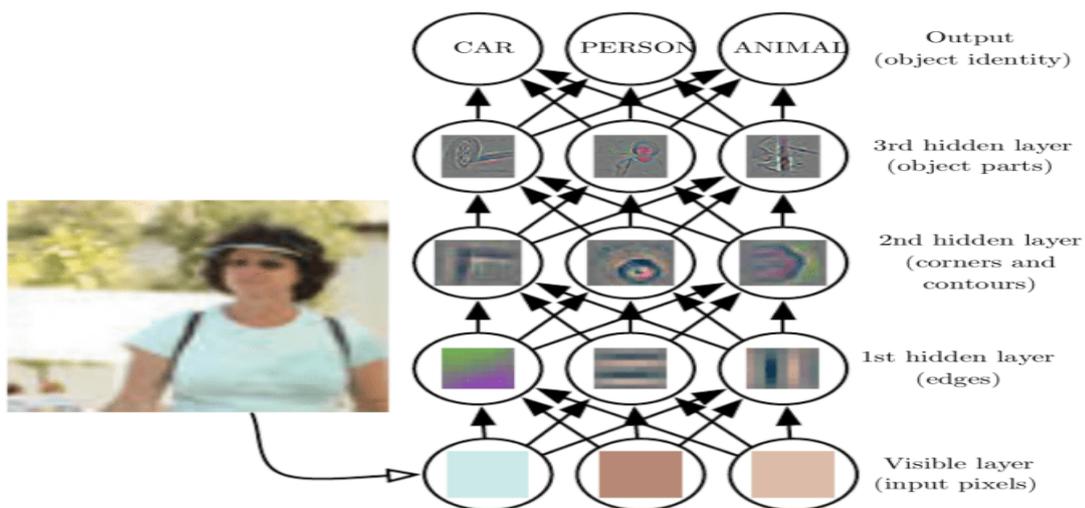


Figure2.10 Couche convolution.

Sur la base de la carte d'activation de la couche de convolution finale, la couche de classification génère un ensemble de scores de confiance (valeurs comprises entre 0 et 1) qui spécifient la probabilité que l'image appartienne à une "classe". Par exemple, si vous avez un ConvNet qui détecte les chats, les chiens et les chevaux, la sortie de la couche finale est la possibilité que l'image d'entrée contienne l'un de ces animaux

- Couche de pooling :** Semblable à la couche convolutive, la couche de regroupement est responsable de la réduction de la taille spatiale de l'entité convoluée. Il s'agit de diminuer la puissance de calcul nécessaire pour traiter les données en réduisant les dimensions. Il existe deux types de mise en commun, la mise en commun moyenne et la mise en commun maximale. Je n'ai eu d'expérience qu'avec Max Pooling jusqu'à présent, je n'ai rencontrée aucune difficulté. diminuer la puissance de calcul nécessaire pour traiter les données

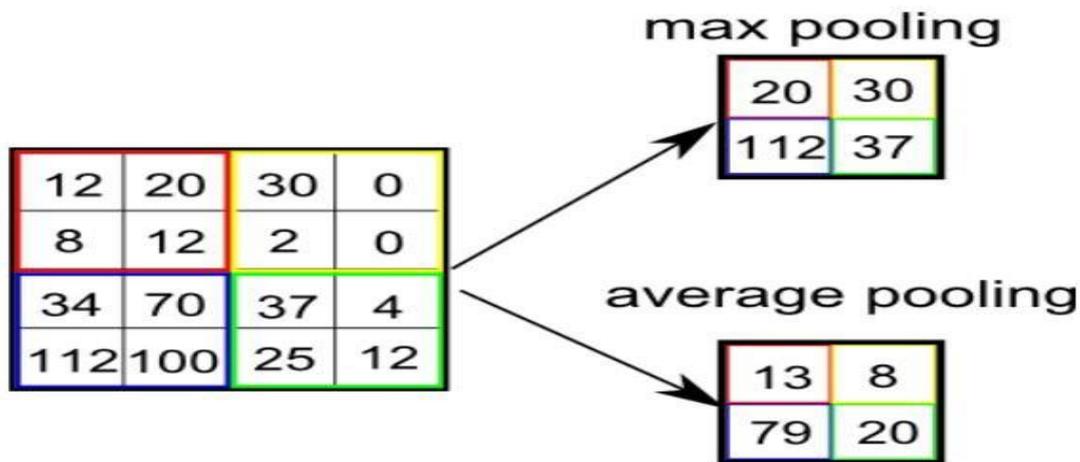


Figure 2.11 : Couche de pooling.

Diminuer la puissance de calcul nécessaire pour traiter les données. Donc, ce que nous faisons dans Max Pooling, c'est que nous trouvons la valeur maximale d'un pixel à partir d'une partie de l'image couverte par le noyau. Max Pooling fonctionne également comme un supprimeur de bruit. Il supprime complètement les activations bruyantes et effectue également un débruitage ainsi qu'une réduction de la dimensionnalité. D'autre part, Average Pooling renvoie la moyenne de toutes les valeurs de la partie de l'image couverte par le noyau. La mise en commun moyenne effectue simplement une réduction de la dimensionnalité en tant que mécanisme de suppression du bruit. Par conséquent, nous pouvons dire que Max Pooling est beaucoup plus performant qu'Average Pooling [62].

4.4.2. CNN Architectures : LeNet, AlexNet, VGG, GoogleNet, ResNet ...

4.4.2.1. LeNet-5

LeNet-5, un réseau convolutionnel pionnier à 7 niveaux par LeCun et al en 1998, qui classe les chiffres, a été appliqué par plusieurs banques pour reconnaître les numéros manuscrits sur les chèques (chèques) numérisés en images d'entrée en niveaux de gris de 32x32 pixels. La capacité de traiter des images à plus haute résolution nécessite des couches plus grandes et plus convolutives, de sorte que cette technique est limitée par la disponibilité des ressources informatiques.

4.4.2.2. AlexNet

Le réseau avait une architecture très similaire à LeNet de Yann LeCun et al mais était plus profond, avec plus de filtres par couche et avec des couches convolutionnelles empilées. Il consistait en 11x11, 5x5, 3x3, convolutions, mise en commun maximale, abandon, augmentation des données, activations ReLU, SGD avec momentum. Il a attaché des activations ReLU après chaque couche convolutive et entièrement connectée. AlexNet a été formé pendant 6 jours simultanément sur deux GPU NVidia Geforce GTX 580, raison pour laquelle leur réseau est divisé en deux pipelines. AlexNet a été conçu par le groupe SuperVision, composé d'Alex Krizhevsky, Geoffrey Hinton et Ilya Sutskever.

4.4.2.3. VGGNet

Le finaliste du concours ILSVRC 2014 est surnommé VGGNet par la communauté et a été développé par Simonyan et Zisserman. VGGNet se compose de 16 couches convolutionnelles et est très attrayant en raison de son architecture très uniforme. Semblable à AlexNet, seulement des convolutions 3x3, mais beaucoup de filtres. Formé sur 4 GPU pendant 2 à 3 semaines. C'est actuellement le choix le plus préféré dans la communauté pour extraire des caractéristiques à partir d'images. La configuration de poids du VGGNet est accessible au public et a été utilisée dans de nombreuses autres applications et défis en tant qu'extracteur de caractéristiques de base. Cependant, VGGNet se compose de 138 millions de paramètres, ce qui peut être un peu difficile à gérer.

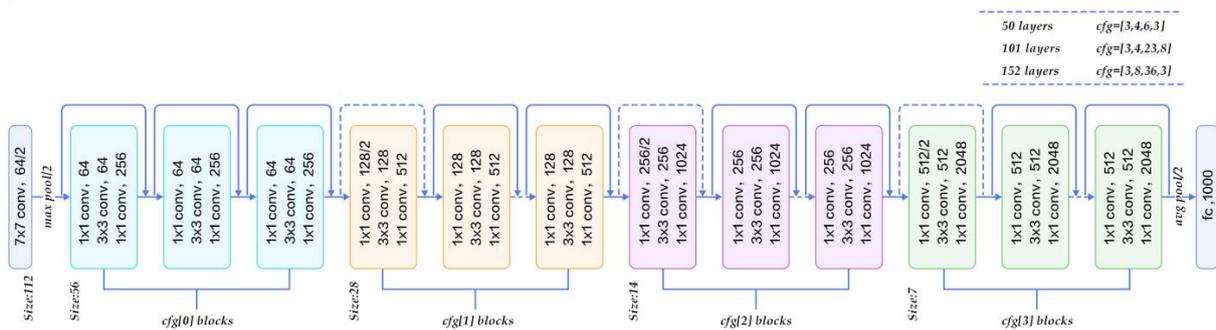


Figure 2.12 : architecture de VGGNet

4.4.2.4. Vgg16

Est une architecture de réseau neuronal convolutifs les activations passent alors par un deuxième bloc similaire, mais avec 128 filtres contre 64 dans la première. Par conséquent, la taille après le deuxième bloc devient 56 x 56 x 128. Elle est suivie par le troisième bloc avec trois couches convolutionnelles et une couche de pool max. Le non. De filtres appliqués ici sont 256, faisant la taille de sortie de le bloc 28 x 28 x 256. Ceci est suivi par deux blocs de trois couches convolutionnelles, chacune contenant 512 filtres. La sortie à la fin de ces deux piles sera de 7 x 7 x 512.

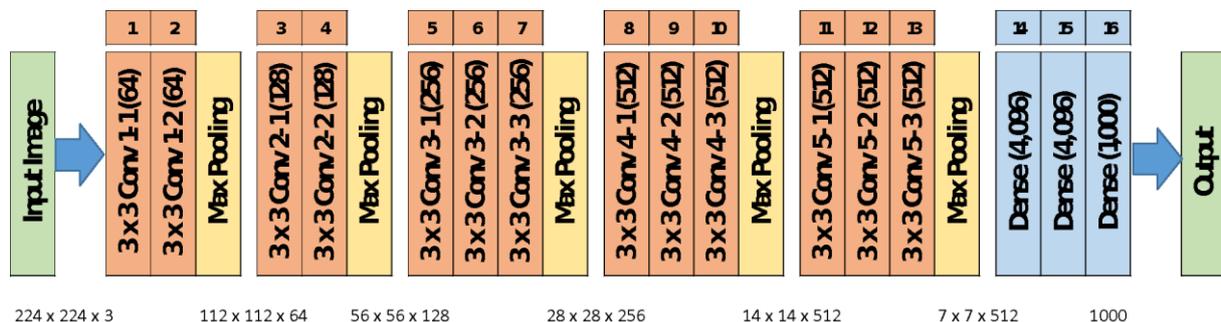


Figure 2.13. model de vgg16

4.4.3. Réseau neuronal récurrent (RNN)

Un réseau neuronal récurrent (RNN) est une classe de réseaux neuronaux artificiels où les connexions entre les nœuds forment un graphe orienté ou non orienté le long d'une séquence temporelle. Cela lui permet de présenter un comportement dynamique temporel. Dérivés des réseaux de neurones à anticipation, les RNN peuvent utiliser leur état interne (mémoire) pour traiter des séquences d'entrées de longueur variable [63] [64] [65]. Cela les rend applicables à des tâches telles que la reconnaissance d'écriture manuscrite non segmentée et connectée [66] ou la reconnaissance vocale. [67] [68] Les réseaux de neurones récurrents sont théoriquement complets de Turing et peuvent exécuter des programmes arbitraires pour traiter des séquences arbitraires d'entrées.

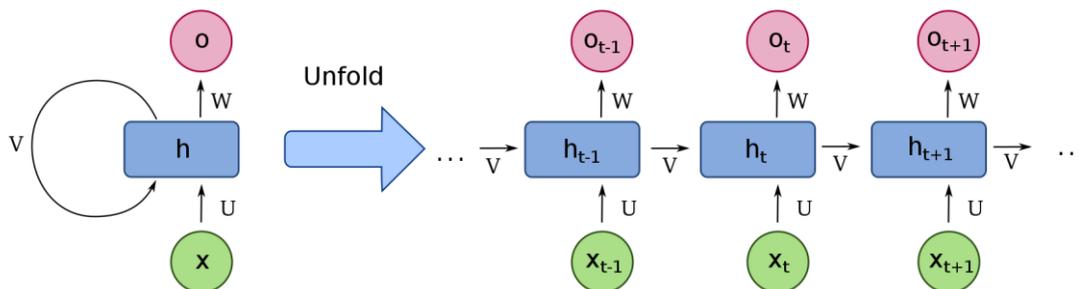


Figure 2.14 architecture de RNN

Le terme "réseau neuronal récurrent" est utilisé pour désigner la classe des réseaux à réponse impulsionnelle infinie, tandis que "réseau neuronal convolutifs" fait référence à la classe des réponses impulsionnelles finies. Les deux classes de réseaux présentent un comportement dynamique temporel. [69] Un réseau récurrent à impulsions finies est un graphe acyclique dirigé qui peut être déroulé et remplacé par un réseau de neurones strictement prédictif, tandis qu'un réseau récurrent à impulsions infinies est un graphe cyclique dirigé qui ne peut pas être déroulé. Les réseaux récurrents à impulsions finies et à impulsions infinies peuvent avoir des états stockés supplémentaires, et le stockage peut être sous le contrôle direct du réseau neuronal. Le stockage peut également être remplacé par un autre réseau ou graphique s'il intègre des temporisations ou comporte des boucles de rétroaction. Ces états contrôlés sont appelés état fermé ou mémoire fermée et font partie des réseaux de mémoire à court terme longs (LSTM) et des unités récurrentes fermées. Ceci est également appelé réseau de neurones de rétroaction (FNN).

