

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 دحلب البلدية
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الآلية والالكترونتقي
Département d'Automatique et d'Electrotechnique



Mémoire de Master

en Automatique

Spécialité : Automatique et Informatique industrielle

Présenté par

Azine Anis

&

Talbi Louay

Analyse de radiographies pulmonaires par deep learning pour la détection de pneumopathies

Dirigé par : Dr. Reguieg F. Zohra & Pr. Benblidia Nadja

Année Universitaire 2020-2021

Dédicace

Je dédie ce travail

A mon cher père

Pour son indéfectibles soutiens et sa patience infinies, qui ma toujours poussé dans mes études, pour le gout à l'effort qu'il a suscité en moi, son affection et la confiance qu'il m'a accordé, que dieu te procure bonne santé, bonheur et longue vie.

A ma chère mère

Aucun hommage ne pourrait être à la hauteur de l'amour dont ne cesse de me combler, ses encouragements, motivations et ses sacrifices que dieu te procure bonne santé et longue vie le courage pour tes projets.

A mon Frère Housssem

Celui qui a partagé avec moi les moments d'émotion de joie et tristesse dans cette difficile année. Ils m'ont chaleureusement supporté et encouragé tout au long de mon parcours, merci énormément pour ton soutien, pour l'ordinateur que tu nous as prêté, sans toi le projet n'a pu voir le jour.

A mon adorable Frère Tamim

Qui sait toujours comment procurer la joie et le bonheur pour toute la famille. Je te souhaite tout le bonheur et la santé dans ta vie.

A la mémoire mon grand-père Abdelaziz et ma grande mère Zineb, ceci est ma profonde gratitude pour votre éternel amour, vous avez toujours été là pour moi, que dieu vous accueillera dans son vaste paradis.

A mes grands-parents Abdallah et Ouidad pour le soutien moral et leurs conseils, pour tous mes oncles et mes cousins adorables je vous aime.

Mon binôme et notre 3ème frère

Vous êtes ma deuxième famille, pour les cinq années passé ensemble, pour les leçons de vie qu'on a apprises ensemble, j'espère qu'un jour nous réussirons à trouver le bonheur, je vous souhaite le succès et le bon courage pour votre carrière professionnel

A mes meilleurs amis

Pour les meilleurs moments passés ensemble, l'expérience et les tragédies qu'on a vécu ensemble, je vous dis que dieu s'en chargera des malfaiteurs, Je vous souhaite tout le bonheur du monde et bon courage pour votre carrière professionnelle.

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

Falbi Louay

Je dédie ce travail :

A mes chers parents

Qui de leur amour inconditionnel et le fait qu'ils ont toujours cru en moi peu importe les choix ou les routes que j'ai suivis ont fait de moi le jeune homme que je suis aujourd'hui.

Je vous souhaite une longue vie et d'être toujours en bonne santé, et qu'un jour vous puissiez être fière de moi.

A mon adorable grande sœur

La personne qui a été toujours là pour moi qu'il importe la situation, qui m'a toujours poussé à être meilleur, qui m'a fait découvrir tant de chose aussi amusantes et intéressantes les unes que les autres, et qui a été la raison principale de la découverte de ma passion. Tu es l'une des choses principales dans ma vie qui me rendent heureux.

A mes meilleurs amis

Plus que des frères à mes yeux, les moments passés avec vous sont mes meilleurs souvenirs, nous avons grandi ensemble et nous avons fait les quatre cents coups ensemble. Sachez que vous êtes les meilleurs et que je vous souhaite tout le bonheur du monde et qu'on soit ensemble pour toujours.

A mon binôme et notre 3eme mousquetaire « F »

Nous avons passés nos années de fac ensemble, grâce à vous j'ai appris quand pouvait encore se faire d'excellents amis même étant adulte, quoique petite exception pour vous savez qui. Je vous souhaite que du bonheur dans votre vie et que notre entrée en vie professionnelle se passe bien.

Azine Mohamed Anis

Remerciements

A Allah

Le créateur de l'univers, le tout puissant et miséricordieux, de nous avoir donné la santé et la volonté d'entamer ses cinq années d'études et de terminer ce mémoire.

