

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique

جامعة سعد حنبل بليدة
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الإلكترونيك
Département d'Électronique



Mémoire de Projet de Fin d'Études

présenté par

Meradi Yasmine Nesrine

&

Khemis Sarah

pour l'obtention du diplôme de Master en Électronique

Option Electronique des Systèmes Embarqués

Thème

Analyse automatique d'images pulmonaires pour la détection de pathologies oncologiques et des pneumopathies

Proposé par : Dr. Reguieg F.zohra & Pr. Benblidia Nadjia

Année Universitaire 2019-2020

Je dédie ce modeste travail A:

A mes très chers parents

Aucun mot ne pourrait exprimer le respect, la gratitude, la reconnaissance, la considération et l'amour éternel que je vous porte.

Je vous remercie pour l'amour, l'encouragement et le soutien que vous m'avez apporté et que vous continuez à le faire.

Que Dieu vous procure bonne santé et une longue vie.

A mon adorable frère Sidahmed

Pour ton soutien et ton encouragement.

Je te souhaite beaucoup de bonheurs et de succès dans ta vie. Que Dieu te protège mon petit frère que j'adore.

A mon cher oncle Mounir et son épouse

Pour vos conseils et votre soutien, je ne vous remercierai jamais assez.

A ma chère tante Anissa et ses deux filles Dalila et Souhila

Pour votre appui et encouragement. Puisse Dieu vous protéger et vous garder.

A ma binôme et ma copine Khemis Sarah

Merci ma chère copine d'être là pour moi.

A toute ta famille que je leur adresse mes salutation et surtout pour tes petit neveux

Hamza et Yasser.

A toutes les personnes qui m'ont aidé, encouragé et qui étaient toujours à mes côtés.

Meradi Yasmine Nesrine

Je dédie ce mémoire à :

A ma chère jumelle Hadjer

Ma jumelle, ma chérie, mon âme... 30 octobre 1996, le jour de notre naissance. Depuis ton départ...tout est difficile. 12 ans cette année... Je ne saurais exprimer mon grand chagrin en ton absence. J'aurais souhaité ta présence en ce moment pour partager ma joie. Tu es toujours présente dans mon esprit et dans mon cœur. Aussi dans ce moment de joie, tu as toutes mes pensées.

Que ton âme repose en paix.

A ma très chère mère Missraoui Safia

Affable, honorable, aimable : Tu représentes pour moi le symbole de la bonté par excellence, la source de tendresse et l'exemple du dévouement qui n'a cessé de m'encourager et de prier pour moi.

Tes prières m'ont été d'un grand secours pour mener à bien mes études. Aucune dédicace ne saurait être assez éloquente, pour exprimer ce que tu mérites pour tous les sacrifices que tu n'as cessé de me donner depuis ma naissance, durant mon enfance et même à mon âge adulte.

Tu as fait plus qu'une mère puisse faire, pour que ses enfants suivent le bon chemin dans leur vie et leurs études.

Je te dédie ce travail en témoignage de mon profond amour. Puisse Dieu, le tout puissant, te préserver et t'accorder santé, longue vie et bonheur.

A mon Père Khemis Mohamed

Aucune dédicace ne saurait exprimer l'amour, l'estime, le dévouement et le respect que j'ai toujours pour toi.

Ce travail est le fruit de tes sacrifices que tu as consentis pour mon éducation et ma formation.

A ma très chère sœur Nawel, son mari

Mohamed et leurs enfants Hamza et Yasser

En témoignage de l'attachement, de l'amour et de l'affection que je porte pour vous. Je vous remercie pour votre encouragement sans égal et votre affection si sincère. Je vous dédie ce travail avec tous mes vœux de bonheur, de santé et de réussite.

A mon très cher frère Yassine, son épouse

Sabrina Et leur petite fille Jennah

Mon cher frère qui m'est le 2ème père, les mots ne suffisent guère pour exprimer l'attachement, l'amour et l'affection que je porte pour toi. Mon ange gardien dans les moments les plus délicats de cette vie mystérieuse. Malgré la distance, vous êtes toujours dans mon cœur. Je vous dédie ce travail avec tous mes vœux de bonheur, de santé et de réussite.

A mon très cher frère Isehak

Mon cher grand frère présent dans tous mes moments d'examens par son soutien moral et ses belles surprises sucrées. Je te souhaite un avenir plein de joie, de bonheur, de réussite et de sérénité.

A ma très chère amie Fettal Rafika

Je ne peux trouver les mots justes et sincères pour toi exprimer mon affection et mes pensées, tu es pour moi une sœur sur qui je peux compter. En témoignage de l'amitié qui nous uni et des souvenirs de tous les moments que nous avons passé ensemble, je te dédie ce travail et je te souhaite une vie pleine de santé et de bonheur.

A ma très chère amie Meradi Yasmine Nesrine

A ma chère amie Yasmine, je te remercie pour ton amitié chère à mon cœur, et je te souhaite tout le bonheur du monde. Toute mon affection pour ton admirable famille, que je remercie beaucoup.

A tous les membres de ma famille, petits et grands

Veillez trouver dans ce modeste travail l'expression de mon affection.

Khemis Sarah.

Remerciements

A Allah

Le créateur de l'univers, le tout puissant et miséricordieux, qui nous a dotés de la force, de l'intelligence et de la patience pour accomplir ce modeste travail.

A Notre Promotrice Mlle Reguieg F.Zohra

Nous avons eu l'honneur d'être parmi vos étudiants et de bénéficier de votre riche enseignement. Vos qualités pédagogiques et humaines sont pour nous un modèle. Votre gentillesse, et votre disponibilité permanente ont toujours suscité notre admiration. Nous vous remercions pour le grand honneur que vous nous avez fait d'accepter l'encadrement de ce travail. Nous vous remercions pour votre accueil, vos conseils, votre support et encouragement toute au long de période de ce travail.

A Notre Co-promotrice Mlle Benblidia Nadjia

Nous vous orientons nos profondes gratitudees pour vos judicieux conseils et votre support permanent.

Aux membres du jury

Vous nous faites un grand honneur en acceptant d'examiner et d'évaluer notre travail.

A Nos enseignants

Pour leur soutien en nous apportant leurs expériences et leurs compétences durant ces années d'études.

Nous tenons à exprimer nos sincères remerciements à nos parents pour leur soutien ainsi qu'à nos familles et amis pour leur encouragement. Nous remercions également nos amis et camarades de promotions pour ces cinq années passées ensemble, dans les meilleurs moments comme dans les pires.

ملخص: إن الأمراض الصدرية من المشاكل الصحية الخطيرة للغاية على حياة الإنسان مثل الالتهاب الرئوي وسرطان الرئة. التشخيص المبكر لأمراض الصدر مهم جدا. في هذه المذكرة ، نقترح عمليتين مختلفتين للتعلم العميق لتصنيف المرضى ، يتم تنفيذ أولهما لتصنيف صور الأشعة المقطعية إلى فئتين خبيثة وحميدة بينما تستخدم الثانية لتصنيف الصور الإشعاعية للصدر، إلى الفئة العادية والالتهاب الرئوي باستخدام الأساليب التعلم العميق

ويبين النهج المعتمد فعاليته بدقة 94 في المائة والمنطقة الواقعة تحت منحنى 98، ROC في المائة.

كلمات المفاتيح : سرطان الرئة ، التصوير الإشعاعي ، التصوير المقطعي ، الالتهاب الرئوي ، الشبكات العصبية التلافيفية ، التعلم العميق.

Résumé : Les pathologies thoraciques telles que la pneumonie et le cancer des poumons, sont des problèmes de santé, très risqués sur la vie de l'Homme. Le diagnostic précoce de ces pathologies est crucial, pour leur prise en charge. Dans ce mémoire, nous proposons deux pratiques DL différentes, pour classier des pathologies oncologiques et des pneumopathies. La première est implémentée pour classer les images TDM en deux catégories, maligne et bénigne alors que la deuxième, sert à classer les radiographiques thoraciques, en classe normale et en pneumopathie suivant les techniques connexionnistes CNN de l'apprentissage profond. L'approche adoptée montre son efficacité avec une précision de 94% et l'aire sous la courbe ROC, de 98%.

Mots clés : Cancer du poumon, Radiographie, TDM, Pneumopathie, CNN, Apprentissage profond.

Abstract: Chest diseases are life-threatening health problems such as pneumonia and lung cancer. Early diagnosis of thoracic disease is very important. In this research, we propose two different DL practices to classify the two pathologies, the first one is implemented to classify CT images, in two classes malignant and benign while the second, is used to classify chest radiographs in normal class and pneumonia, using the deep learning through the CNN techniques. The adopted approach, show its effectiveness with an accuracy of 94% and the area under the ROC curve, 98%

Keywords : Lung cancer, X-ray, CT scan, Pneumonia, CNN, DL.

Listes des acronymes et abréviations

ACC : Accuracy

API : Application Programming Interface

AUC : Area Under the Curve

AUROC : Area Under the Receiver Operating Curve

CNN : Convolutional Neural Network

CONV : Convolution

CONV2D : 2D Convolution layer

CPU : Central Processing Unit

DL : Deep Learning

FC : Fully Connected

FN : False Negative

FP : False Positive

FPR : False Positive Rate

GMDH : Group of Method of Data Handling

GPU : Graphic Processing Unit

GUI : Graphic User Interface

IA : Intelligence Artificiel

IDRI : Image Database Resource Initiative

ILSVRC : Large Scale Visual Recognition Challenge

IRM : Imagerie par Résonance Magnétique

JPEG : Joint Photographic Experts Group

LIDC : Lung Image Database Consortium

LUNA16 : Lung Nodule Analysis

ML : Machine Learning

PAC : pneumonies aigues communautaires

PAV : pneumonie acquise sous ventilation.

RELU :Rectified Linear Unit.

PET : Positron Emission Tomography.

PMC : Perceptron Multicouche.

RAM : Random Access Memory.

RCNN : Region-Convolutional Neural Network.

RNA : Réseau Neuronal Artificiel.

RN : Réseau Neuronal.

RNN : Recurrent Neural Network.

ROC : Receiver Operating Characteristic.

ROI : Région of Interest.

SE : Sensibilité.

SP : Spécificité.

SVM : Support Vector Machine.

TDM : Tomodensitométrie.

TN : True Negative.

TP : True Positive.

TPR : True Positive Rate.

VGG : Visual Geometry Group.

UH : Unité de Hounsfield.

Table des matières

Introduction générale	1
Chapitre 1 Contexte Médical.....	3
1.1 Introduction	3
1.2 Pneumologie	3
1.2.1 Anatomie des poumons.....	4
1.3 Cancer des poumons.....	5
1.3.1 Nodules Pulmonaires.....	6
1.3.2 Catégories du cancer de poumon.....	7
1.4 Pneumonie	8
1.4.1 Types de pneumonie.....	9
1.5 Imagerie médicale.....	9
1.5.1 Radiographie	10
1.5.2 IRM	11
1.5.3 PET scan	12
1.5.4 Scanner	13
1.6 Analyse des nodules dans le scanner.....	16
1.6.1 Morphologie du nodule	17
1.6.2 Contenu d'un nodule	18
1.6.3 Densité	19
1.7 Classification des nodules	20
1.8 Conclusion	21
Chapitre 2 Classification par Deep Learning.....	22
2.1 Introduction	22
2.2 Définition du Deep Learning	22
2.3 Historique du deep Learning.....	23
2.4 Principe du deep Learning	24
2.5 Réseaux de neurones classiques.....	25
2.5.1 Neurone biologique	25

2.5.2	Neurone artificiel	26
2.5.3	Architecture des réseaux de neurones.....	30
2.6	Apprentissage.....	32
2.6.1	Apprentissage supervisé	32
2.6.2	Apprentissage non supervisé.....	32
2.7	Réseaux de neurones dans le deep Learning.....	32
2.7.1	Réseau de neurones convolutifs « CNN ».....	32
2.7.2	Réseau de neurones convolutifs basée région « R-CNN »	36
2.7.3	Réseau de neurones récurrents.....	38
2.8	Conclusion	39
Chapitre 3 Fonctionnalités des modèles CNN		40
3.1	Introduction	40
3.2	Historique des CNNS	40
3.3	Architectures des CNNs.....	41
3.3.1	LeNet-5.....	41
3.3.2	AlexNet.....	42
3.3.3	ZFNet.....	43
3.3.4	GoogleNet (inception)	44
3.3.5	VGG16	44
3.3.6	VGG19	45
3.3.7	ResNet.....	46
3.3.8	SqueezeNet.....	47
3.3.9	DenseNet	49
3.3.10	ResNext	51
3.4	Travaux connexes.....	52
3.4.1	Classification des tumeurs	52
3.4.2	Classification des pneumonies.....	53
3.5	Conclusion	55
Chapitre 4 Mise en œuvre du système PneumoCNN.....		56
4.1	Introduction	56
4.2	Environnement de travail.....	56
4.2.1	Matériel utilisé.....	56

4.2.2	Environnement de programmation.....	56
4.3	Architecture du système 'PneumoCNN'	59
4.3.1	Description des bases de données	59
4.3.2	Classification des tumeurs pulmonaires par le modèle VGG16	61
4.3.3	Classification des tumeurs par le modèle VGG19	62
4.3.4	Classification des pneumonies par le modèle VGG19	64
4.4	Application du système sur des données réelles.....	65
4.4.1	Application PneumoCNN pour la classification des nodules pulmonaires.....	65
4.4.2	Application PneumoCNN pour la classification de pneumonies	65
4.4.3	Evaluation du système développé.....	66
4.5	Résultats.....	67
4.5.1	Résultats de la classification des tumeurs pulmonaires par le modèle VGG16.....	67
4.5.2	Résultats de la classification des tumeurs pulmonaires par le modèle VGG19.....	68
4.5.3	Résultats de la classification de pneumonies par le modèle VGG19	68
4.5.4	Discussion et comparaison des résultats obtenus	70
4.5.5	Evaluation de classification des tumeurs avec des travaux connexes	72
4.5.6	Evaluation des résultats de classification de la pneumonie avec des travaux connexes.....	73
4.6	Conclusion	73
	Conclusion générale.....	75
	Bibliographie	77

Liste des figures

Chapitre 1 Contexte Médical

Figure 1.1 Composition des poumons	4
Figure 1.2 Tumeur dans le poumon observé au microscope électronique à balayage....	5
Figure1.3 Micronodule pulmonaire	6
Figure1.4. Nodule pulmonaire	7
Figure 1.5 Masse pulmonaire	7
Figure1.6 Image radiologique du thorax.....	9
Figure 1.7 Image radiologique du thorax... ..	10
Figure1. 8 IRM pulmonaire	11
Figure 1.9 Nodule pulmonaire (pet scan).....	12
Figure 1.10 Scanner thoracique : nodule pulmonaire	13
Figure 1.11 Tube et détecteurs tournant autour du patient.....	14
Figure 1.12 Rangées de détecteurs alignées en face du tube à rayons X.	14
Figure 1.13 Matrice correspondant à la taille des pixels.....	14
Figure 1.14 Fenêtres de visualisation des structures thoraciques.....	15
Figure 1.15 Acquisition hélicoïdale.....	16
Figure 1.16 Différentes tailles des nodules.....	17
Figure 1.17 Types de contours.....	17
Figure 1.18 Types de calcifications.....	18
Figure 1.19. Graisse dans l'hématome pulmonaire.....	19
Figure 1.20. Nodule solide.....	19
Figure 1.21. Nodule en verre dépoli.....	20
Figure 1.22 Nodule mixte.....	20

Chapitre 2 Classification par Deep Learning

Figure 2.1 Neurone avec son arborisation dendritique	25
Figure 2.2 Représentation du neurone artificiel.....	26
Figure 2.3 Passage du neurone biologique vers le neurone formel	27
Figure 2.4 Aperçu d'un perceptron monocouche	30
Figure 2.5. Aperçu d'un perceptron multicouche	31
Figure 2.6 Exemple d'un réseau de neurones dynamique	31
Figure 2.7 Opération de convolution de profondeur 1.....	34
Figure 2.8 Opération de convolution.....	34
Figure 2.9. Opération de convolution.....	34
Figure 2.10 Opération de Pooling maximal.....	35
Figure 2.11 Architecture R-CNN	36
Figure 2.12 Architecture R-CNN rapide.....	37
Figure 2.13 Architecture Faster R-CNN.....	37
Figure 2.14 Masque R-NN.....	38
Figure 2.15. Réseaux de neurones récurrents (RNN).....	38

Chapitre 3 Fonctionnalités des modèles CNN

Figure 3.1 Architecture classique de LeNet-5.....	42
Figure 3.2 Architecture classique d'AlexNet.....	43
Figure 3.3 Architecture globale de ZFNet.....	43
Figure 3.4 Architecture globale de googleNet.....	44
Figure 3.5 Architecture globale de VGG16.....	45
Figure 3.6 Présentation de l'architecture VGG19 en comparaison avec le VGG16.....	46
Figure 3.7 Architecture globale de ResNet.....	47
Figure 3.8 Fire Module.....	48

Figure 3.9 Architecture de SqueezeNet.....	48
Figure 3.10 Représentation de l'architecture DenseNet.....	49
Figure 3.11 Couche de composition de base.....	50
Figure 3.12 Représentation du DenseNet-B.....	50
Figure 3.13 Représentation des blocs denses.....	51
Figure 3.14 Blocs ResNet et ResNeXt.....	51

Chapitre 4 Mise en œuvre du système 'PneumoCNN '

Figure 4.1 Architecture globale du Système PneumoCNN.....	59
Figure 4.2 Echantillons d'images de la base Luna16.....	60
Figure 4.3 Exemples d'images de la base Pneumonia.....	61
Figure 4.4 Architecture du VGG16 pour la classification des nodules.....	62
Figure 4.5 Architecture du VGG19 pour la classification des nodules.....	63
Figure 4.6 Architecture du VGG19 pour la classification des pneumonies.....	64
Figure 4.7 Courbe roc du modèle VGG16 pour les données Luna16.....	67
Figure 4.8 Courbe roc du modèle VGG19 pour la base Luna16.....	68
Figure 4.9 Courbes de la précision et de la perte	69
Figure 4.10 Représentation de la carte d'activation du modèle.....	70

Liste des tableaux

Chapitre 1 Contexte Médical

Tableau 1.1 Critères des nodules pulmonaires.....	21
----------------------------------------------------------	----

Chapitre 2 Classification par Deep Learning

Tableau 2.1 Passage du neurone biologique vers le neurone formel.....	27
------------------------------------------------------------------------------	----

Tableau 2.2 Fonctions d'activation d'un neurone artificiel.....	29
------------------------------------------------------------------------	----

Chapitre 3 Fonctionnalités des CNN

Tableau 3.1 Comparaison entre les architectures VGG16 et VGG19.....	46
----------------------------------------------------------------------------	----

Tableau 3.2 Résultats de M.Farukh Hashmi et al.....	54
------------------------------------------------------------	----

Chapitre 4 Conception et Implémentation

Tableau 4.1 Composition de la base de données des pneumopathies.....	61
-----------------------------------------------------------------------------	----

Tableau 4.2 Présentation des résultats obtenus (VGG16).....	67
--------------------------------------------------------------------	----

Tableau 4.3 Présentation des résultats obtenus (VGG19).....	68
--------------------------------------------------------------------	----

Tableau 4.4 Présentation des résultats de la classification des pneumonies.....	69
----------------------------------------------------------------------------------------	----

Tableau 4.5 Comparaison des deux architectures du système de classification des nodules.....	71
-----------------------------------------------------------------------------------------------------	----

Tableau 4.6 Comparaison des résultats obtenus des travaux proposés avec des travaux connexes.....	72
----------------------------------------------------------------------------------------------------------	----

Tableau 4.7 Comparaison des résultats du classifieur des pneumopathies avec un travail connexe.....	73
------------------------------------------------------------------------------------------------------------	----

Introduction générale

Le poumon est un organe vital de la structure physiologique humaine dont, les maladies pulmonaires sont l'une des causes de morbidité et de mortalités principales, dans le monde. La recherche dans le domaine de la pneumologie revêt une grande importance dans les études de santé publique et se concentre principalement sur le cancer des poumons et la pneumonie.

Le cancer du poumon est l'un des cancers, les plus meurtriers au monde. Cependant, une détection précoce de la maladie améliore considérablement le taux de survie. Si les classifications de tumeurs, bénignes ou malignes sont reconnues avec succès, une procédure de traitement, telle que la chirurgie, la radiothérapie ou la chimiothérapie peut être appliquée pour réduire le risque de décès. Le cancer du poumon peut être diagnostiqué à l'aide de différentes modalités d'imagerie, telle que la tomodensitométrie (TDM) qui est l'une des modalités les moins coûteuses et les plus efficaces, envisagées dans les cliniques pour examiner l'état des poumons. A cet effet, l'examen manuel de l'anomalie pulmonaire, nécessite un pneumologue expérimenté.

La pneumonie est une maladie pulmonaire infectieuse saisonnière, qui peut entraîner des complications potentiellement mortelles pour les enfants (âge <5 ans) et les personnes âgées (âge > 60 ans), si elles ne sont pas diagnostiquées et traitées tôt. La pneumonie peut être due au virus causal du COVID-19 (la nouvelle maladie à coronavirus 2019), ou peut être causée par une autre infection virale ou bactérienne. La pneumonie est diagnostiquée avec une variété de modalités d'imagerie, y compris la tomodensitométrie, l'IRM et la radiographie thoracique qui est l'outil de diagnostic le plus rentable, pour la détection de la pneumonie. En effet, le diagnostic de cette maladie à partir des radiographies pulmonaires, nécessite des radiologues hautement qualifiés, car ces images se chevauchent souvent, avec d'autres structures anormales des poumons. La détection manuelle de la pneumonie, est un processus qui prend du temps conduisant souvent à des différences subjectives, qui peuvent retarder le diagnostic.

De plus, l'étendue des pneumopathies, peut apparaître vague sur les images radiographiques. L'objectif de cette initiation à la recherche, est de détecter les pneumopathies, via des outils d'intelligence artificielle. En effet, le Deep Learning surmonte les problèmes du diagnostic, par la détection et la classification automatique des deux pathologies, grâce à des paramètres appropriés. Les évaluations basées sur le réseau de neurones convolutifs (CNN), montrent qu'ils sont largement utilisés, dans la classification d'images et la détection des anomalies [1]. Les CNN impliquent des filtres spatiaux qui collectent automatiquement des informations sur la structure intégrée dans l'image. Contrairement aux méthodes classiques de classification d'images existantes dans le ML, les CNN sont appliqués directement sur les images, par une approche basée sur les pixels, permettant plusieurs traitements de l'image, y compris, le prétraitement de l'image. Dans ce travail un cadre DL est proposé pour la classification des anomalies pulmonaires, telles que la pneumonie et le cancer, à l'aide des architectures des CNN, telles que le VGG16 et le VGG19 permettant d'aider le radiologue dans sa prise de décision.

Ce mémoire est structuré comme selon quatre chapitres :

Dans le chapitre 1, nous présentons l'anatomie des poumons, les deux pathologies pulmonaires, ainsi que les différentes techniques d'imagerie médicale.

Le Chapitre 2 introduit le concept du Deep Learning, en passant par son historique, pour décrire les différents réseaux de neurones correspondants.

Le Chapitre 3 parcourt les différentes architectures des CNN ainsi que, la présentation de quelques travaux connexes dans le domaine de l'imagerie pulmonaire.

Le Chapitre 4 est consacré à la présentation du système proposé, ainsi qu'aux résultats obtenus.

Nous terminons ce mémoire par une conclusion générale, résumant les résultats obtenus et présentant les perspectives possibles.

1.1 Introduction

Les maladies pulmonaires sont l'un des problèmes de santé les plus fréquents et, l'une des principales causes de décès chez les hommes, les femmes et même les enfants. Cependant, le taux de survie peut être augmenté, si ces maladies sont diagnostiquées et détectées à un stade précoce. Actuellement, la pneumonie et le cancer du poumon sont parmi les maladies mortelles, les plus courantes. La principale chance pour la détection précoce de ces maladies, est l'imagerie médicale qui reste la preuve formelle pour valider la présence ou pas de la pathologie.

Ce chapitre présente les aspects médicaux, nécessaires pour comprendre l'importance de l'analyse des images des poumons. Nous décrivons ainsi l'anatomie des poumons, le cancer des poumons avec ses catégories en passant, par la pneumonie et ses différents types. Nous décrivons les outils d'imagerie médicale pulmonaire, la qualité des images acquises ainsi que l'analyse des nodules par TDM. La fin de ce chapitre est consacrée aux classifications des nodules, en se basant sur leurs critères.

1.2 Pneumologie

La pneumologie est une branche de la médecine interne, qui s'intéresse à l'étude du fonctionnement physiologique de l'appareil respiratoire, qui englobe les voies aériennes inférieures. Cette discipline se penche principalement sur les maladies d'origine broncho-pleuro-pulmonaire, qu'elles soient aiguës ou chroniques. Les pathologies majeures traitées, sont : l'insuffisance respiratoire, l'asthme et l'emphysème, ainsi que les maladies infectieuses telles que la pneumonie, la tuberculose, la pleurésie et les abcès pulmonaires, ou encore les syndromes tumoraux comme le cancer bronchique.

Le rayon d'action de la pneumologie, est vaste. Il recouvre de nombreuses autres spécialités : anesthésie-réanimation, explorations et réentraînement à l'exercice, ventilation assistée... Considérant que le poumon est un organe vital et central de l'appareil respiratoire, il a pour rôle essentiel d'assurer une bonne oxygénation à l'organisme [2].

1.2.1 Anatomie des poumons

Les poumons sont des viscères de consistance molle, élastique, comparable à une éponge gorgée d'air et de sang (figure 1.1). Ces derniers sont responsables de la transmission de l'oxygène dans le sang et, de l'élimination du gaz carbonique. Les deux poumons occupent la majeure partie dans le thorax, au sein de la cage thoracique, ils sont séparés par le médiastin. La plèvre est une fine membrane, qui recouvre les poumons et tapisse la paroi thoracique. Elle protège les poumons et forme tout autour un coussin. La plèvre produit un liquide qui agit comme un lubrifiant, afin que les poumons puissent glisser, dans la cavité thoracique. Chaque poumon est composé de lobes, dont deux pour le poumon gauche et trois pour le droit. Chaque lobe contient des ramifications de bronches ainsi que, des artères et des veines pulmonaires. Les terminaisons des bronches, nommées bronchioles terminales, forment l'acinus. Ce dernier est composé des alvéoles pulmonaires. L'acinus possède une paroi très fine en contact avec l'air, en provenance des bronchioles et le réseau formé par les vaisseaux capillaires pulmonaires, qui sont le siège des échanges gazeux [3].