4.4.4. Generative Adversarial Networks (Gan)

Il s'agit d'une combinaison de deux techniques d'apprentissage en profondeur des réseaux de neurones - un générateur et un discriminateur. Alors que le réseau générateur produit des données artificielles, le discriminateur aide à discerner entre une vraie et une fausse donnée. Les deux réseaux sont compétitifs, car le générateur continue de produire des données artificielles identiques aux données réelles - et le discriminateur détecte en permanence les données réelles et irréelles. Dans un scénario où il est nécessaire de créer une bibliothèque d'images, le réseau Generator produirait des données simulées pour les images authentiques. Il générerait alors un réseau de neurones de déconvolution. Il serait ensuite suivi d'un réseau de détecteurs d'images pour différencier les images réelles des fausses. A partir d'une chance de précision

de 50%, le détecteur doit développer sa qualité de classification puisque le générateur se développerait mieux dans sa génération d'image artificielle. Une telle concurrence contribuerait globalement à l'efficacité et à la rapidité du réseau. Fonctionne mieux dans : Génération d'images et de textes Amélioration d'images Processus de découverte de nouveaux médicaments

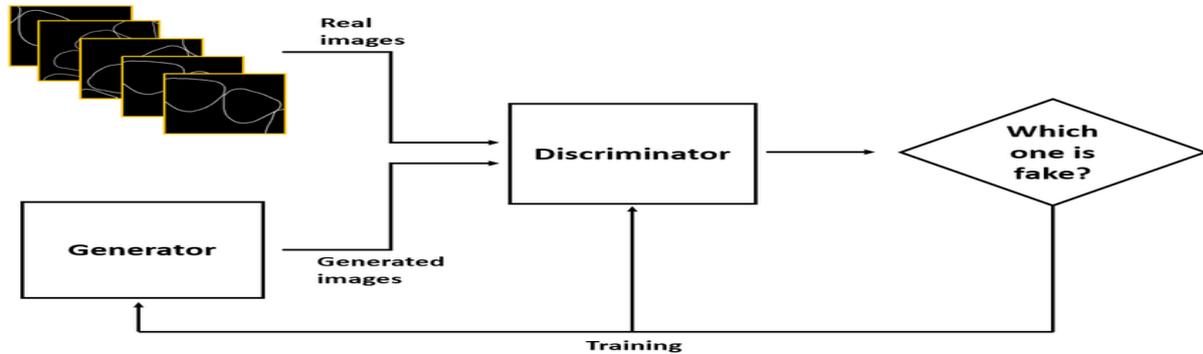


Figure2.15 : architecture de GAN

4.4.5. Transfer learning

Le transfert d'apprentissage est une approche permettant de transférer le savoir d'un modèle, à un autre. En l'occurrence, transférez les poids d'un modèle pré entraîné à une tâche précise, pour les associer à un autre modèle. Avec l'apprentissage par transfert, nous essayons essentiellement d'utiliser ce que nous avons appris dans une tâche pour mieux comprendre les concepts d'une autre. Les pondérations sont automatiquement transférées vers un réseau exécutant la « tâche A » à partir d'un réseau qui a effectué une nouvelle « tâche B ». En raison de l'énorme quantité de puissance CPU requise, l'apprentissage par transfert est généralement appliqué dans les tâches de vision par ordinateur et de traitement d'images d'analyse.

Conclusion

En ce qui concerne le sujet de l'analyse d'images biomédicales, les CNN ont été utilisés avec succès pour diverses tâches telles que la classification des lésions ou des tumeurs, la détection des régions suspectes et la détection des anomalies. Les solutions basées sur DL servent d'outil de deuxième opinion pour les radiologues experts et les aident à prendre des décisions et à planifier un traitement approprié. Cependant, il doit y avoir une grande quantité de vérité terrain pour construire un modèle DL capable de déduire des connaissances à partir de données et d'éviter que le modèle ne soit très précis uniquement sur les images de l'ensemble de données d'entraînement. Cette dernière porte le nom d'overfitting pour éviter l'overfitting dans les modèles DL. Les méthodes d'augmentation des données peuvent aider à accomplir cette tâche. Sujet de notre suivant chapitre.

Chapitre 03 :

Augmentation des données Concepts, méthodes et outils

1. Introduction

L'augmentation des données est une technique d'augmentation artificielle de la taille d'un ensemble de données en ajoutant une certaine variation à l'ensemble de données existant et en l'ajoutant à l'ensemble de données d'origine pour créer des données "légèrement modifiées et multipliées". Dans ce chapitre, nous définirons les techniques classiques et avancées d'augmentation de données.

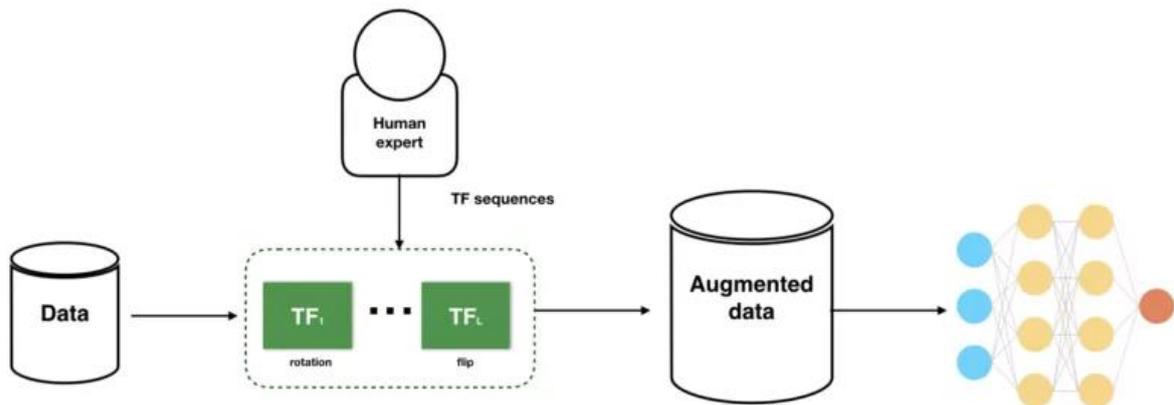


Figure 3.1 : Augmentation des données

2. Techniques de base d'augmentation d'image

Des techniques d'augmentation des données ont été utilisées pour augmenter la taille de l'ensemble de formation afin de fournir des échantillons de formation plus illustratifs aux apprenants à grande capacité [102]. L'augmentation des données englobe une gamme complète de techniques en insérant des variations aléatoires dans les échantillons d'apprentissage existants tout en préservant les étiquettes de classe. Le but de l'augmentation des données est d'améliorer la capacité d'inférence des connaissances du modèle. L'un des principes les plus significatifs adoptés dans l'augmentation des données concerne le phénomène physique d'une perturbation d'état. Ce dernier prend la forme de versions légèrement modifiées des images. Par conséquent, cela augmente la taille de l'ensemble de données, permettant au réseau de déduire des connaissances à partir d'un plus grand nombre d'image.

2.1. Transformation géométrique

Dans la transformation géométrique, une image originale subit diverses modifications telles que la traduction, la rotation, la mise à l'échelle, le retournement ou le redimensionnement pour augmenter la taille de l'ensemble de données d'apprentissage [5]. Ces techniques d'augmentation de données conventionnelles produisent des images quelque peu corrélées [103] et offrent donc beaucoup moins d'amélioration à la formation du modèle et à la généralisation sur les données de test. Cependant, ces transformations entraînent une augmentation significative de l'ensemble de données d'apprentissage ; par conséquent, ils sont largement utilisés dans le domaine d'augmentation de données [13]. Cette section présente les transformations géométriques les plus couramment utilisées pour le diagnostic du cancer du

sein assisté par ordinateur. Il examine également brièvement les méthodes s'appuyant sur les méthodes d'augmentation des données mentionnées ci-dessus :

2.1.1. Retournement

Le retournement génère une image miroir d'une image avec des axes horizontaux ou verticaux. L'axe horizontal est préféré au retournement vertical car les parties supérieure et inférieure d'une image peuvent ne pas toujours être interchangeables [13]. Cependant, le retournement ne peut pas toujours être une transformation préservant l'étiquette (par exemple, l'ensemble de données MNIST) [1].

2.1.2. Rotation

Les images sont tournées vers la gauche ou vers la droite sur un axe dans la plage $[1^\circ, 359^\circ]$. L'angle de rotation détermine la sécurité de cette technique d'augmentation. La possibilité de conserver l'étiquette après transformation est connue sous le nom de sécurité d'une méthode d'augmentation des données. Une étiquette d'image peut ne plus être conservée avec une augmentation du degré de rotation. Par exemple, la transformation par rotation est peut-être sûre sur les ensembles de données d'images médicales (rayons X, mammographies, IRM mammaire, etc.) ainsi que sur les images d'autres ensembles de données comme ImageNet [104], mais pas sur les images de 9 et 6 pour l'identification des chiffres Tâches.

2.1.3. Traduction

La traduction s'applique pour éviter les biais de position [1]. Cette transformation traduit toute l'image par un vecteur de traduction donné selon une direction spécifique. Cela aide le réseau à apprendre des propriétés géographiquement invariantes plutôt que de se concentrer sur des caractéristiques présentes dans un seul emplacement spatial [13]. Dans le cas des mammographies mammaires, la traduction des images peut générer des images augmentées appropriées. Après la traduction, le rembourrage ou la réplication de pixels entre généralement en jeu pour remplir l'espace restant. Le processus conserve les dimensions de l'image [1].

2.1.4. Mise à l'échelle

Des versions mises à l'échelle des images sont ajoutées à l'ensemble d'apprentissage ; les réseaux de neurones profonds peuvent apprendre des fonctionnalités quelle que soit leur échelle d'origine. De plus, la mise à l'échelle peut être appliquée en utilisant des facteurs de mise à l'échelle dans différentes directions. Par exemple, les lésions mammaires peuvent varier en taille ; cette transformation peut apporter des images augmentées réalistes dans l'ensemble de données de formation. La figure 4 montre des exemples de transformations géométriques appliquées aux images MIAS [105].

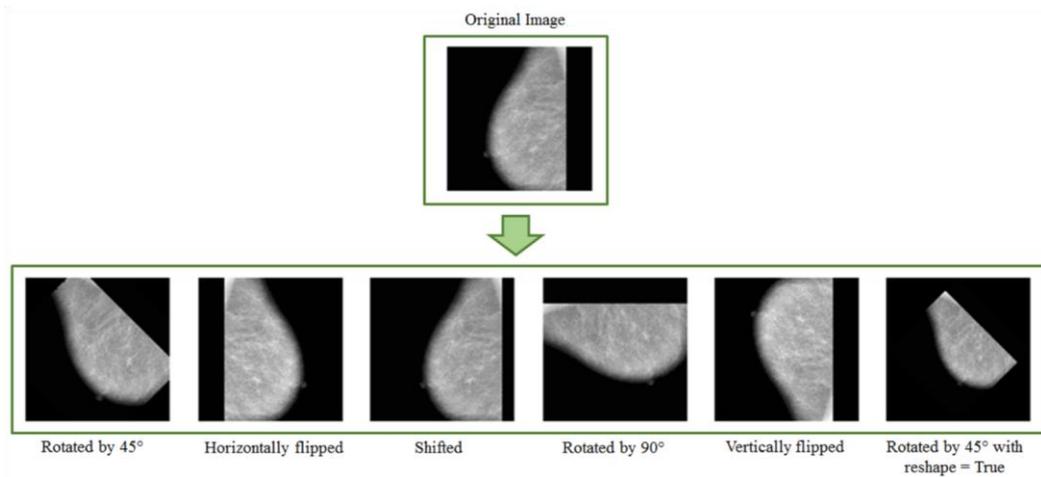


Figure 3.3. Exemple d'images après application de la transformation géométrique.

La taille limitée des ensembles de données est l'un des obstacles les plus courants dans la recherche médicale domaine. Par conséquent, la littérature scientifique offre un large éventail de techniques pour traiter ce problème.

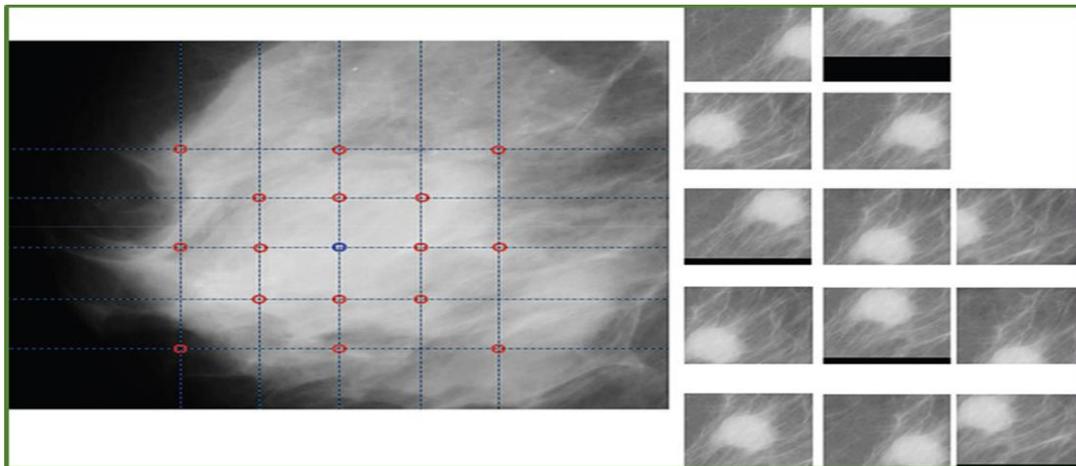


Figure 3.4. Un exemple de patch de mammographie et un échantillon de patches générés avec des transformations [12]

2.2. Augmentation du niveau de pixel

L'augmentation au niveau des pixels est très utile pour la recherche dans les domaines de l'imagerie médicale, car les images médicales sont obtenues avec plusieurs technologies et modalités d'imagerie ; par conséquent, ils peuvent être essentiellement assortis d'intensités de pixels [13]. Dans l'augmentation au niveau du pixel, les intensités de pixels sont perturbés par un bruit aléatoire et une probabilité donnée, aussi appelée aléatoire variations d'intensité. De plus, une augmentation au niveau du pixel modifie la luminosité d'une image. Entre autres, la correction gamma (et toutes ses variantes), le flou d'image et l'image la netteté représente des formes d'augmentation au niveau des pixels [106–108].

2.3. Augmentation de pseudo-couleur

L'augmentation de pseudo-couleur s'applique aux espaces de canaux de couleur. Isoler un seul canal de couleur, tel que R, G ou B, est la première étape de l'augmentation de couleur consistant de dériver un histogramme de couleur qui décrit l'image permet d'obtenir des couleurs plus avancées majorations. Les mammographies sont transformées en images pseudo-couleur pour évaluer l'efficacité du masque R-CNN. Ce dernier est réalisé par tamisage morphologique multi-échelles, qui stimule les modèles de masse. Le masque R-CNN est ensuite utilisé avec l'apprentissage par transfert pour détecter et des masses de segments sur des images pseudo-couleurs en même temps [109].

2.4. Random Erasing (Effacement aléatoire)

L'effacement aléatoire est une autre technique d'augmentation de données complémentaire de celles décrites précédemment [110]. L'objectif principal de cette technique est de rendre un modèle robuste contre les occlusions dans les images. L'une des caractéristiques les plus significatives est que la phase d'apprentissage est sans paramètre. Sur la figure (3.5), quelques exemples d'augmentation d'image d'effacement aléatoire sont donnés.