A Notre Promotrice Mlle Reguieg F. Zohra

Nous avons eu l'honneur d'être parmi vos étudiants, on vous remercie pour la qualité de votre encadrement exceptionnel, pour votre patience, votre rigueur, le sérieux et la disponibilité permanente aussi le temps consacré durant notre préparation de ce mémoire

On vous remercie pour votre accueil, vos conseils, votre support et l'encouragement toute au long de période de ce travail. On vous souhaite le bonheur et une longue vie

A Notre Co-promotrice Mlle Benblidia Nadja

Nous avons eu l'honneur d'être parmi vos étudiants et de bénéficier de votre riche enseignement, on vous souhaite le courage et la bonne santé

Aux membres du jury

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

A Nos enseignants honorables

Pour votre soutien en nous apportant vos expériences et vos compétences durant ces années d'études

ملخص: ان تشخيص الالتهاب الرئوي يستغرق كثير من الوقت ويستلزم تأهيلا ومهاراه كبيرة من قبل الأطباء لاكتشافه في صور الاشعة السينية للقفص الصدري، مما يجعله مرضا بالغ الخطورة لدى الانسان، في هذه المذكرة سنتطرق الى ، VGG16 , VGG19 , RESNET50 استعمال تقنية التعلم العميق وبعض انواع هندسة الشبكات العصبية الالتفافية لغرض تصنيف صور الاشعة السينية الى فئتين، عادية او مصابة بالتهاب رئوي، لهدف المساعدة في التشخيص. هذه الدراسة اظهرت لنا ان جميع النتائج المتحصل عليها قد فاقت 97% من الدقة في مختلف هندسيات الشبكة العصبية الالتفافية

كلمات المفاتيح: الامراض الصدرية، صور الأشعة السينية للقفص الصدري، التعلم العميق، الشبكة العصبية الالتفافية، VGG16 et VGG19, Resnet50, المساعدة في التشخيص,

Résumé : Le diagnostic de la pneumonie est très gourmand au niveau du temps, il requiert à cet effet, une grande qualification des médecins, afin de la détecter sur les différentes images de radiographie du thorax, ce qui en fait une maladie à haut risque, chez l’homme. Dans ce mémoire, nous réalisons un système basé sur l’apprentissage profond suivant plusieurs modèles des réseaux de neurones convolutifs ‘CNN’, le VGG16, le VGG19 et le Resnet50, afin de classifier les images radiographiques en deux catégories, normale ou pneumonie, pour une aide au diagnostic. Cette étude montre des résultats, dépassent les 97% en termes de précision, sur les différents modèles de CNN explorés.

Mots clés : Pneumologie, images radiographiques du thorax, Apprentissage profond, CNN, VGG16 et VGG19, Resnet50, Aide au diagnostic.

Abstract: the diagnosis of pneumonia is very time consuming and requires great skill to detect it on various x-ray images of the chest, making it a high risk disease for humans. In this research, we propose a method using the deep learning and different types of ‘CNN’, the VGG16, the VGG19 and the ResNet50, to classify different radiographic images into two categories, normal or pneumonia, for diagnostic aid. This approach shows great results all exceeding an accuracy of 97% on various CNN architecture models

Keywords: pneumonia, deep learning, CNN, X-ray, VGG16, VGG19, ResNet50.

Listes des acronymes et abréviations

CNN: Convolutional Neural Network

CONV: Convolution

CONV2D: 2D Convolution layer

CPU: Central Processing Unit

DL: Deep Learning

FC: Fully Connected

GPU: Graphic Processing Unit

IRM : Imagerie par Résonance Magnétique

JPEG : Joint Photographic Experts Group

PNG: Portable Network Graphics

ML: Machine Learning

RELU: Rectified Linear Unit.

RAM: Random Access Memory.

RESNET : Residual neural network

RNA : Réseau Neuronal Artificiel.

RN : Réseau Neuronal.

RNN : Recurrent Neural Network.

TDM: Tomodensitométrie.

VGG: Visual Geometry Group.