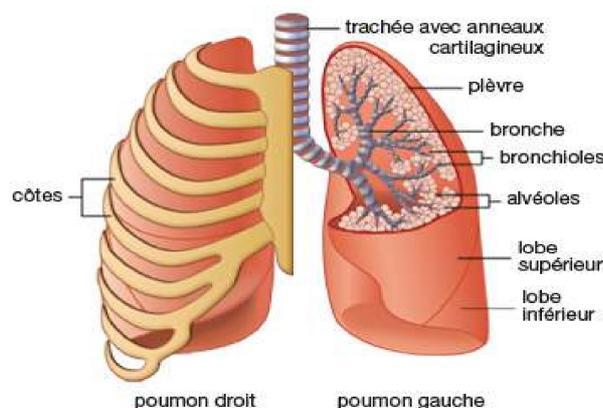


Figure 1.1 Composition des poumons [4]

1.3 Cancer des poumons

Le cancer est une maladie, qui peut toucher une partie quelconque de l'organisme, lorsque les cellules du corps commencent à se développer de façon incontrôlée [5]. Derrière ce terme existe plus d'une centaine de cancers selon l'organe qui l'abrite, le type de cellules impliquées, le degré d'évolution de la maladie et le profil de la personne qui en est atteinte et si cela commence dans les poumons, on parle alors de cancer du poumon (figure 1.2).

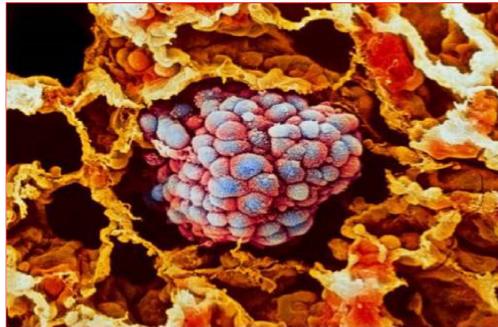


Figure 1.2 Tumeur dans le poumon observé au microscope électronique à balayage [6]

Le cancer du poumon regroupe un ensemble de pathologies, causées par la transformation cancéreuse d'un type cellulaire bronchique, amenant à la formation d'une masse qualifiée de tumeur maligne. Cette pathologie est plus fréquente, indépendamment du sexe, c'est la deuxième chez l'homme et, la troisième chez la femme. Cependant, elle reste en progression chez la femme, à cause de l'augmentation de leur consommation de tabac, au cours de ces dernières années. Le tabagisme y compris passif, est le principal facteur de risque du cancer bronchique. D'autres facteurs sont incriminés, notamment la prédisposition génétique, la consommation d'alcool, la mauvaise alimentation et l'exposition professionnelle. Cette dernière correspond au contact d'un travailleur avec des substances d'origines chimique, physique ou biologique [7].

Le cancer du poumon peut ne pas causer de symptômes, aux tout premiers stades de la maladie. Les signes et les symptômes dépendent de l'évolution de la tumeur pour provoquer ainsi, des changements dans le corps, comme la toux ou l'essoufflement. D'autres maladies peuvent causer les mêmes symptômes, que le cancer du poumon. Certains signes peuvent attirer l'attention, tels que :

- L'infection respiratoire récurrente : pneumopathie, bronchite.
- Perte d'appétit avec perte de poids sans cause apparente.
- Gonflement de la paupière et du cou.
- Toux intense avec crachat sanglant.
- Douleurs thoraciques.
- Difficulté respiratoire.
- Difficulté d'avaler.
- Fatigue majeure.

Si ces symptômes apparaissent, il est important de consulter un pneumologue pour un diagnostic, qui repose sur un examen clinique (prise de sang, radiographie, biopsie). Les bilans ont pour objectif de confirmer ou non, la présence du cancer et de caractériser la tumeur, afin de proposer un traitement optimisé pour le patient [7].

1.3.1 Nodules Pulmonaires

Le nodule est une lésion plus ou moins sphérique, siégeant à la surface d'un tissu ou bien dans un organe. Un nodule pulmonaire est en quelque sorte, une petite boule au niveau des poumons, de diamètre entre 10mm et 3cm, alors que les diamètres des micronodules, est inférieur à 10mm. Au-delà de 3 cm, la pathologie représente une masse pulmonaire [8].

a *Micronodule pulmonaire*

Un micro nodule pulmonaire (figure 1.3) est un nodule de très petite taille localisé dans une zone des poumons qui se développe dans le tissu pulmonaire et plus précisément, dans les lobules, là où prennent naissance les bronchioles [8].

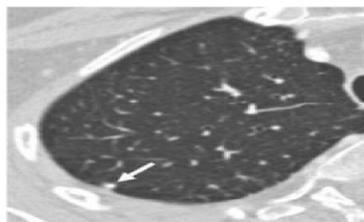


Figure 1.3. *Micronodule pulmonaire (flèche) [9]*

b Nodule pulmonaire

Une opacité radiologique sphérique (figure 1.4) qui mesure jusqu'à 3 cm de diamètre et qui est complètement entourée de parenchyme pulmonaire. Dans la majorité des cas, le nodule pulmonaire est bénin [8].

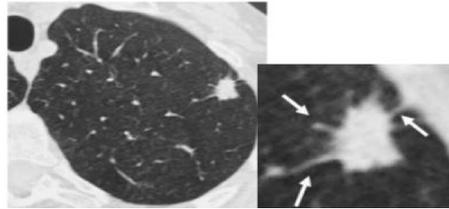


Figure 1.4 Nodule pulmonaire (flèche) [9]

c Masse pulmonaire

Il s'agit d'une opacité supérieure à 3 cm (figure 1.5), avec une haute probabilité du cancer pulmonaire [8].

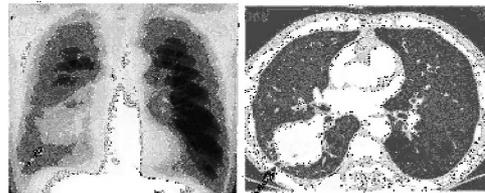


Figure 1.5 Masse pulmonaire (flèche) [9]

1.3.2 Catégories du cancer de poumon

a Cancer du poumon à petites cellules

Le cancer du poumon à petites cellules, est caractérisé par de petites cellules qui se divisent particulièrement vite. La tumeur prend naissance dans les voies respiratoires principales, du poumon appelées bronches. La tumeur se développe et se propage très rapidement, à d'autres parties du corps formant ainsi, des métastases. Le cancer du poumon à petites cellules est le type le plus agressif des cancers pulmonaires [10].

b Cancer du poumon non à petites cellules

Le cancer du poumon non à petites cellules, est le type le plus courant des pathologies pulmonaires cancéreuses. Il représente 85% des cas des cancers pulmonaires.

La tumeur est caractérisée par des cellules cancéreuses, de plus grande taille. Ce cancer se développe et se dissémine, moins rapidement. Il se divise en sous-types dont :

- **Le type à cellules glandulaires** : est le type le plus courant du cancer du poumon non à petites cellules. La tumeur prend naissance dans les cellules pulmonaires, qui fabriquent le mucus. Ce type est souvent observé dans les bords externes des poumons, chez les fumeurs mais aussi chez les non-fumeurs [10].
- **Le type à cellules pavimenteuses** : est le deuxième type le plus courant du cancer du poumon, non à petites cellules. Cette tumeur apparaît généralement dans les grandes voies respiratoires, chez les fumeurs [10].

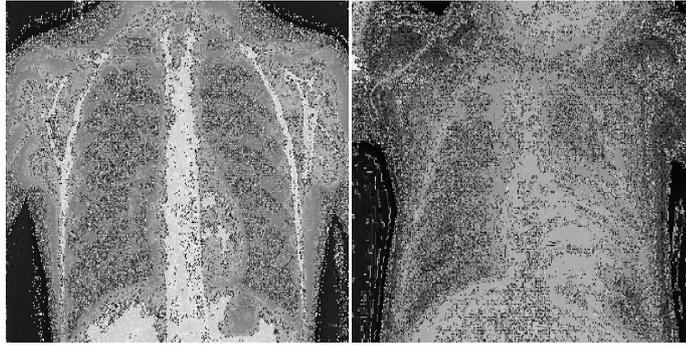
1.4 Pneumonie

La pneumonie est une infection qui enflamme les sacs aériens, dans l'un ou les deux poumons. Les sacs aériens peuvent se remplir de liquide ou de pus (matière purulente). Une pneumonie peut être causée le plus souvent par des bactéries, des virus y compris le COVID-19 et des champignons. La pneumonie peut varier d'une gravité légère, à potentiellement mortelle. Cette maladie est plus grave chez les nourrissons, les jeunes enfants, les personnes âgées de plus de 60 ans et les personnes ayant, des problèmes de santé ou un système immunitaire affaibli.

Les signes et symptômes d'une pneumonie varient de légers à graves, selon différents facteurs (le type du germe, l'âge et l'état de santé). Les signes et les symptômes de la pneumonie peuvent inclure :

- Douleur thoracique lors de la respiration.
- Confusion ou perte de conscience mentale (chez les personnes âgées de 60 ans et plus).
- Toux, fatigue, fièvre, transpiration et frissons.
- Nausées, vomissements ou diarrhée.
- Essoufflement.

La pneumonie peut ne pas causer de signe d'infection chez les nouveau-nés et les nourrissons, comme elle peut leurs causer des vomissements, de la fièvre, des toux, de la fatigue, ou paraître agités ou sans énergie, ou avoir des difficultés à respirer et à manger [71].



(a) Cas normal

(b) Cas d'une pneumonie

Figure 1.6 Image radiographique du thorax [12]

1.4.1 Types de pneumonie

La pneumonie est classée en fonction des types de germes, qui la provoquent et de l'endroit où l'infection a été contractée. La pneumonie nosocomiale est un type bactérien, qui est acquis lors d'un séjour à l'hôpital. Cela peut être plus grave que d'autres types, car les bactéries impliquées peuvent être plus résistantes aux antibiotiques. La pneumonie d'origine communautaire (PAC), fait référence à la pneumonie contractée à l'extérieur du cadre médical, ou institutionnel.

La pneumonie associée à un respirateur (PAV), correspond aux personnes qui utilisent des appareils respiratoires (ventilateurs). Souvent utilisés dans les unités de soins intensifs, les patients courent un risque plus élevé de ce type de pneumonie. La pneumonie par aspiration survient lors de l'inhalation des bactéries, dans les poumons à partir d'aliments, de boissons ou de salive. D'autres pneumonies existent qui sont moins courantes et, qui peuvent être causées par d'autres infections, y compris des champignons.

1.5 Imagerie médicale

L'imagerie médicale a subi une révolution, qui a permis d'exécuter les actes médicaux plus précisément et plus rapidement. Ses techniques élargissent la capacité des médecins pour observer, comprendre et modéliser les fonctions physiologiques et les dysfonctionnements du corps humain.

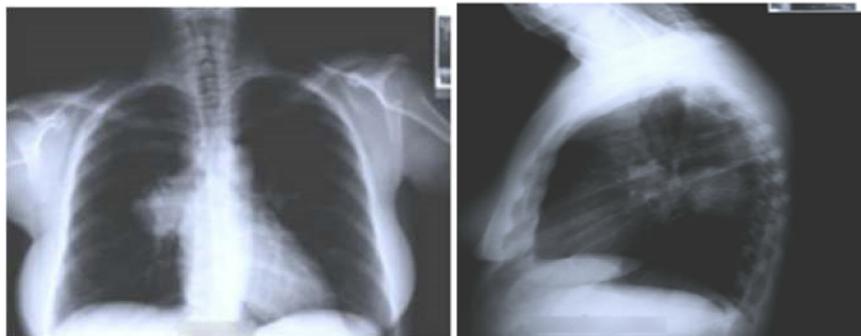
Les images sont utilisées comme des moyens d'obtention des informations, sur la santé du patient, depuis 1895, l'année de la découverte des rayons X.

En 1917, J. Radon a développé des théories mathématiques qui pourraient reconstruire des images par tomographie.

A partir de 1967, l'utilisation des images s'est élargie avec la première tomographie construite par G.N Hounsfield. Actuellement, l'imagerie médicale est une partie essentielle de la médecine pour sa possibilité d'observer des pathologies, au lieu de les déduire à partir des symptômes. Dans le domaine médical, il existe plusieurs modalités d'imagerie, chacune d'elles, offrant une vue différente du même tissu. Certaines sont utilisées pour l'anatomie de l'organe, dont la radiographie, la tomodensitométrie et l'imagerie par résonance magnétique (IRM). Une autre modalité, comme la tomographie par émission de positons (PET), étudie le métabolisme des tissus [1].

1.5.1 Radiographie

La radiographie est une technique d'imagerie médicale, qui permet d'obtenir une image des poumons grâce à l'impulsion des rayons X, pour visualiser les organes intra thoraciques ; comme les poumons, la trachée, les bronches, le médiastin et la plèvre. Cet examen a pour objectif de diagnostiquer les pathologies pulmonaires (le cancer, les inflammations, le pneumothorax, la pneumonie.....) [11].



(a) Cliché thoracique de face

(b) Cliché de profil

Figure 1.7 Image radiologique du thorax [12]

a **Avantages et les inconvénients**

Avantages

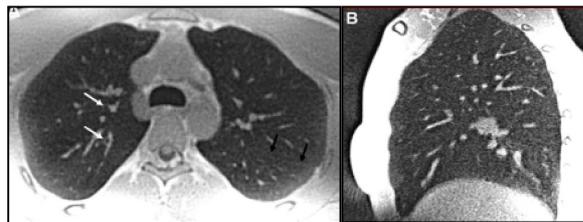
La radiographie des poumons donne des informations sur l'état des poumons, de la plèvre, et de la cage thoracique [13].

Inconvénients

La radiographie n'est pas un examen précis pour visualiser les nodules pulmonaires de petite taille [13].

1.5.2 IRM

L'imagerie par résonance magnétique (IRM) est un examen qui permet d'obtenir des vues, en deux ou trois dimensions de l'intérieur du corps, tels que le cerveau, afin de savoir si le cancer s'y est propagé. L'IRM peut aussi pour vérifier, si le cancer n'a pas envahi le cœur, ou les gros vaisseaux sanguins et les nerfs situés au sommet du poumon. Cette technique a ses limites, certaines parties du corps sont moins visibles (figure 1.8). Une IRM est particulièrement performante pour explorer le cerveau, mais pas les poumons [14].



(a) IRM pulmonaire de face

(b) IRM pulmonaire de profil

Figure 1.8 IRM pulmonaire [24]

a *Avantages et inconvénients*

Avantages

L'IRM permet de s'approcher des coupes anatomiques avec une résolution supérieure à celle des autres imageries médicales auquel la possibilité de visualiser tous les organes et l'os du corps humain, C'est un examen indolore, inoffensif et sans irradiation. Cet examen n'a aucun effet secondaire. Pour cela l'IRM peut être utilisé chez les enfants et aussi chez les femmes enceintes [15].

Inconvénients

Un patient portant un pacemaker ne peut pas passer d'IRM, à cause des champs magnétiques intenses qui pourraient, causer un arrêt cardiaque. La mauvaise visibilité des bronches intrathoraciques est l'absence du contraste du parenchyme pulmonaire. [15].

1.5.3 PET scan

Le PET-scan est un type de scanner amélioré, très précis qui permet de détecter des nodules d'une taille supérieure à 7 ou 8 mm. Le principe est d'injecter une intraveineuse de glucose radioactif sans danger pour l'organisme, puis, une heure après, les différents détecteurs placés à l'intérieur de cet appareil, captent les radiations émises et les restituent sur un écran. Dans le cas d'une fixation du glucose, cela signifie la présence d'un métabolisme élevé qui peut être en rapport avec une pathologie bénigne, inflammatoire ou maligne (figure 1.9). L'absence totale d'une fixation est généralement rassurante [16].

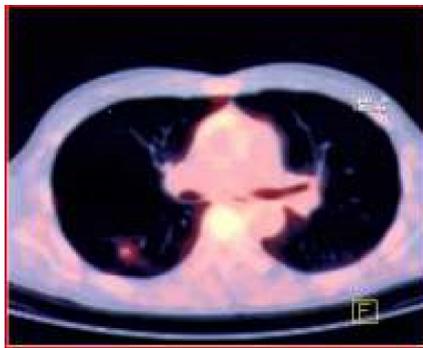


Figure 1.9 Nodule pulmonaire (pet scan) [16]

a *Avantages et inconvénients*

Avantages

Le PET ne cause ni douleurs, ni effet secondaire. En effet, il n'affecte pas le fonctionnement normal du corps, puisque les éléments radioactifs utilisés, sont à des doses extrêmement faibles [17].

Le PET scan est plus précis que l'IRM. Il possède le grand avantage, de pouvoir repérer la présence de métastases, chez le patient. Cet examen fait la différence entre une masse bénigne et une tumeur cancéreuse. Le PET a l'habileté de visualiser des tumeurs, qui ne sont pas toujours visibles aux examens radiologiques classiques [17].

Inconvénients

L'examen est inefficace pour les personnes diabétiques, à cause de la répartition différente du glucose dans leur corps. Cet examen est contre-indiqué pour la femme enceinte, même si les risques pour le fœtus sont faibles. Le PET peut causer une réaction allergique provoquant des gonflements, des douleurs ou des rougeurs [17].

1.5.4 Scanner

Le scanner thoracique est un examen d'imagerie qui peut être utilisé pour explorer les structures anatomiques du thorax : poumons, plèvre, cœur, os, tissus mous, muscles et vaisseaux sanguins irriguant les bronches et les poumons. Son principe est de réaliser des images en coupe fine d'un organe, à l'aide d'un faisceau de rayons X. Son objectif est de donner plus de précisions, sur les résultats d'une radiographie, comme la localisation et l'étendue d'une lésion (figure 1.10) sur un organe ou un tissu [18].



Figure 1.10 Scanner thoracique : nodule pulmonaire (flèche) [16]

a Principe du scanner

La tomodensitométrie repose sur la théorie de Radon, qui date de 1917. Elle décrit la possibilité de reconstruire la géométrie bidimensionnelle d'un objet, à partir d'une série de projections mesurées tout autour de celui-ci. Mais les calculs nécessaires à cette technique, la rendaient impraticable avant l'apparition des ordinateurs. L'ordinateur donne une valeur de gris proportionnelle à l'absorption des rayons X, par le volume corporel correspondant à chaque pixel d'image. Le premier scanner à rayons X a vu le jour en 1972 par un ingénieur britannique G. N. Hounsfield, d'après les travaux du physicien américain A. Macleod Cormack. Le premier prototype scanner ne permettait d'imager que le cerveau, au moyen d'une série de capteurs ou détecteurs disposés autour de la tête [19].

b Formation de l'image

La TDM constituée d'un anneau à l'intérieur duquel, se trouve le tube à rayons X, s'affronte à des rangées de détecteurs tournant autour du patient (**Figure 1.11**). Le nombre de rangées augmente à chaque nouvelle génération de détecteurs (**Figure 1.12**).

La valeur du coefficient d'atténuation des rayons X, de chaque pixel de l'image est obtenue à partir du traitement informatique des informations numériques, issues des différentes incidences angulaires, durant la rotation. La matrice de l'image est un tableau composé de n lignes et n colonnes, le plus souvent d'une taille de 512×512. Chaque pixel à l'écran représente donc une unité de volume élémentaire, appelé voxel (*figure 1.13*).

En TDM, à chaque voxel de la matrice de reconstruction, correspond un coefficient d'atténuation [20].

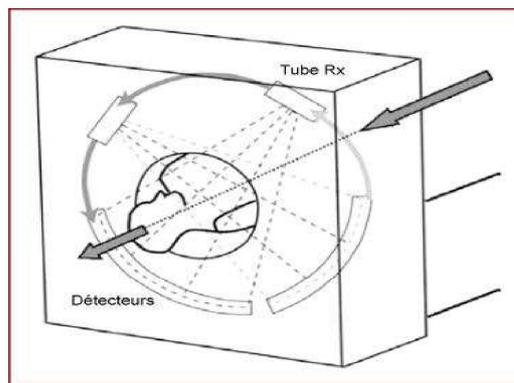


Figure 1.11 Tube et détecteurs tournant autour du patient [20]

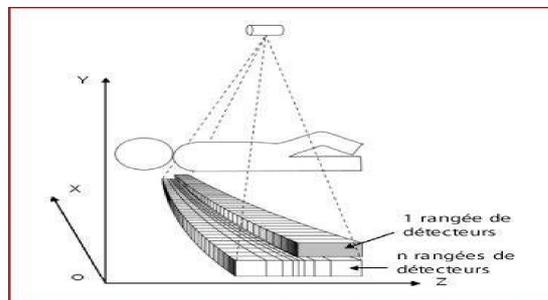


Figure 1.12 Rangées de détecteurs alignées en face du tube à rayons X [20]

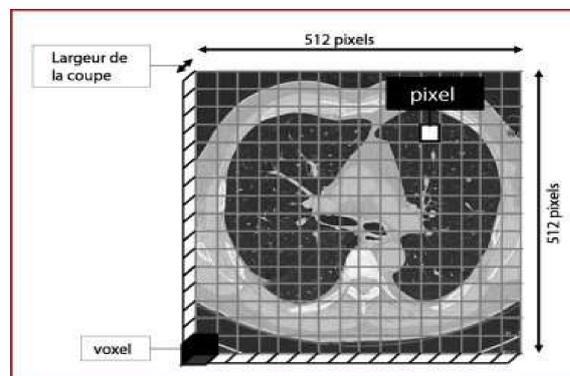


Figure 1.13 Matrice correspondant à la taille des pixels [20]

L'échelle du coefficient d'atténuation, correspond à différents intervalles, en allant de -1000 à +3000 pour l'air, avec 0 pour l'eau et +1000 pour l'os compact. La densité de La structure tissulaire varie entre 20 et 80 UH, la structure grasseuse est entre -40 et -120 UH et, la structure liquidienne pure varie entre 0 et 20 UH. L'œil humaine ne distingue que 16 niveaux de gris, alors que le corps humain a une densité de -1000 jusqu'à +1000 UH. Ce large éventail ne peut pas être visualisé simultanément à l'écran. Une fenêtre de densités est donc définie par des niveaux de gris à l'écran [20].

L'étude du médiastin se fait en utilisant, une fenêtre de largeur $w=400$ UH et, centrée par la densité moyenne des structures médiastinales $C=0$ UH (**Figure 1.13**). Les densités inférieures à -200 UH apparaîtront en noir et celles supérieures à $+200$ UH, en blanc.

Dans le poumon, l'éventail des densités est très large, d'où un contraste naturel dit élevé. Une fenêtre plus large de 1600 UH centrée sur -600 UH, est utilisée (**Figure 1.14**) [20].

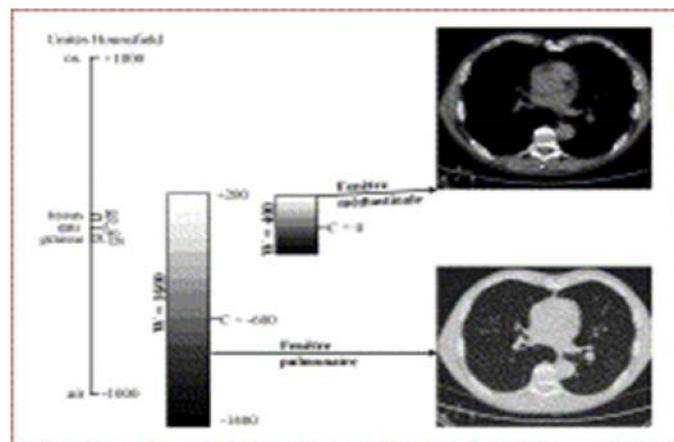


Figure 1.14 Fenêtres de visualisation des structures thoraciques [20]

- **Acquisition volumique**

La table d'examen se déplace, pendant la rotation continue du couple tube-détecteur autour du patient. Ce type d'acquisition est appelé hélicoïdal. C'est l'examen le plus utilisé actuellement, pour sa capacité d'imager la totalité du thorax, en moins de 15 secondes (**figure 1.15**) [20].

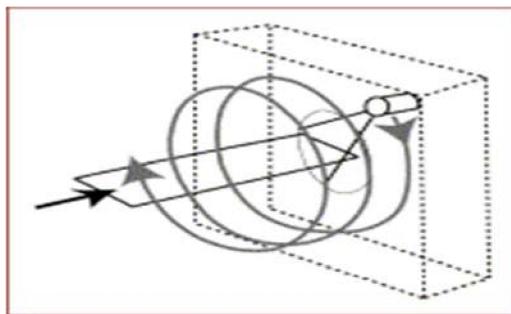


Figure 1.15 Acquisition hélicoïdale [20]

c *Qualité de l'image*

La qualité d'une image dépend de :

- La résolution en contraste : il s'agit de la capacité à différencier deux structures dont la densité est proche et altérée, par le bruit qui gêne beaucoup plus la visualisation des structures à faible contraste naturel. Ce bruit augmente avec la diminution de la dose de rayons X, la diminution de l'épaisseur des coupes reconstruites et du filtre de reconstruction de l'image [20].
- La résolution spatiale : est la distance définie par la taille du voxel qui dépend de facteurs intrinsèques à la machine, mais aussi de facteurs choisis : l'épaisseur de l'image reconstruite, la taille de la matrice, le filtre de reconstruction, le champ de reconstruction (la largeur du thorax) ou, la dose de rayons X [20].

d *Avantages et inconvénients*

Avantages

Le scanner donne des informations précises sur l'état des poumons, de la plèvre, et de la cage thoracique, grâce à des images en 3D fournies en quelques secondes. Ces images de très bonne qualité, permettent aussi l'analyse des vaisseaux des poumons [13].

Inconvénients

L'exposition aux rayons x peut causer des réactions d'intolérance imprévisible, qui peuvent se révéler sur le long terme. L'injection du radio-opaque, peut causer un hématome sans gravité et même des allergies. Ce type de réactions est fréquent chez les personnes qui souffrent du diabète, des maladies pulmonaires ou même cardiaques [13].

1.6 Analyse des nodules dans le scanner

La caractérisation d'un nodule confirmé, repose ensuite sur l'analyse de la morphologie du nodule, puis de son contenu et de sa densité.

1.6.1 Morphologie du nodule

a La taille

La taille d'un nodule (figure 1.16) est corrélée à sa probabilité de malignité. Ainsi, plus le nodule est petit, plus sa chance d'être bénin est grande. Malheureusement, ce critère ne suffit pas pour exclure la présence d'un cancer [21].