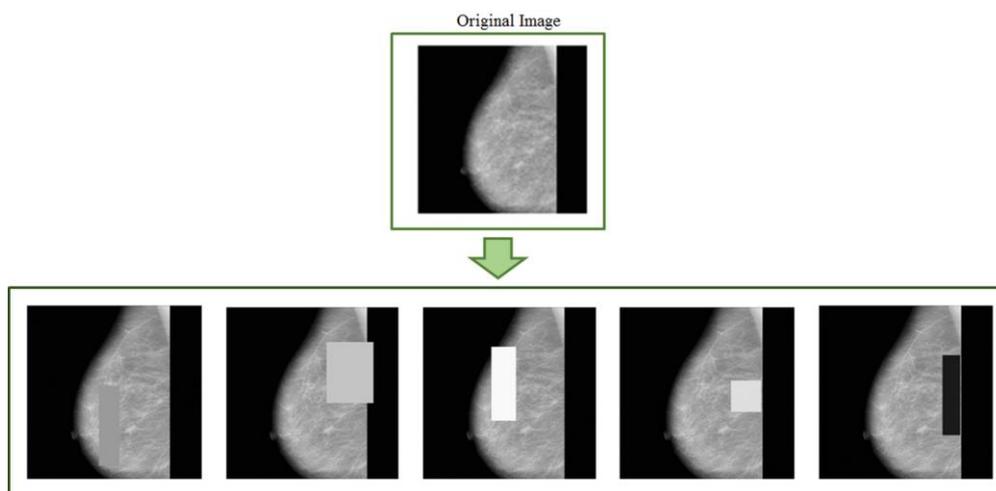
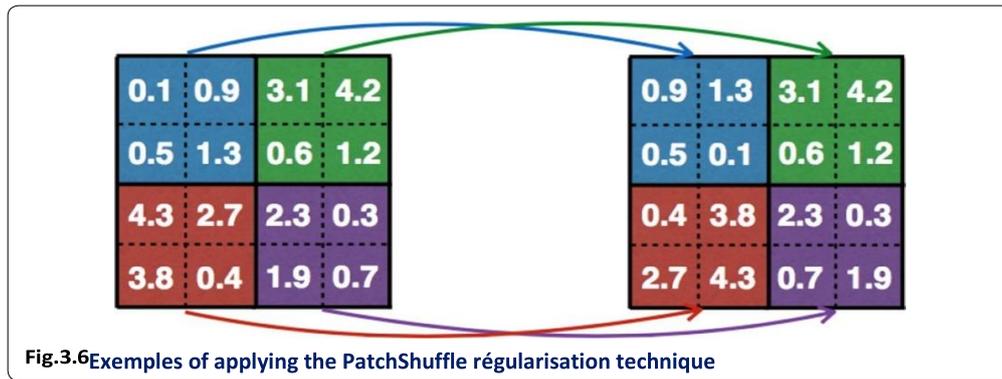


Figure 3.5. Mammographies après application d'un effacement aléatoire.

2.5. Kernel Filters (Filtres du noyau)

Les filtres de noyau s'appuient sur des techniques de filtrage spatial pour affiner ou lisser les valeurs de pixel. Ce utilise des masques de filtrage de taille $M \times M$. Outre les transformations telles que le rembourrage, le retournement, et le recadrage, Kang et al. [111] ont utilisé un filtre noyau permutant les valeurs de pixel avec un $n \times n$ fenêtre coulissante. Les expériences ont été menées sur quatre jeux de données différents tels que SVHN [112], MNIST [113], CIFAR-10 [114] et STL-10 [115]. Une augmentation de données différente consiste à combiner des images en faisant la moyenne de leurs valeurs de pixels. L'essentiel est générer différents échantillons pour que le modèle puisse généraliser les informations à partir de données [1]. Divers filtres de noyau tels que le flou gaussien, le filtre moyen, le filtre médian, le laplacien filtre, etc., peut être utilisé à des fins d'augmentation de données.



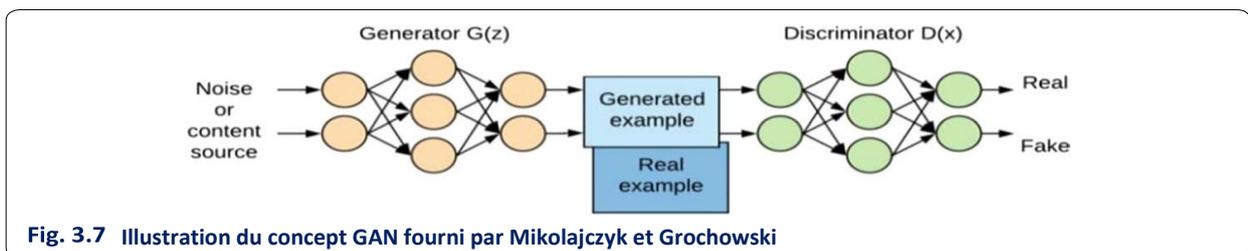
3. Techniques d'augmentation avancées

Au cours de la dernière décennie, plusieurs méthodes ont été proposées pour générer de nouveaux échantillons à partir de un jeu de données de référence. L'objectif principal a été de surmonter tous les problèmes liés aux données de base techniques d'augmentation. Cette section regroupe des techniques avancées d'augmentation de données en deux catégories principales : l'augmentation basée sur GAN (Generative Adversarial Networks) et l'augmentation NST (Neural Style Transfer).

3.1. Augmentation basée sur le GAN

Une autre stratégie passionnante pour l'augmentation des données est la modélisation générative. La modélisation générative fait référence à la pratique consistant à créer des instances artificielles à partir d'un ensemble de données de sorte qu'elles conservent des caractéristiques similaires à l'ensemble d'origine.

Les GAN (Generative Adversarial Networks) appartiennent à la famille des réseaux profonds non supervisés. Algorithmes d'apprentissage capables d'extraire les propriétés sous-jacentes cachées des données et les employant dans la prise de décision. L'objectif fondamental d'un GAN est de développer de nouveaux échantillons d'image (par un générateur) que le discriminateur ne pourra pas distinguer de celles d'origine (les deux branches du réseau se font concurrence et progressivement apprendre à produire de meilleurs résultats) [116]



De recherche ont été publiés qui modifient le cadre GAN à travers différentes architectures de réseau, fonctions de perte, méthodes évolutives et beaucoup plus. Cette recherche a considérablement amélioré la qualité des échantillons créés par GAN. De nombreuses nouvelles architectures ont été proposées pour développer le concept de GAN et produire des images de sortie à plus haute résolution, dont beaucoup sont sorties.

3.1.1. Présentation de la structure du Gan

Un generative adversarial network (GAN) comporte deux parties :

- ✚ **Le générateur** apprend à générer des données plausibles. Les instances générées deviennent des exemples d'apprentissage négatifs pour le discriminateur.
- ✚ **Le discriminateur** apprend à distinguer les fausses données du générateur des vraies données. Le discriminateur pénalise le générateur pour avoir produit des résultats non plausibles. Lorsque l'entraînement commence, le générateur produit des données manifestement fausses, et le discriminateur apprend rapidement à dire que c'est faux :

Le générateur La partie génératrice d'un GAN (generative adversarial network) apprend à créer de fausses données en incorporant les commentaires du discriminateur. Il apprend à faire en sorte que le discriminateur classe sa sortie comme réelle. L'entraînement du générateur nécessite une intégration plus étroite entre le générateur et le discriminateur que ne l'exige l'entraînement du discriminateur. La partie du GAN (generative adversarial network) qui entraîne le générateur comprend : entrée aléatoire réseau générateur, qui transforme l'entrée aléatoire en une instance de données réseau discriminateur, qui classe les données générées sortie du discriminateur perte du générateur, qui pénalise le générateur pour ne pas avoir trompé le discriminateur

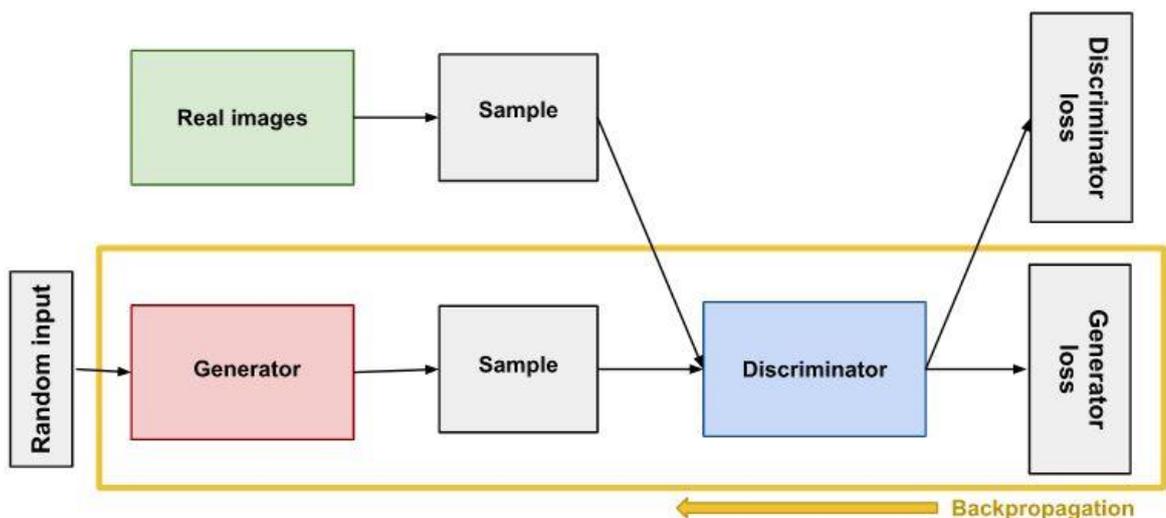


Figure 1.8 : Backpropagation in generator training.

Le discriminateur dans un GAN (generative adversarial network) est simplement un classifieur. Il essaie de distinguer les données réelles des données créées par le générateur. Il peut utiliser n'importe quelle architecture de réseau appropriée au type de données qu'il classe.

Le discriminateur se connecte à deux fonctions de perte. Pendant l'entraînement du discriminateur, le discriminateur ignore la perte du générateur et utilise uniquement la perte du discriminateur. Nous utilisons la perte du générateur pendant la formation du générateur, comme décrit dans la section suivante. Pendant l'entraînement du discriminateur : Le discriminateur classe à la fois les données réelles et les fausses données du générateur. La

perte du discriminateur pénalise le discriminateur pour avoir mal classé une instance réelle comme fausse ou une fausse instance comme réelle. Le discriminateur met à jour ses poids par rétropropagation à partir de la perte du discriminateur à travers le réseau de discriminateurs. Dans la section suivante, nous verrons pourquoi la perte du générateur se connecte au discriminateur.

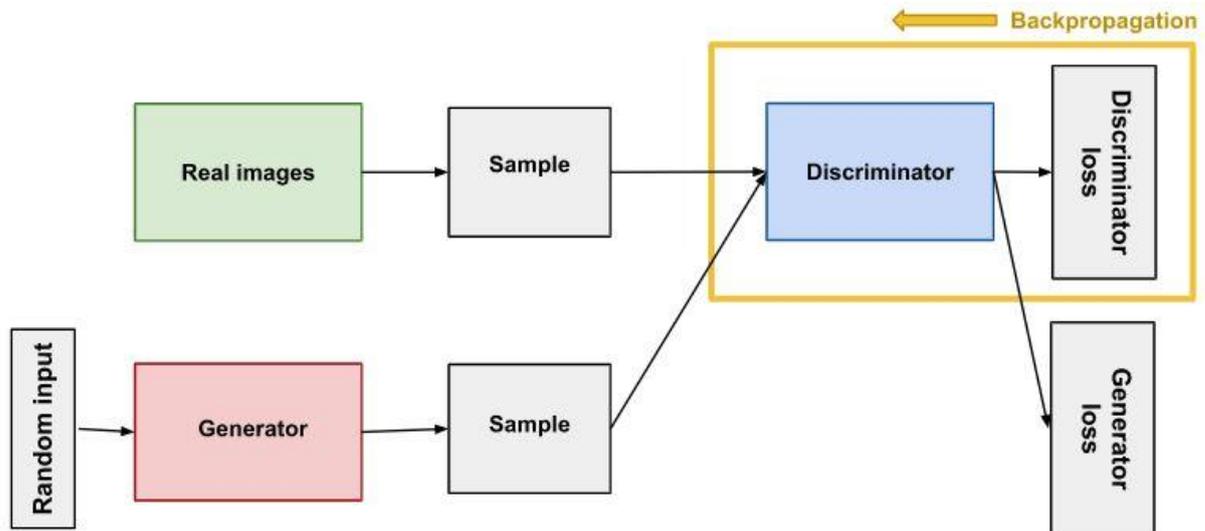


Figure 1.9 : Backpropagation in Discriminator training.

3.2. Neural Style Transfer (NST)

Neural Style Transfer [117] est l'une des démonstrations les plus en vogue du Deep Learning capacités. L'idée générale est de manipuler les représentations d'images créées dans CNN. Neural Style Transfer est probablement mieux connu pour ses applications artistiques, mais il sert également d'excellent outil pour l'augmentation des données. L'algorithme fonctionne en manipulant les représentations séquentielles à travers un CNN de sorte que le style d'une image peut être transféré à un autre tout en préservant son contenu d'origine. Une explication plus détaillée de l'opération de matrice de gramme alimentant Neural Style Transfer peut être trouvée par Li et al. [100] (fig. 3.10).

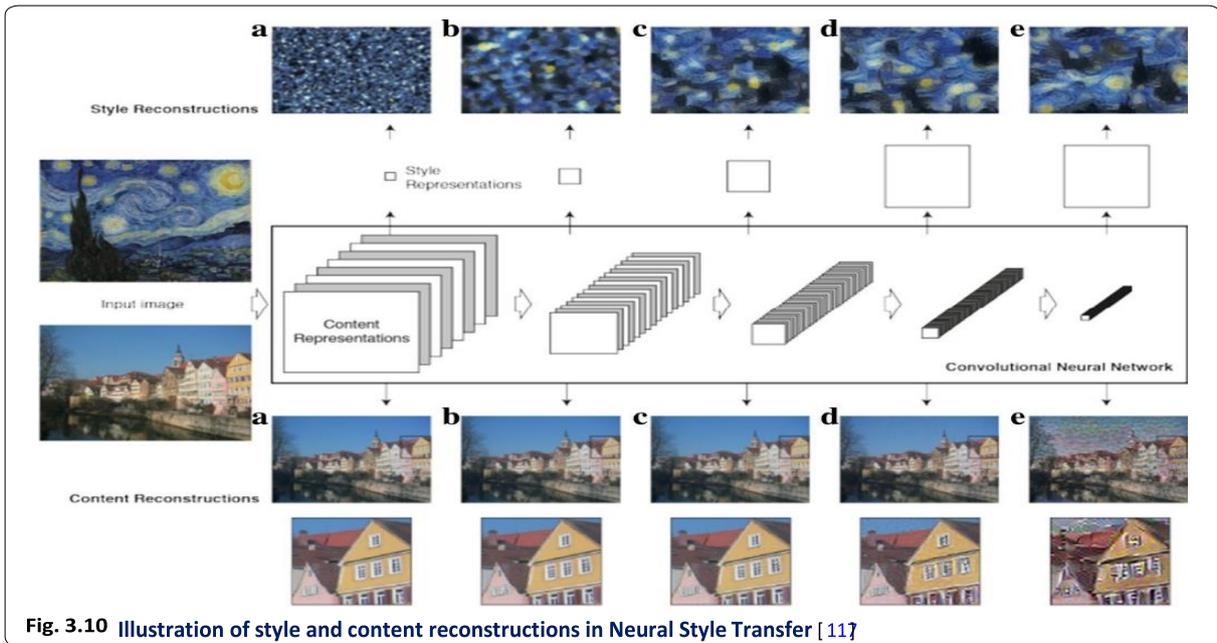


Fig. 3.10 Illustration of style and content reconstructions in Neural Style Transfer [117]

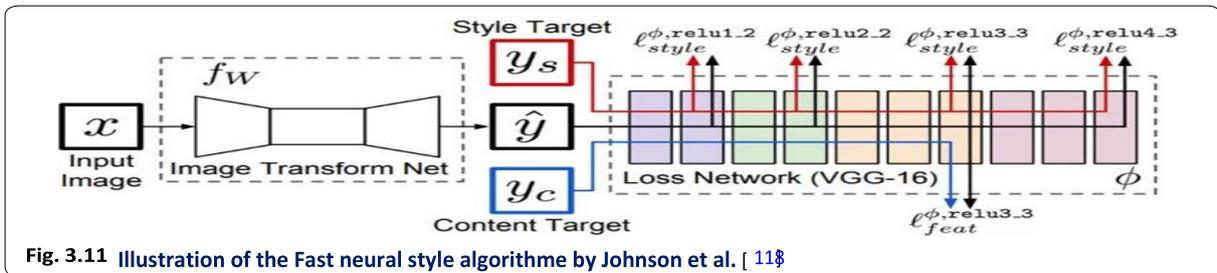


Fig. 3.11 Illustration of the Fast neural style algorithme by Johnson et al. [118]

4. Etat de l'art

Plusieurs chercheurs ont utilisé des techniques d'augmentation des données pour analyser le cancer du sein avec des dataset différent, ce qui a donné des résultats différents.