Table des matières

Introduction générale	1
Chapitre 1 Contexte Médical.....	3
1.1 Introduction.....	3
1.2 Anatomie des poumons et leurs structures	3
1.3 Pathologies pneumologiques	5
1.3.1 Définition d'une pathologie	5
1.3.2 Symptômes du pneumothorax	5
1.3.3 Types de pneumothorax	5
1.3.4 Tuberculose.....	6
1.3.5 Pneumonie	9
1.4 Cancer du poumon.....	10
1.4.1 Nodule pulmonaire.....	11
1.4.2 Type des cancers du poumon	12
1.4.3 Classification TNM	12
1.4.4 Stade du cancer du poumon.....	14
1.5 Systèmes d'acquisition en imagerie médicale	14
1.5.1 Introduction à l'imagerie médicale	14
1.5.2 Rayons X	15
1.5.3 Systèmes de détection moderne.....	16
1.5.4 Diagnostic médical.....	20
1.5.5 Introduction au diagnostic par les systèmes informatiques	21
1.6 Conclusion	21
Chapitre 2 Notions d'apprentissage automatique et profond	22
2.1 Introduction.....	22
2.2 Introduction à l'apprentissage automatique	22
2.3 Apprentissage profond	23
2.3.1 Historique.....	24
2.3.2 Principe du deep learning	26
2.4 Réseaux de neurones classiques	27

2.4.1	Neurone biologique.....	27
2.4.2	Neurone artificiel.....	29
2.5	Architectures des réseaux de neurones	33
2.5.1	Réseaux de neurones feed forwarded	33
2.5.2	Réseaux de neurones récurrents (RNN)	34
2.5.3	Réseaux de neurones à résonance.....	34
2.5.4	Réseaux de neurones auto-organisés	35
2.5.5	Apprentissage	35
2.6	Réseaux de neurones convolutifs	37
2.6.1	Couche de convolution	38
2.6.2	Couche de pooling.....	39
2.6.3	Couche de correction ReLU	40
2.6.4	Couche fully-connected	40
2.6.5	Couche de perte	42
2.7	Augmentation des données	42
2.8	Conclusion	43
Chapitre 3	Architectures des réseaux de neurones convolutifs.....	44
3.1	Introduction.....	44
3.2	Architecture des réseaux neuronaux convolutifs	44
3.2.1	Modèle VGG 16.....	44
3.2.2	VGG19	46
3.2.3	ResNet	46
3.2.4	Architecture Inception et ses dérivées	48
3.2.5	Architecture DenseNet.....	49
3.2.6	Architecture Squeeze-and-Excitation	50
3.2.7	Architecture de MobileNet.....	51
3.3	Critique documentaire de quelques travaux connexes.....	52
3.3.1	Travaux de Khemis et Meradi	52
3.3.2	Introduction aux travaux de F. Demir	53
3.3.3	Travaux de T. Ozturk et al	56
3.4	Conclusion	57
Chapitre 4	Mise en œuvre de 'PneumoCNNV2.1' & résultats.....	58
4.1	Introduction.....	58

4.2	Environnement de travail	58
4.2.1	Matériel utilisé.....	58
4.2.2	Langage de programmation utilisé.....	58
4.2.3	Anaconda	59
4.2.4	Spyder.....	59
4.2.5	Scipy.....	59
4.2.6	Numpy	59
4.2.7	Tensorflow	60
4.2.8	Keras	60
4.2.9	Matplotlib.....	60
4.2.10	Pandas	60
4.3	Architecture du système 'PneumoCNNV2.1'	60
4.4	Base de données	61
4.5	Classification des pneumonies par le modèle VGG19	62
4.6	Classification des pneumonies par le modèle VGG16	63
4.7	Classification des pneumonies par le modèle Resnet50	64
4.8	Paramètres d'évaluation des performances de 'PneumoCNNV2.1'	65
4.9	Résultats de la classification des pneumonies par le modèle VGG16	66
4.10	Résultats de la classification des pneumonies par le modèle VGG19	67
4.11	Résultats de la classification des pneumonies par le modèle resnet50	69
4.12	Résultats de la classification des pneumonies par le modèle resnet50 (optimisateur RMSprop)	70
4.13	Comparaison des résultats obtenus entre les différents modèles utilisés ..	71
4.14	Comparaison des résultats de la classification avec des travaux connexes	72
4.15	Conclusion	73
	Conclusion générale	74
	Bibliographie.....	76