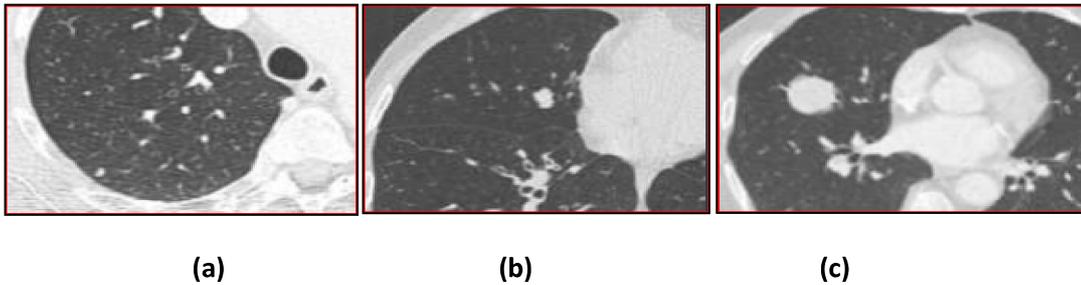


Figure 1.16 Différentes tailles des nodules
(a) <5mm avec 0.4% de malignité (b) 5-6mm avec 1-2% de malignité (c) >10mm avec 15% de malignité [21]

b Forme

La forme d'un nodule permet de diagnostiquer, la bénignité ou la malignité de ce dernier. La malformation d'un nodule est généralement une preuve de malignité [22].

c Contour

Les contours des nodules (figure 1.17) sont classés en quatre catégories, en fonction de leurs apparences sur le scanner :

- Un nodule avec des bords nets et réguliers, d'une forme sphérique. La plupart de ces nodules sont bénins. Cependant, cela ne nie pas que ces derniers puissent être malins.
- Un nodule avec des bords nets et réguliers, mais présentant des lobulations. Cela est associé souvent à la malignité.
- Un nodule avec un contour flou et mal défini. Cela est associé à une forte malignité.
- Un nodule avec un contour spiculé. Cela est associé à une forte malignité [22].

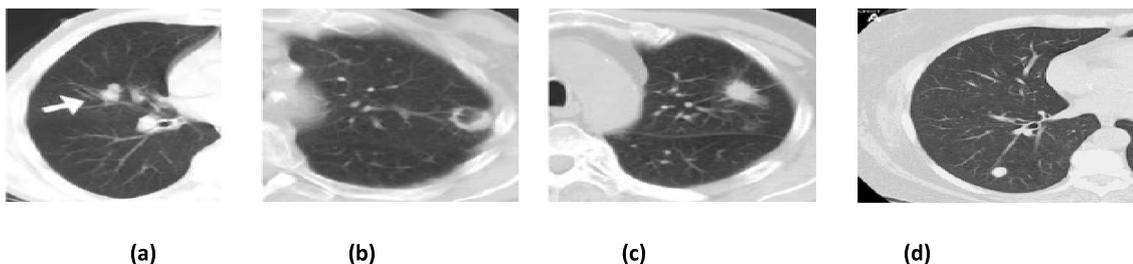


Figure 1.17 Différents contours des nodules pulmonaires
(a).Contour lobulé. (b).Contour flou et mal défini. (c).Contour spiculé. (d).Contour net et régulier [25]

1.6.2 Contenu d'un nodule

a *Calcifications*

La présence des calcifications (figure 1.18) au sein d'un nodule, est importante à considérer. Elles sont de six types :

Type 1 : Calcifications diffuses de type solide sont souvent des granulomes calcifiés.

Type 2 : Calcifications rondes, centrales, en cible. Ce type est caractérisé comme une tuberculose.

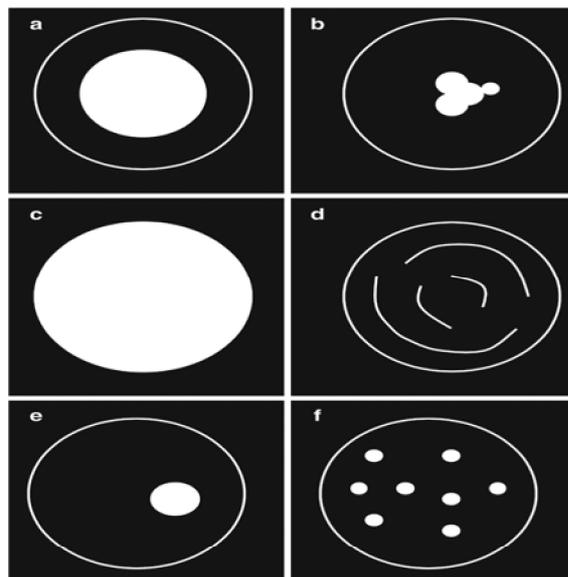
Type 3 : Calcifications lamellaires et concentriques. Ce type est également caractérisé comme une tuberculose.

Type 4 : Calcifications « en pop-corn ».

Type 5 : Calcifications excentriques.

Type 6 : Calcifications dispersées.

Les quatre premiers types peuvent être considérées comme bénignes. Par contre les deux autres calcifications, sont suggestives de lésions malignes [22].



*Figure 1.18 Types de calcifications
(a) centrales (b) popcorn (c) diffusés (d) concentriques (e) excentriques (f) dispersées [26]*

b *Graisse*

La présence de graisse dans une lésion, est l'indicateur le plus précis d'une lésion bénigne, généralement un hamartochondrome. La détermination des graisses dans un nodule pulmonaire, nécessite la détection de petites régions d'intérêt, mesurant la densité des graisses (figure 1.19) entre -40 et -120 UH [22].

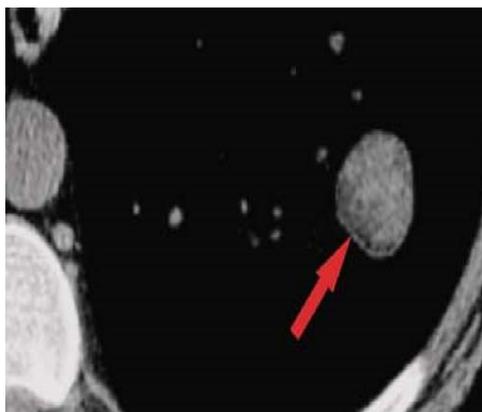


Figure 1.19 Graisse dans l'hématome pulmonaire (flèche). [27]

1.6.3 Densité

a Nodule solide

Les nodules solides (figure 1.20) de densité tissulaire, sont les plus fréquents [23]. Cette catégorie efface le contour des vaisseaux à leur contact. Leurs prises en charge dépendent de leurs tailles dont :

- Les nodules de plus de 10 mm de diamètre sont considérés comme très suspects.
- Les nodules solides de moins de 5 mm dont 0,4 % des cas sont malins.
- Les nodules solides entre 5 et 10 mm dont 1 à 3 % des cas sont malins

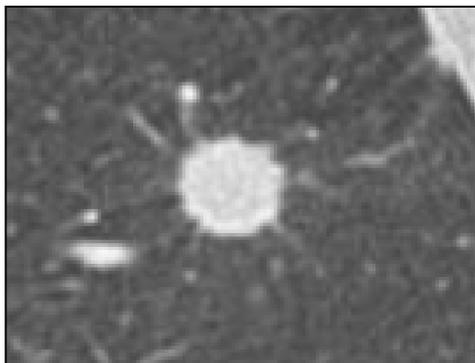


Figure 1.20 Nodule solide [21]

b Nodule Non Solide

Les nodules non solides (figure 1.21) apparaissent sous forme de plages, en verre dépoli avec une densité inférieure aux vaisseaux. Ces nodules peuvent être inflammatoires, infectieux, tumoraux ou non. Dans le cas où le nodule est de taille inférieure à 5 mm sa probabilité d'être malin, est très faible. Une forte probabilité d'avoir un nodule hyperplasique, si les nodules sont multiples [23].



Figure 1.21 Nodule en verre dépoli [21]

c Nodule semi solide ou mixte

Un nodule mixte (figure 1.22) est l'association d'une plage en verre dépoli et, d'une autre de densité tissulaire. Ce nodule peut être un adénocarcinome, ou bénin de nature infectieuse ou inflammatoire [23].

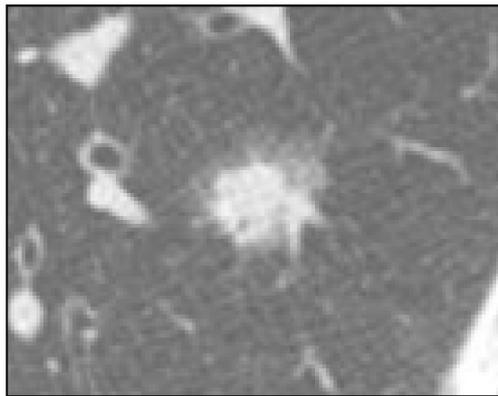


Figure 1.22 Nodule mixte [21]

1.7 Classification des nodules

A la fin de l'analyse, le nodule peut être classé [22] dans l'une des trois catégories (tableau 1.1) suivantes :

- Un nodule bénin qui ne nécessite pas d'exploration supplémentaire,
- un nodule suspecté de malignité qui nécessite une vérification histologique,
- un nodule indéterminé (le plus fréquent).

Nodule	Critères de classification
Bénin	<ul style="list-style-type: none"> - L'imprégnation calcique diffuse et intense. - Une malformation. - Les calcifications bénignes (les quatre premiers types de calcifications). - La Présence de la graisse au sein du nodule.
Malin	- Identification d'un nodule verre dépoli ou nodule mixte mesure plus de 10mm de diamètre, présente des contours spéculés ou lobulés de calcification type malin.
Indéterminé	<ul style="list-style-type: none"> - Nodule verre dépoli de 10 mm de diamètre. - Nodule solide inférieur à 20 mm de diamètre à contour non spéculé sans calcification de type malin ou bénin et sans amas graisseux.

Tableau 1.1 Critères des nodules pulmonaires [22]

1.8 Conclusion

Le cancer des poumons et la pneumonie sont les maladies les plus complexes qui soient difficiles, à diagnostiquer. Dans ce chapitre, nous avons présenté la structure anatomique des poumons, en se concentrant davantage sur l'imagerie médicale. En effet, actuellement, le scanner est devenu la technique d'imagerie thoracique de référence, qui permet de classer les lésions cancéreuses. Par contre, pour la pneumonie, la radiographie est la technique la plus recommandée. Dans le second chapitre, nous introduisons les notions fondamentales sur l'apprentissage profond.

2.1 Introduction

La classification des images médicales joue un rôle essentiel, dans le traitement clinique et le diagnostic. Cependant, les méthodes traditionnelles ont atteint leur plafond de performance. De plus, en les utilisant, cela nécessite beaucoup de temps et de traitements, à l'extraction et à la sélection des caractéristiques de la classification. Le réseau neuronal profond est une méthode de ML émergente, qui a prouvé son potentiel pour différentes tâches de classification. Notamment, le réseau neuronal convolutif domine avec les meilleurs résultats, pour les différentes tâches de classification d'images. Cependant, les ensembles de données d'images médicales, sont difficiles à collecter en raison de l'exigence d'expertise professionnelle pour les étiqueter. Ce chapitre, introduit d'abord le Deep Learning, puis les réseaux de neurones classiques et pour finir, les réseaux de neurones profonds, tels que les CNN, les R-CNN et les RNN.

2.2 Définition du Deep Learning

Le Deep Learning est une approche qui consiste à rapprocher le ML, de l'intelligence artificielle. Cette méthode concerne les algorithmes inspirés par la structure et, le fonctionnement du cerveau humain. Le Deep Learning est basé sur l'idée des réseaux de neurones artificiels, qui permettent de gérer de larges quantités de données et d'effectuer également plusieurs tâches d'imagerie : la segmentation, la détection et la classification. Les capacités des approches du DL, offrent la possibilité de diagnostiquer les soucis de santé, à un stade précoce [28].

Le Deep Learning a fait des progrès impressionnants dans l'amélioration des résultats dans l'imagerie médicale, y compris dans les domaines de l'oncologie tels que le cancer du sein ou les tumeurs cérébrales et, les maladies pulmonaires par des algorithmes spécifiques.

2.3 Historique du deep Learning

L'histoire des réseaux de neurones a connu plusieurs époques. En effet, de nombreuses personnes ont contribué à leur développement, au fil des décennies. Dans ce qui suit, une présentation des contributions les plus distinguées est abordée [28].

En 1943, le premier modèle mathématique d'un neurone a été créé par McCulloch et Pitts.

En 1949, Hebb a introduit la première idée d'apprentissage à motivation biologique, qui est une forme de l'apprentissage non supervisé (apprentissage Hebbian).

En 1957, le Perceptron a été introduit par Rosenblatt.

En 1960, Widrow et Hoff ont introduit la règle d'apprentissage Delta (la règle des moindres carrés) et une règle d'apprentissage de descente de gradient, pour mettre à jour les poids des neurones.

En 1968, la méthode GMDH (Group Method of Data Handling) a été introduite par Ivakhnenko, pour la formation des réseaux de neurones. Ces réseaux sont largement considérés comme les premiers réseaux d'apprentissage profonds du type 'Feedforward Multilayer Perceptron'.

En 1969, un article important de Minsky et Papert a été publié, qui a montré que le problème XOR ne peut pas être appris, par un Perceptron, car XOR n'est pas linéairement séparable.

En 1974, Werbos a suggéré d'utiliser la rétropropagation d'erreur (BP), dans les réseaux de neurones.

En 1980, Fukushima a introduit un réseau neuronal multicouche hiérarchique, pour la reconnaissance visuelle des formes appelé Neocognitron.

En 1982, Hopfield a introduit un réseau neuronal de mémoire, adressable par le contenu, aujourd'hui appelé Hopfield Network (un exemple de réseaux de neurones récurrents). En 1986, Rumelhart et al ont montré expérimentalement que la rétropropagation peut générer des représentations internes utiles.

En 1987, Sejnowski et Rosenberg ont introduit l'algorithme NETtalk. Le programme a appris à prononcer des mots anglais et, a pu s'améliorer avec le temps.

En 1989, Le Cun et al ont formé un réseau de neurones à convolution, avec l'algorithme de rétropropagation pour apprendre les chiffres manuscrits.

En 1991, Hochreiter a révélé le problème du gradient de disparition ou d'explosion. En 1992, Schmidhuber a proposé une solution partielle à ce problème, dont l'idée était de préformer un RNN d'une manière non supervisée, pour accélérer l'apprentissage supervisé ultérieur.

En 1995, Wang et Terman ont introduit les réseaux de neurones oscillatoires, qui ont été utilisés dans diverses applications, telles que la segmentation d'images, de la parole et la génération de séries chronologiques complexes.

En 1997, Hochreiter et Schmidhuber ont introduit le premier modèle supervisé d'apprentissage RNN.

En 1998, Le Cun et al ont introduit LeNet-5.

En 2006, Hinton et al ont montré que les 'Deep Belief Networks' peuvent être efficacement entraînés en utilisant 'Layered Greedy Pre-Workout'. Cela a lancé la troisième vague de réseaux de neurones, qui a également rendu populaire l'utilisation du terme d'apprentissage en profondeur.

En 2012, Alex Krizhevsky a remporté le défi de reconnaissance visuelle, à grande échelle ImageNet en utilisant AlexNet.

En 2014, des réseaux antagonistes génératifs ont été introduits par Goodfellow et al. L'idée est que deux réseaux de neurones, se font concurrence. Cela établit un modèle génératif, qui peut produire de nouvelles données.

En 2019, Le Cun et al ont reçu le prix Turing, pour les percées conceptuelles et techniques, qui ont fait des réseaux de neurones profonds, une composante essentielle de l'informatique.

2.4 Principe du deep Learning

Le Deep Learning fait apprendre à un modèle informatique comment réaliser des classifications à partir d'images, de textes ou d'audio. Les modèles de l'apprentissage profond, peuvent atteindre un niveau de précision exceptionnel et performant. L'entraînement des modèles s'effectue, à travers un vaste ensemble de données labellisées et, d'architectures de réseaux de neurones qui contiennent de nombreuses couches, dont chacune reçoit et interprète les informations de la couche précédente [28, 29].

2.5 Réseaux de neurones classiques

Les réseaux de neurones sont un ensemble d'algorithmes inspirés, du fonctionnement cérébral de l'être humain. Un réseau de neurone est un assemblage de neurones où chacun d'eux, fonctionne indépendamment des autres, ce qui forme un système parallèle. Ainsi, chaque neurone réalise un traitement simple, mais dont l'ensemble en interaction, fait émerger des propriétés globales complexes.

L'information est stockée d'une façon distribuée dans le réseau, sous forme de coefficients ou de fonctions d'activation, ce qui signifie l'absence de zone de mémoire et, de zone de calcul. Un réseau de neurone ne se programme pas, mais s'entraîne grâce à un mécanisme d'apprentissage. Plusieurs tâches sont adaptées au traitement par les réseaux de neurones dont : l'association, la classification, la discrimination, l'estimation, et la commande de processus complexes [29].

2.5.1 Neurone biologique

Le neurone biologique (figure 2.1) est une cellule vivante considérée, comme l'élément de base qui constitue les unités élémentaires de traitement dans le cerveau. Celui-ci reçoit des signaux, en provenance des neurones voisins, les traite, engendre, conduit et transmet l'influx nerveux à d'autres neurones [30]. Le neurone biologique se compose des parties suivantes :

- Le corps cellulaire (soma) est composé d'un noyau qui effectue les transformations biochimiques, essentielles à la vie du neurone. Il se ramifie pour former les dendrites, qui établissent la liaison avec d'autres cellules.
- L'axone est attaché au noyau qui est électriquement actif. Ce dernier conduit l'impulsion générée par le neurone.
- La synapse est le relais qui assure la transmission de l'influx nerveux.
- Les dendrites reçoivent les impulsions d'autres neurones.

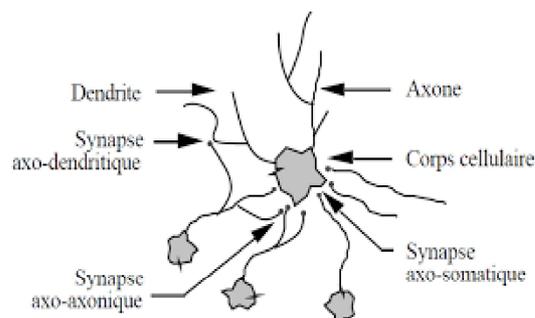


Figure 2.1 Neurone avec son arborisation dendritique [31]

2.5.2 Le neurone artificiel

Le neurone artificiel (ou le neurone formel) est la forme mathématique du neurone biologique. Ce dernier est composé de plusieurs parties dont plusieurs entrées et une seule sortie (figure 2.2). Le neurone est défini comme un processus de calcul simple, qui fait la somme des valeurs d'entrées, pour l'obtention d'une seule valeur finale. Un signal est donc transmis aux prochains neurones et ainsi de suite, si sa valeur est significative (par exemple : supérieure à un seuil minimum) [32].

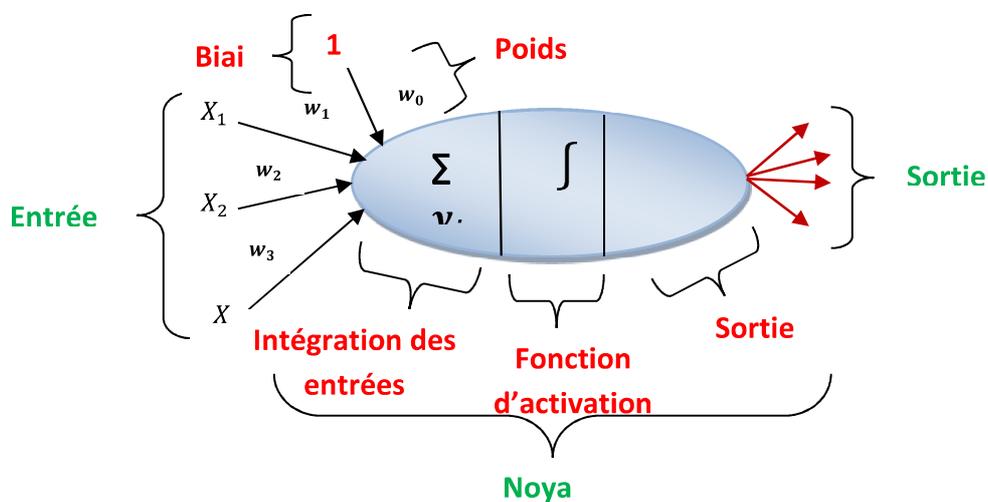


Figure 2.2 Représentation du neurone artificiel [32]

- Entrées : soit ce sont les entrées du système, soit des sorties d'autres neurones (peuvent être binaires ou réelles).
- Biais : Entrée toujours à 1 qui permet d'ajouter de la flexibilité, au réseau en permettant de varier le seuil de déclenchement du neurone, par l'ajustement du poids du biais, lors de l'apprentissage.
- Poids : Facteurs multiplicateurs qui affectent l'influence de chaque entrée, sur la sortie du neurone.
- Sortie : elle représente une des sorties du système, qui peut être distribuée vers d'autres neurones.

$$\mathbf{u} = \sum_j^n w_j x_j + \theta = \mathbf{W}'\mathbf{X} + \theta \quad (2.1)$$

$$\mathbf{y} = \varphi(\mathbf{u}) \quad (2.2)$$

Chaque entrée externe x_n est multipliée par son poids w_n associé. Toutes les entrées sont alors sommées et additionnées, à un biais. X est le vecteur d'entrée et W' est le vecteur poids. Le résultat de la somme, passe à travers une fonction de transfert ϕ (parmi lesquelles : la fonction signe, la sigmoïde, la gaussienne....etc). Cette fonction (tableau 2.2) produit alors la sortie voulue [33].

La modélisation consiste à mettre en œuvre un système sous un aspect non biologique mais artificiel. Pour chaque élément du neurone biologique, il existe son correspondant en neurone formel. Cette modélisation est résumée par le tableau 2.1 et la figure 2.3 où on voit clairement, la transition du neurone biologique au neurone formel.

Neurone biologique	Neurone artificiel
Synapses	Poids de connexions
Axones	Signal de sortie
Dendrite	Signal d'entrée
Somma	Fonction d'activation

Tableau 2.1 Passage du neurone biologique vers le neurone formel

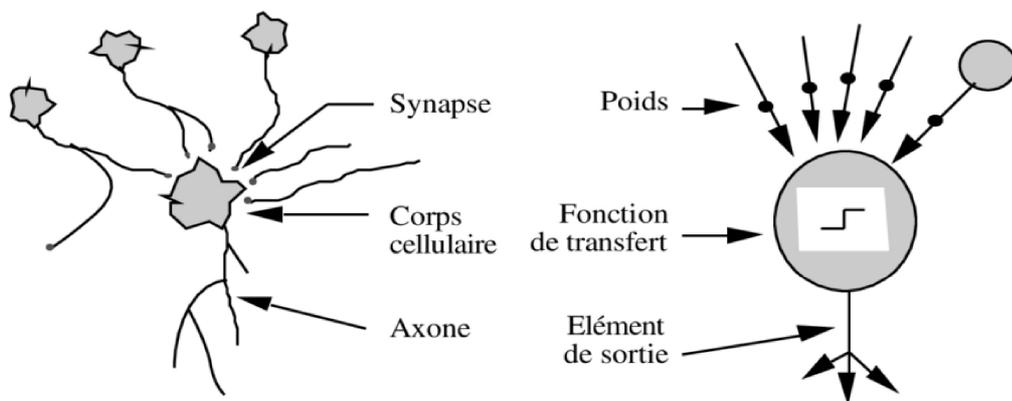
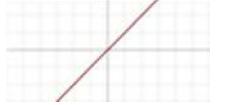
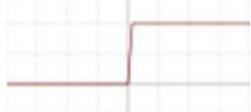


Figure 2.3 Passage du neurone biologique vers le neurone formel [31]

a La fonction d'activation

Les fonctions d'activation sont des équations mathématiques, qui déterminent la sortie d'un neurone. La fonction a pour rôle de décider d'activer ou de désactiver la sortie du neurone, en fonction d'une règle ou d'un seuil. Les fonctions d'activation aident également à normaliser la sortie de chaque neurone, dans une plage comprise entre 0 et 1 ou entre -1 et 1 [34].

Nom	Equation	Graphe
Identité / Rampe	$Y = u$	
Marche / Heaviside	$y = \begin{cases} 0 & \text{for } u < 0 \\ 1 & \text{for } u \geq 0 \end{cases}$	
Sigmoïde (Logistique)	$y = \frac{1}{1 + e^{-u}}$	
Tangente Hyperbolique (TanH)	$Y = \tanh(u) = \frac{2}{1 + e^{-2u}} - 1$	
Arc Tangente (ArcTan ou Tan-1)	$y = \tan^{-1}(u)$	
Signe doux	$y = \frac{u}{1 + u }$	
Unité de Rectification Linéaire (ReLU)	$y = \begin{cases} 0 & \text{for } u < 0 \\ u & \text{for } u \geq 0 \end{cases}$	
Unité de Rectification Linéaire Paramétrique (PReLU)	$y = \begin{cases} \alpha u & \text{for } u < 0 \\ u & \text{for } u \geq 0 \end{cases}$	
Unité Exponentielle Linéaire (ELU)	$y = \begin{cases} \alpha(e^u - 1) & \text{for } u < 0 \\ u & \text{for } u \geq 0 \end{cases}$	
Unité de Rectification Linéaire Douce (SoftPlus)	$y = \log_e(1 + e^u)$	
Identité courbée	$y = \frac{\sqrt{u^2 + 1} - 1}{2} + u$	

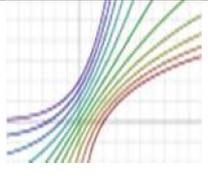
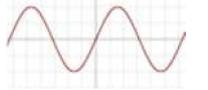
Exponentielle douce paramétrique (soft exponentiel)	$y(\alpha, u) = \begin{cases} -\frac{\log_e(1 - \alpha(u + \alpha))}{\alpha} & \text{for } \alpha < 0 \\ u & \text{for } \alpha = 0 \\ \frac{e^{\alpha u} - 1}{\alpha} + \alpha & \text{for } \alpha > 0 \end{cases}$	
Sinusoïde	$y = \sin(x)$	
Sinus cardinal (Sinc)	$y = \begin{cases} 1 & \text{for } u = 0 \\ \frac{\sin(u)}{u} & \text{for } u \neq 0 \end{cases}$	
Fonction Gaussienne	$y = e^{-u^2}$	

Tableau 2.2 Fonctions d'activation d'un neurone artificiel [42]

- **Fonction sigmoïde**

La fonction sigmoïde (logistique) est un classificateur binaire. La fonction sigmoïde prend une valeur réelle en entrée et la transforme en une valeur réelle de sortie comprise entre 0 et 1. Si la valeur en entrée est un très grand nombre positif, la fonction convertira cette valeur en une probabilité de 1. A l'inverse, si la valeur en entrée est un très grand nombre négatif, la fonction convertira cette valeur en une probabilité de 0.