4.1. Image Augmentation Techniques for Mammogram Analyse

Tableau3.1 : Résumé des techniques d'augmentation d'image de base et avancées [135].

Sr No.	Technique AD	Sous-catégorie	Préservation des étiquettes	Force	Limitation
1	Transformation géométrique [1,5]	Retournement	Non	Bonnes solutions pour les biais de position présents dans les données d'entraînement. implementation facile	Additional memory, Transformation compute cost, Additional training time, Manual observation
		Traduction	Pas toujours		
		Recadrer	Pas toujours		
		Rotation	oui		
2	Injection de bruit [77]	-	oui	Permet au modèle d'apprendre plus robuste	Difficile de décider de la quantité de bruit à ajouter

3	Filtres du noyau [1]	-	oui	Bon pour générer des images nettes et floues	Similaire au mécanisme CNN
4	Mélanger des images [78]	-	Non	-	N'a pas beaucoup de sens de la part de l'humain perspective. Ne convient pas aux images médicales
5	Effacement aléatoire [109]	-	Pas toujours	Analogue à la régularisation des abandons. Conçue pour lutter contre les problèmes de reconnaissance d'image dus à l'occlusion, une technique prometteuse pour garantir qu'un réseau prête attention à l'image entière, et non à un sous-ensemble de celle-ci	Certaines interventions manuelles peuvent être nécessaires en fonction de l'ensemble de données et demande
6	Adversarial Training [79]	-	oui	Aide à mieux illustrer les limites de décision faibles que les métriques de classification standard	Moins exploré
7	Generative Adversarial Network [80]	-	oui	GANs générer des données qui ressemblent aux données d'origine	Plus difficile à former, générer des résultats à partir de texte ou de discours est très complexe.
8	Neural Style Transfer [119]	Améliore la capacité de généralisation des jeux de données simulés			Efforts nécessaires pour sélectionner le style, mémoire supplémentaire, coût de transformation

Tableau 3.2 : Résumé des articles utilisant l'augmentation d'image [135].

Ref.	Tâche effectuée	Modèle	Dataset	Performances du modèle	Approche d'augmentation des données
[120]	AD detection	Deep CNN (Augmenté CNN-SW+)	Privée	AUC : 0.83 ± 0.14	Rotation de 90, 180 et 270 degrés, mise en miroir et ajout de bruit de Poisson
[8]	AD detection	Deep CNN	MIAS, DDSM, INBreast	précision : 93.75%	Rotation, retournement, cisaillement, mise à l'échelle, etc.
[121]	Mass detection	Faster R-CNN	CBIS-DDSM	Sensitivity : 0.833 ± 0.038	Retournement horizontal et vertical
[63]	Mass detection	mr2NST	Mammograms from GE and UIH	-	Neural Style Transfer
[81]	BI-RADS Classification	AlexNet	INBreast	précision : 83.4	Co-enregistrement d'images
[106]	Tumor detection	Modified AlexNet	MIAS	95.70%	Mise à l'échelle, retournement horizontal, rotation (90, 180, 270)
[122]	Mass Classification	InceptionV3 and ResNet50	DDSM	précision : InceptionV3 : 79.6 ResNet50-85.71	Transformation géométrique
[82]	Mammographie classification	Pre-trained CNN Architectures	Privée	-	Réflexion et rotation
[123]	BI-RADS classification	CNN	MIAS	précision : 83.6%	Retournement, rotation, décalage et zoom
[124]	Mammographie Classification	Pre-trained CNN Architectures	MIAS	précision : 99.01%	Flou gaussien, retournement horizontal,

Un algorithme d'augmentation de données appliqué sur dataset du cancer du sein

					réflexion interne et léger ajout de bruit blanc
[125]	Mass detection	Google Inception-V3	INBreast	ROC : 0.86	Bruit gaussien, retournement, Modification de la luminosité de l'image
[83]	Mass Classification	VGG based DCNN	INBreast, CBIS, BCRP	-	déformations élastiques
[10]	Mass Classification	DCNN	MIAS, INBreast, DDSM	Conventional DA techniques : 88% GAN : 94%	GAN
[84]	Mass Classification	AlexNet, InceptionV3	INBreast, CBIS-DDSM	précision : INBreast : Alexnet : 0.9892, InceptionV3 : 0.9919 CBIS-DDSM : Alexnet : 0.6138, InceptionV3 : 0.8142	rotation, retournement, cisaillement

Tableau 3.3 : Résumé des techniques d'augmentation d'image de base et avancées [135].

. Ref	Tâche effectuée	Modèle	Dataset	Performances du modèle	Data Augmentation Approach
[85]	Lesion Classification	ResNet50, VGG16, VGG19	CBIS-DDSM	précision : 90.4%	Transformation géométrique, Réglage du contraste et de la luminosité
[86]	Abnormality Classification	Meta Learning, Resnet101	CBIS-DDSM	précision : Méta-apprentissage : 76%, Resnet10 : 71%	Transformations géométriques
[126]	Mammographie Classification	VGGNet, GoogleNet, Resnet	CBIS-DDSM, MIAS	AUC : 0.932	Transformations géométriques
[87]	Mammographie Classification	Residual Networks	INBreast	Spécificité : 0.89	Rotation, Traduction
[88]	Détection de masse	InceptionV3	INBreast	ROC : 0.91	Geometric transformations, Contrast and brightness adjustment,
[127]	Mammographie Classification	Alexnet, Resnet	Private	-	Transformations géométriques
[89]	AD détection	Alexnet, SVM	CBIS-DDSM, DDSM, MIAS	précision : 92	Transformations géométriques TTA
[130]	Mammographie détection et classification	YOLO	INBreast	précision : 89.6	Rotation, Traduction
[90]	Construire des ensembles de données de mammographie mammaire	Alexnet, Densenet, Shufflenet	INBreast	-	Rotation, Traduction
[91]	Détection de masse	Faster R-CNN	OMI-DB	TPR : 0.99 ± 0.03 at 1.17 FPI— malignant 0.85 ± 0.08 at 1.0 FPI— benign	Retournement horizontal
[92]	Diagnosis cancer du sein	Pre-trained CNN Architectures	CBIS- DDSM, BCDR, INBreast, MIAS	F1 Score pour MIAS 0.907 ± 0.150	-

[93]	Classification de cancer du sein	DCNN	MIAS	précision : 90.50	Augmentation des données en fonction des caractéristiques
[56]	Classification de masse	CNN	DDSM	-	cycle GAN
[128]	Discrimination de masse	GoogleNet	DDSM	précision : 90.38%	Retournement, Cropped-ROI, bruit gaussien
[66]	Classification des images	VGG-16/19	Mini MIAS	-	Technique croisée
[131]	Synthèse d'images de masse	GAN	DDSM, Private	-	Informations contextuelles basées sur les GANs
[133]	Détection de masse	Détection d'objet en une étape Architecture (BMassDNet)	INBreast DDSM	Recall : INBreast : 0.93 DDSM : 0.943	Déformation élastique
[132]	Détection de masse	Réseau entièrement convolutionnels	CBIS-DDSM Inbreast	0.8040 PAUC 0.8787 TPR@0.5FPI	Apprentissage contradictoire
[118]	Classification du cancer du sein	Deep CNN	MIAS, DDSM, Inbreast	Précision : MIAS : 96.55%, DDSM : 90.68%, Inbreast : 91.28%,	Transformations géométriques, Bruit gaussien
[129]	Détection de masse	Apprentissage contrastif, CycleGAN	Inbreast, Privée	-	Transformation géométrique
[68]	Classification de masse	Deep CNN	Private	0.760 ± 0.015 for 80% données étiquetées	Formation contradictoire virtuelle
[71]	Détection de masse	Huit modèles de détection d'objets	OPTIMAM, Inbreast, BCDR	Sur huit modèles, DETR [94] pourrait bien fonctionner	Découpe et RandConv
[75]	BI-RADS Classification	EfficientNet-B2	Private	Macro F1 score : 0.595	Stratégie de transparence
[95]	Détection de masse	Pre-trained CNNs, DenseNet, ResNet, ResNeXt	BCDR	précision : 84%	Transformation géométrique
[96]	Détection des lésions	YOLOv4 Algorithme de contours imbriqués	INBreast	Spécificité : 93% by NCA	Transformation géométrique
[97]	Mammographie Classification de densité	DenseNet201, ResNet50	MIAS	précision : DenseNet201 : 90.47%	Transformation géométrique
[134]	Mass Segmentation	U-Net	DDSM	Spécificité : 92.32%	Transformation géométrique
[98]	Détection du cancer du sein	Pre-trained CNNs VGG-16, VGG-19, ResNet-50	MIAS	précision : ResNet-50 : 71%	Transformation géométrique

4.2. Techniques d'augmentation d'image pour le cancer du sein ensemble de données d'images échographiques

TABLEAU 3.4. COMPARAISON DE LA PRÉCISION DE DIFFÉRENTES MÉTHODES LORS DE TESTS SUR UN JEU DE DONNÉES UNIQUE ET COMBINÉ [136].

Dataset	Méthode	Sous-Méthode	Sans Augmentation	Augmentation traditionnelle	DAGAN Augmentation	Augmentation traditionnelle et DAGAN
Dataset BUSI	CNN-AlexNet		58%	62%	73%	78%
	TL	VGG16	70%	74%	84%	88%
		Inception	68%	73%	82%	85%
		ResNet	79%	82%	89%	93%
		NASNet	83%	85%	91%	94%

Un algorithme d'augmentation de données appliqué sur dataset du cancer du sein

Dataset B	CNN-AlexNet	overfitting	56%	75%	80%
	TL	VGG16	68%	72%	80%
		Inception	65%	70%	77%
		ResNet	75%	79%	86%
		NASNet	79%	82%	90%
Datasets (BUSI+B)	CNN-AlexNet	60%	65%	82%	84%
	TL	VGG16	72%	75%	86%
		Inception	70%	73%	84%
		ResNet	76%	79%	88%
		NASNet	84%	88%	96%

4.2. Techniques d'augmentation d'image pour le cancer du sein Ensemble de données d'image d'histologie

Tableau 3.5. Compare les performances de classification du cancer du sein avant et après l'augmentation des données avec la synthèse images. Précision du classement [137]

Méthode	Precision	Recall	Accuracy
réel	0.642	0.856	0.682
CCAN	0.513	1.000	0.513
CCAN et réel	0.675	0.783	0.695
DCGAN	0.495	0.051	0.471
DCGAN et réel	0.760	0.695	0.731

Conclusion

L'objectif principal ici est de discuter de l'impact de l'augmentation des données sur les techniques d'apprentissage en profondeur pour des tâches telles que la détection, la classification et la segmentation des régions suspectes. En utilisant différentes techniques basic et avancées, ce chapitre fournit un aperçu complet des dernières données sur la technologie d'augmentation en général et son utilisation dans la classification des données, qui est l'objectif principal de notre travail dans cette mémoire. Le chapitre suivant présente notre contribution à ce domaine en présentant Un algorithme d'augmentation de donnés appliqué sur dataset du cancer du sein.

Chapitre 04 :

**Un algorithme d'augmentation des données
appliqué sur une dataset de cancer du sein
Contribution & Implémentation**

1. Introduction

Dans ce chapitre nous présentons notre travail d'augmentation de dataset de cancer de sein basé sur l'algorithme de GAN. Dans ce fait nous avons commencé par la description de notre contribution, puis la description de dataset ainsi que la création des modèles et finalement nous avons présenté les étapes d'implémentation et les résultats obtenus.

2. Contribution

L'objectif principale derrière ce projet est de créer un modèle utilisant l'apprentissage en profondeur, en particulier dans le domaine des GAN, et de fournir la même précision que l'étude de la littérature menée. Notre contribution unique consiste à construire un modèle GAN à l'aide de techniques d'apprentissage supervisées pour la catégorisation des images histopathologiques dans la prédiction du cancer du sein. Afin d'améliorer la précision du modèle et de rendre le modèle approprié pour l'apprentissage supervisé, nous modifierons également certaines limitations architecturales. Nous suggérons plus d'élan, ce qui a stabilisé la majorité de notre processus d'apprentissage.

3. Dataset

L'ensemble de données utilisé dans notre contribution nommé « TMI Dataset » [1]. La conception expérimentale de l'ensemble de données était presque identique à celle utilisée par [2] afin que les résultats de l'expérience puissent être comparés à ceux du modèle SSAE. Nous avons utilisé le même ensemble de données de 537 images histopathologiques colorées H&E provenant de lames de verre numérisées représentant 49 patientes de l'Université Case Western Reserve atteintes d'un cancer du sein sans ganglion lymphatique et avec récepteurs aux œstrogènes positifs (LN-, ER + BC). 2 000 patches nucléaires et 6 000 patches non nucléaires font partie des données d'entraînement. Il y a 1 000 correctifs au total - 500 nucléaires et 500 non nucléaires - pour la certification. La création des ensembles de données de formation et de vérité terrain a été décrite par Xu et al. L'ensemble de données de test n'a pas été utilisé dans cet article. Au lieu de cela, l'ensemble de données de validation a servi d'ensemble de données de test.

Les données de cet ensemble de données ont déjà été divisées en train et validation. La plage de valeurs initiale de chaque image était $[0, 1]$, mais nous l'avons normalisée à $[-1, 1]$. Nous changeons les étiquettes pour la formation et les tests. Le noyau représente 1 ; le non-noyau représente 0.