Liste des figures

Chapitre 1 Contexte Médical

Figure 1. 1 Anatomie des poumons	4
Figure 1. 2 Structure et composants des poumons	4
Figure 1. 3 Macroscopie de la tuberculose nodulaire avec beaucoup petits et grands nodules avec nécrose caséuse	6
Figure 1. 4 Pneumonie précoce avec hémorragie	10
Figure 1. 5 Différence entre les cellules saines et les cellules cancéreuses	10
Figure 1. 6 Main de Rontgen	16
Figure 1. 7 Processus de conversion de rayons X en lumière visible [.....	17
Figure 1. 8 Appareil de radiographie pulmonaire.....	18
Figure 1. 9 : Image radiographique des poumons	18
Figure 1. 10 : Appareil de tomодensitométrie:	19

Chapitre 2 Notions d'apprentissage automatique et profond

Figure 2. 1 Structure d'un neurone biologique	28
Figure 2. 2 Simple réseau de neurones	29
Figure 2. 3 Architecture d'un réseau neuronal monocouche	33
Figure 2. 4 Architecture d'un réseau multicouches	34
Figure 2. 5 Réseaux de neurones à résonance	35
Figure 2. 6 Apprentissage supervisé	36
Figure 2. 7 Apprentissage non supervisé	37
Figure 2. 8 Réseau de neurones convolutif	38
Figure 2. 9 Couche convolutive	38
Figure 2. 10 Couche de max pooling.....	40
Figure 2. 11 Couche fully-connected	41

Chapitre 3 Architecture des réseaux de neurones convolutifs

Figure 3. 1 Architecture globale du VGG16	45
Figure 3. 2 Architecture du VGG16	45
Figure 3. 3 Architecture du VGG19	46
Figure 3. 4 : Bloc résiduel	47
Figure 3. 5 Architecture Inception	48
Figure 3. 6 Architecture de Inception ResNet	49
Figure 3. 7 Architecture DensNet	50
Figure 3. 8 Architecture du modèle squeeze-and-Extinction	51
Figure 3. 9 Architecture de MobileNet	52
Figure 3. 10 Images radiographiques des 3 catégories	54
Figure 3. 11 Représentation de la méthode utilisée	55
Figure 3. 12 Résultats des travaux de Demir et al	55
Figure 3. 13 Images radiographiques d'un patient de 50 ans atteint du covid19	56
Figure 3. 14 : Architecture du modèle proposé	57

Chapitre 4 mise en œuvre de 'PneumoCNNV2.1' & résultats

Figure 4. 1 Architecture du système 'PneumoCNNV1.2'	61
Figure 4. 2 Exemples d'images de la base 'pneumonia'	62
Figure 4. 3 Classification des pneumonies par le modèle VGG19	63
Figure 4. 4 Classification des pneumonies par le modèle VGG16	64
Figure 4. 5 Classification des pneumonies par le modèle Resnet50	65
Figure 4. 6 Courbe de la perte pour VGG16	67
Figure 4. 7 : Courbe de la précision pour VGG16.....	67
Figure 4. 8 Matrice de confusion vgg16	67
Figure 4. 9 Courbe de la perte pour VGG19	68
Figure 4. 10 : Courbe de la précision pour VGG19.....	68
Figure 4. 11 Matrice de confusion pour VGG19	68

Figure 4. 12 : Courbe de la perte pour Resnet50	69
Figure 4. 13 Courbe de la précision pour Resnet50	69
Figure 4. 14 Matrice de confusion pour Resnet50	69
Figure 4. 15 Courbe de la perte pour Resnet50 (rmsprop)	70
Figure 4. 16 Courbe de la précision pour Resnet50 (rmsprop)	70
Figure 4. 17 Matrice de confusion	70

Liste des tableaux

Chapitre 1 Contexte Médical

Tableau 1. 1 Classification NTM des stades d'un cancer	14
---	----

Chapitre 2 Notions d'apprentissage automatique et profond

Tableau 2. 1 résume l'évolution du deep learning jusqu'à l'année 2019	26
--	----

Tableau 2. 2 Fonctions d'activation	33
--	----

Chapitre 4 mises en œuvre de 'PneumoCNNV2.1' & résultats

Tableau 4. 1 Division de la base de données 'pneumonia'	62
--	----

Tableau 4. 2 Résultats de la classification des pneumonies par le modèle VGG16	66
---	----