- **Fonction Relu**

Relu est la fonction d'activation la plus utilisée (presque tous les CNN l'utilise). Cette fonction est interprétée par la formule: $y = \max(\mathbf{0}, u)$. Si l'entrée est négative, la sortie est 0, sinon la sortie est u. Cette fonction d'activation augmente considérablement, la convergence du réseau et ne sature pas [43].

- **Fonction softmax**

La fonction d'activation softmax est utilisée dans les réseaux de neurones lors de la construction d'un classificateur multi-classe qui résout le problème de l'affectation d'une instance à une classe lorsque le nombre de classes possibles est supérieur à deux. Softmax s'utilise comme fonction de sortie de la dernière couche dans les réseaux neuronaux. Ce fait est important car le but de la dernière couche est de transformer le score produit par le réseau neuronal en valeurs qui peuvent être interprétées par les humains [56].

2.5.3 Architecture des réseaux de neurones

L'architecture joue un rôle déterminant, dans la classification des RNA dont chaque modèle a sa propre organisation selon la topologie de leur connexion adaptée à des applications bien spécifiques. Les RNA peuvent être classés en deux grandes catégories :

a Réseaux statiques

Les Réseaux statiques (FEED FORWARD) sont des réseaux à couches, dont l'information circule des entrées vers les sorties, sans retour en arrière. Les neurones qui effectuent le dernier calcul sont ceux de la sortie. Ceux qui effectuent les calculs intermédiaires, sont les neurones cachés. Ce type de réseaux est utilisé pour classifier ou modéliser, des tâches de fonctions non linéaires [35].

✚ Perceptron

Le perceptron simple (figure 2.4) est un réseau monocouche, acyclique qui est déclenché par la réception d'information en entrée. Ce réseau est très simple grâce à sa composition d'une couche d'entrée et une autre de sortie, sans avoir une couche cachée. L'ensemble des unités de la couche d'entrée sont connectés à celles de la couche de sortie. Ce réseau obéit généralement à un apprentissage supervisé, selon la règle de correction d'erreur [36].

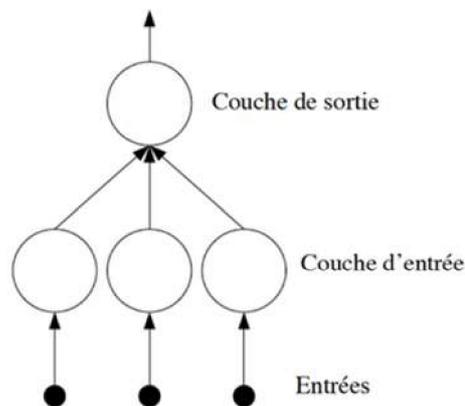


Figure 2.4 Aperçu d'un perceptron monocouche [37]

✚ Perceptron multicouches « PMC »

Un PMC (figure 2.5) est un réseau feed-forward qui dispose d'une couche d'entrée, une couche de sortie et des couches intermédiaires, appelées couches cachées. Chaque neurone dans la couche cachée, est connecté à tous les neurones de la couche précédente et de la couche suivante. Les cellules d'une même couche, n'ont pas de connexions entre elles. Dans un PMC, les neurones peuvent utiliser une fonction d'activation de type sigmoïde.

Un PMC associe une entrée à une sortie et est capable de réaliser des tâches de classification, généralisation et de prédiction. Chaque neurone contient aussi une fonction somme, une fonction d'activation et un biais [37].

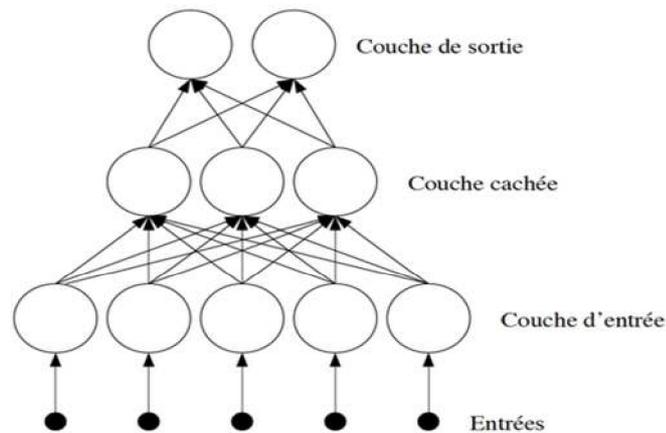


Figure 2.5 Aperçu d'un perceptron multicouche [36]

✚ Réseaux à connexion locales

Les réseaux à connexions locales, ont une structure multicouche, à l'image de la rétine (conserve une certaine topologie). Chaque neurone entretient des relations avec un nombre réduit et localisé, de neurones de la couche avale. Les connexions sont moins nombreuses, que dans un réseau multicouche classique [31].

b Réseaux dynamiques

Les réseaux dynamique (Feedback) ont un graphe de connexions cycliques (figure 2.6), comprenant des boucles qui ramènent la valeur de la sortie (une ou plusieurs) aux entrées. La sortie d'un neurone du réseau, peut donc être fonction d'elle-même. Les connexions récurrentes ramènent l'information, en arrière par rapport au sens de la propagation définie dans un réseau multicouche (ce sont le plus souvent des connexions locales). Un retard est introduit, pour éliminer le problème de la détermination de l'état du réseau par bouclage. Cela permet de conserver le mode de fonctionnement séquentiel du réseau [38].

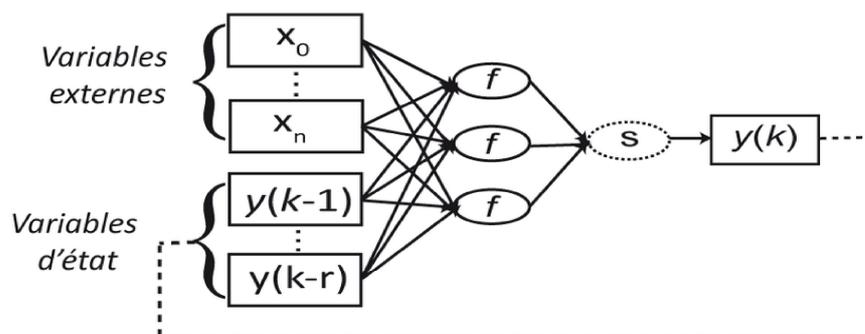


Figure 2.6 Exemple d'un réseau de neurones dynamique [38]

2.6 Apprentissage

L'apprentissage est une étape itérative du développement du RN, permettant de déterminer ou de modifier les paramètres du réseau, jusqu'à l'obtention du comportement désiré. Durant cette phase, le réseau ajuste ses poids par des algorithmes spécifiques, afin d'obtenir des valeurs optimales pour résoudre le problème. L'apprentissage est défini aussi, comme un processus de la mise à jour des poids, au sein du réseau qui a pour but d'ajuster la réponse du réseau. Le type d'apprentissage est déterminé, par la manière dont les changements de paramètres auront lieu [39].

2.6.1 Apprentissage supervisé

Dans l'apprentissage supervisé, la connaissance a priori de la sortie désirée, est nécessaire. Le vecteur d'entrée est présenté au réseau, puis sa sortie est calculée et comparée à la sortie désirée. L'ajustement des poids est ensuite fait, à partir de l'erreur de façon à réduire l'écart entre elles. Cette procédure est répétée jusqu'à ce qu'un, critère de performance soit satisfait [41].

2.6.2 Apprentissage non supervisé

L'apprentissage non supervisé se base uniquement sur les valeurs d'entrée, sans fournir de réponse désirée. Des exemples sont fournis à l'entrée du réseau, pour produire des valeurs de sortie proches en réponse à des valeurs d'entrée similaires. L'apprentissage est accompli à l'aide des règles, qui changent ou adaptent le poids des coefficients synaptiques en fonction des exemples, présentés à l'entrée. Ce comportement est connu sous le nom "auto organisation" [40].

2.7 Réseaux de neurones dans le deep Learning

2.7.1 Réseau de neurones convolutifs « CNN »

Les réseaux convolutifs sont une forme particulière des réseaux neuronaux multicouches, dont l'architecture des connexions est inspirée, de celle du cortex visuel des mammifères. En d'autres termes, c'est l'un des algorithmes les plus répandus pour le Deep Learning composé de multiples couches, qui sont organisées en blocs (CONV → RELU → POOL). Ces types de réseaux de neurones sont utilisés principalement, pour classer les images, regrouper les images par similitude (recherche d'images) et effectuer la reconnaissance d'objets, pour identifier les visages, les individus et même les tumeurs.

C'est l'une des principales raisons, pour lesquelles l'apprentissage profond est devenu dominant dans diverses tâches de la vision par ordinateur, suscitant l'intérêt dans une variété de domaines, y compris la radiologie [29].

a **Architecture des CNNs**

Les couches de neurones sont organisées de façon à couvrir tout le champ visuel, afin d'éviter le problème du traitement d'images fragmentées, des réseaux neuronaux classiques. Un CNN utilise un système comparable au perceptron multicouche, mais conçu pour réduire le nombre de calculs. La structure d'un CNN consiste en une succession de couches : une couche d'entrée, une couche de sortie et une couche cachée constituée d'au moins d'une couche de convolution, de pooling et, de ReLu suivies d'une ou plusieurs couches complètement connectées [44].

Couche convolution

La convolution est le cœur du réseau de neurones convolutif. Son but est d'extraire les tuiles de la carte de caractéristiques d'entrée, en leur appliquant des filtres, pour calculer de nouvelles caractéristiques ; qui produisent une carte de caractéristiques de sortie, ou caractéristique convolutive (dont la taille et la profondeur peuvent être différentes de celles de la carte des caractéristiques d'entrée). Deux hyperparamètres clés définissent l'opération de convolution, la taille et le nombre de noyaux. Le premier est généralement de 3×3 , mais parfois de 5×5 ou de 7×7 . Le second est arbitraire et détermine la profondeur des cartes des caractéristiques de sortie, qui correspond au nombre de filtres appliqués. Au cours d'une convolution, les filtres commencent à se déplacer horizontalement et verticalement sur la grille de la carte de caractéristiques d'entrée, par un pixel à la fois, extrayant chaque tuile correspondante. Le modèle CNN multiplie la matrice de filtres, par la matrice de tuiles (**figure 2.8**) puis additionne tous les éléments de la matrice résultante, pour obtenir une seule valeur. Les valeurs résultantes sont insérées par la suite dans la matrice de caractéristiques convolutive (**figures 2.9**).

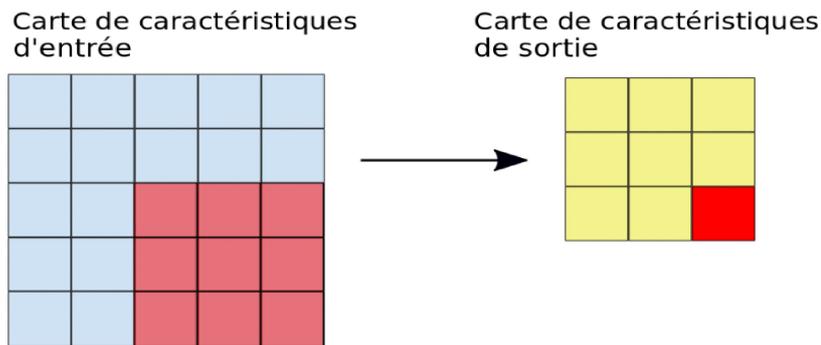


Figure 2.7 Opération de convolution [44]

Une convolution de 3x3 de profondeur 1 effectuée sur une carte de caractéristiques d'entrée 5x5, également de profondeur 1

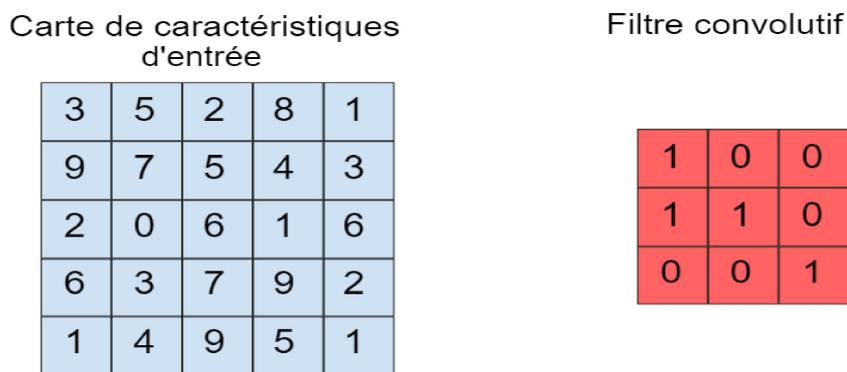


Figure 2.8 Opération de convolution [44]

À gauche : une carte de caractéristiques d'entrée 5x5 (profondeur 1). À droite : une convolution 3x3 (profondeur 1)

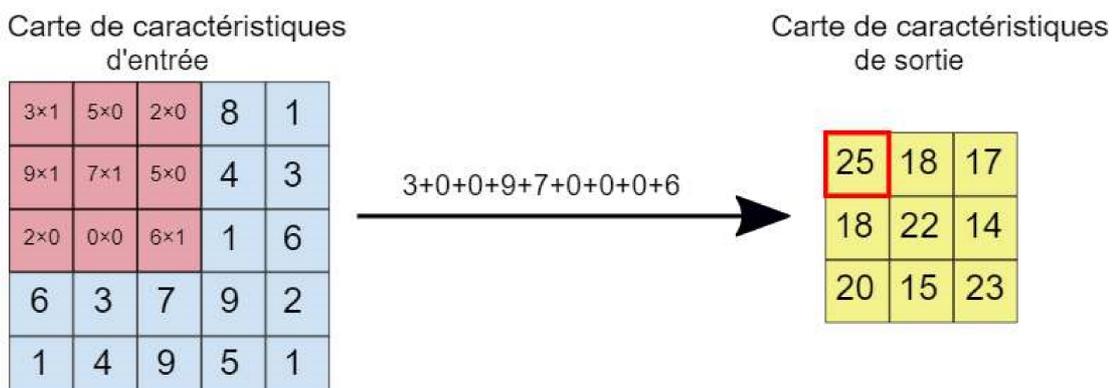


Figure 2.9 Opération de convolution [44]

À gauche : la convolution 3x3 est appliquée à la carte de caractéristiques d'entrée 5x5. À droite : la caractéristique convoluée résultante

Pour éviter le sur-apprentissage (pour qu'un réseau de neuronal soit plus efficace lors de la phase de test), les filtres ne doivent pas être trop petits ou d'un nombre très important.

Couche RELU

Relu est la fonction d'activation non linéaire, la plus utilisée actuellement.

Cette fonction est appliquée par le CNN après chaque opération de convolution, dans le but d'introduire la non linéarité dans le modèle. La fonction Relu, $f(u) = \max(0, u)$, renvoie u pour toutes les valeurs de $u > 0$ et renvoie 0 pour toutes les valeurs de $u \leq 0$.

Couche de pooling

Dans cette étape, le CNN sous-échantillonne la caractéristique convoluée, réduit donc le temps de traitement, la quantité d'informations que la couche convolutive génère pour chaque caractéristique et, conserve les informations les plus essentielles. La forme la plus populaire d'opération du pooling est le pooling maximal (figure 2.10).

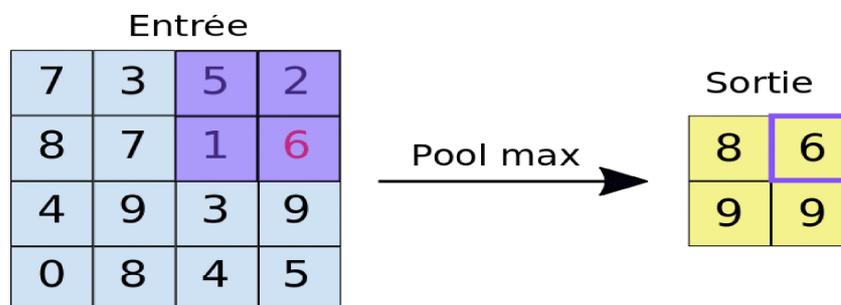


Figure 2.10 Opération de pooling maximal [44]

À gauche : pooling maximal sur une carte de caractéristiques 4x4 avec un filtre 2x2 et un pas de 2. À droite : résultat de l'opération de pooling maximal

Le pooling maximal fonctionne de la même manière, que la convolution. Pour chaque tuile, la valeur maximale est transférée vers une nouvelle carte de caractéristiques. Le pooling maximal utilise deux paramètres :

- Taille du filtre de pooling maximal (généralement 2x2 pixels).
- Pas : distance, en pixels, séparant chaque tuile extraite.

Dans le cas d'un filtre 2x2, un pas de 2 signifie, que l'opération de pooling maximal extrait toutes les tuiles 2x2 de la carte de caractéristiques (**figure 2.10**) qui ne se chevauchent pas [44].

La couche fully-connected

La couche fully-connected (une ou plusieurs) constitue toujours la dernière couche, d'un CNN (Dans le cas de deux couches fully-connected chaque nœud de la première est connecté à chaque nœud de la deuxième). Cette couche effectue une classification basée sur les caractéristiques extraites, par les convolutions.

Généralement, l'application de la fonction d'activation softmax aux sorties de la couche fully-connected, donne la probabilité d'une classe [44.]

2.7.2 Réseau de neurones convolutifs basée région « R-CNN »

Région-CNN (R-CNN), proposé en 2014 par Ross Girshik et al est un algorithme de détection d'objets, à apprentissage profond qui vise à trouver et à classer plusieurs objets dans une image (figure 2.11). Le R-CNN commence par extraire les régions d'intérêt (ROI) de l'image, puis les utiliser comme données d'entrée pour un CNN [47]. Ce système se compose des trois modules suivants :

- L'algorithme de recherche sélective qui génère environ 2000 propositions de régions.
- Un CNN profond qui extrait un vecteur de caractéristiques de chaque région.
- Un ensemble de classificateurs spécifiques à une classe (SVM linéaires).

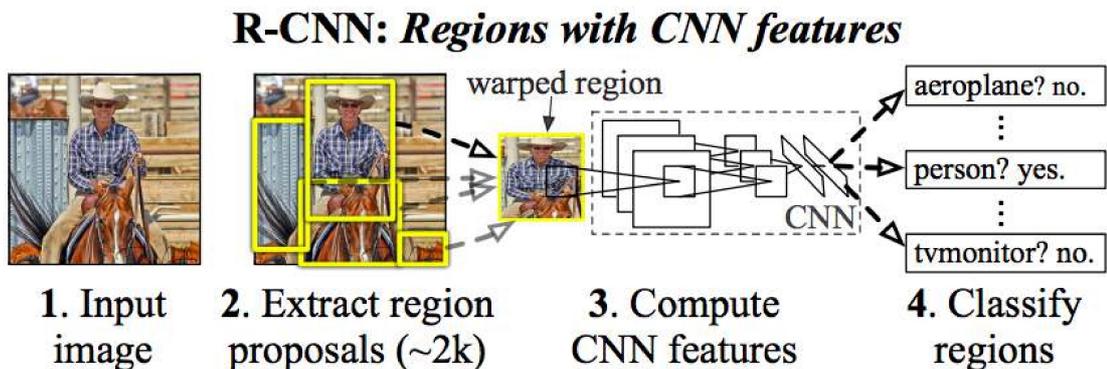


Figure 2.11 Architecture R-CNN [47]

Sur cette base, existe un R-CNN rapide et un R-CNN plus rapide pour une détection d'objet plus rapide, ainsi qu'un masque R-CNN pour la segmentation d'instance d'objets.

a **Fast R-CNN**

Comme le détecteur R-CNN, le détecteur Fast R-CNN (figure 2.12) utilise également un algorithme comme les Edge Boxes pour générer des propositions de régions. Le détecteur Fast R-CNN traite l'image entière et, regroupe les caractéristiques CNN, correspondant à chaque proposition de région. Fast R-CNN est plus efficace que R-CNN, car dans le détecteur Fast R-CNN, les calculs pour les régions qui se chevauchent, sont partagés [48].

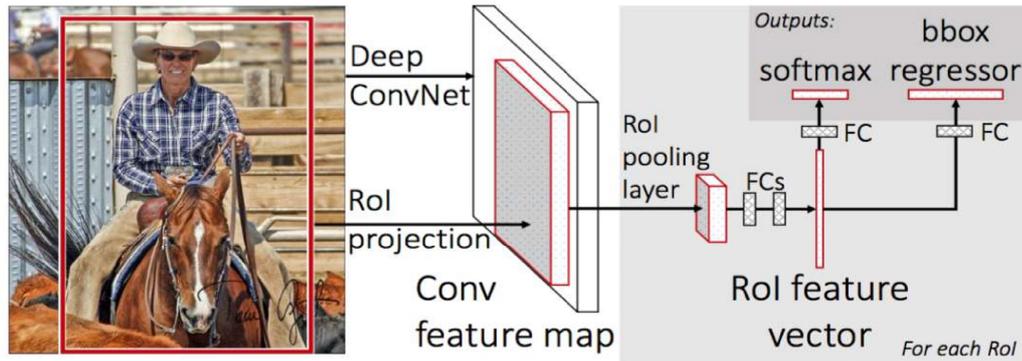


Figure 2.12 Architecture R-CNN rapide [50]

b Faster R-CNN

Faster R-CNN (figure 2.13) est la version modifiée du Fast R-CNN. La principale différence entre les deux est que Fast RCNN utilise la recherche sélective pour générer des régions d'intérêt, tandis que Faster RCNN utilise le "RegionProposal Network" qui prend des cartes de caractéristiques d'images en entrée et, génère un ensemble de propositions d'objets, chacune avec un score d'objectivité en sortie. Une couche de pooling des ROI est appliquée, pour ramener toutes ces propositions à la même taille. Enfin, ces propositions sont transmises à une couche fully-connected qui comporte une couche softmax et une couche de régression linéaire, pour classer et produire les bounding boxes des objets [51].

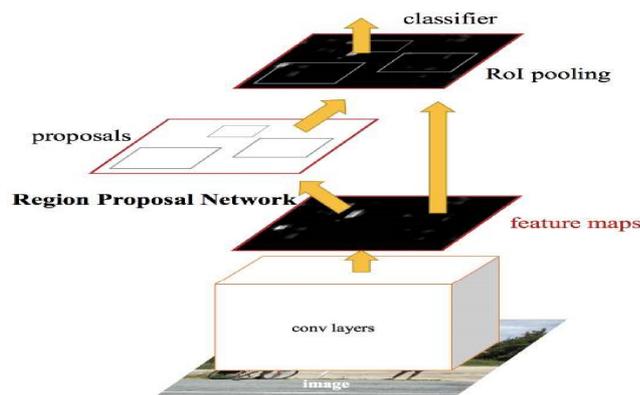


Figure 2.13 Architecture Faster R-CNN [51]

c Mask R-CNN

Le masque R-CNN est une technique de segmentation d'instance, qui localise chaque pixel de chaque objet, de l'image au lieu des cadres de délimitation (bounding boxes).

Cette architecture (figure 2.14) comporte deux étapes : les propositions de régions, puis la classification des propositions, la génération des cadres de délimitation et des masques. Pour ce faire, le Mask R-CNN utilise un réseau entièrement convolutif supplémentaire au-dessus d'une carte de caractéristiques, basée sur un CNN avec une entrée comme carte de caractéristiques. Il génère donc, une matrice avec 1 sur tous les emplacements, où le pixel appartient à l'objet et 0 ailleurs comme sortie [52].

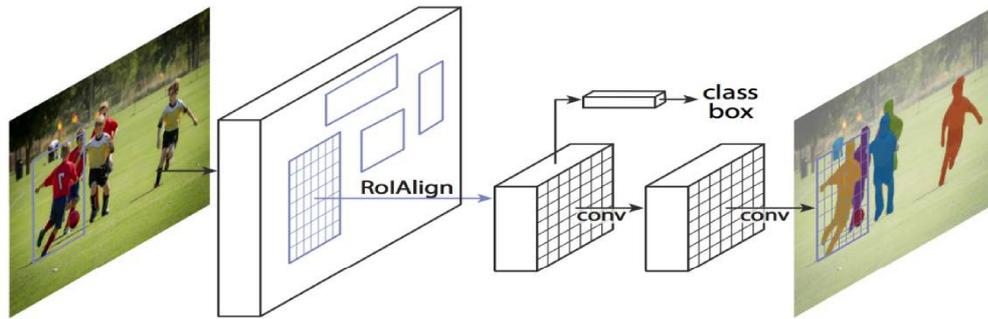


Figure 2.14 Masque R-CNN [52]

2.7.3 Réseau de neurones récurrents

Un réseau neuronal récurrent (RNN) est un réseau neuronal multicouche, principalement utilisé pour analyser des textes, de la parole ou des vidéos, à des fins de classification et de prédiction. Les RNN (figure 2.15) fonctionnent en évaluant les sections, d'une entrée en comparaison avec les sections avant et après la section classée, grâce à l'utilisation de la mémoire pondérée et, des boucles de rétroaction.

Les RNN sont utiles, car ils ne sont pas limités par la longueur d'une entrée et peuvent utiliser le contexte temporel, pour mieux prédire la signification.

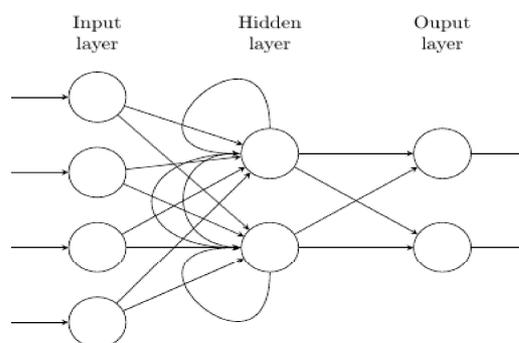


Figure 2.15 Réseaux de neurones récurrents (RNN) [54]

Le RNN se compose de trois couches représentant différentes étapes de l'opération.

- La couche d'entrée représente les informations à traiter.
- La couche cachée représente les algorithmes à l'œuvre.
- La couche de sortie montre le résultat de l'opération.

La couche cachée contient une boucle temporelle, qui permet à l'algorithme non seulement de produire une sortie, mais de la renvoyer à lui-même. Cela signifie que les neurones, ont une caractéristique qui peut être comparée à la mémoire à court terme [53].

2.8 Conclusion

Nous avons présenté au cours de ce chapitre, l'apprentissage profond avec ses différentes notions (définition, principe.... etc.). Les réseaux de neurones classiques tels que le perceptron simple et le perceptron multicouches ont été introduits, ensuite les différentes méthodes du deep Learning : CNN, R-CNN, RNN. Le prochain chapitre, traite les différents modèles pré-entraînés du CNN, sur lesquels notre approche est basée.