4. Création de modèle

4.1. Création de générateur (G)

Notre approche consistait à remodeler un vecteur aléatoire z pour qu'il ait une forme 4D, puis à l'alimenter en une séquence de convolutions transposées, de normalisation par lots et d'opérations RELU qui fuient qui augmentent les dimensions spatiales du vecteur d'entrée tout en diminuant le nombre de canaux. En conséquence, le réseau produit une forme de tenseur RGB $32 \times 32 \times 3$ qui est normalisée entre les valeurs de $[-1...1]$ via la fonction de tangente hyperbolique (\tanh).

```

Model: "sequential_9"
-----
Layer (type)                Output Shape              Param #
-----
dense_30 (Dense)            (None, 8192)              827392
dense_31 (Dense)            (None, 256)               2097408
leaky_re_lu_32 (LeakyReLU)  (None, 256)               0
batch_normalization_22 (Bat (None, 256)              1024
chNormalization)
dense_32 (Dense)            (None, 512)               131584
leaky_re_lu_33 (LeakyReLU)  (None, 512)               0
batch_normalization_23 (Bat (None, 512)              2048
chNormalization)
dense_33 (Dense)            (None, 1024)              525312
leaky_re_lu_34 (LeakyReLU)  (None, 1024)              0
batch_normalization_24 (Bat (None, 1024)             4096
chNormalization)
dense_34 (Dense)            (None, 3072)              3148800
reshape_4 (Reshape)         (None, 32, 32, 3)         0
-----
Total params: 6,737,664
Trainable params: 6,734,080
Non-trainable params: 3,584
    
```

Figure 4. 1: generator model

G est formé 10 fois par époque pour surmonter un mode de défaillance dans lequel D a maîtrisé G, classant les images générées comme fausses avec une certitude absolue et ne laissant aucun gradient au générateur pour descendre. Le nombre 10 a été défini empiriquement.

4.2. Création de discriminateur (D)

Pour ce modèle, une série de convolutions, de normalisation par lots, de RELU qui fuient et d'abandon, nous instancions le modèle avec deux fonctions d'activation. Une fonction d'activation sigmoïde pour indiquer la probabilité prédite que l'image donnée soit réelle ou fausse, et, si et seulement si l'image est réelle, une fonction d'activation softmax avec $K = 2$ classes pour indiquer les probabilités prédites que l'image donnée soit noyau (label=1) ou non noyau (label=0).

```

Model: "sequential_8"
-----
Layer (type)                Output Shape                Param #
-----
conv2d_16 (Conv2D)          (None, 16, 16, 32)         896
leaky_re_lu_28 (LeakyReLU)  (None, 16, 16, 32)         0
dropout_16 (Dropout)        (None, 16, 16, 32)         0
conv2d_17 (Conv2D)          (None, 8, 8, 64)           18496
zero_padding2d_4 (ZeroPaddi (None, 9, 9, 64)           0
ng2D)
leaky_re_lu_29 (LeakyReLU)  (None, 9, 9, 64)           0
dropout_17 (Dropout)        (None, 9, 9, 64)           0
batch_normalization_20 (Bat (None, 9, 9, 64)           256
chNormalization)
conv2d_18 (Conv2D)          (None, 5, 5, 128)          73856
leaky_re_lu_30 (LeakyReLU)  (None, 5, 5, 128)          0
dropout_18 (Dropout)        (None, 5, 5, 128)          0
batch_normalization_21 (Bat (None, 5, 5, 128)          512
chNormalization)
conv2d_19 (Conv2D)          (None, 5, 5, 256)          295168
leaky_re_lu_31 (LeakyReLU)  (None, 5, 5, 256)          0
dropout_19 (Dropout)        (None, 5, 5, 256)          0
flatten_4 (Flatten)         (None, 6400)                0
-----
Total params: 389,184
Trainable params: 388,800
Non-trainable params: 384
    
```

Figure 4. 2: discriminator model

5. Environnement de développement

Notre modèle est implémenté avec une machine laptop avec les caractéristiques suivant :

- Processeur Intel Core i5 (1,8 GHz)
- Mémoire de 04 Go
- Stockage 500 Go de.

Le langage de programmation est le langage python le plus spécifié pour le domaine d'analyse des donnés. L'implémentation été réalisation localement sur le cloud de google (Google colab) pour bénéficier de GPU. Les étapes d'implémentation sont réalisé à l'aide de diverses bibliographies telles que : SciPy, Numpy, Librosa, Matplotlib, Keras, Tensorflow



Figure 4. 3: outils de développements

6. Etapes d'implémentation

- ✚ Connexion au drive pour importer la dataset

Connexion au google colab pour accédé au dataset

```
# pour google drive
from google.colab import drive
drive.mount('/content/gdrive')
```

Figure 4. 4: Importation de données à partir de drive

- ✚ Unzip le fichier de dataset

Unzip le fichier de dataset (training.zip)

```
[ ] !unzip 'gdrive/MyDrive/data_de _cancer_de_sein.zip'

Archive:  gdrive/MyDrive/data_de _cancer_de_sein.zip
  inflating: training.mat
```

Figure 4. 5: Unzip le fichier de données

- ✚ Importation des bibliographies nécessaire

Importation des bibliographies

```
from scipy.io import loadmat
import tensorflow as tf
import tensorflow.keras as K
import os
import itertools
import time
import numpy as np
from sklearn.metrics import accuracy_score
from skimage.transform import resize
import scipy.io
import matplotlib.pyplot as plt
import shutil
from sklearn.metrics import confusion_matrix, classification_report, average_precision_score
```

Figure 4. 6 : Importation des bibliographies nécessaire

✚ Chargement de dataset

```
[ ] def charger_dataset():

    dataset = scipy.io.loadmat('training.mat') #charger les données

    # devision des données
    X_train = np.transpose(dataset['train_x'], (3, 0, 1, 2))
    y_train = list(dataset['train_y'][0])

    X_test = np.transpose(dataset['test_x'], (3, 0, 1, 2))
    y_test = list(dataset['test_y'][0])

    y_train = np.asarray(y_train).reshape(-1, 1)
    y_test = np.asarray(y_test).reshape(-1, 1)

    y_test -= 1
    y_train -= 1

    #resize 32*32
    X_train_resized = np.empty([X_train.shape[0], 32, 32, X_train.shape[3]])
    for i in range(X_train.shape[0]):
        X_train_resized[i] = resize(X_train[i], (32, 32, 3), mode='reflect')

    X_test_resized = np.empty([X_test.shape[0], 32, 32, X_test.shape[3]])
    for i in range(X_test.shape[0]):
        X_test_resized[i] = resize(X_test[i], (32, 32, 3), mode='reflect')

    #normalisation des valeur [0..1] au [-1..1]
    X_train_resized = 2 * X_train_resized - 1
    X_test_resized = 2 * X_test_resized - 1
    return X_train_resized, y_train, X_test_resized, y_test
```

Figure 4. 7: fonction de chargement de dataset

✚ Définition des hyperparamètres

Pour former le modèle avec le jeu de données TMI, la taille du patch a été initialement définie comme 34×34 pixels. Cependant, étant donné que l'image d'entrée G doit commencer à partir d'un nombre entier, chaque image de l'ensemble de données d'apprentissage a été réduite à $32 \times 32 = 1024$ pixels, ce qui est suffisamment grand pour contenir un noyau dans le patch sous des images de résolution de grossissement optique 40X. Chaque taille de patch a trois canaux de couleur (channel =3).

Concernant l'optimiseur, nous avons utilisé le même optimiseur Adam avec 0,0002 taux ce qui a permis de stabiliser la formation. G et D ont tous deux utilisé le même optimiseur.

Aussi nous avons :

- Remplacez toutes les couches de mise en commun par des convolutions à foulée (discriminateur) et des convolutions à foulée fractionnaire (générateur).
- Utilisez batchnorm dans le générateur et le discriminateur.
- Supprimez les couches cachées entièrement connectées pour des architectures plus profondes.
- Utilisez l'activation LeakyReLU dans le générateur pour toutes les couches sauf pour la sortie, qui utilise Tanh.
- Utilisez l'activation LeakyReLU dans le discriminateur pour toutes les couches.
- la première couche G qui est de taille de $8 \times 8 \times 128$ pour garantir que G génère une image de taille égale à celle des images d'apprentissage.

**Définir les paramètres **

```

img_rows = 32
img_cols = 32
channels = 3
img_shape = (img_rows, img_cols, channels)

#####Define number of class
latent_dim = 100
num_classes = 2
#####Define training history

training_history = {
    'D_loss': [],
    'D_acc': [],
    'G_loss': [],
    'G_acc': [],
}

```

Figure 4. 8: Définition des hyperparamètres

 Création de model Génération

```

def build_generator(self):

    model = K.Sequential()

    model.add(K.layers.Dense(128 * 8 * 8, activation="relu", input_dim=100))
    model.add(K.layers.Dense(256, input_dim=self.latent_dim))
    model.add(K.layers.LeakyReLU(alpha=0.2))
    model.add(K.layers.BatchNormalization(momentum=0.8))
    model.add(K.layers.Dense(512))
    model.add(K.layers.LeakyReLU(alpha=0.2))
    model.add(K.layers.BatchNormalization(momentum=0.8))
    model.add(K.layers.Dense(1024))
    model.add(K.layers.LeakyReLU(alpha=0.2))
    model.add(K.layers.BatchNormalization(momentum=0.8))
    model.add(K.layers.Dense(np.prod(self.img_shape), activation='tanh'))
    model.add(K.layers.Reshape(self.img_shape))

    noise = K.layers.Input(shape=(self.latent_dim,))
    img = model(noise)

    return Model(noise, img)

```

Figure 4. 9: Fonction de création de model Génération

 Création de model discriminateur

```

def build_discriminator(self):

    model = K.Sequential()

    model.add(K.layers.Conv2D(32, kernel_size=3, strides=2, input_shape= self.img_shape, padding="same"))
    model.add(K.layers.LeakyReLU(alpha=0.2))
    model.add(K.layers.Dropout(0.25))
    model.add(K.layers.Conv2D(64, kernel_size=3, strides=2, padding="same"))
    model.add(K.layers.ZeroPadding2D(padding=((0,1),(0,1))))
    model.add(K.layers.LeakyReLU(alpha=0.2))
    model.add(K.layers.Dropout(0.25))
    model.add(K.layers.BatchNormalization(momentum=0.8))
    model.add(K.layers.Conv2D(128, kernel_size=3, strides=2, padding="same"))
    model.add(K.layers.LeakyReLU(alpha=0.2))
    model.add(K.layers.Dropout(0.25))
    model.add(K.layers.BatchNormalization(momentum=0.8))
    model.add(K.layers.Conv2D(256, kernel_size=3, strides=1, padding="same"))
    model.add(K.layers.LeakyReLU(alpha=0.2))
    model.add(K.layers.Dropout(0.25))
    model.add(K.layers.Flatten())

    img = K.layers.Input(shape=self.img_shape)
    features = model(img)
    valid = K.layers.Dense(1, activation="sigmoid")(features)
    label = K.layers.Dense(self.num_classes+1, activation="softmax")(features)
    return Model(img, [valid, label])

```

Figure 4. 10: Fonction de création de model discriminateur

✚ Lancement le discriminateur et le générateur

```

#lancer le discriminator
self.discriminator = self.build_discriminator()

optimizer = K.optimizers.Adam(learning_rate=0.0002)
self.discriminator.compile(loss=['binary_crossentropy', 'categorical_crossentropy'], # binary (real / fake)
    optimizer=optimizer,
    metrics=['accuracy'])

#lancer le generator
self.generator = self.build_generator() #gener les image aprtir de noise

z = K.layers.Input(shape=(self.latent_dim,))
img = self.generator(z)

self.discriminator.trainable = False

#discriminator valide les image generé
validity, _ = self.discriminator(img)

self.combined = Model(z, validity)
self.combined.compile(loss='binary_crossentropy', optimizer=optimizer)

```

Figure 4. 11: Lancement le discriminateur et le générateur

✚ Génération des images avec le générateur

```
def train(self, X_train, y_train, X_test, y_test, epochs, batch_size, save_interval):
    shutil.rmtree('GAN_generators_output', ignore_errors=True)
    os.makedirs("GAN_generators_output")

    valid = np.ones((batch_size, 1))
    fake = np.zeros((batch_size, 1))

    for epoch in range(epochs):

        idx = np.random.randint(0, X_train.shape[0], batch_size)
        imgs = X_train[idx]
        noise = np.random.normal(0, 1, (batch_size, self.latent_dim))
        gen_imgs = self.generator.predict(noise)
        labels = tf.keras.utils.to_categorical(y_train[idx], num_classes=self.num_classes+1)
        fake_labels = tf.keras.utils.to_categorical(np.full((batch_size, 1), self.num_classes), num_classes=self.num_classes+1)
        d_loss_real = self.discriminator.train_on_batch(imgs, [valid, labels])
        d_loss_fake = self.discriminator.train_on_batch(gen_imgs, [fake, fake_labels])
        d_loss = 0.5 * np.add(d_loss_real, d_loss_fake)
        noise = np.random.normal(0, 1, (batch_size, self.latent_dim))
        g_loss = self.combined.train_on_batch(noise, valid)
        self.training_history["D_loss"].append(d_loss[0]);
        self.training_history["D_acc"].append(100*d_loss[3]);
        self.training_history["G_loss"].append(g_loss);
        self.training_history["G_acc"].append(100*d_loss[4]);
        # print ( % (epoch, d_loss[0], 100*d_loss[3], g_loss))

        self.evaluate_discriminator(X_test, y_test)
        if epoch % save_interval == 0:
            self.save_images(epoch)
```

Figure 4. 12: fonction de génération des images avec le générateur

✚ Sauvegarde les images de génération

```
def save_images(self, epoch):
    r, c = 5, 5
    noise = np.random.normal(0, 1, (r * c, self.latent_dim))
    gen_imgs = self.generator.predict(noise)

    gen_imgs = 0.5 * gen_imgs + 0.5

    fig, axs = plt.subplots(r, c)
    cnt = 0
    for i in range(r):
        for j in range(c):
            axs[i,j].imshow(gen_imgs[cnt, :, :, 0])
            axs[i,j].axis('off')
            cnt += 1

    fig.savefig("GAN_generators_output/gan_%d.png" % epoch)
    plt.close()
```

Figure 4. 13: Sauvegarde les images de génération

✚ Evaluation de discriminateur

```
def evaluate_discriminator(self, X_test, y_test):
    valid = np.ones((y_test.shape[0], 1))

    labels = tf.keras.utils.to_categorical(y_test, num_classes=self.num_classes+1)

    scores = self.discriminator.evaluate(X_test, [valid, labels], verbose=0)

    print("Evaluating D [loss: %.4f, bi-loss: %.4f, cat-loss: %.4f, bi-acc: %.2f%%, cat-acc: %.2f%%]\n" %
          (scores[0], scores[1], scores[2], scores[3]*100, scores[4]*100))

    return (scores[0], scores[3]*100)
```

Figure 4. 14: Evaluation de discriminateur

✚ Test de prédiction

```
def predict(self, X_test, y_test):

    y_pred = self.discriminator.predict(X_test)

    y_pred = np.argmax(y_pred[1][:,-1], axis=1)

    print ('\nOverall accuracy: %f%% \n' % (accuracy_score(y_test, y_pred) * 100))
    print ('\nAveP: %f%% \n' % (average_precision_score(y_test, y_pred) * 100))
    class_names = ['Non-nuclei', 'Nuclei']
    print("Classification report:\n %s\n"
          % (classification_report(y_test, y_pred, target_names=class_names)))

    cm = confusion_matrix(y_test, y_pred)

    plt.figure()
    plot_confusion_matrix(cm, class_names, title='Confusion matrix')
```

Figure 4. 15: Test de prédiction

✚ Lancement de code

La procédure de formation était de 100 époques, avec une taille de lot de 32 images. Le nombre d'époques a été choisi après avoir évalué notre historique d'entraînement du modèle en termes de précision et de perte.