Tableau 4. 3 Résultats de la classification des pneumonies par le modèle VGG19	68
---	----

Tableau 4. 4 Résultats de la classification des pneumonies par le modèle Resnet50 ...	69
--	----

Tableau 4. 5 Résultats de la classification des pneumonies par le modèle resnet50 (optimisateur RMSprop)	70
--	----

Tableau 4. 6 Comparaison des résultats obtenus entre les différents modèles utilisés	71
---	----

Tableau 4. 7 Comparaison des résultats de la classification avec des travaux connexes	72
---	----

Introduction générale

Situés au sein de la cage thoracique et faisant partie du système respiratoire, le poumon joue un rôle essentiel dans la respiration et, l'oxygénation du sang. De ce fait les maladies touchant l'organe du poumon, représente un pourcentage élevé de la mortalité globale, à travers le monde. Dans ce cadre, la détection et le traitement de cette pathologie, est un sujet majeur pour les experts de la santé.

La pneumonie se définit comme une infection respiratoire aigüe, qui touche directement les poumons, pouvant entraîner des complications jusqu'à causer la mort, plus fréquemment chez les jeunes enfants, ou les personnes âgées. La pneumonie est causée par infection suite à un agent pathogène bactérien, causant douleurs, fièvre, toux...etc. le diagnostic de la pneumonie se fait par plusieurs types d'imagerie tels que : la radiographie des poumons, l'IRM, ainsi que la tomодensitométrie. Cependant ce dernier est un processus lent et difficile, nécessitant des médecins radiologues experts, capables de discerner les pneumonies des autres maladies, affectant les poumons à travers des radiographies du thorax.

Le fondement de cette initiation à la recherche, repose sur la détection de pneumopathies (pneumonies) en utilisant l'intelligence artificielle. Plus précisément, ce mémoire, adopte les techniques du deep learning, permettant d'effectuer un diagnostic, par la détection et la classification automatique des pneumonies. Dans ce cadre, l'objectif de ce projet, est de réaliser un système de classification de pneumologies, suivant différents types d'architectures des réseaux de neurones convolutifs (CNN), afin d'aider les radiologues dans le diagnostic.

Ce mémoire est structuré en quatre chapitres :

Le chapitre 1 présente le contexte médical suivant l'anatomie des poumons, les différentes pathologies pulmonaires, ainsi que les différentes techniques d'imagerie médicale permettant la détection de ces lésions.

Le chapitre 2 introduit le concept de la machine ainsi que du deep learning, afin de décrire les réseaux de neurones existants.

Le chapitre 3 présente les différentes architectures des CNN suivant leurs paramètres et, décrit quelques travaux antérieurs, dans le domaine de l'imagerie pulmonaire.

Le chapitre 4 est consacré à la présentation de l'environnement du travail, du système réalisé, des résultats obtenus, ainsi qu'à la comparaison avec les résultats des travaux du laboratoire LATSI.

Chapitre 1 Contexte Médical

1.1 Introduction

Lors de la mention de l'appareil respiratoire, la première chose qui vient généralement à l'esprit, est le poumon. Le poumon est un organe intrathoracique pair permettant l'échange de gaz vitaux (l'oxygène et le dioxyde de carbone). Au niveau de l'alvéole l'oxygène enrichira le sang et le dioxyde présent dans ce dernier, diminuera. Lors de ces dernières années et suite à plusieurs conséquences parfois écologique ou sanitaire, plusieurs pneumopathies ont fait leur apparition, où les diagnostics relatifs à ces derniers, ont grandement évolués notamment grâce à l'imagerie médicale.

Ce chapitre expose l'anatomie de l'appareil respiratoire et plus précisément l'organe du poumon, les différentes pathologies ainsi que le système d'acquisition (imagerie pulmonaire) tout en le clôturant, par le diagnostic médical.

1.2 Anatomie des poumons et leurs structures

L'organe du poumon (figure 1.1) est un organe pair, ayant une forme de cône avec un sommet convexe pour cause de la cage thoracique qui l'entoure ; bien que dit identiques ces derniers diffèrent sur certains points.