3.1 Introduction

Les progrès rapides de l'apprentissage automatique, des technologies de traitements graphiques et la disponibilité des données d'imagerie médicale, ont conduit à une augmentation rapide de l'utilisation des modèles d'apprentissage profond, dans le domaine de la santé. Cette situation a été exacerbée par les progrès rapides des architectures basées sur le réseau neuronal convolutif (CNN), qui ont été adoptées par la communauté de l'imagerie médicale pour aider les cliniciens à diagnostiquer les maladies. Depuis le grand succès d'AlexNet en 2012, les CNN gagnent rapidement en acceptabilité et en déploiement, avec les différentes architectures d'analyse d'image médicale. Ces architectures servent de lignes directrices de conception générales, que les praticiens de l'apprentissage automatique adapteront pour résoudre diverses tâches, et aussi d'extracteurs de fonctionnalités riches, qui peuvent être utilisés pour la classification d'images médicales. Dans ce chapitre, un état de l'art sur les architectures des CNN les plus populaires, va être esquissé. Une première partie, consiste à présenter l'historique des CNN. Par la suite une deuxième partie, présente les différentes architectures des CNN et, enfin la dernière partie décrit quelques travaux connexes.

3.2 Historique des CNNs

Les CNN peuvent avoir leurs origines dans le concept de Néocognitron proposé par Fukushima en 1982 mais c'était Le Cun qui a formalisé les CNN, en utilisant la rétropropagation d'erreur décrite par Rumelhart, Hinton et Williams pour réussir la reconnaissance automatique des chiffres manuscrits. L'utilisation généralisée des CNN dans la reconnaissance d'image est survenue après les auteurs Krizhevsky et al qui ont remporté le défi de la reconnaissance visuelle à grande échelle Imagenet en 2012 (ILSVRC), avec un CNN qui avait un taux d'erreur de 15%. Le finaliste avait presque le double du taux d'erreur à 26%. Krizhevsky a introduit des concepts importants, qui sont utilisés dans les CNN aujourd'hui, y compris l'utilisation des fonctions d'unité linéaire rectifiée (RELU), l'augmentation des données et le Dropout.

Depuis lors, les CNN ont figuré comme les réseaux connexionnistes, les plus utilisés dans tous les concours ILSVRC, dépassant les performances humaines en matière de reconnaissance d'images en 2015. Parallèlement, une augmentation spectaculaire a eu lieu relativement au nombre d'articles de recherche publiés sur les applications des CNN, dans l'analyse d'images médicales [57].

3.3 Architectures des CNNs

Dans le domaine des réseaux convolutifs, il existe plusieurs architectures qui servent de lignes directrices de conceptions générales, pour résoudre diverses tâches de la vision par ordinateur. Ces architectures peuvent être utilisées pour la classification d'images, la détection d'objets, la segmentation d'images et de nombreuses autres opérations plus avancées. Les modèles les plus courants sont :

3.3.1 LeNet-5

Le modèle LeNet-5 (figure 3.1) a été développé en 1998 par Yann Lecun, dans le but d'identifier les chiffres manuscrits pour la reconnaissance des codes postaux dans le service postal. Un LeNet se compose de deux parties :

- Un bloc de couches convolutives.
- Un bloc de couches entièrement connectées.

Les unités de base dans le bloc convolutif, sont la couche convolutive et une couche average pooling subséquente. La couche convolutive est utilisée pour reconnaître les motifs spatiaux dans l'image (les lignes et les parties d'objets). La couche average pooling est utilisée pour réduire les dimensions. Chaque couche convolutive utilise un filtre de taille 5×5 pour traiter chaque sortie, avec une fonction d'activation sigmoïde. Les deux couches average pooling sont de taille 2×2 avec un pas de 2. Le bloc convolutif émet une sortie, avec une taille donnée par (batch size, canal, hauteur, largeur). Avant de pouvoir transmettre la sortie du bloc convolutif au bloc entièrement connecté, un flatten est appliqué. Le bloc de couches FC de LeNet a trois couches FC, avec respectivement 120, 84 et 10 sorties [45].

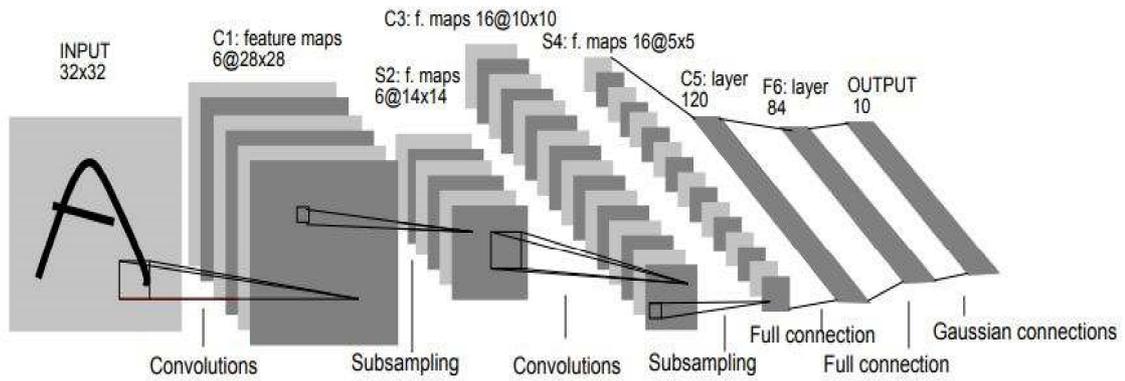


Figure 3.1 Architecture classique de LeNet-5 [45]

3.3.2 AlexNet

AlexNet (figure 3.2) a été développé par Alex Krizhevsky et al en 2012, pour participer au concours ImageNet. Ce modèle a eu un grand impact dans le domaine de l'apprentissage automatique, en particulier dans l'application de l'apprentissage en profondeur à la vision artificielle. L'architecture générale du modèle est assez similaire à celle de LeNet-5, bien que ce modèle soit considérablement plus grand, plus profond puisqu'il comporte des couches convolutives empilées les unes sur les autres. L'une des différences les plus importantes entre AlexNet et les autres algorithmes de détection d'objets, est l'utilisation de la fonction ReLU pour la partie non linéaire, au lieu de la fonction Sigmoid ou Tanh comme les réseaux neuronaux traditionnels. AlexNet contenait huit couches dont les cinq premières, étaient des couches convolutionnelles alors que les trois dernières étaient des couches entièrement connectées. Ce réseau a parallèlement deux lignes CNN formées, sur deux GPU avec des connexions croisées. AlexNet a largement surperformé tous ses concurrents précédents et, a remporté le défi en réduisant l'erreur de top 5 de 26% à 15,3%. Ce dernier a été formé pendant 6 jours, simultanément sur deux GPU Nvidia GeForce GTX 580, ce qui explique pourquoi le réseau est divisé en deux pipelines [46].

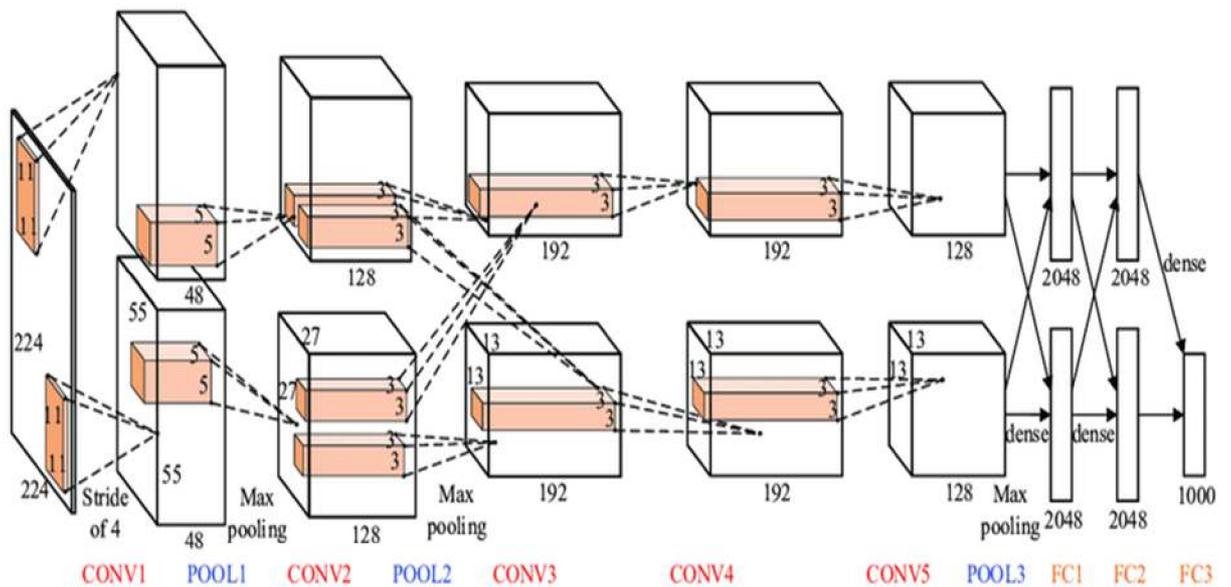


Figure 3.2 Architecture classique d'AlexNet [58]

3.3.3 ZFNet

ZFNetest (figure 3.3) est une amélioration d'AlexNet. Elle est effectuée en modifiant les hyperparamètres de l'architecture, en particulier en augmentant la taille des couches de convolution moyennes et, en réduisant la taille des pas ainsi que des filtres sur la première couche [46].

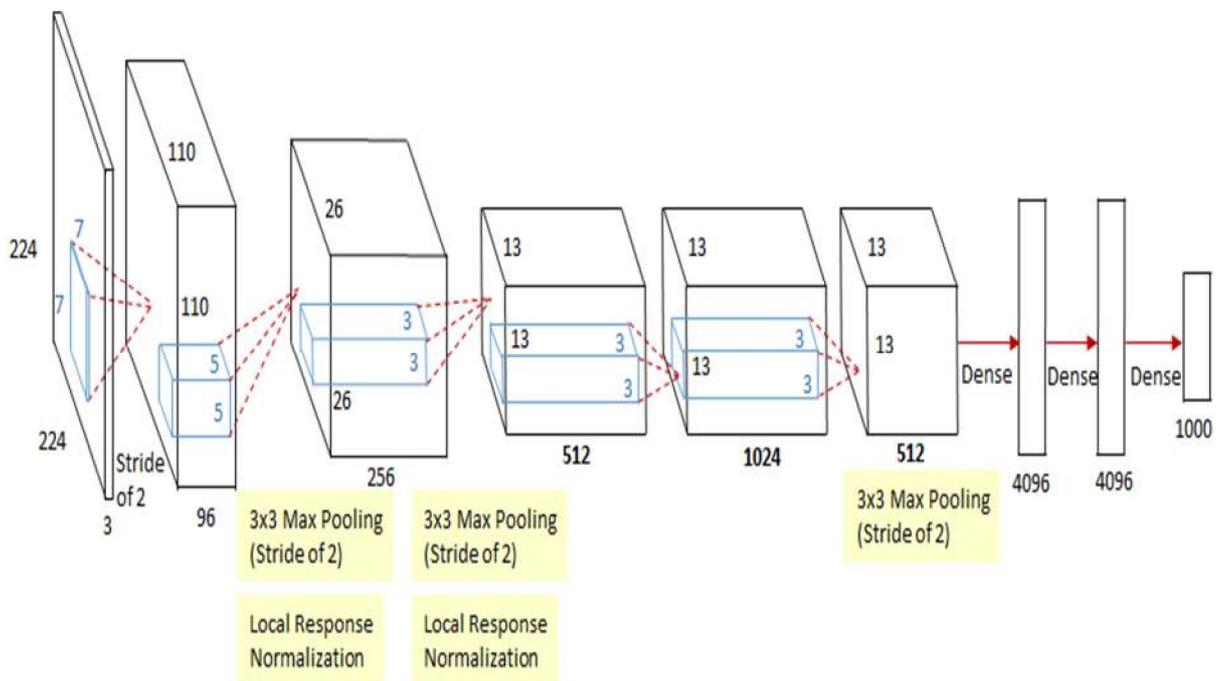


Figure 3.3 Architecture globale de ZFNet [59]

3.3.4 GoogleNet (inception)

Le réseau Inception (figure 3.4) a été l'une des avancées majeures, dans les domaines des réseaux de neurones, en particulier pour les CNN. GoogleNet a été construit avec un CNN inspiré de LetNet en 2014, par une équipe de Google. Ce réseau était chargé d'établir un nouvel état de l'art sur la classification et la détection dans l'ILSVRC (GoogleNet a été le vainqueur de l'ILSVRC 2014). GoogleNet a permis la diminution du taux d'erreur, par rapport aux précédents lauréats AlexNet et ZF-Net. L'architecture de Google Net comprend 22 couches de profondeur et 9 modules de départ, qui sont empilés linéairement au total avec presque 12x moins de paramètres (plus rapide qu'Alexnet et beaucoup plus précis). L'idée était de créer un modèle, qui pourrait également être utilisé sur un téléphone intelligent. Cette architecture utilise des techniques, telles que les convolutions 1×1 au milieu de l'architecture et, le global average pooling [49].

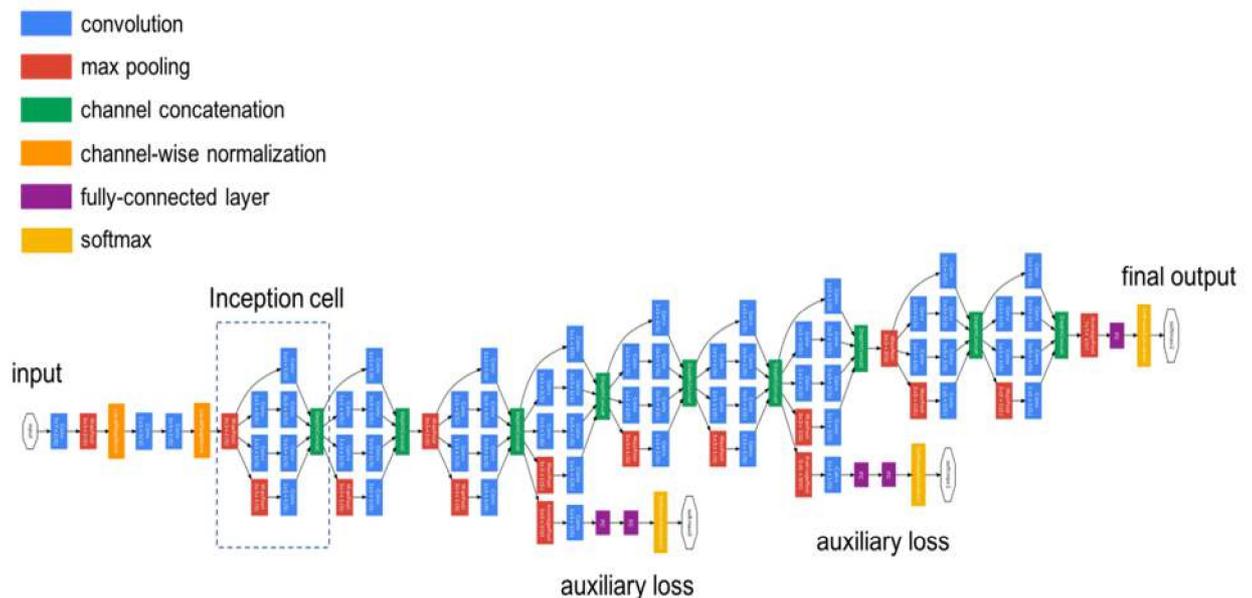


Figure 3.4 Architecture globale de googleNet [49]

3.3.5 VGG16

En 2014, le VGG16 (figure 3.5) a été développé par Karen Simonyan et Andrew Zisserman, dont sa principale contribution a été de montrer, que la profondeur du réseau est un composant essentiel pour de bonnes performances.

Leur modèle final contient 16 couches CONV / FC et, de manière attrayante, présente une architecture extrêmement homogène, qui ne réalise que 3 x 3 convolutions et un regroupement de 2x2 du début à la fin.

Le problème avec VGG16 est sa composition de 138 millions de paramètres, 34,5 fois plus que GoogleNet, ce qui le rend difficile à exécuter [46].

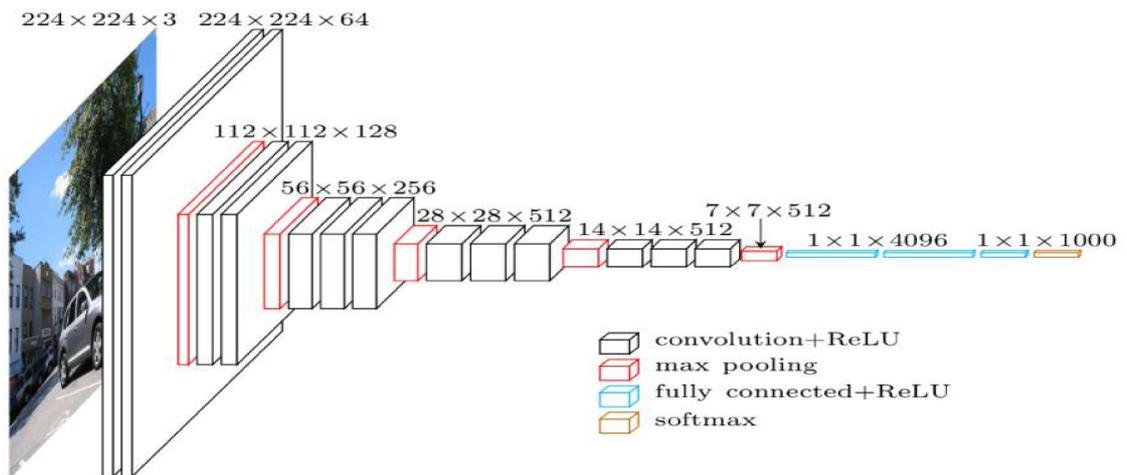


Figure 3.5 Architecture globale de VGG16 [45]

3.3.6 VGG19

AlexNet est sorti en 2012 et s'est amélioré sur les réseaux de neurones convolutionnels traditionnels. Le VGG est considéré comme un successeur d'AlexNet, qui a été créé par le groupe Visual Geometry Group chez Oxford (VGG). VGG19 (figure 3.6) est une variante du modèle VGG, qui se compose de 19 couches dont 16 couches de convolution, 3 couches entièrement connectées, 5 couches MaxPool et 1 couche SoftMax [60].

Couche	VGG16	VGG19
Taille d'image d'entrée	224x224 pixels	224x224 pixels
Couches convolutives	13	16
Taille des filtres	64, 128, 256, 512	64, 128, 256, 512

Relu	15	18
Max pooling	5	5
Fully connected	3	3
Softmax	1	1

Tableau 3.1 Comparaison entre les architectures VGG16 et VGG19

L'architecture du VGG a été utilisée dans de nombreuses tâches telle que, que la classification de nombreux ensembles de données. Cette architecture peut être utilisée telle quelle, ou avec des modifications pour d'autres tâches similaires.

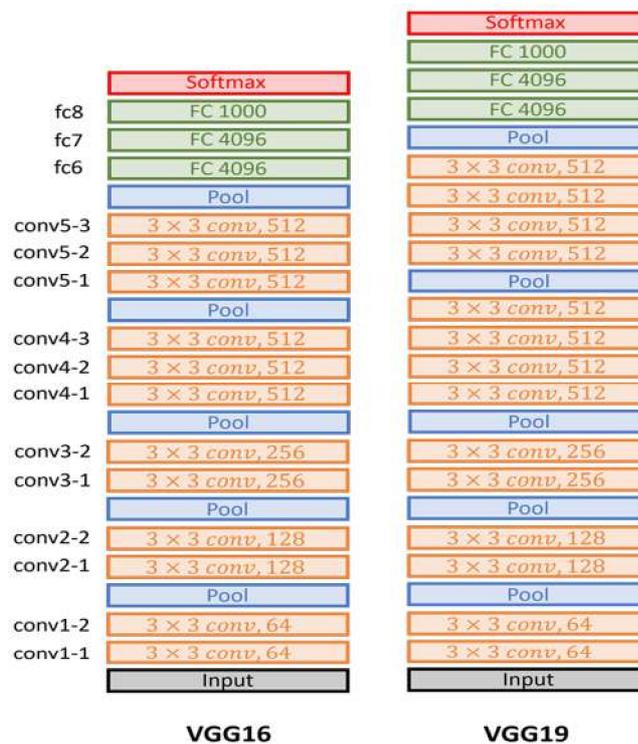


Figure 3.6 Présentation de l'architecture VGG19 en comparaison avec le VGG16 [45]

3.3.7 ResNet

ResNet (figure 3.7) a été développé par Kaiming He et al en 2015. Ce modèle est caractérisé par l'emploi de connexions saute-couches. Un ResNet est un RNA d'un type qui, s'appuie sur des constructions connues, à partir de cellules pyramidales du cortex cérébral. Les réseaux de neurones résiduels peuvent avoir jusqu'à 152 couches.

Une couche convolutive de compression n'a que des filtres 1×1 , qui sont introduits dans une couche d'expansion, qui comprend un mélange de filtres 1×1 et 3×3 . L'ensemble de couches de compression et d'expansion, est appelé fire module (*figure 3.8*).

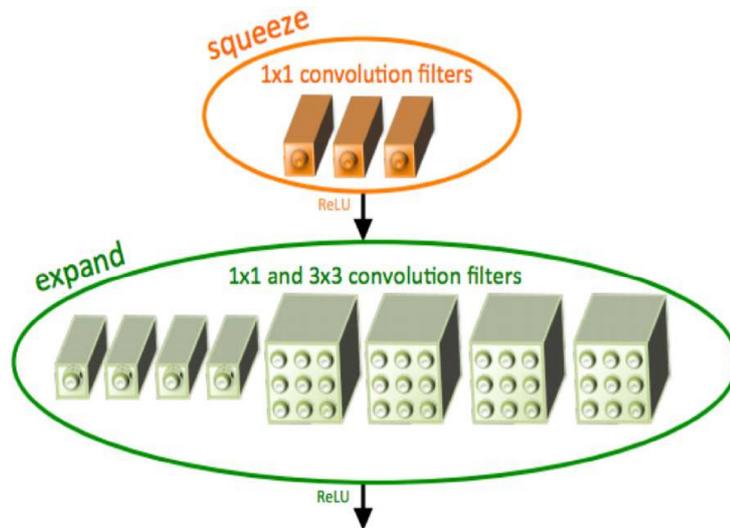


Figure 3.8 Fire Module [49]

L'image d'entrée est envoyée dans une couche convolutive autonome qui est suivie de 8 'fire' modules (*figure 3.9*).

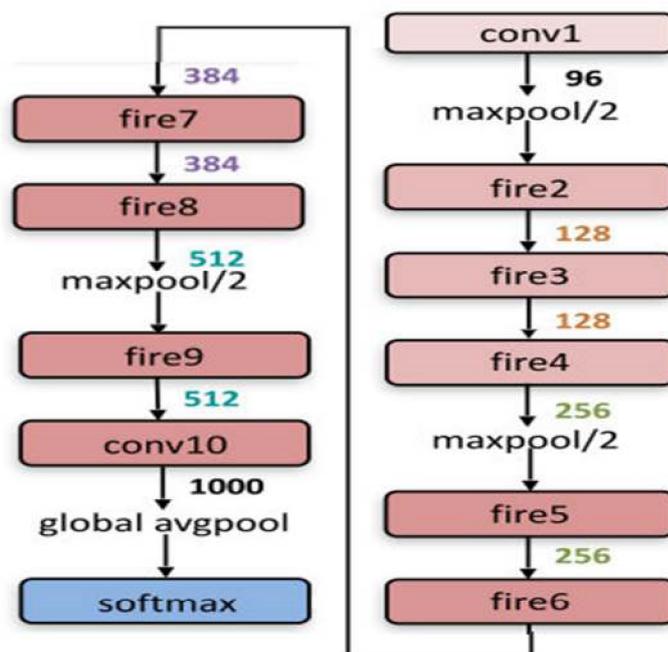


Figure 3.9 Architecture de SqueezeNet [61]

3.3.9 DenseNet

Gao Huang, Zhuang Liu et leur équipe ont proposé en 2017, lors d'une conférence les réseaux convolutifs connectés de manière dense (DenseNet) (figure 3.10). Dans ce réseau chaque couche, se connecte à chaque autre couche de manière anticipée, ce qui signifie que DenseNet a $n(n+1)/2$ connexions au total. Pour chaque couche, les cartes d'entités de toutes les couches précédentes, sont utilisées comme entrées et ses propres cartes d'entités, sont utilisées comme entrées pour toutes les couches suivantes. L'avantage de Dense Net par rapport aux autres modèles CNN, est que les informations transmises à travers de nombreuses couches, ne seront pas effacées ou ne disparaîtront pas au moment où elles atteindront la fin du réseau [49].

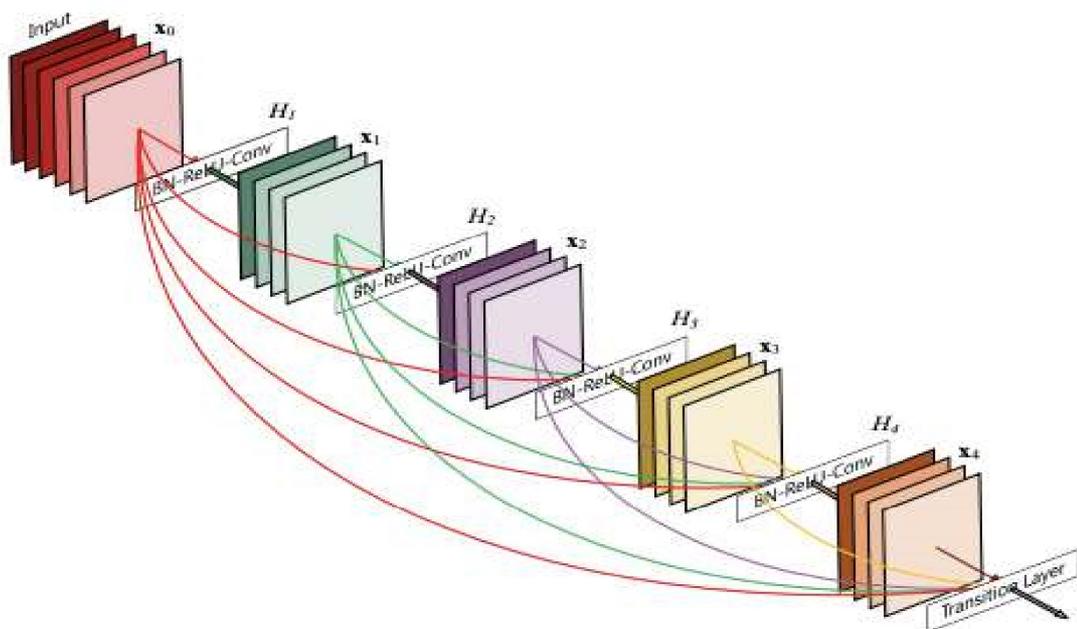


Figure 3.10 Représentation de l'architecture DenseNet [49]

En fonction de la dimensionnalité de l'entrée, différents types de blocs denses sont utilisés (figure 3.11). Une brève description d'une couche de composition DenseNet de base est présentée dans ce cadre. A cet effet, chaque couche est suivie d'une couche de normalisation pré-activée par lots, d'une fonction d'activation ReLU et d'une convolution 3×3 (**figure 3.11**).