Le temps de formation moyen était de 10 minutes utilisant Keras, Tensorflow dans la plateforme google colab.

Lancer le code

```
[ ] if __name__ == '__main__':
    Model = tf.keras.Model
    X_train, y_train, X_test, y_test = charger_dataset() # charger les train et test
    gan = GAN() # appeler la class gan
    gan.train(X_train, y_train, X_test, y_test, epochs=100, batch_size=32, save_interval=5) # fit le model
    gan.plot_training_history() # afficher le plot de training
    gan.evaluate_discriminator(X_test, y_test) # evaluation de discriminator
    gan.predict(X_test, y_test) # prediction
```

Figure 4. 16: Lancement de code

✚ Résultat de génération des images

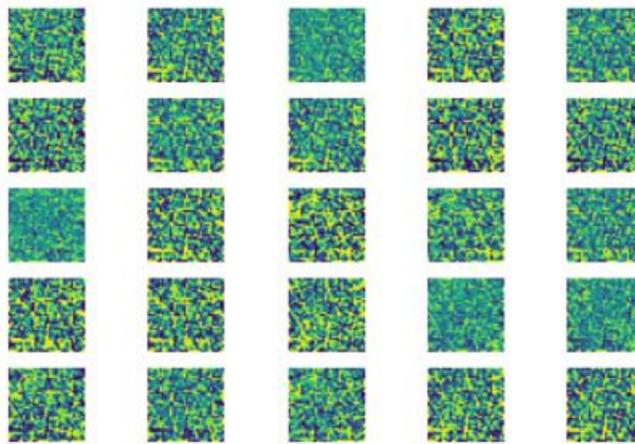


Figure 4. 17: Résultats de générateur

7. Résultats et discussion

7.1. Les matrice d'évaluation

Pour évaluer notre travaille nous avons utilisé les métriques suivantes :

- Précision (Pr) : le pourcentage des images identifiées comme des vrai (TP) parmi tous les exemples prédits comme les autres classes, il est donné par :

$$\text{Précision} = \frac{TP}{TP + FP}$$

- Recall : le pourcentage des images identifiées comme vrai (TP) parmi tous les attaques dans l'ensemble de données :

$$\text{Recall} = \frac{TP}{TP + FN}$$

- F1-score : la moyenne harmonique pondérée de précision et de rappel (Recall), il est donné par :
- $F1 - \text{score} = \frac{2 * \text{precision} * \text{recall}}{\text{Precision} + \text{recall}}$
- Matrice de confusion : La matrice de confusion est un outil de mesure de la **performance des modèles de classification à 2 classes ou plus**. Dans le cas binaire (i.e. à deux classes, le cas le plus simple), la matrice de confusion est un tableau à 4 valeurs

représentant les différentes combinaisons de valeurs réelles et valeurs prédites comme dans la figure ci-dessous.

Confusion matrix		Reality	
		Negative : 0	Positive : 1
Prediction	Negative : 0	True Negative : TN	False Negative : FN
	Positive : 1	False Positive : FP	True Positive : TP

Figure 4. 18: Matrice de confusion

Cette matrice est indispensable pour définir les différentes métriques de classification telles que l'Accuracy, le F1-score ou encore l'AUC PR et l'AUC ROC.

Les cas possibles lors d'une prédiction binaire telle qu'une grossesse sont :

- **Vrai négatif** (True Negative) :
 - La prédiction est négative et c'est la réalité.
 - Le médecin prédit que la patiente n'est pas enceinte, ce qui est vrai.
- **Vrai positif** (True Positive) :
 - La prédiction est positive et c'est la réalité.
 - Le médecin prédit que la patiente est enceinte, ce qui est vrai.
- **Faux positif** (False positive), **erreur de 1ère espèce** :
 - La prédiction est positive mais ce n'est pas la réalité.
 - Le médecin prédit que la patiente est enceinte alors qu'elle ne l'est pas.
- **Faux négatif** (False negative), **erreur de 2ème espèce** :
 - La prédiction est négative mais ce n'est pas la réalité.
 - Le médecin prédit que la patiente n'est pas enceinte alors qu'elle l'est.

7.2. Les résultats obtenus

Précision de la classification globale de D sur les 200 tests l'ensemble était de 94.7%

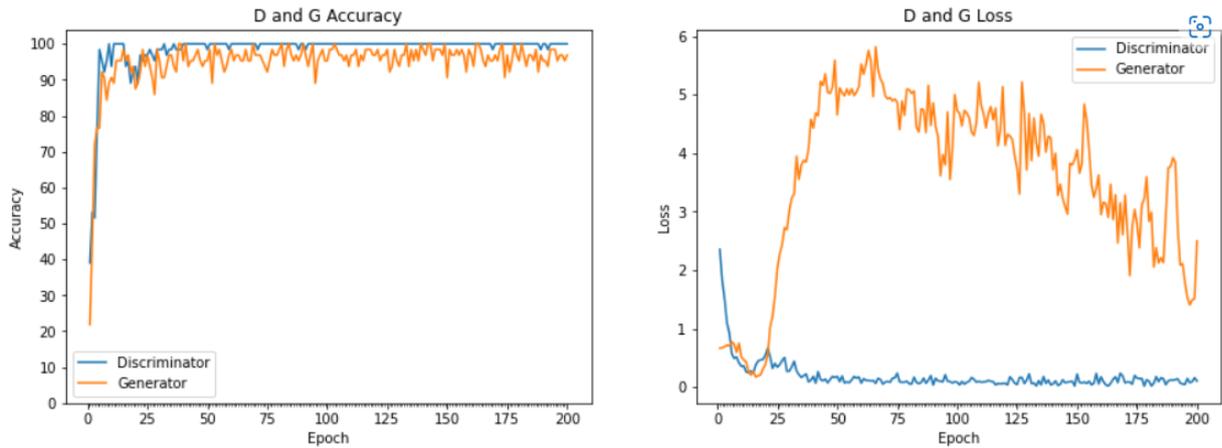


Figure 4. 19: Acc et loss de Discriminateur et Générateur

Les Figures suivant montrent le rapport de classification et la matrice de confusion pour visualiser les performances de notre modèle GAN. Il convient de mentionner que le système rend une distinction très précise entre les deux classes (97 % pour la classe 0 et 92 % pour la classe 1) car les valeurs en dehors de la diagonale sont très faibles et équilibrées.

Classification report:

	precision	recall	f1-score	support
0	0.92	0.97	0.95	500
1	0.97	0.92	0.95	500
accuracy			0.95	1000
macro avg	0.95	0.95	0.95	1000
weighted avg	0.95	0.95	0.95	1000

Figure 4. 20: rapport de classification

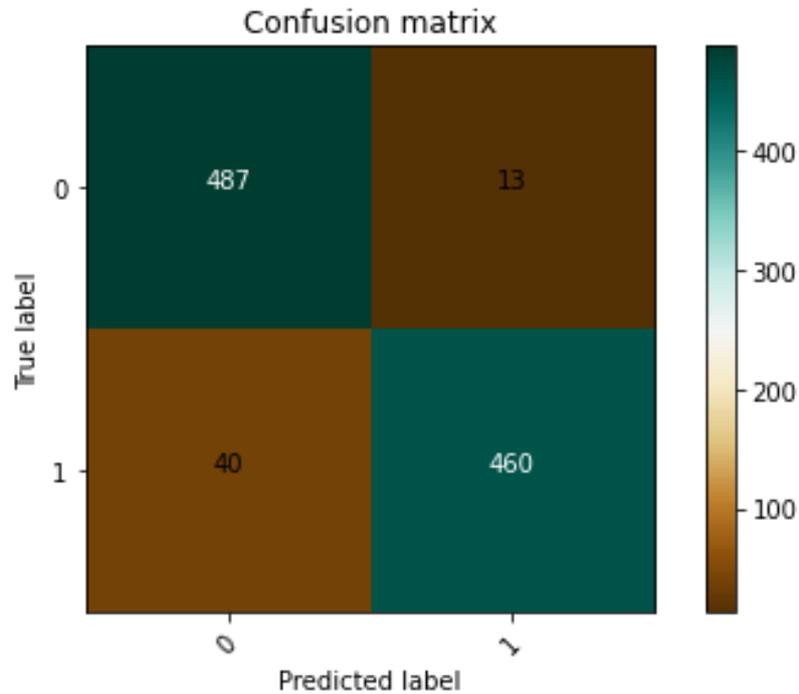


Figure 4. 21: Matrice de confusion

Conclusion

Dans ce chapitre, un algorithme GAN d'augmentation de dataset de cancer de sein est présenté. Nous avons montré comment le modèle peut capturer des représentations de caractéristiques de haut niveau de l'intensité des pixels ainsi que le processus d'implémentation de chaque étape.

Le model proposé suggérer qu'il fonctionne bien pour apprendre des fonctionnalités de haut niveau utiles pour une meilleure représentation des structures des images.

Conclusion Générale

Conclusion

La recherche dans le domaine de l'imagerie médicale utilisant des approches d'apprentissage profond est devenue progressivement contingente. Les découvertes scientifiques révèlent que les performances des méthodes d'apprentissage profond supervisé dépendent fortement de la taille de l'ensemble de formation, que les radiologues experts doivent annoter manuellement.

Dans ce projet on est créé un model utilisant l'apprentissage en profondeur, en particulier dans le domaine des GANs, et de fournir la même précision que l'étude de la littérature menée. Notre contribution unique consiste à construire un model GAN à l'aide de techniques d'apprentissage supervisées pour la catégorisation des images histopathologies dans la prédiction du cancer du sein. Afin d'améliorer la précision du modèle et de rendre le modèle approprié pour l'apprentissage supervisé, nous modifierons également certaines limitations architecturales. Nous suggérons plus d'élan, ce qui a stabilisé la majorité de notre processus d'apprentissage.

Le model proposé suggérer qu'il fonctionne bien pour apprendre des fonctionnalités de haut niveau utiles pour une meilleure représentation des structures des images.

Travaux futures

À l'avenir, nous pensons que les approches d'apprentissage en profondeur pourrait être adapté à d'autres techniques d'imagerie médicale telles que Échographie 3D ou autres modalités. La classification de masse est l'étape initiale d'un système de Conception Assistée par Ordinateur (CAO). Ainsi, dans nos travaux futurs, nous prévoir de faire la détection et la segmentation des lésions par échographie mammaire, et évaluer les performances du système Conception Assistée par Ordinateur (CAO) complet. En raison des résultats améliorés de nos expériences utilisant deep auxiliaires generative adversarial networks (DAGAN), plusieurs futurs domaines de recherche pourraient voir le jour. Nous envisagent d'expérimenter différentes structures pour développements sur la qualité des données, soit au sein du WGAN-GP en utilisant un discriminateur plus robuste, ou en utilisant un nouveau, cadre plus moderne qui conduit à une meilleure expérience performance, tels que les GAN à croissance progressive [59] ou les GANs de classificateurs auxiliaires [60].

Références bibliographiques

Références bibliographiques

1. Shorten, C.; Khoshgoftaar, T.M. A survey on image data augmentation for deep learning. *J. Big Data* 2019, 6, 60. [CrossRef]
2. Oza, P.; Sharma, P.; Patel, S. Machine learning applications for computer-aided medical diagnostics. In Proceedings of Second International Conference on Computing, Communications, and Cyber-Security; Springer: Singapore, 2021; pp. 377–392.
3. Pillai, R.; Oza, P.; Sharma, P. Review of machine learning techniques in health care. In Proceedings of ICRIC 2019; Springer: Cham, Switzerland, 2020; pp. 103–111.
4. Oza, P.; Sharma, P.; Patel, S.; Kumar, P. Deep convolutional neural networks for computer-aided breast cancer diagnostic: A survey. *Neural Comput. Appl.* 2022, 34, 1815–1836. [CrossRef]
5. Chlap, P.; Min, H.; Vandenberg, N.; Dowling, J.; Holloway, L.; Haworth, A. A review of medical image data augmentation techniques for deep learning applications. *J. Med. Imaging Radiat. Oncol.* 2021, 65, 545–563. [CrossRef]
6. LeCun, Y.; Bengio, Y.; Hinton, G. Deep learning. *Nature* 2015, 521, 436–444. [CrossRef]
7. Patel, H.J.; Oza, P.; Agrawal, S. AI Approaches for Breast Cancer Diagnosis: A Comprehensive Study. In International Conference on Innovative Computing and Communications; Springer: Singapore, 2022; pp. 393–419.
8. Oyelade, O.N.; Ezugwu, A.E. A deep learning model using data augmentation for detection of architectural distortion in whole and patches of images. *Biomed. Signal Process. Control* 2021, 65, 102366. [CrossRef]
9. Wu, E.; Wu, K.; Cox, D.; Lotter, W. Conditional infilling GANs for data augmentation in mammogram classification. In Image Analysis for Moving Organ, Breast, and Thoracic Images; Springer: Cham, Switzerland, 2018; pp. 98–106.
10. Dhivya, S.; Mohanavalli, S.; Karthika, S.; Shivani, S.; Mageswari, R. GAN based Data Augmentation for Enhanced Tumor Classification. In Proceedings of the 2020 4th International Conference on Computer, Communication and Signal Processing (ICCCSP), Chennai, India, 28–29 September 2020; pp. 1–5. [CrossRef]

11. Oza, P.; Shah, Y.; Vegda, M. A Comprehensive Study of Mammogram Classification Techniques. In Tracking and Preventing

Diseases with Artificial Intelligence; Springer: Cham, Switzerland, 2022; pp. 217–238.

12. Bruno, A.; Ardizzone, E.; Vitabile, S.; Midiri, M. A novel solution based on scale invariant feature transform descriptors and deep

learning for the detection of suspicious regions in mammogram images. *J. Med. Signals Sens.* 2020, 10, 158

[13]. American Cancer Society. Breast Cancer. 2015: <http://www.cancer.org/cancer/breastcancer/index>.

[14]. Foxson SB, Lattimer JG & Felder B . Breast cancer. Yarbro, CH, Wujcki D, & Holmes Gobel B. (eds.).

[15]. Cancer Nursing: Principles and Practice. 7th ed. Sudbury, MA: Jones and Bartlett; 2011: 48: pp. 1091-1145.