Le poumon droit est constitué de 3 lobes (figure 1.2), une fissure oblique profonde sépare le lobe supérieur du lobe inférieur, une deuxième fissure cette fois horizontale sépare le lobe du milieu, du lobe supérieur.

Il se trouve parfois, que cette dernière est incomplète ou carrément absente, au contraire du poumon gauche qui lui est constitué de deux lobes seulement et est légèrement plus petit, pour cause du cœur qui se trouve à côté.

Les poumons sont aussi divisés par des tissus, vers les segments de la bronche pulmonaire, qui elle sera responsable de l'acheminement de l'oxygène [1].

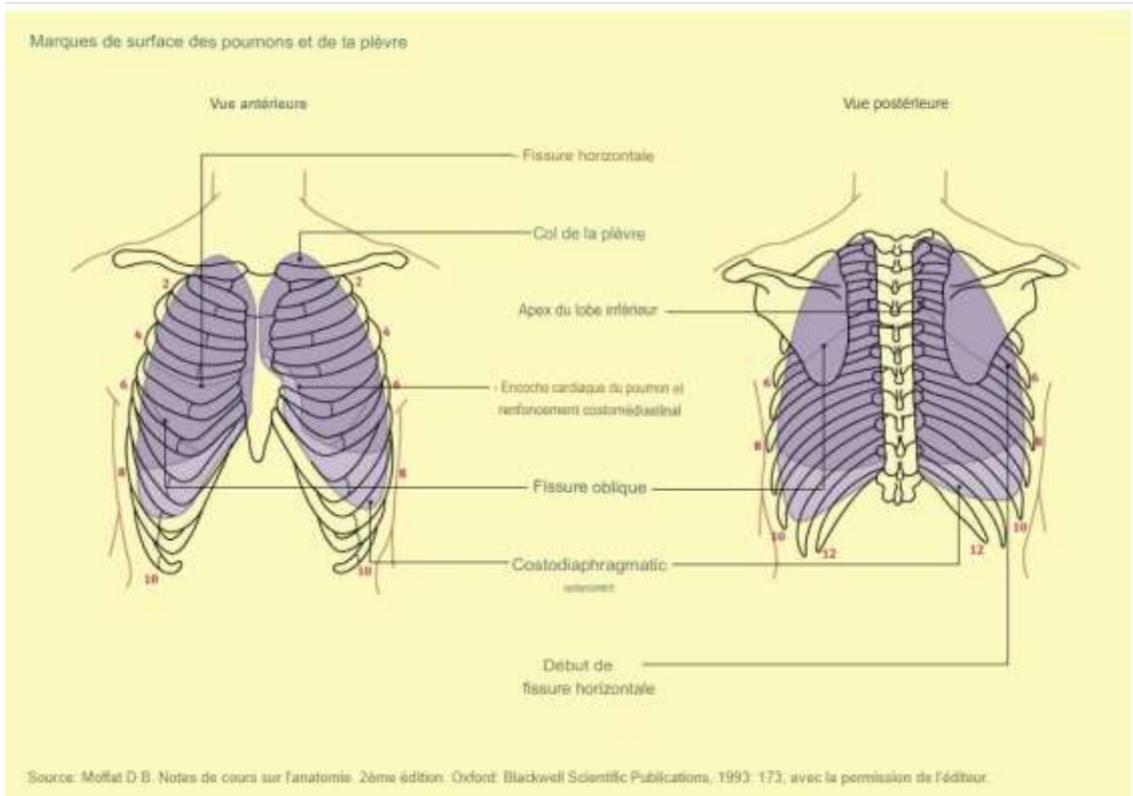


Figure 1. 1 Anatomie des poumons [1]