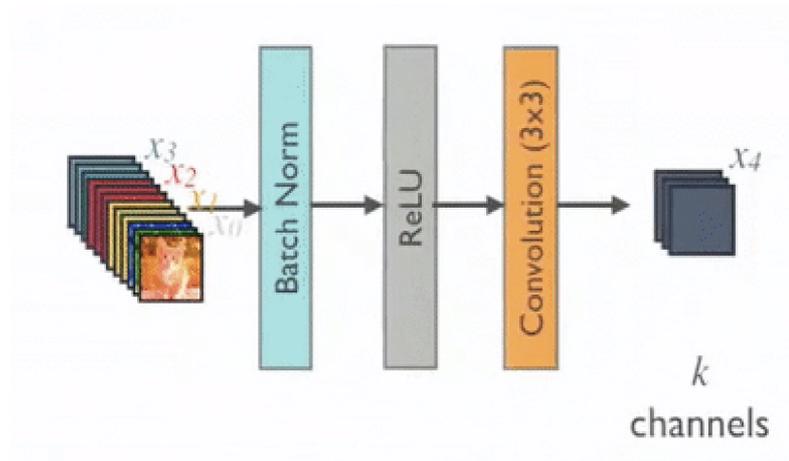


Figure 3.11 Couche de composition de base [49]

- **BottleNeck DenseNet (DenseNet-B):** chaque couche produit k cartes d'entités en sortie, ce qui rend le calcul plus difficile à tous les niveaux. Par conséquent, une structure de goulot d'étranglement a été proposée, dans laquelle des convolutions 1×1 sont utilisées avant une couche de convolution 3×3 (figure 3.12).

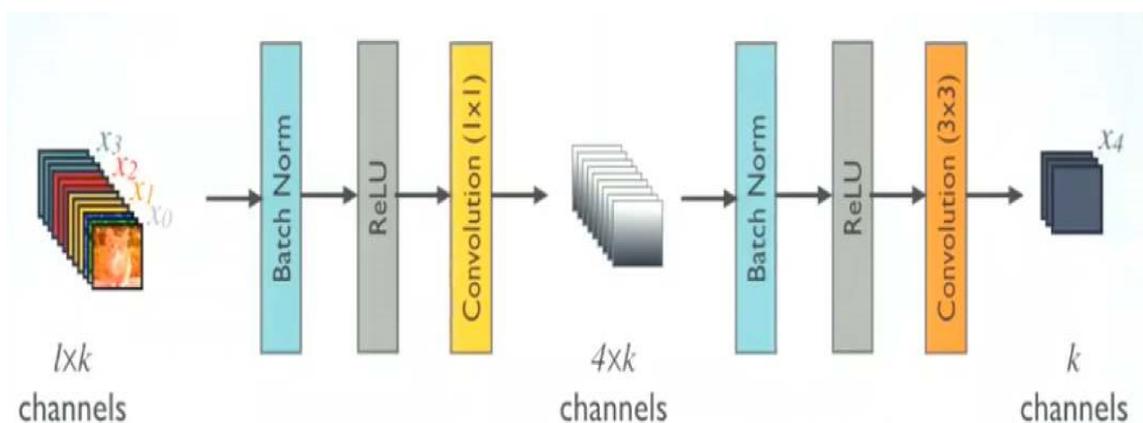


Figure 3.12 Représentation du DenseNet-B [49]

Compression DenseNet : pour l'amélioration de la compacité du modèle, les auteurs ont essayé de réduire les cartes des entités, au niveau des couches de transition. Ainsi, si un bloc dense est composé de m cartes d'entités, i cartes d'entités sont générés par la couche de transition en sortie, où $0 < i \leq 1$ (i désigne également le facteur de compression). Si $i = 1$, le nombre de cartes d'entités à travers les couches de transition reste inchangé. Si $i < 1$ l'architecture est appelée DenseNet-C et, la valeur de i serait changée en 0,5. Lorsque les couches de goulot d'étranglement et de transition avec $i < 1$ sont utilisées, le modèle est nommé DenseNet-BC.

Blocs denses multiples avec couches de transition : les blocs (figure 3.13) sont suivis d'une couche de convolution 1×1 et d'une couche de MaxPooling 2×2 . Puisque les tailles de la carte d'entités sont identiques, cela facilite la concaténation des couches de transition. A la fin du bloc, un Global Average Pooling est effectué, qui est attaché à un classificateur softmax [49].

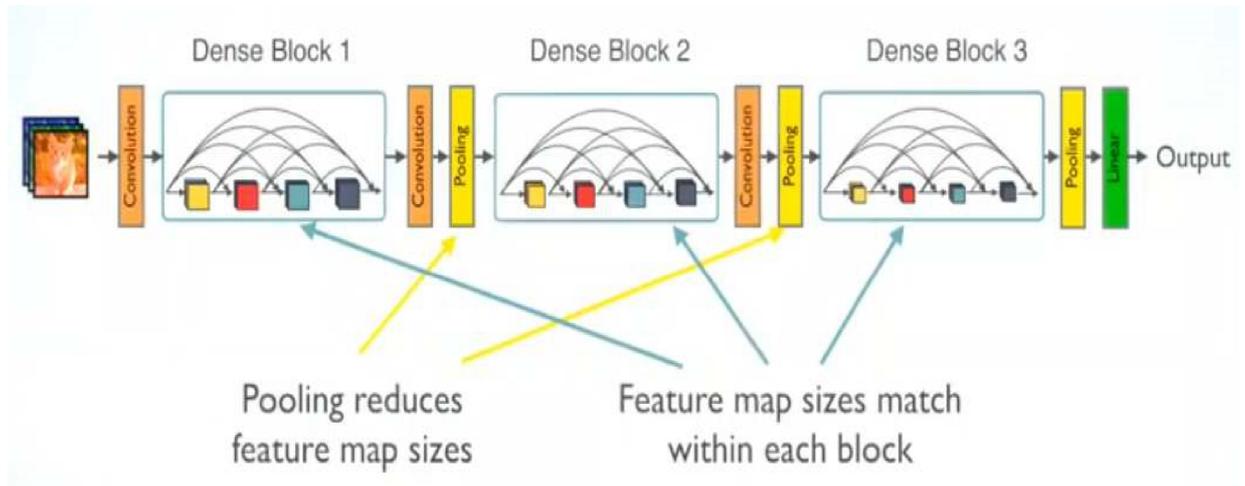


Figure 3.13 Représentation des blocs denses [49]

3.3.10 ResNext

Saining Xie et al en 2017 ont suggéré le ResNeXt (Aggregated Residual Transformations for Deep Neural Networks) qui est un réseau neuronal homogène (figure 3.14), qui réduit le nombre d'hyperparamètres requis par ResNet. Ceci est réalisé par leur utilisation de la "cardinalité", une dimension supplémentaire en plus de la largeur et de la profondeur de ResNet. La cardinalité définit la taille de l'ensemble des transformations [49].

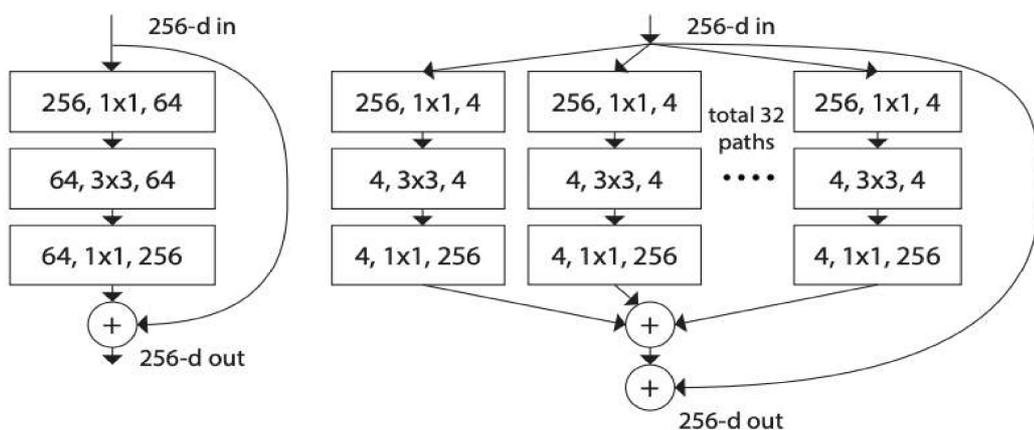


Figure 3.14 Blocs ResNet et ResNeXt [49]

A gauche: un bloc ResNet , A droite: un bloc ResNeXt

La figure 3.14 présente deux diagrammes, dont le plus à gauche est un bloc ResNet conventionnel alors que le plus à droite, est le bloc ResNeXt, qui a une cardinalité de 32. Les mêmes transformations sont appliquées 32 fois et le résultat est agrégé à la fin.

3.4 Travaux connexes

3.4.1 Classification des tumeurs

K. Narmada et al [62] ont proposé un système pour classifier les cancers des poumons a petites et à grandes cellules, avec la prédiction des stades à l'aide des CNN. Ce système se concentre également, sur les processus de prétraitement et de segmentation. Testé sur des données réelles, il fonctionne selon 4 étapes dont :

- Constitution des ensembles d'entraînement, de validation et de test.
- Redimensionnement de l'image à une taille de 500 x 500 pixels.
- Prétraiter l'image avec un filtre gaussien.
- Classification des pathologies par le CNN.

L'apprentissage a été effectué dans l'environnement Python TensorFlow (en utilisant les classes keras models). La précision de système a été de 94.97% avec une sensibilité de 93%.

Q. Abbas [63] a proposé un système pour classifier les nodules pulmonaires en deux classe beigne et maligne. Ce système est divisé en trois étapes principales ; telles que l'extraction de caractéristiques à l'aide du CNN, la sélection des plus discriminantes via le RNN sur les régions d'intérêt pulmonaires. Les nodules sont par la suite, classifiés à l'aide du classificateur linéaire softmax. Le système a été testé sur les 1200 scans obtenus, à partir de la base de données LIDC-IDRI. Le système proposé a été réalisé sur la plate-forme MATLAB 2016, dont les performances ont été évaluées à travers des métriques statistiques telles que, la sensibilité (SE), la spécificité (SP) et l'aire sous la courbe de fonctionnement du récepteur (AUC). Le système a engendré une SE de 94%, une SP de 96% et l'aire AUC de 95%. La une précision du modèle est de 95%.

G. Tran et al [64] ont proposé une architecture d'un réseau neuronal à convolution profonde 2D, le LdcNet qui se compose de 3 types de couches (convolutive, pooling et FC). Le réseau développé, comprend 3 blocs convolutifs, chacun d'eux contient 3 couches convolutives et une couche MaxPooling. Chaque couche convolutive est suivie d'une fonction d'activation ReLu. Les 3 blocs sont suivis de deux couches FC, suivis respectivement d'une fonction d'activation ReLu et, de la fonction softmax, qui calcule la probabilité de présence de nodules ou pas. Le modèle développé est appliqué sur des images CT de la base LUNA16. Le système proposé a été implémenté, avec python en utilisant Keras avec TensorFlow comme backend, ainsi que CUDA 8.0 pour l'accélération GPU. Leur évaluation sur l'ensemble de données, a montré que des résultats de haute qualité, avec une précision de 97,2%, une sensibilité de 96,0% et une spécificité de 97,3%.

Li et al [65] ont proposé un réseau neuronal convolutif profond, pour la classification des nodules pulmonaires de la base de données LIDC. La méthode qui a été utilisée dans le système, remplace les deux composants d'extraction et de classification des caractéristiques. Le réseau proposé a été formé et validé sur 62 492 échantillons de régions d'intérêt (ROI) d'images extraits de 1 010 TDM de la base LIDC / IDRI, dont 40 772 échantillons sont des nodules pulmonaires et 21 720 échantillons sont des non nodules. Le réseau qui a été proposé, a atteint une précision de 86,4% et une sensibilité de 89,0%.

3.4.2 Classification des pneumonies

K. Kadam et al [66] ont proposé le développement d'un modèle neuronal profond, pour la prédiction d'une pneumonie, en utilisant des radiographies pulmonaires. Le modèle classe l'image comme « pneumonie » ou « normale ». Ce système est basé sur des réseaux de neurones convolutifs et un réseau résiduel, ainsi que des techniques de recuit cosinus et de gradient stochastique, avec des redémarrages pour obtenir l'efficacité et la précision. L'ensemble de données Kaggle utilisé, est constitué d'un total de 5863 images radiographiques (JPEG). Le modèle a été implémenté sur python et a atteint une précision de 92,9%, avec une sensibilité de 99,27%.

M.Farukh Hashmi et al [67] ont proposé un modèle basé sur les applications de l'apprentissage en profondeur et des réseaux de neurones convolutifs, capables de classer automatiquement des images radiographiques numériques du thorax, en deux classes, pneumonie ou normale. La méthodologie proposée a utilisé une combinaison des prédictions pondérées, des modèles du DL, tels que ResNet18, Xception, InceptionV3, DenseNet121 et MobileNetV3 de manière optimale. Un algorithme d'apprentissage par transfert profond, a été exploré pour extraire les caractéristiques de l'image radiographique. Le système a été implémenté sur python avec les bibliothèques de TensorFlow. Les modèles sont évalués en termes de précision et également en termes de score AUC, les résultats des différentes architectures sont illustrés dans le tableau 3.2.

Architecture	Précision	AUC Score
ResNet18	97.29	99.46
DenseNet121	98.00	99.65
InceptionV3	97.00	99.49
Xception	96.57	99.59
MobileNetV2	96.71	99.52
Weighted Classifier	98.43	99.76

Tableau 3.2 Résultats de M.Farukh Hashmi et al [67]

O. Stephen et al [68] ont proposé un modèle des CNN, pour classer et détecter la présence d'une pneumonie, à partir d'une collection d'échantillons d'images radiographiques pulmonaires, qui se compose 5 856 échantillons radiographiques du thorax antéropostérieur. L'architecture globale de ce modèle, comprend deux parties principales : les extracteurs de caractéristiques et un classificateur (fonction d'activation sigmoïde). Le système proposé se compose de quatre couches de convolution, chacune d'elles est suivie d'une fonction d'activation ReLu et un MaxPooling de 2x2. La couche de classification contient deux couches denses, suivies respectivement d'une fonction d'activation Relu et, d'une fonction d'activation sigmoïde qui effectue les tâches de classification. Le modèle proposé a été implémenté avec python en utilisant Keras avec tensorflow.

Les résultats obtenus montrent une perte d'entraînement de 0,1288 avec une précision de 95%, une perte de validation de 0,1835 avec une précision de validation de 93.73%.

3.5 Conclusion

Les réseaux de neurones convolutifs (CNN) ont accompli des réalisations étonnantes dans une variété de domaines, y compris la recherche médicale. Ils sont devenus une approche dominante dans une variété de tâches complexes ; telles que la classification d'images et la détection d'objets. Actuellement, les CNN sont capables de surpasser les humains dans les tâches de reconnaissance visuelle, car ses théories sont toujours en développement. Se familiariser avec les concepts clés et les avantages des CNN ainsi que les limites d'apprentissage en profondeur, est essentiel pour en tirer parti dans les recherches médicales, dans le but d'améliorer les performances des radiologues. Le prochain chapitre présente la mise en œuvre des modèles développés par l'approche proposée.

4.1 Introduction

Ce chapitre constitue la dernière étape de notre étude, qui se focalise sur l'implémentation de deux systèmes d'analyse automatique d'images pulmonaires, pour la classification des pathologies oncologiques pulmonaires et des pneumopathies.

4.2 Environnement de travail

Le système PneumoCNN a été développé sous l'environnement Windows, en utilisant le langage python sous, l'environnement de programmation anaconda 3.

4.2.1 Matériel utilisé

Ce travail a été réalisé à l'aide d'un ordinateur portable Intel core I5-3230M CPU @2.60GHz, 2.60GHz avec une capacité de mémoire vive 4,00GB RAM avec un système d'exploitation 64bits.

4.2.2 Environnement de programmation

Le langage le plus utilisé dans le domaine de programmation du deep learning, est python. C'est ce langage qui est déployé, pour développer notre approche.

a *Anaconda*

Anaconda est une distribution Python qui offre de nombreuses fonctionnalités, comme la possibilité d'installer des bibliothèques et de les utiliser, dans ses programmes [69].

b *Anaconda prompt*

Anaconda Prompt est une console disponible initialement dans Python, permettant à ses utilisateurs d'installer des bibliothèques facilement à l'aide de conda et, de les réutiliser tout aussi facilement, grâce à d'autres logiciels. L'installation de la bibliothèque, se fait en entrant « conda install » suivi du nom de la bibliothèque [69].

c *Anaconda Navigator*

Anaconda Navigator est un GUI (Graphic user interface) disponible pour Windows, macOS et Linux, qui permet le lancement des applications et la gestion facile, des paquets, environnements et canaux conda sans utiliser, de commandes en ligne de commande [69].

d *Spyder*

Spyder est un environnement scientifique puissant écrit en Python, pour Python, et conçu par et pour des scientifiques et des ingénieurs. Cet environnement offre une combinaison unique des fonctionnalités avancées d'édition, d'analyse, de débogage et de profilage d'un outil de développement complet, avec l'exploration de données, l'exécution interactive, l'inspection approfondie et les capacités de visualisation d'un logiciel scientifique [70].

e *Python*

Python est un langage de programmation de haut niveau open source créé par le programmeur Guido van Rossum (en 1991) [71] qui est largement utilisé, dans la science des données ainsi que, pour le développement d'algorithmes d'apprentissage profond. C'est un langage de programmation interprété, qui ne nécessite donc pas d'être compilé pour fonctionner. Ceci permet d'exécuter le code Python, sur n'importe quel ordinateur ce qui permet d'observer rapidement, les résultats d'un changement dans le code. Python est devenu très populaire ces dernières années, grâce à ses avantages dont :

- Programmation dans des paradigmes orientés objet et procéduraux.
- Les programmes Python sont généralement plus courts par rapport les autres langages de programmation comme Java.
- La plus grande force de Python est une énorme collection de la bibliothèque standard qui peut être utilisées pour ce qui suit: Apprentissage automatique Applications GUI (comme Kivy, Tkinter, PyQt etc.) Des Framework Web comme Django (utilisés par YouTube, Instagram, Dropbox) le traitement d'image (comme OpenCV, Pillow) Scraping Web (comme Scrapy, BeautifulSoup, Selenium) des cadres de test Multimédia, de calcul scientifique, de traitement de texte et bien d'autres encore.

f *Librairies utilisées*

Python offre un terrain de jeu opportun, pour expérimenter des algorithmes d'apprentissage automatique, en raison de sa lisibilité et de l'efficacité syntaxique du langage. La grande disponibilité des bibliothèques ML accessibles aux utilisateurs de Python, en fait une solution encore plus attrayante pour interpréter l'immense quantité de données disponibles, aujourd'hui. Les bibliothèques citées ci-dessous, sont les plus utilisées [72].

❖ *numpy*

NumPy est très populaire pour le traitement de grands tableaux multidimensionnels et de matrices, à l'aide d'une grande collection de fonctions mathématiques, de haut niveau. Cette bibliothèque est très utile pour les capacités d'algèbre linéaire, de transformée de Fourier et de nombres aléatoires.

❖ *scipy*

SciPy est une bibliothèque très célèbre dans le domaine du Machine Learning, grâce à sa contenance des différents modules d'optimisation, d'algèbre linéaire, d'intégration et de statistiques. Le SciPy est également très utile, pour la manipulation d'images.

❖ **Tensorflow**

TensorFlow est une bibliothèque open-source très populaire, pour le calcul numérique haute performance et largement utilisée dans le deep learning. Cette librairie est un Framework permettant de créer et d'exécuter des calculs, impliquant des tenseurs. TensorFlow peut entraîner et gérer des réseaux de neurones profonds, qui peuvent être utilisés pour développer plusieurs applications d'IA.

❖ *Keras*

keras est une bibliothèque de ML très populaire pour Python. C'est une API de réseaux de neurones de haut niveau, qui est fonctionnable sur TensorFlow. Elle est réalisée aussi sur les processeurs CPU et le GPU, de manière transparente. Cette bibliothèque est modulaire, extensible et conviviale, ce qui la rend parfaite pour les débutants.

❖ *Pandas*

Pandas est une bibliothèque d'analyse de données. Pandas a été développée spécifiquement, pour l'extraction et la préparation de données. Cette dernière fournit des structures de données de haut niveau, une grande variété d'outils pour l'analyse des données et de nombreuses méthodes intégrées pour tâtonner, combiner et filtrer les données.

❖ *Matplotlib*

Matplotlib est une bibliothèque de visualisation de données, qui est utilisée pour le traçage 2D afin de produire des graphiques, de qualité dans une variété de formats. La bibliothèque permet de générer des histogrammes, des graphiques d'erreur, des nuages de points et, des graphiques à barres, avec seulement quelques lignes de code.

❖ *Scikit-learn*

Scikit-learn est une des bibliothèques pour les algorithmes ML classiques, qui repose sur NumPy et SciPy.

Scikit-learn dispose d'un large éventail d'algorithmes d'apprentissage supervisé et, non supervisé qui fonctionnent sur une interface cohérente, en Python. Scikit-learn peut également être utilisé, pour l'analyse de données. Les principales fonctions d'apprentissage automatique, que la bibliothèque Scikit-learn peut gérer sont la classification, la régression, le regroupement, la réduction de la dimensionnalité, la sélection du modèle et le prétraitement.

4.3 Architecture du système 'PneumoCNN'

L'approche Pneumo-CNN est conçu pour la classification des pathologies pulmonaires basée, sur des images thoraciques. L'objectif est de catégoriser les tumeurs pulmonaires et les pneumopathies, à l'aide des modèles des CNN. La figure 4. 1 montre l'architecture globale, du système proposé appliqué à deux types pathologies : les nodules pulmonaires oncologiques et les pneumopathies.

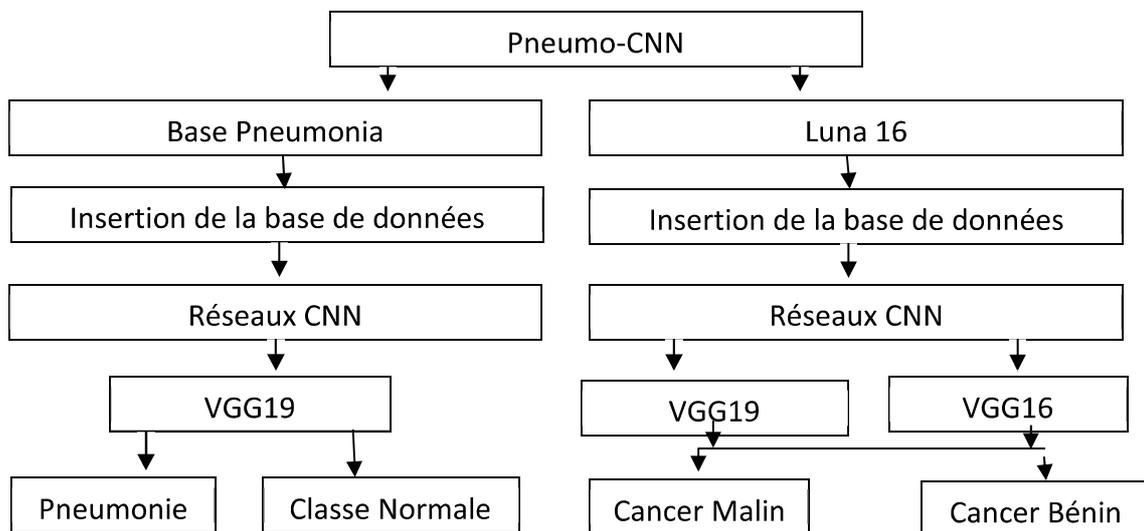


Figure 4.1 Architecture globale du système 'PneumoCNN'

4.3.1 Description des bases de données

a Base LUNA16

Nous avons utilisé l'ensemble de données public du défi LUNg Nodule Analysis 2016 (LUNA16) [73]. Les organisateurs du défi ont sélectionné 888 tomodensitogrammes sur un total de 1012 tomodensitogrammes dans la base de données LIDC-IDRI. Les nodules candidats ont été annotés manuellement par quatre radiologues thoraciques expérimentés (figure 4.2).

Chaque radiologue a classé les nodules comme des nodules ≥ 3 mm, des nodules <3 mm ou des non-nodules. Les organisateurs du défi ont utilisé un total de 1186 nodules. Les nodules restants ont été considérés comme des faux positifs.