[16]. Martini FH, Timmons MJ, Tallitsch RB. Human Anatomy. 7th ed. San Francisco: Pearson Benjamin Cummings; 2012.

[17]. Morrow M, Burstein HJ, and Harris JR . Malignant tumors of the breast. DeVita VT Jr, Lawrence TS, & Rosenberg SA.

[18]. Cancer: Principles and Practice of Oncology. 10th ed. Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins; 2015: 79: 1117-1156.

[19].ref: Runbin P, Hansen JT. TNM Staging Atlas with Oncoanatomy. 2nd ed. Philadelphia, PA: Lippincott Williams & Wilkins; 2012: <http://www.lwwoncology.com>.

[20].American Cancer Society. Breast Cancer. 2016: <https://www.cancer.org/cancer/breast-cancer.html>.

[21]. American Institute for Cancer Research / World Cancer Research Fund. Continuous Update Project Report: Diet, Nutrition, Physical Activity and Breast Cancer. 2017: <http://www.aicr.org/continuous-update-project/breast-cancer.html>.

[22]. Colditz, G. A., Baer, H. J., & Tamini, R. M . Breast cancer. Schottenfeld, D. & Fraumeni, J. F. Jr. (eds.). Cancer Epidemiology and Prevention. 3rd ed. New York: Oxford University Press; 2006: 51: pp. 995-1012.

[23]. Hankinson, S., Tamini, R., & Hunter, D . Breast cancer. Adami, H.-O., Hunter, D., & Trichopoulos, D. Textbook of Cancer Epidemiology. 2nd ed. Oxford: Oxford University Press; 2008: 16: pp. 403-445.

[24]. International Agency for Research on Cancer (IARC). Volme 74: Surgical implants and other foreign bodies. 1999: <http://monographs.iarc.fr/ENG/Monographs/vol74/mono74.pdf>.

[25]. International Agency for Research on Cancer (IARC). Volume 77: Some industrial chemicals. 2000: <http://monographs.iarc.fr/ENG/Monographs/vol77/mono77.pdf>.

- [26]. International Agency for Research on Cancer (IARC). Volume 98: Painting, firefighting and shiftwork. 2010: <http://monographs.iarc.fr/ENG/Monographs/vol98/mono98.pdf>.
- [27]. International Agency for Research on Cancer (IARC). Volume 100A: Pharmaceuticals - A Review of Human Carcinogens. 2012: <http://monographs.iarc.fr/ENG/Monographs/vol100A/mono100A.pdf>.
- [29]. International Agency for Research on Cancer (IARC). Volume 100D: Radiation: a review of human carcinogens. 2011: <http://monographs.iarc.fr/ENG/Monographs/vol100D/mono100D.pdf>.
- [30]. International Agency for Research on Cancer (IARC). Volume 100E: Personal Habits and Indoor Combustions. 2012: <http://monographs.iarc.fr/ENG/Monographs/vol100E/mono100E.pdf>.
- [31]. Morrow M, Burstein HJ, and Harris JR . Malignant tumors of the breast. DeVita VT Jr, Lawrence TS, & Rosenberg SA. Cancer: Principles and Practice of Oncology. 10th ed. Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins; 2015: 79: 1117-1156.
- [32]. National Cancer Institute. Genetics of Breast and Gynecologic Cancers (PDQ®) Health Professional Version. 2016: <https://www.cancer.gov/types/breast/hp/breast-ovarian-genetics-pdq#section/all>.
- [33]. National Cancer Institute. Breast Cancer Prevention (PDQ®) Health Professional Version. 2017: <https://www.cancer.gov/types/breast/hp/breast-prevention-pdq>.
- [34]. National Cancer Institute. Breast Cancer Treatment (PDQ®) Health Professional Version. 2017: https://www.cancer.gov/types/breast/hp/breast-treatment-pdq#link/_627_toc.
- [35]. National Toxicology Program . 14th Report on Carcinogens . Department of Health and Human Services ; 2016 .4
- [36]. American Cancer Society. Breast Cancer. 2015: <http://www.cancer.org/cancer/breastcancer/index>.
- [37]. Molckovsky A, Fitzgerald B, Freedman O, et al . Clinical review: approach to inflammatory breast cancer. Canadian Family Physician. Mississauga, ON: The Family Physicians of Canada; 2009.
- [38]. Morrow M, Burstein HJ, and Harris JR . Malignant tumors of the breast. DeVita VT Jr, Lawrence TS, & Rosenberg SA. Cancer: Principles and Practice of Oncology. 10th ed. Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins; 2015: 79: 1117-1156.
- [39]. National Cancer Institute. Breast Cancer Treatment for Health Professionals (PDQ®). 2015.
- [40]. American Cancer Society. Breast Cancer. 2015: <http://www.cancer.org/cancer/breastcancer/index>.
- [41]. Morrow M, Burstein HJ, and Harris JR . Malignant tumors of the breast. DeVita VT Jr, Lawrence TS, & Rosenberg SA. Cancer: Principles and Practice of Oncology. 10th ed. Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins; 2015: 79: 1117-1156.
- [42]. National Cancer Institute. Breast Cancer Treatment for Health Professionals (PDQ®). 2015.
- [43]. National Comprehensive Cancer Network. NCCN Clinical Practice Guidelines in Oncology: Breast Cancer (Version 2.2015). http://www.nccn.org/professionals/physician_gls/f_guidelines.asp.
- [44]. American Cancer Society. Breast Cancer. 2015: <http://www.cancer.org/cancer/breastcancer/index>.

- [45]. Foxson SB, Lattimer JG & Felder B . Breast cancer. Yarbro, CH, Wujcki D, & Holmes Gobel B. (eds.). Cancer Nursing: Principles and Practice. 7th ed. Sudbury, MA: Jones and Bartlett; 2011: 48: pp. 1091-1145.
- [46]. Morrow M, Burstein HJ, and Harris JR . Malignant tumors of the breast. DeVita VT Jr, Lawrence TS, & Rosenberg SA. Cancer: Principles and Practice of Oncology. 10th ed. Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins; 2015: 79: 1117-1156.
- [47]. National Cancer Institute. Breast Cancer Treatment for Health Professionals (PDQ®). 2015.
- [48]P. Baldi et S. Brunak (1998), « Bioinformatics, the Machine Learning Approach », MIT Press, 579.
- [49](en) Anindya Gupta, Philip J. Harrison, Håkan Wieslander et Nicolas Pielawski, « Deep Learning in Image Cytometry: A Review », Cytometry Part A, vol. 95, no 4, 2019, p. 366–380 (ISSN 1552-4930, DOI 10.1002/cyto.a.23701, lire en ligne [archive], consulté le 23 avril 2019).
- [50]D. Held, S. Thrun et S. Savarese (2015), « Deep Learning for Single-View Instance Recognition » [archive], arXiv preprint arXiv:1507.08286.
- [51]W. Y. Lim, A. Ong, L. L. Soh et A. Sufi (2016), « Teachers' Voices and Change: The Structure and Agency Dialectics that Shaped Teachers' Pedagogy Toward Deep Learning », dans Future Learning in Primary Schools (pp. 147-158), Springer Singapore.
- [52]I. Mariolis, G. Peleka, A. Kargakos, et S. Malassiotis (juillet 2015). Pose and category recognition of highly deformable objects using deep learning. In Advanced Robotics (ICAR), 2015 International Conference on (pp. 655-662). IEEE (résumé [archive]).
- [53]S. E. Kahou, X. Bouthillier, P. Lamblin, C. Gulcehre, V. Michalski, K. Konda, ... et Y. Bengio (2015). EmoNets: Multimodal deep learning approaches for emotion recognition in video [archive]. arXiv preprint arXiv:1503.01800.
- [54]M. Oberweger, P. Wohlhart et V. Lepetit (2015), « Hands Deep in Deep Learning for Hand Pose Estimation » [archive], arXiv preprint arXiv:1502.06807.
- [56]A. Kendall et R. Cipolla (2015), « Modelling Uncertainty in Deep Learning for Camera Relocalization » [archive], arXiv preprint arXiv:1509.05909 (résumé [archive]).
- [57]A. Halpern et J. R. Smith (octobre 2015), « Deep Learning, Sparse Coding, and SVM for Melanoma Recognition in Dermoscopy Images », dans Machine Learning in Medical Imaging: 6th International Workshop, MLMI 2015, organisé en conjonction avec MICCAI 2015, Munich, Allemagne, 5 octobre 2015, Proceedings (Vol. 9 352, p. 118), Springer (résumé [archive]).
- [58](en) Laetitia Jeancolas, Dijana Petrovska-Delacrétaz, Graziella Mangone, Badr-Eddine Benkelfat, Jean-Christophe Corvol, Marie Vidailhet, Stéphane Lehericy et Habib Benali, « X-Vectors: New Quantitative Biomarkers for Early Parkinson's Disease Detection From Speech », Frontiers in Neuroinformatics, vol. 15, 2021 (ISSN 1662-5196, DOI 10.3389/fninf.2021.578369, lire en ligne [archive]).
- [58]M. Veres, G. Lacey et G. W. Taylor (juin 2015), « Deep Learning Architectures for Soil Property Prediction » [archive] [PDF], dans Computer and Robot Vision (CRV), 2015 12th Conference on (pp. 8-15), IEEE (résumé [archive]).
- [59]« DeepArt, l'ordinateur qui peint votre portrait » [archive], sur <https://actu.epfl.ch/> [archive], 11 avril 16 (consulté le 5 juillet 2016).

- [60]Olivier Lascar, « Le système de reconnaissance visuelle Horus destiné aux aveugles doit tout au "deep learning" » [archive], sur Sciences et Avenir.fr, 9 janvier 2017 (consulté le 21 février 2018).
- [61](en) H. Tembine, « Deep Learning Meets Game Theory: Bregman-Based Algorithms for Interactive Deep Generative Adversarial Networks », IEEE Transactions on Cybernetics, 2018, p. 1–14 (DOI 10.1109/TCYB.2018.2886238, lire en ligne [archive], consulté le 14 octobre 2019).
- [62]Ian Goodfellow and Yoshua Bengio and Aaron Courville (2016). Deep Learning. MIT Press. p. 326.
- [63]Dupond, Samuel (2019). "A thorough review on the current advance of neural network structures". Annual Reviews in Control. 14: 200–230.
- [64]Abiodun, Oludare Isaac; Jantan, Aman; Omolara, Abiodun Esther; Dada, Kemi Victoria; Mohamed, Nachaat Abdelatif; Arshad, Humaira (2018-11-01). "State-of-the-art in artificial neural network applications: A survey". Heliyon. 4 (11): e00938. doi:10.1016/j.heliyon.2018.e00938. ISSN 2405-8440. PMC 6260436. PMID 30519653.
- [65]Tealab, Ahmed (2018-12-01). "Time series forecasting using artificial neural networks methodologies: A systematic review". Future Computing and Informatics Journal. 3 (2): 334–340. doi:10.1016/j.fcij.2018.10.003. ISSN 2314-7288.
- [67]Graves, Alex; Liwicki, Marcus; Fernandez, Santiago; Bertolami, Roman; Bunke, Horst; Schmidhuber, Jürgen (2009). "A Novel Connectionist System for Improved Unconstrained Handwriting Recognition" (PDF). IEEE Transactions on Pattern Analysis and Machine Intelligence. 31 (5): 855–868. CiteSeerX 10.1.1.139.4502. doi:10.1109/tpami.2008.137. PMID 19299860. S2CID 14635907.
- [68]Sak, Haşim; Senior, Andrew; Beaufays, Françoise (2014). "Long Short-Term Memory recurrent neural network architectures for large scale acoustic modeling" (PDF).
- [69]Li, Xiangang; Wu, Xihong (2014-10-15). "Constructing Long Short-Term Memory based Deep Recurrent Neural Networks for Large Vocabulary Speech Recognition". arXiv:1410.4281 [cs.CL].
- [70]Hyötyniemi, Heikki (1996). "Turing machines are recurrent neural networks". Proceedings of STeP '96/Publications of the Finnish Artificial Intelligence Society: 13–24.
- [71] Miljanovic, Milos (Feb–Mar 2012). "Comparative analysis of Recurrent and Finite Impulse Response Neural Networks in Time Series Prediction" (PDF). Indian Journal of Computer and Engineering. 3 (1).
71. Garrucho, L.; Kushibar, K.; Jouide, S.; Diaz, O.; Igual, L.; Lekadir, K. Domain generalization in deep learning-based mass detection in mammography: A large-scale multi-center study. arXiv 2022, arXiv:2201.11620.
72. Halling-Brown, M.D.; Warren, L.M.; Ward, D.; Lewis, E.; Mackenzie, A.; Wallis, M.G.; Wilkinson, L.S.; Given-Wilson, R.M.; McAvinchey, R.; Young, K.C. OPTIMAM Mammography image database: A large-scale resource of mammography images and clinical data. Radiol. Artif. Intell. 2020, 3, e200103. [CrossRef]
73. Moreira, I.C.; Amaral, I.; Domingues, I.; Cardoso, A.; Cardoso, M.J.; Cardoso, J.S. Inbreast: Toward a full-field digital mammographic database. Acad. Radiol. 2012, 19, 236–248. [CrossRef]
74. Moura, D.C.; López, M.A.G.; Cunha, P.; Posada, N.G.d.; Pollan, R.R.; Ramos, I.; Loureiro, J.P.; Moreira, I.C.; Araújo, B.M.; Fernandes, T.C. Benchmarking datasets for breast cancer computer-aided

- diagnosis (CADx). In Proceedings of the Iberoamerican Congress on Pattern Recognition, Havana, Cuba, 20–23 November 2013; Springer: Berlin/Heidelberg, Germany, 2013; pp. 326–333.
75. Tran, S.B.; Nguyen, H.T.; Pham, H.H.; Nguyen, H.Q. Transparency strategy-based data augmentation for BI-RADS classification of mammograms. *arXiv* 2022, arXiv:2203.10609.
76. Yun, S.; Han, D.; Oh, S.J.; Chun, S.; Choe, J.; Yoo, Y. Cutmix: Regularization strategy to train strong classifiers with localizable features. In Proceedings of the IEEE/CVF International Conference on Computer Vision, Seoul, Korea, 27–28 October 2019; pp. 6023–6032.
77. Moreno-Barea, F.J.; Strazzera, F.; Jerez, J.M.; Urda, D.; Franco, L. Forward noise adjustment scheme for data augmentation. In Proceedings of the 2018 IEEE Symposium Series on Computational Intelligence (SSCI), Bangalore, India, 18–21 November 2018; pp. 728–734.
78. Naveed, H. Survey: Image mixing and deleting for data augmentation. *arXiv* 2021, arXiv:2106.07085.
79. Baek, F.; Park, S.; Kim, H. Data augmentation using adversarial training for construction-equipment classification. *arXiv* 2019, arXiv:1911.11916.
80. Antoniou, A.; Storkey, A.; Edwards, H. Data augmentation generative adversarial networks. *arXiv* 2017, arXiv:1711.04340.
81. Domingues, I.; Abreu, P.H.; Santos, J. Bi-rads classification of breast cancer: A new pre-processing pipeline for deep models training. In Proceedings of the 2018 25th IEEE International Conference on Image Processing (ICIP), Athens, Greece, 7–10 October 2018; pp. 1378–1382.
82. Zhang, X.; Zhang, Y.; Han, E.Y.; Jacobs, N.; Han, Q.; Wang, X.; Liu, J. Classification of whole mammogram and tomosynthesis images using deep convolutional neural networks. *IEEE Trans. Nanobiosci.* 2018, 17, 237–242. [CrossRef] [PubMed]
83. Castro, E.; Cardoso, J.S.; Pereira, J.C. Elastic deformations for data augmentation in breast cancer mass detection. In Proceedings of the 2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI), Las Vegas, NV, USA, 4–7 March 2018; pp. 230–234.
84. Razali, N.F.; Isa, I.S.; Sulaiman, S.N.; Karim, N.K.A.; Osman, M.K. High-level Features in Deeper Deep Learning Layers for Breast Cancer Classification. In Proceedings of the 2021 11th IEEE International Conference on Control System, Computing and Engineering (ICCSC), Penang, Malaysia, 27–28 August 2021; pp. 170–175.
85. Alkhaleefah, M.; Chittem, P.K.; Achhannagari, V.P.; Ma, S.C.; Chang, Y.L. The influence of image augmentation on breast lesion classification using transfer learning. In Proceedings of the 2020 International Conference on Artificial Intelligence and Signal Processing (AISP), Amaravati, India, 10–12 January 2020; pp. 1–5.
86. Wang, Y.; Song, M.; Tian, X. Meta-learning Based Breast Abnormality Classification on Screening Mammograms. In Proceedings of the 2021 International Conference on Computer Engineering and Application (ICCEA), Kunming, China, 25–27 June 2021; pp. 153–156.
87. Bagchi, S.; Mohd, M.N.H.; Debnath, S.K.; Nafea, M.; Suriani, N.S.; Nizam, Y. Performance Comparison of Pre-trained Residual Networks for Classification of the Whole Mammograms with Smaller Dataset. In Proceedings of the 2020 IEEE Student Conference on Research and Development (SCORED), Batu Pahat, Malaysia, 27–29 September 2020; pp. 368–373.