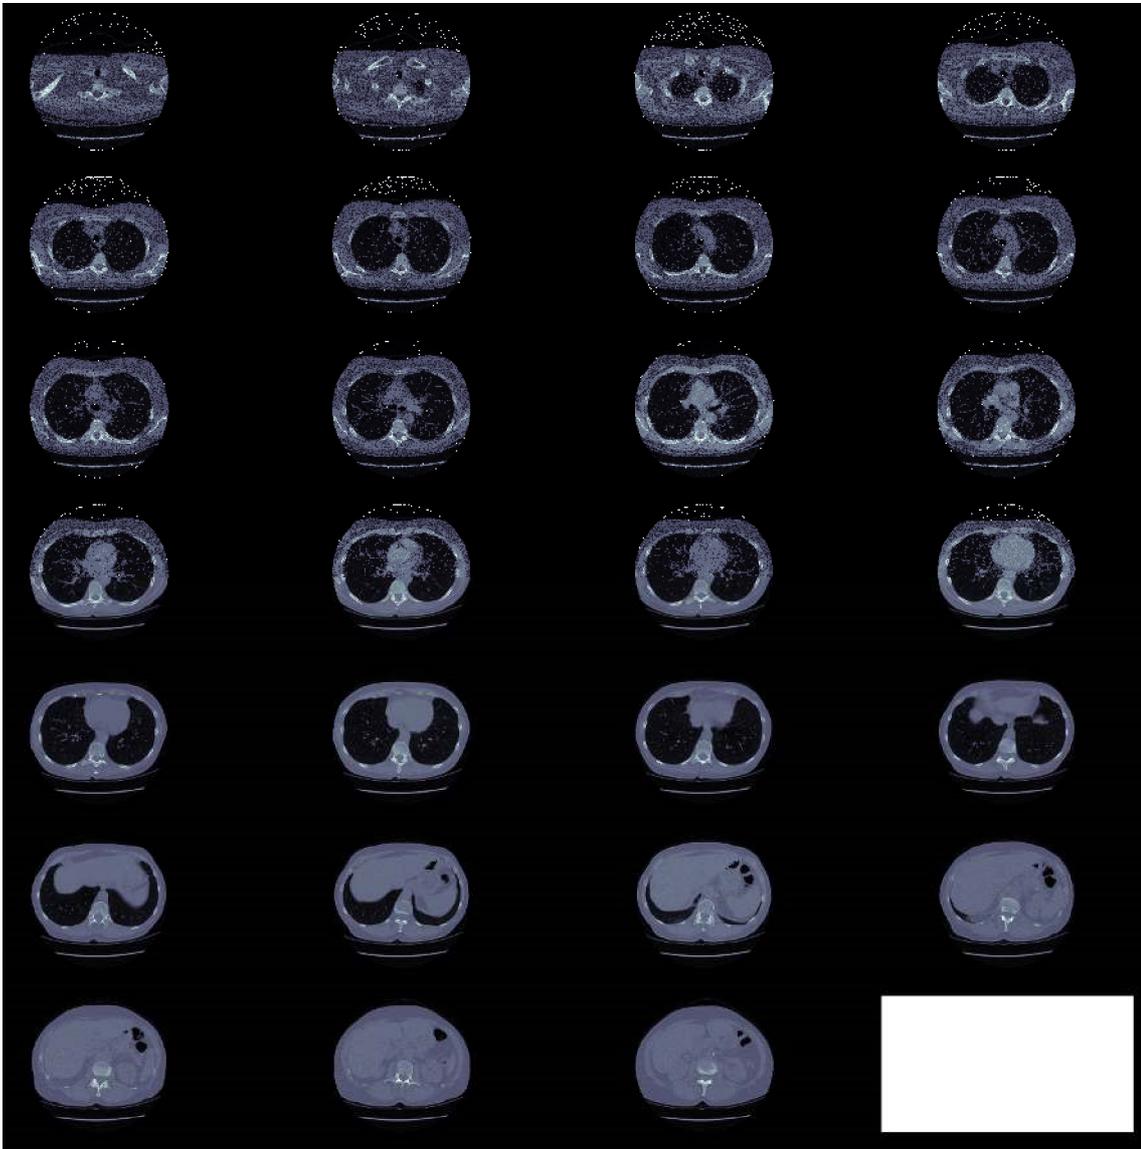


Figure 4.2 Echantillons d'images de la base Luna16 [73]

b Base de données des pneumonies

La base d'images des pneumopathies utilisée (figure 4.3), est un ensemble des radiographies pédiatriques collectées et étiquetées par Kermay et al [74], du centre médical pour femmes et enfants de Guangzhou en Chine. L'ensemble de données se compose de trois répertoires principaux (répertoires d'entraînement, de test et de validation) classés selon, des pneumonies et normales. Au total, 5 856 radiographies de thorax ont été sélectionnées, parmi des patients pédiatriques rétrospectifs âgés de 1 à 5 ans.

-	Test	Entrainement	Validation
Normal	234	1341	8
Pneumonie	390	3875	8

Tableau 4.1 Composition de la base de données des pneumopathies

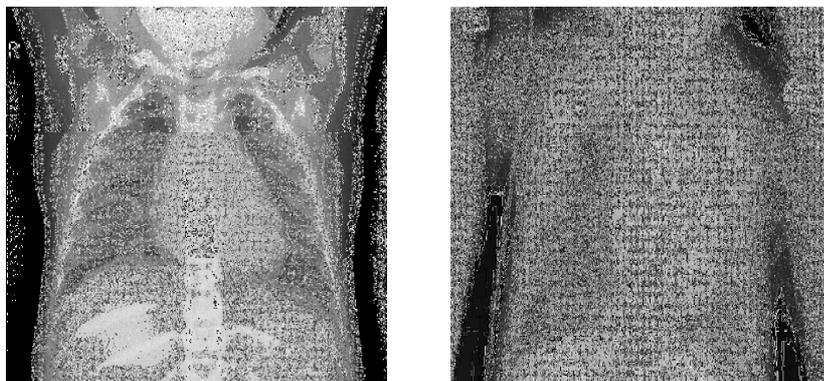


Figure 4.3 Exemples d'images de la base 'pneumonia' [74]

4.3.2 Classification des tumeurs pulmonaires par le modèle VGG16

Le premier modèle utilisé pour la classification des tumeurs, est le VGG16 qui est composé de 13 couches de convolution, 5 couches de MaxPooling et 3 couches fully connected. Une fonction d'activation ReLu est appliquée après chaque convolution. Un Flatten est réalisé avant la première couche FC, pour transformer les résultats en des dimensions appropriées. Un DropOut est appliqué avant la couche de sortie, qui est une fully connected avec une fonction d'activation softmax, pour activer les classes obtenues. Une description détaillée du modèle CNN susmentionné est affichée sur la figure 4.4.

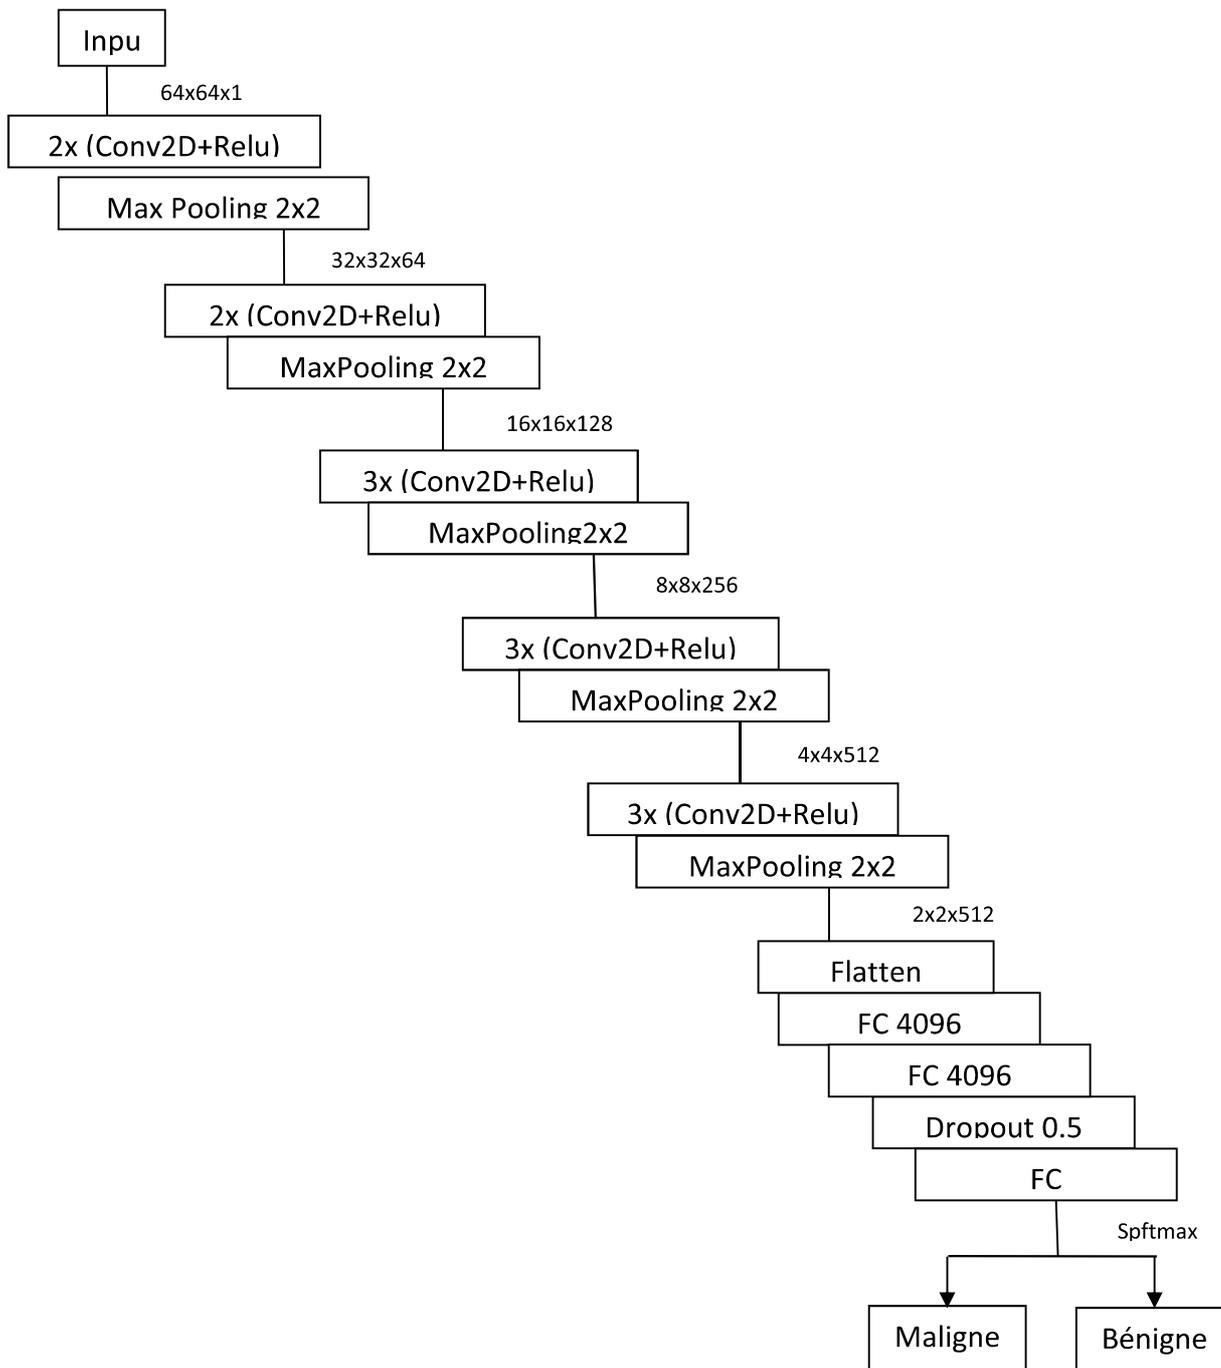


Figure 4.4 Architecture du VGG16 pour la classification des nodules

4.3.3 Classification des tumeurs par le modèle VGG19

Le deuxième modèle consacré à la classification des tumeurs, est le VGG19 qui est composé de 16 couches de convolution, 5 couches de MaxPooling et 3 couches fully connecte. Une fonction d'activation Relu est appliquée après chaque convolution.

Un Flatten est effectué, avant la première couche FC, qui consiste à transformer les résultats en des dimensions adéquates.

Un Dropout est appliqué avant la couche de sortie, qui est une fully connected avec une fonction d'activation softmax, pour recevoir les données classifiées. Une description détaillée du modèle CNN susmentionné est illustré sur la figure 4.5.

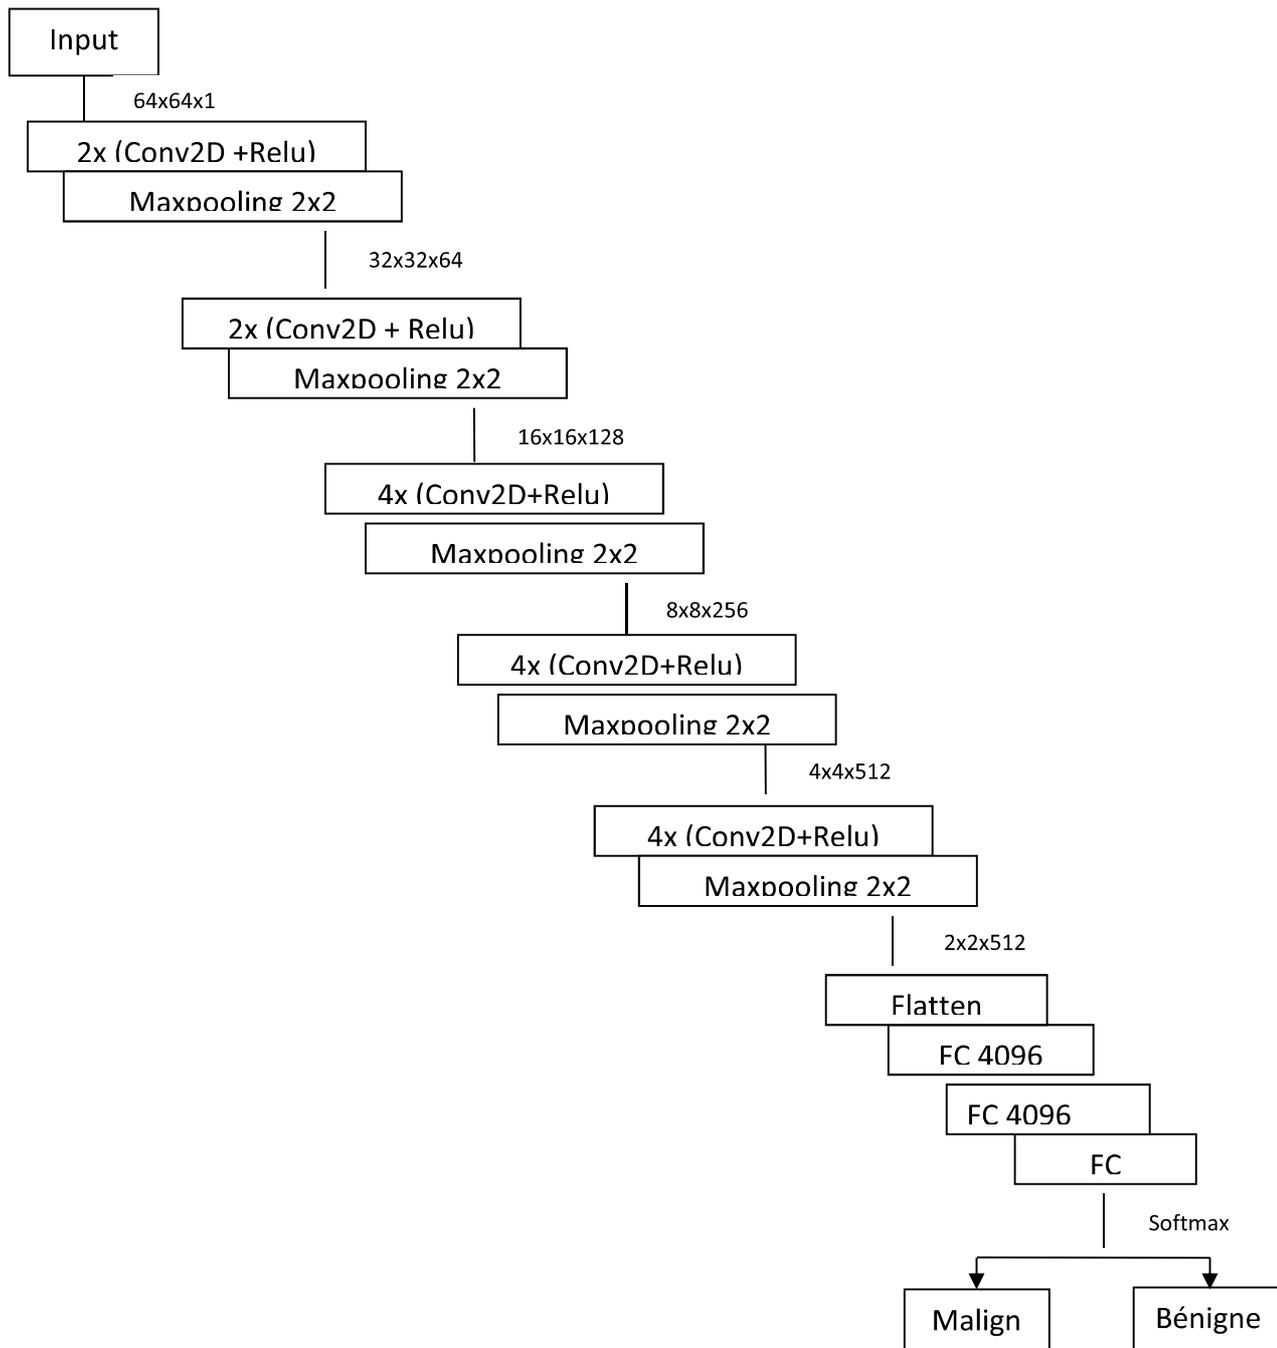


Figure 4.5 Architecture du VGG19 pour la classification des nodules

4.3.4 Classification des pneumonies par le modèle VGG19

L'application PneumoCNN est destinée aussi à la classification de pneumonies suivant l'architecture CNN VGG19. Celle-ci consiste à classifier des radiographies thoraciques, en deux catégories engendrées par les pneumonies et les cas normalaux. Cette architecture est composée de 16 couches de convolution, 5 couches de MaxPooling et 4 couches FC. Chacune des trois premières couches FC, est suivie d'une fonction d'activation Relu et d'un Dropout.

Un Flatten est appliqué avant la première couche FC. La dernière couche FC de sortie est suivie d'une fonction sigmoïde. Une description globale du modèle susmentionné, est présentée sur la figure 4.6.

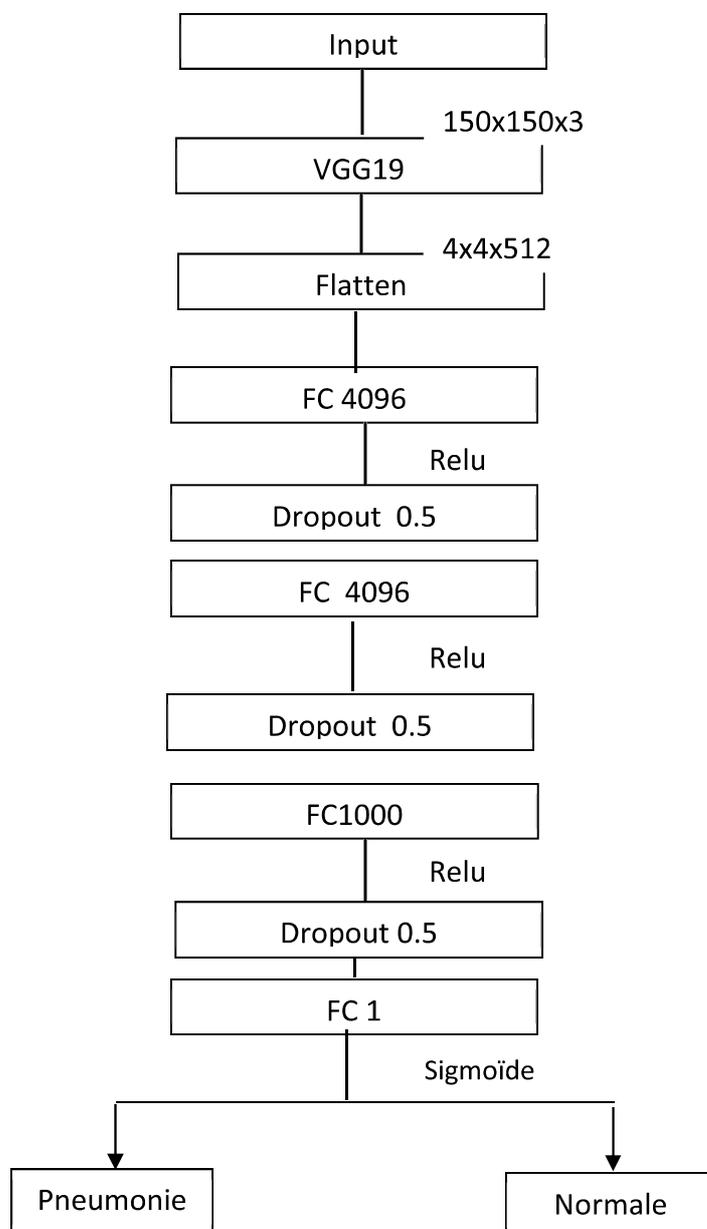


Figure 4.6 Architecture du VGG19 pour la classification des pneumonies

4.4 Application du système sur des données réelles

L'objectif de notre système, est d'analyser des CT scans des poumons via le deep learning selon deux architectures différentes, pour classifier des images en des classes malignes ou bénignes. La 2ème partie du système PneumoCNN est consacré à l'analyse des radiographies des poumons, via les CNN en les séparant selon deux classes, les pneumonies et les cas normaux.

4.4.1 Application PneumoCNN pour la classification des nodules pulmonaires

L'entraînement des deux modèles (VGG16 et VGG19) a été fait en Python, en utilisant le package Keras avec Tensorflow comme back-end. Chaque modèle a été formé, en divisant la base de données, en un groupe de formation composé de 70% pour l'apprentissage, 15% pour le test et 15% pour la validation. L'entraînement s'est poursuivi pendant 30 époques, avec une taille du lot, de 32. Le taux d'apprentissage qui a engendré la meilleure précision, est de 0.0001.

4.4.2 Application PneumoCNN pour la classification de pneumonies

L'expérience était basée sur un ensemble d'images radiographiques thoraciques, via l'architecture VGG19. Le modèle a été entraîné sur python, en utilisant keras avec tensorflow comme backend. L'une des phases importantes pour augmenter les performances du système, à consister à redimensionner les images à (150x150x3).

Le réseau CNN a besoin d'une quantité suffisante de données, pour obtenir d'excellentes performances. Pour cela une augmentation des données, a été effectuée pour augmenter les données insuffisantes dans l'entraînement. Les techniques utilisées incluent un redimensionnement, une rotation de 40°, un décalage horizontal, vertical, une translation, un zoom et un retournement horizontal des images. L'entraînement s'est poursuivi pendant 25 époques, pour une taille du lot à 20 avec un taux d'apprentissage de 0.0001.

4.4.3 Evaluation du système développé

Nous utilisons quatre métriques pour estimer les performances de la classification de nos modèles sur un jeu de données de test. Dans notre cas, le vrai positif (TP) est le nombre d'échantillons correctement identifiés comme malins. Le faux positif (FP) est le nombre d'échantillons, incorrectement identifiés comme malins. Le vrai négatif (TN) est le nombre d'échantillons correctement identifiés, comme bénins et le faux négatif (FN), est le nombre d'échantillons incorrectement identifiés comme bénins.

a *La précision*

La précision est la capacité du modèle à différencier correctement, les échantillons malins et bénins. Ce paramètre peut être défini mathématiquement comme suit:

$$\textit{Précision} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

b *Sensibilité*

La Sensibilité représente la capacité du modèle à déterminer correctement les échantillons malins, qui peut être définie mathématiquement comme :

$$\textit{Sensibilité} = \frac{TP}{TP + FN} \quad (4.2)$$

c *Spécificité*

La spécificité représente la capacité du classificateur, à identifier les échantillons bénins. Elle peut être définie mathématiquement comme :

$$\textit{Spécificité} = \frac{TN}{TN + FP} \quad (4.3)$$

d *ROC*

La courbe ROC est le tracé graphique, qui illustre la capacité du diagnostic du système (classification binaire). Le score AUC est la zone sous la courbe ROC.

e *Perte*

La perte est une valeur qui indique l'erreur de performance du modèle.

4.5 Résultats

4.5.1 Résultats de la classification des tumeurs pulmonaires par le modèle VGG16

Le système PneumoCNN conçu pour la classification des tumeurs pulmonaires, en deux classes malignes et bénignes a été réalisé sur la base des images pulmonaires LUNA16. Les performances du système PneumoCNN sont évaluées l'aide des métriques telles que la sensibilité, la précision, la perte, la spécificité et la courbe AUC(ROC). Le tableau 4.2 présente les différents résultats, d'évaluation du système.

Métriques	Précision	Sensibilité	Perte	AUC(ROC)	Spécificité
Résultat	97.5%	90%	0.07	0.98	97%

Tableau 4.2 Présentation des résultats obtenus (VGG16)

La courbe ROC permet d'évaluer les performances d'un système de classification binaire, en analysant la relation, entre le taux de vrais positifs et le taux de faux positifs. Chaque paire de (TPR, FPR) est ensuite tracée pour produire une courbe ROC. Un bon classificateur a généralement un TPR élevé et un FPR faible ; ainsi sa courbe ROC se déplacerait vers le coin supérieur gauche. La Figure 4.7 montre que la courbe ROC de notre modèle, est très proche du coin supérieur gauche de la figure, indiquant la haute qualité de notre classifieur. L'aire représente 98% sous la courbe ROC.

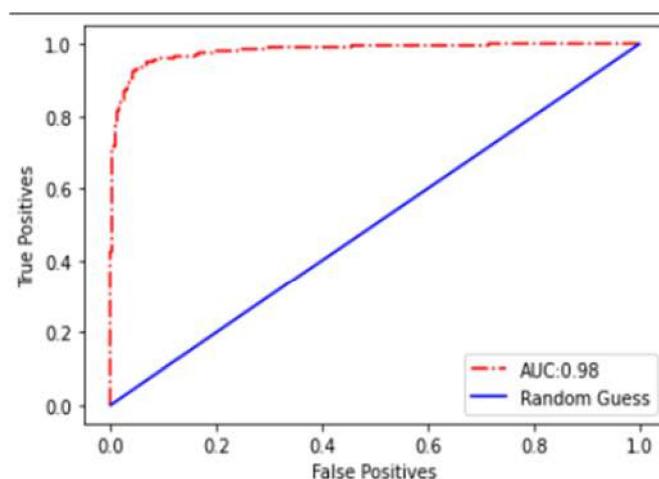


Figure 4.7 Courbe roc du modèle VGG16 pour les données Luna16

4.5.2 Résultats de la classification des tumeurs pulmonaires par le modèle VGG19

Le système Pneum-CNN conçu à base du modèle VGG19, permet aussi, la classification des tumeurs pulmonaires suivant, la base de données LUNA16. Les performances du système PneumoCNN (VGG19) sont évaluées l'aide des métriques, telles que la sensibilité, la précision, la perte, la courbe AUC(ROC) et la spécificité. Le Tableau 4.3 présente les différents résultats d'évaluation du système.

Métrique	Précision	Sensibilité	Perte	AUC(ROC)	Spécificité
Résultat	98.5	91%	0.05	0.98	96%

Tableau 4.3 Présentation des résultats obtenus (VGG19)

Au début, ce modèle a été lancé pour un entraînement de 30 époques, mais au-delà de la 18^{ème} époque, l'erreur de perte avait tendance à augmenter. Pour cela nous avons entraîné le modèle adopté, seulement avec 18 époques. La figure 4.8 montre que la courbe ROC, de notre modèle VGG19 est très proche du coin supérieur gauche de la figure, indiquant la haute qualité de notre classifieur.