88. Lu, H.C.; Loh, E.W.; Huang, S.C. The classification of mammogram using convolutional neural network with specific image preprocessing for breast cancer detection. In Proceedings of the 2019 2nd International Conference on Artificial Intelligence and Big Data (ICAIBD), Chengdu, China, 25–28 May 2019; pp. 9–12.
89. Vedalankar, A.V.; Gupta, S.S.; Manthalkar, R.R. Addressing architectural distortion in mammogram using AlexNet and support vector machine. *Inform. Med. Unlocked* 2021, 23, 100551. [CrossRef]
90. Huang, M.L.; Lin, T.Y. Dataset of breast mammography images with masses. *Data Brief* 2020, 31, 105928. [CrossRef]
91. Agarwal, R.; Díaz, O.; Yap, M.H.; Llado, X.; Marti, R. Deep learning for mass detection in Full Field Digital Mammograms. *Comput. Biol. Med.* 2020, 121, 103774. [CrossRef]
92. Chougrad, H.; Zouaki, H.; Alheyane, O. Multi-label transfer learning for the early diagnosis of breast cancer. *Neurocomputing* 2020, 392, 168–180. [CrossRef]
93. Ting, F.F.; Tan, Y.J.; Sim, K.S. Convolutional neural network improvement for breast cancer classification. *Expert Syst. Appl.* 2019, 120, 103–115. [CrossRef]
94. End-to-end object detection with transformers. In *European Conference on Computer Vision*; Springer: Cham, Switzerland, 2020.
95. Azevedo, V.; Silva, C.; Dutra, I. Quantum transfer learning for breast cancer detection. *Quantum Mach. Intell.* 2022, 4, 5. [CrossRef] [PubMed]
96. Kolchev, A.; Pasyukov, D.; Egoshin, I.; Kliouchkin, I.; Pasyukova, O.; Tumakov, D. YOLOv4-Based CNN Model versus Nested Contours Algorithm in the Suspicious Lesion Detection on the Mammography Image: A Direct Comparison in the Real Clinical Settings. *J. Imaging* 2022, 8, 88. [CrossRef] [PubMed]
97. Sadad, T.; Khan, A.R.; Hussain, A.; Tariq, U.; Fati, S.M.; Bahaj, S.A.; Munir, A. Internet of medical things embedding deep learning with data augmentation for mammogram density classification. *Microsc. Res. Tech.* 2021, 84, 2186–2194. [CrossRef] [PubMed]
98. Susilo, A.B.; Sugiharti, E. Accuracy Enhancement in Early Detection of Breast Cancer on Mammogram Images with Convolutional Neural Network (CNN) Methods using Data Augmentation and Transfer Learning. *J. Adv. Inf. Syst. Technol.* 2021, 3, 9–16.
99. Wang, G.; Li, W.; Aertsen, M.; Deprest, J.; Ourselin, S.; Vercauteren, T. Aleatoric uncertainty estimation with test-time augmentation for medical image segmentation with convolutional neural networks. *Neurocomputing* 2019, 338, 34–45. [CrossRef] [PubMed]
100. Kim, I.; Kim, Y.; Kim, S. Learning loss for test-time augmentation. *arXiv* 2020, arXiv:2010.11422.
101. Wong, S.C.; Gatt, A.; Stamatescu, V.; McDonnell, M.D. Understanding data augmentation for classification: When to warp? In *Proceedings of the 2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*, Gold Coast, QLD, Australia, 30 November–2 December 2016; pp. 1–6

102. Wong, S.C.; Gatt, A.; Stamatescu, V.; McDonnell, M.D. Understanding data augmentation for classification: When to warp? In Proceedings of the 2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA), Gold Coast, QLD, Australia, 30 November–2 December 2016; pp. 1–6
104. Deng, J.; Dong, W.; Socher, R.; Li, L.J.; Li, K.; Fei-Fei, L. ImageNet: A large-scale hierarchical image database. In Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, USA, 20–25 June 2009; pp. 248–255. [CrossRef]
105. Suckling, J.; Parker, J.; Dance, D.; Astley, S.; Hutt, I.; Boggis, C.; Ricketts, I.; Stamatakis, E.; Cerneaz, N.; Kok, S.; et al.
- Mammographic Image Analysis Society (mias) Database v1. 21. International Congress Series. 2015. Available online: <https://www.repository.cam.ac.uk/handle/1810/250394> (accessed on 1 January 2022).
106. Costa, A.C.; Oliveira, H.C.; Vieira, M.A. Data augmentation: Effect in deep convolutional neural network for the detection of architectural distortion in digital mammography. In Proceedings of the Brazilian Congress on Medical Physics, Santos, Brazil, 21–24 August 2019.
107. Agarwal, M.; Mahajan, R. Medical images contrast enhancement using quad weighted histogram equalization with adaptive gamma correction and homomorphic filtering. *Procedia Comput. Sci.* 2017, 115, 509–517. [CrossRef]
108. Sahnoun, M.; Kallel, F.; Dammak, M.; Mhiri, C.; Mahfoudh, K.B.; Hamida, A.B. A comparative study of MRI contrast enhancement techniques based on Traditional Gamma Correction and Adaptive Gamma Correction: Case of multiple sclerosis pathology. In Proceedings of the 2018 4th International Conference on Advanced Technologies for Signal and Image Processing (ATSIP), Sousse, Tunisia, 21–24 March 2018; pp. 1–7.
109. Galdran, A.; Alvarez-Gila, A.; Meyer, M.I.; Saratxaga, C.L.; Araújo, T.; Garrote, E.; Aresta, G.; Costa, P.; Mendonça, A.M.; Campilho, A. Data-driven color augmentation techniques for deep skin image analysis. *arXiv* 2017, arXiv:1703.03702.
109. Min, H.; Wilson, D.; Huang, Y.; Liu, S.; Crozier, S.; Bradley, A.P.; Chandra, S.S. Fully automatic computer-aided mass detection and segmentation via pseudo-color mammograms and mask r-cnn. In Proceedings of the 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI), Iowa City, IA, USA, 3–7 April 2020; pp. 1111–1115.
110. Zhong, Z.; Zheng, L.; Kang, G.; Li, S.; Yang, Y. Random erasing data augmentation. In Proceedings of the AAAI Conference on Artificial Intelligence, New York, NY, USA, 7–12 February 2020; Volume 34, pp. 13001–13008.
111. Kang, G.; Dong, X.; Zheng, L.; Yang, Y. Patchshuffle regularization. *arXiv* 2017, arXiv:1707.07103.
112. Netzer, Y.; Wang, T.; Coates, A.; Bissacco, A.; Wu, B.; Ng, A.Y. Reading Digits in Natural Images with Unsupervised Feature Learning. 2011. Available online: http://ufldl.stanford.edu/housenumbers/nips2011_housenumbers.pdf (accessed on 14 March 2022).

113. LeCun, Y.; Bottou, L.; Bengio, Y.; Haffner, P. Gradient-based learning applied to document recognition. *Proc. IEEE* 1998, 86, 2278–2324. [CrossRef]
114. Krizhevsky, A.; Hinton, G. Learning Multiple Layers of Features from Tiny Images. 2009. Available online: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.222.9220&rep=rep1&type=pdf> (accessed on 15 December 2021).
115. Coates, A.; Ng, A.; Lee, H. An analysis of single-layer networks in unsupervised feature learning. In Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, Fort Lauderdale, FL, USA, 11–13 April 2011; pp. 215–223.
116. Oza, P.; Sharma, P.; Patel, S.; Bruno, A. A Bottom-Up Review of Image Analysis Methods for Suspicious Region Detection in Mammograms. *J. Imaging* 2021, 7, 190. [CrossRef] [PubMed]
117. Suckling, J.P. The mammographic image analysis society digital mammogram database. *Digital Mammography* 1994, 375–386. Available online: <http://peipa.essex.ac.uk/info/mias.html> (accessed on 1 January 2022).
118. Muduli, D.; Dash, R.; Majhi, B. Automated diagnosis of breast cancer using multi-modal datasets: A deep convolution neural network based approach. *Biomed. Signal Process. Control* 2022, 71, 102825. [CrossRef]
119. Jing, Y.; Yang, Y.; Feng, Z.; Ye, J.; Yu, Y.; Song, M. Neural Style Transfer: A Review. *IEEE Trans. Vis. Comput. Graph.* 2020, 26, 3365–3385. [CrossRef]
120. Heath, M.; Bowyer, K.; Kopans, D.; Kegelmeyer, P.; Moore, R.; Chang, K.; Munishkumaran, S. Current status of the digital Database for screening mammography. In *Digital Mammography*; Springer: Dordrecht, The Netherlands, 1998; pp. 457–460.
121. Cha, K.H.; Petrick, N.A.; Pezeshk, A.X.; Graff, C.G.; Sharma, D.; Badal, A.; Sahiner, B. Evaluation of data augmentation via synthetic images for improved breast mass detection on mammograms using deep learning. *J. Med. Imaging* 2019, 7, 012703. [CrossRef] [PubMed]
122. Rahman, A.S.A.; Belhaouari, S.B.; Bouzerdoum, A.; Baali, H.; Alam, T.; Eldaraa, A.M. Breast mass tumor classification using deep learning. In Proceedings of the 2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT), Doha, Qatar, 2–5 February 2020; pp. 271–276.
122. Rahman, A.S.A.; Belhaouari, S.B.; Bouzerdoum, A.; Baali, H.; Alam, T.; Eldaraa, A.M. Breast mass tumor classification using deep learning. In Proceedings of the 2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT), Doha, Qatar, 2–5 February 2020; pp. 271–276.
123. Shi, P.; Wu, C.; Zhong, J.; Wang, H. Deep learning from small dataset for BI-RADS density classification of mammography images. In Proceedings of the 2019 10th International Conference on Information Technology in Medicine and Education (ITME), Qingdao, China, 23–25 August 2019; pp. 102–109.
126. Khan, H.N.; Shahid, A.R.; Raza, B.; Dar, A.H.; Alquhayz, H. Multi-view feature fusion based four views model for mammogram classification using convolutional neural network. *IEEE Access* 2019, 7, 165724–165733. [CrossRef]

127. Zhang, X.; Zhang, Y.; Han, E.Y.; Jacobs, N.; Han, Q.; Wang, X.; Liu, J. Whole mammogram image classification with convolutional neural networks. In Proceedings of the 2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), Kansas City, MO, USA, 13–16 November 2017; pp. 700–704.
128. Assari, Z.; Mahloojifar, A.; Ahmadinejad, N. A bimodal BI-RADS-guided GoogLeNet-based CAD system for solid breast masses discrimination using transfer learning. *Comput. Biol. Med.* 2022, 142, 105160. [CrossRef]
129. Li, Z.; Cui, Z.; Wang, S.; Qi, Y.; Ouyang, X.; Chen, Q.; Yang, Y.; Xue, Z.; Shen, D.; Cheng, J.Z. Domain Generalization for Mammography Detection via Multi-style and Multi-view Contrastive Learning. In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, Strasbourg, France, 27 September–1 October 2021; Springer: Cham, Switzerland, 2021; pp. 98–108.
130. discrimination using transfer learning. *Comput. Biol. Med.* 2022, 142, 105160. [CrossRef] 130. Aly, G.H.; Marey, M.; El-Sayed, S.A.; Tolba, M.F. YOLO based breast masses detection and classification in full-field digital mammograms. *Comput. Methods Programs Biomed.* 2021, 200, 105823. [CrossRef]
131. Shen, T.; Hao, K.; Gou, C.; Wang, F.Y. Mass Image Synthesis in Mammogram with Contextual Information Based on GANs. *Comput. Methods Programs Biomed.* 2021, 202, 106019. [CrossRef]
132. Shen, R.; Yao, J.; Yan, K.; Tian, K.; Jiang, C.; Zhou, K. Unsupervised domain adaptation with adversarial learning for mass detection in mammogram. *Neurocomputing* 2020, 393, 27–37. [CrossRef]
133. Cao, H.; Pu, S.; Tan, W.; Tong, J. Breast mass detection in digital mammography based on anchor-free architecture. *Comput. Methods Programs Biomed.* 2021, 205, 106033. [CrossRef] [PubMed]
134. Zeiser, F.A.; da Costa, C.A.; Zonta, T.; Marques, N.; Roehle, A.V.; Moreno, M.; da Rosa Righi, R. Segmentation of masses on mammograms using data augmentation and deep learning. *J. Digit. Imaging* 2020, 33, 858–868. [CrossRef] [PubMed] *J. Imaging* 2022, 8, 141 21 of 22
135. *J. Imaging* 2022, 8, 141
136. (IJACSA) International Journal of Advanced Computer Science and Applications, Vol. 10, No. 5, 2019 [2] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio. Generative adversarial networks. 2014. arXiv:1406.2661v1 [stat.ML]. 1