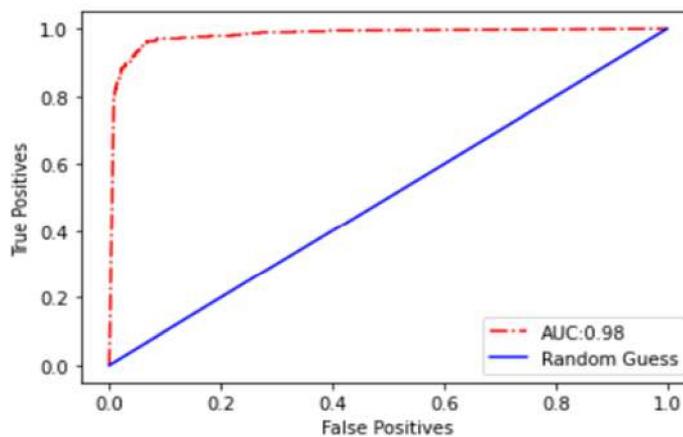


Figure 4.8 Courbe roc du modèle VGG19 pour la base Luna16

4.5.3 Résultats de la classification de pneumonies par le modèle VGG19

Le système Pulmo-CNN qui a été conçue pour la classification des pneumonies, en deux classes pneumonie et normale, a été réalisé sur une base d'images de radiographies pulmonaires d'enfants de 1 à 5 ans.

Pour augmenter les performances du modèle, les paramètres ont été modifié plusieurs fois, jusqu'à l'obtention des meilleurs résultats. La courbe d'entrainement est calculée à partir de l'ensemble de données d'entrainement (qui donne une idée de la qualité d'apprentissage du modèle), tandis que la courbe de validation est calculée à partir d'un ensemble de données de validation d'attente (qui donne une idée de la façon dont le modèle se généralise). De plus, la perte d'apprentissage et de validation est définie comme une somme des erreurs commises pour chaque exemple, dans les ensembles de validation ou d'apprentissage. L'augmentation de données et la variation du taux d'apprentissage, ont contribué à l'obtention des résultats substantiels comme le montre la figure 4.9. Les résultats obtenus sont illustrés, dans le tableau 4.4 ci-dessous.

Modèle	Précision d'entrainement	Précision de validation	La perte d'entrainement	La perte de validation
VGG19	94.35%	93%	0.158	0.0216

Tableau 4.4 Présentation des résultats de la classification des pneumonies

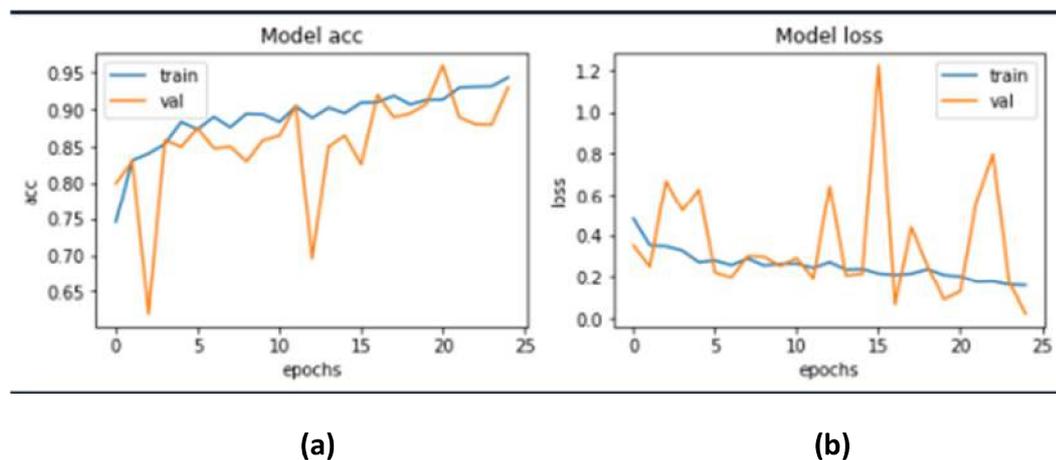


Figure 4.9 Courbes de la précision et de la perte
(a) précisions de la validation et de l'entrainement **(b)** Perte de la validation et de l'entrainement

La figure 4.10 représente une carte d'activation du modèle, dont la première ligne, les cas sont sains alors que, pour la deuxième ligne les cas sont infectés (pneumonie). Comme nous pouvons le remarquer, les images des cas sains sont lumineuses, alors que celles des cas infectés sont sombres.

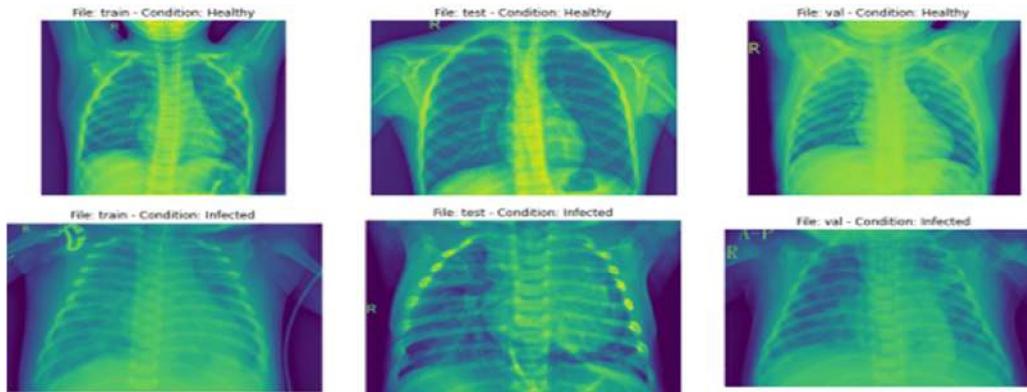


Figure 4.10 Représentation de la carte d'activation du modèle

4.5.4 Discussion et comparaison des résultats obtenus

Le DL présente une opportunité d'étendre la recherche et la classification des pathologies pulmonaires, à l'aide de modèles connexionnistes, suivant des paramètres appropriés. Les modèles rapides et précis sont nécessaires, pour détecter les maladies à temps. Pour ce travail, les ensembles de données utilisées, sont LUNA16 qui a été réparti en deux classes (classe bénigne et classe maligne), ainsi des radiographies pulmonaires, réparties en des pneumonies et des catégories normales.

Le tableau 4.5 présente les résultats des deux modèles de la classification des images CT thoraciques suivant des paramètres d'évaluation.

Modèle	conv	Max Pool	Drop out	FC	Nombre d'époque	ACC	SE	SP	Perte	AUC (ROC)	Temps d'exécution
VGG16	13	5	1	3	30	97.5%	90%	97%	0.07	0.98	1215s 211ms
VGG19	16	5	0	3	18	98.5%	91%	96%	0.05	0.98	37360s 569ms (10h 23mn)

Tableau 4.5 Comparaison des deux architectures du système de classification des nodules

Les deux modèles ont montré une performance similaire et statistiquement significative. En commençant par l'AUC, les deux modèles ont engendré le même résultat avec 98%, ce qui représente une classification presque excellente. En revanche, dans la métrique de précision, le VGG16 a obtenu un résultat de 97,5% alors que, le VGG19 a montré un résultat plus élevé avec 98,5%. Pour la mesure de sensibilité, le VGG16 a obtenu un résultat de 90% et le VGG19 a amélioré le résultat, avec 91%. En revanche la spécificité du VGG16 est de 97%, alors que celle du VGG19, elle est de 96%. Et enfin, la perte du modèle VGG16 est de 0,07, ce qui le rend moins performant que le VGG19 qui a une perte de 0,05. En effet, comme indiqué, les deux modèles ont atteint des performances statistiquement significatives dans chaque mesure. De plus, sur la base du temps de traitement nécessaire à chaque CNN, pour effectuer le processus de classification, le VGG16 a montré les meilleures performances, en prenant le temps le plus court, ce qui implique une meilleure efficacité par rapport au VGG19. Nous notons que l'inconvénient du VGG16, dans les mesures statistiques est non significatif, par rapport aux résultats du VGG19. Ce qui pourrait donc être envisagé de sacrifier une diminution minimale de la précision, en échange d'une plus grande efficacité du traitement.

4.5.5 Evaluation de classification des tumeurs avec des travaux

connexes

Les deux modèles pré-entraînés (VGG16 et VGG19) utilisés pour la classification des tumeurs ont été évalués par diverses métriques, en utilisant les mêmes hyperparamètres. Pour les évaluer encore plus, leurs performances doivent être mises en perspective, par rapport à d'autres systèmes issus des recherches antérieures. Le tableau 4.6 présente la comparaison de nos réseaux CNN proposés avec d'autres travaux.

Travaux	Base de données	Précision	Sensibilité	Spécificité	AUC(ROC)
VGG16 proposé	Luna 16	97.5%	90%	97%	98%
VGG19 Proposé	Luna 16	98.5%	91%	96%	98%
LdcNet par tran et al [64]	Luna 16	95.6%	90.2%	96%	95.6%
Li et al [65]	LIDC-IDRI	86.4%	87.1%	-	-

Tableau 4.6 Comparaison des résultats obtenus des travaux proposés avec des travaux connexes

D'après le tableau, le modèle VGG19 présente la meilleure sensibilité de 91,0% indiquant la haute qualité du classifieur, pour déterminer correctement les cas des nodules pulmonaires. Par contre la sensibilité de la méthode de Tran et al [64] a dépassé la sensibilité du VGG16, d'une différence de 0,2%. En outre, le système PneumoCNN réalisé, a engendré des résultats encourageants, avec une précision de 97,5% et une spécificité de 97% pour le VGG16, une précision de 98.5% et une spécificité de 96% pour le VGG16. Les résultats expérimentaux de l'approche PneumoCNN, prouvent que les méthodes CNN proposées, sont adaptées à la nature des images classifiées.

4.5.6 Evaluation des résultats de classification de la pneumonie avec des travaux connexes

La deuxième application proposée pour la classification des pneumopathies, à partir des images radiographiques thoraciques a été évaluée par divers métriques : la précision de validation, de l'entraînement ainsi que la perte de la validation et de l'entraînement. Afin d'évaluer la performance de cette application, nous comparons les résultats obtenus avec ceux d'autres auteurs (tableau 4.7).

Modèle	Époque	Précision de l'entraînement	Précision de la Validation	Perte lors de l'entraînement	Perte lors de la Validation
VGG19	25	94.35%	93%	0.158	0.0126
O. Stephen [68]	100	95.31%	93.73	0.1288	0.1835

Tableau 4.7 Comparaison des résultats du classifieur des pneumopathies avec un travail connexe

Selon les résultats montrés sur le tableau 4.7, qui sont assez similaires, nous remarquons que le modèle d'O. Stephen et al [68] a eu une précision pour l'entraînement et la validation, supérieure par rapport au modèle proposé, montrant une différence respectivement de 0.96% et 0.73% ; alors que la perte de validation des travaux de O.Stephen et al, est de 0.1835 supérieure, à celle du modèle proposé, qui est de 0.0126. De plus, la perte de l'entraînement de l'application proposée est légèrement supérieure à celle d'O. Stephen. Nous Notons que le modèle d'O. Stephen a été entraîné sur un GPU alors que notre modèle a été entraîné sur un CPU, ce qui rend l'application proposée en soit un succès.

4.6 Conclusion

Le CNN présente de multiples avantages dans l'analyse des images médicales, notamment la reconnaissance des structures complexes, le gain de temps grâce au calcul parallèle complexe, qui conduisent à des résultats généralement satisfaisants.

Nous avons présenté dans ce chapitre les deux systèmes de classification basée sur deux modèles des réseaux de neurones convolutionnels : le VGG16 et le VGG16.

Les premiers résultats de notre système semblent prometteurs, puisqu'ils présentent une précision dépassant les 90%. Néanmoins pour les améliorer encore plus, plusieurs possibilités existent, telle que l'exploration des ensembles de données plus volumineux.

Conclusion générale

L'initiation à la recherche réalisée dans le cadre de ce mémoire, s'inscrit dans les objectifs de l'équipe, "IMAD", du laboratoire LATSI, pour la conception de systèmes d'aide au diagnostic en imagerie médicale.

Dans ce mémoire, deux systèmes ont été proposés pour détecter les anomalies pulmonaires sur des images considérées par deux modalités différentes : les radiographies et les tomodensitométries pulmonaires. L'approche PneumoCNN proposée pour la classification de pathologies oncologiques en deux classes (malignes et bénignes), a été testée séparément avec deux différentes architectures CNN (VGG16 et VGG19) sur les données de la base LUNA16.

La classification des pneumopathies a été réalisée avec le modèle VGG19 sur des radiographies pulmonaires. Dans ce cas, le système PneumoCNN est utilisé pour classer les radiographies thoraciques, en classe normale et en pneumonie.

L'approche DL proposée offre des précisions de 97.5% et 98.5% pour la classification des nodules. Les résultats du modèle étudié pour la classification des pneumopathies, ont engendré une précision de l'entraînement de 94.35% et une précision de la validation de 93%. Ce qui offre des résultats encourageants, en comparant avec les systèmes existants.

Quelques problèmes ont été rencontrés lors de l'implémentation, tels que le long temps d'exécution, à cause de l'utilisation du CPU qui peut être réglé en explorant un GPU.

Des perspectives possibles, peuvent améliorer le travail présenté dans le cadre de ce mémoire. Parmi lesquelles :

- L'étude d'autres modèles, tels que les RNN.
- L'hybridation de deux modèles CNN.

- L'exploration d'autres modalités pour la détection de nodules pulmonaires.
- L'analyse des pneumopathies du coronavirus.

Bibliographie

- [1] Cornelius Weber, Mark Elshaw and Norbert Michael Mayer: 'Application on Reinforcement Learning for Diagnosis Based on Medical Image', In: Reinforcement Learning, Edition in techopen, ISBN: 978-3-902613-14-1, London, 2008.
- [2] F. Reinaud: 'pneumologie : l'étude du poumon et des maladies pulmonaires', en ligne le 16 août 2018, <https://www.concilio.com/>. date de consultation Février 2020.
- [3] C. Gillot, R. Piéron, A. Policard : 'Appareil respiratoire - Anatomie ', IN : Encyclopædia Universalis, France, 2020, <http://www.universalis.fr/>, date de consultation, Février 2020.
- [4] Centre de transplantation d'organes : 'Anatomie et physiologie', en ligne septembre 2019, <https://www.chuv.ch/fr/>, date de consultation, Mars 2020.
- [5] O. Clouet : 'Qu'est-ce qu'un cancer ?', Rose up, en ligne le 12 Octobre 2011, <https://www.rose-up.fr/>, date de consultation, Février 2020.
- [6] D. Rodde : 'Le nouveau souffle des traitements du cancer bronchique primitif', en ligne 9 juillet 2018, <https://www.lequotidiendupharmacien.fr/>, date de consultation, Mars 2020.
- [7] C. Jean : 'Cancer du poumon', <https://www.sante-sur-le-net.com/>, date de consultation, Février 2020.
- [8] C. Lewandowski : 'Nodule au poumon : est-ce un cancer ?', en ligne 05 Mars 2019, <https://sante.journaldesfemmes.fr/>, date de consultation, Mars 2020.
- [9] P. Chaffanjon : 'Anatomie paroi thoracique ', UNIVERSITE JOSEPH FOURIER, 2006/2007.
- [10] J. Vansteenkiste: ' CANCER DU POUMON ', In: MediPedia, Edition Viviosprl, Bruxelles, 2020.
- [11] S. Ronze: 'La radiographie pulmonaire', 2016, <https://www.doctissimo.fr/>. date de consultation, Mars 2020.

- [12] Université paul sabatier toulouse 3: 'tumeurs du poumon, primitives et secondaires', <http://www.medecine.ups-tlse.fr/>, date de consultation, Mars 2020.
- [13] Y. Castier : 'EXPLORATIONS THORACIQUES PRINCIPALES', In :Service de Chirurgie Vasculaire Thoracique et Transplantation Pulmonaire, Edition ChirVTT, Paris, 2017.
- [14] Institut national du cancer : 'Examens : IRM et cancer', <https://www.e-cancer.fr/> . date de consultation, Mars 2020.
- [15] eleve-tpe : 'Avantages & Inconvénients', <http://tpe-irm.e-monsite.com/> . date de consultation, Mars 2020.
- [16] D. Gossot, E. Brian, R. Caliandro, et al : 'LE NODULE PULMONAIRE', In :L'Institut Mutualiste Montsouris, Edition IMM2014, Paris,2016.
- [17] imagerie médicale : le TEP scan : 'Avantages et inconvénients', <http://pet-scanner.e-monsite.com/>, date de consultation, Mars 2020.
- [18] Passeport Santé : 'Définition du scanner thoracique', en ligne en2015, <https://www.passeportsante.net/> . date de consultation, Mars 2020.
- [19] TPE imagerie : 'Historique du scanner',en ligne en 2012, <http://tpe-imagerie.over-blog.fr/> . date de consultation, Mars 2020.
- [20] A. Jankowskiet G. Ferretti: 'Tomodensitométrie volumique : principe, paramètres', In :Elsevier Masson, Edition Elsevier Masson SAS, France,2010.
- [21] M. Leaderlin : 'CAT devant la découverte fortuite d'un nodule pulmonaire', Cours référentiel du CERF-imagerie thoracique de l'adulte,11 décembre 2015.
- [22] P. Grenier et C. Beigelman-Aubry : 'Conduite à tenir devant un nodule pulmonaire de découverte fortuite', pages 34-37.
- [23] M. Lederlin, M.-P. Revel, A. Khalil, et al : 'Prise en charge du nodule pulmonaire', Journal de Radiologie diagnostique et interventionnelle, Volume 94, n° 11, pages 1084-1098,2013.
- [24] G. Dournes, J. Macey, E. Blachard, et al : 'IRM du parenchyme pulmonaire : vers une application clinique ?', In : ElsevierMasson, Edition Elsevier Masson SAS, France,2017.
- [25] B. Ericsoussi: 'Approach to the Solitary Pulmonary Nodule - New Staging System for NSCLC - Lymph Node Map-Update', University of Illinois Medical Center, Chicago,2010.
- [26] G.F. Abbott et L. Vlahos: 'CT Diagnosis and Management of Focal Lung Disease', In:Diseases of the Chest, Breast, Heart and Vessels, Edition Spring, ISBN-13: 978-3-030-11148-9, USA,2019.

- [27] J.S. Klein : 'Pulmonary Neoplasms', en ligne en 2016, <https://radiologykey.com/pulmonary-neoplasms-4/> , date de consultation, Mars 2020.
- [28] Histoire de l'intelligence artificielle, <https://siecldigital.fr/2018/08/20/histoire-intelligence-artificielle/>, date de consultation, mars 2020.
- [29] C. Nicholson. A Beginner's Guide to Neural Networks and Deep learning, 2019, <https://pathmind.com/> , juin 2020.
- [30] F. Hocine. Application des réseaux de neurones artificiels au diagnostic des défauts des machines tournantes. Mémoire de Master en optique et mécanique de précision, UNIVERSITE FERHAT ABBAS de SETIF ,2017.
- [31] C. Touzet. Les réseaux de neurones artificiels, introduction au connexionnisme. Ec2, 1992.
- [32] l'intelligence artificielle –TPE. L'Intelligence Artificielle, 2015, <https://iatpe2015.wordpress.com/>, date de consultation, Juin 2020.
- [33] R. Zemouri. Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la maintenance. Thèse de Doctorat, Université de Franche Comté, Besançon, 2003.
- [34] Missinglink.7 Types of Neural Network Activation Functions: How to Choose?, 2019, <https://missinglink.ai/> , juillet 2020.
- [35]O. Nerrand, P. Roussel-Ragot, L. Personnaz, G. Dreyfus. Neural Networks and Non-linear Adaptive Filtering: Unifying Concepts and New Algorithms. Neural Computation, Vol 5, pages 165-199, 1993.
- [36] I. Chraïbi-Kaadoud. Architecture des réseaux de neurones : Réseaux de neurones artificiels classiques (2/3), en ligne en Novembre 2018, <http://www.scilog.fr/> .date de consultation, juillet 2020.
- [37] R.Keim. How to Train a Basic Perceptron Neural Network, en ligne en 2019, <https://www.allaboutcircuits.com/> , date de consultation, juillet 2020.
- [38] H.G.N.Wouafo. Architectures matérielles numériques intégrées et réseaux de neurones à codage parcimonieux, cours d'intelligence artificielle. Université de Bretagne Sud, 2016.
- [39] L.Kong A Siou.Exemple de réseau de neurones bouclé ou récurrent, en ligne en 2011, <https://www.researchgate.net/> ,date de consultation , juillet 2020.

- [40] E.brakni. Réseaux de neurones artificiels appliqués à la méthode électromagnétique transitoire, mémoire de master en maîtrise en ingénierie, université du Québec, mai 2011.
- [41] M.C.Laoubi. Contrôle d'un pendule inversé par un réseau de neurones artificiels, Mémoire de master en électronique des systèmes embarqués, Université Akli Mohand Oullhadj, Bouira, 2018.
- [42] A. Josselin. Vue d'ensemble des fonctions d'activation, en ligne en 2019, <http://www.netforceteam.com/> . date de consultation, juillet 2020.
- [43] GeeksforGeeks. Understanding Activation Functions in Depth, en ligne en 2020, <https://www.geeksforgeeks.org/> . Date de consultation, en juillet 2020.
- [44] Google Developers. Travaux pratiques sur le machine learning : Classification d'images, en ligne en 2020, <https://developers.google.com/> . Date de consultation, juillet 2020.
- [45] J.Jordan. Common architectures in convolutional neural networks. En ligne en 2018, <https://www.jeremyjordan.me/> . date de consultation, juillet 2020.
- [46] E.Benlahlar. Les réseaux de neurones convolutifs, en ligne en 2018, <http://datasciencetoday.net/> . date de consultation, juillet 2020.
- [47] Github. R-CNN: Regions with Convolutional Neural Network Features, en ligne en 2014, <https://github.com/> . date de consultation, juillet 2020.
- [48] MathWorks. Getting Started with R-CNN, Fast R-CNN, and Faster R-CNN, <https://www.mathworks.com/> . date de consultation, juillet 2020.
- [49] V. KURAMA. A Review of Popular Deep Learning Architectures: AlexNet, VGG16, and GoogleNet, en ligne en 2020, <https://blog.paperspace.com/>, date de consultation, juillet 2020.
- [50] GeeksforGeeks. R-CNN vs Fast R-CNN vs Faster R-CNN | ML, en ligne en 2018, <https://www.geeksforgeeks.org/> . date de consultation, juillet 2020.
- [51] P. SHARMA. A Step-by-Step Introduction to the Basic Object Detection Algorithms (Part 1), en ligne en 2018, <https://www.analyticsvidhya.com/> . Date de consultation, juillet 2020.
- [52] Towards data science. Image Segmentation Using Mask R-CNN, en ligne en 2020, <https://towardsdatascience.com/> . date de consultation, juillet 2020.
- [53] Missinglink. Neural Network Concepts CNN vs RNN, <https://missinglink.ai/> . date de consultation, juillet 2020.

- [54] V. Bilky. How business can benefit from recurrent neural networks: 8 major applications, <https://theappsolutions.com/> . Date de consultation, juillet 2020.
- [55] F.Emmert-streib,Z.Yang,H.Feng et al. An Introductory Review of Deep Learning for Prediction Models With Big Data , en ligne en 2020, <https://www.frontiersin.org/> . date de consultation, Août 2020.
- [56] B. Mikulski. Understanding the softmax activation function, enligne en 2019, <https://www.mikulskibartosz.name/> . date de consultation ,Aout 2020.
- [57] R. Draelos. The History of Convolutional Neural Networks, enligne en 2019, <https://glassboxmedicine.com/> . date de consultation, juillet 2020.
- [58] M. Zhang, L.Li, H.Wang et al . Optimized Compression For Implementation Convolutional Neural Networks on FPGA , enligne en 2019, <https://www.researchgate.net/> . date de consultation , Aout2020.
- [59] Aggregated news about artificial intelligence. Review of ZFNet, enligne en 2018, <https://mc.ai/> . date de consultation, Aout 2020.
- [60]A. Kaushik. Understanding the VGG19 Architecture. <https://iq.opengenus.org/> , date de consultation aout 2020.
- [61] E. Park, X. Cuil, H. Kim et al . fPADnet: Small and Efficient Convolutional Neural Network for Presentation Attack Detectionn, enligne en 2018, <https://www.researchgate.net/> .date de consultation , aout 2020.
- [62] K. Narmada, G. Prabakaran, S. Mohan. Classification and Stage Prediction of LungCancer using Convolutional Neural Networks, International Journal of Innovative Technology and Exploring Engineering (IJITEE), vol 8, N°10, pages 993-998,2019.
- [63] Q. Abbas. Nodular-Deep: Classification of Pulmonary Nodules using Deep Neural Network, International Journal of Medical Research & Health Sciences, vol 6, N°8, pages 111-118, 2017.
- [64] G. Tran, T.Nghiem ,J.Burie et al. Improving Accuracy of Lung Nodule Classification Using Deep Learning with Focal Loss, Hindawi Journal of Healthcare Engineering, vol 2019, 2019.
- [65] W.Li, P. Cao , D.Zhao et al. Pulmonary Nodule Classification with Deep Convolutional Neural Networks on Computed Tomography Images, Hindawi Publishing Corporation Computational and Mathematical Methods in Medicine, vol 2016,2016.
- [66] K.Kadam, S.Ahirrao, H.Kaur et al. Deep Learning Approach For Prediction Of Pneumonia, INTERNATIONAL JOURNAL OF SCIENTIFIC & TECHNOLOGY RESEARCH, vol 8, N° 10, pages 2986-2989,2019.

- [67] M.Farukh Hashmi, S.Katiyar, A.G Keskar et al. Efficient Pneumonia Detection in Chest Xray Images Using Deep Transfer Learning, Détection efficace de la pneumonie dans les images de radiographie thoracique à l'aide de l'apprentissage par transfert profond, Bibliothèque nationale de médecine des États-Unis National Institutes of Health, vol 10 , N°6 , page 417, 2020.
- [68] O. Stephen, M.Sain, U.J.Maduh et al. An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare, US National Library of Medicine National Institutes of Health, vol 2019,2019.
- [69] Anaconda. Your data science toolkit, <https://www.anaconda.com/products/individual>, consulté en janvier 2020.
- [70] Spyder, <https://www.spyder-ide.org/>, consulté en janvier 2020.
- [71] L. Bastien. Python : tout savoir sur le principal langage Big Data et Machine Learning, en ligne en 2019, <https://www.lebigdata.fr/>, date de consultation, août 2020.
- [72] R. Roy. Best Python libraries for Machine Learning, en ligne en 2019, <https://www.geeksforgeeks.org/>, date de consultation , août 2020.
- [73] Data base Luna16, <https://luna16.grand-challenge.org/>, date de consultation, février 2020.
- [74] Chest X-ray images, <https://data.mendeley.com/datasets/rscbjbr9sj/2>, date de consultation, juillet 2020.