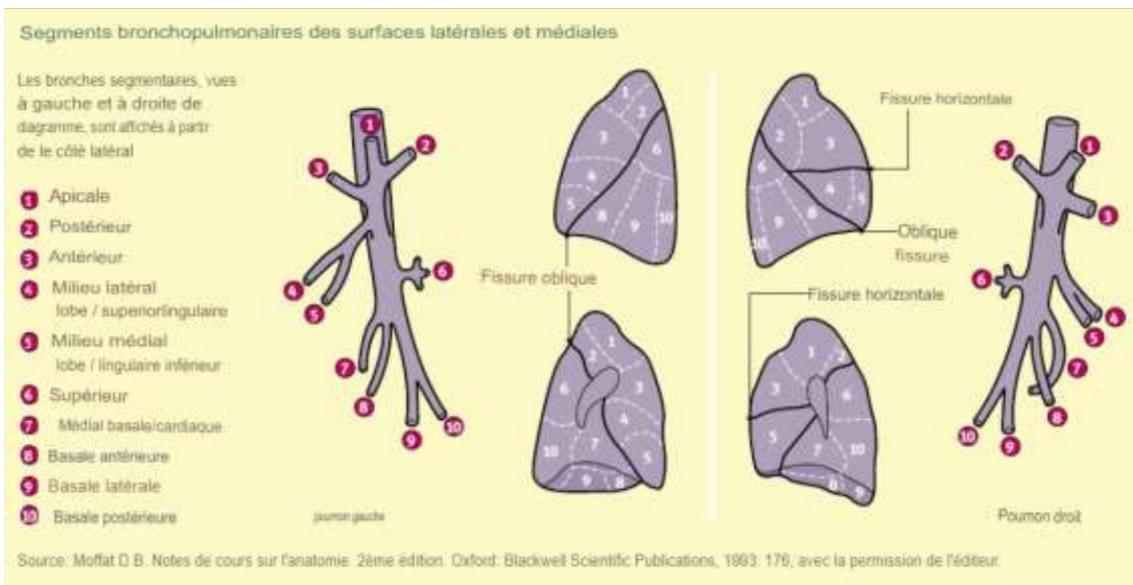


Figure 1. 2 : Structure et composants des poumons [1]

1.3 Pathologies pneumologiques

Comme mentionner plus haut le poumon est relié de très près, à l'appareil respiratoire. De ce fait, les pathologies qui affecteront ce dernier, causeront toutes quasiment des problèmes respiratoires.

1.3.1 Définition d'une pathologie

Il s'agit d'un ensemble des manifestations d'une maladie et des effets morbides, qu'elle entraîne. C'est aussi l'étude des maladies, de leurs causes et de leurs symptômes [2].

1.3.2 Symptômes du pneumothorax

Le pneumothorax est une entrée d'air anormale, au niveau de la cavité pleurale. Sa principale cause, est le tabagisme. Dans ce cas, une poche d'air se forme entre le poumon et la plèvre, laquelle fait pression sur les poumons. Cette bulle d'air se résorbe le plus souvent, spontanément. Mais parfois, la ventilation pulmonaire s'en retrouve affectée et le poumon peut s'affaisser [3].

Le pneumothorax présente divers symptômes :

- Essoufflement.
- Difficulté à respirer.
- Douleur lors de la toux.
- Oppression thoracique.
- Douleur thoracique aigüe.
- Augmentation du rythme cardiaque.
- Fatigue.
- Peau bleutée.

1.3.3 Types de pneumothorax

Il existe de nombreux types de pneumothorax [3]. Nous citons :

- a ***Pneumothorax de petite taille*** : Selon l'American College of Chest Physicians, ce dernier est défini par une distance entre l'apex pulmonaire et la plèvre pariétale, de 3 cm sur la ligne médio-claviculaire.

- b Pneumothorax iatrogène** : ce pneumothorax survient des suites d'une intervention médicale, à visée diagnostique ou thérapeutique.
- c Pneumothorax traumatique** : il s'agit du pneumothorax résultant, d'un traumatisme thoracique direct ou indirect.
- d Pneumothorax spontané** : c'est un pneumothorax survenant en l'absence d'un traumatisme préalable, iatrogène ou non ou d'une cause précipitante.
- e Pneumothorax primaire** : c'est un pneumothorax survenant en l'absence d'une pathologie pulmonaire connue.
- f Pneumothorax secondaire** : c'est un pneumothorax survenant dans le cadre d'une pathologie pulmonaire connue.

1.3.4 Tuberculose

C'est une maladie contagieuse potentiellement mortelle, qui peut toucher n'importe quelle partie du corps, mais elle infecte principalement les poumons (figure 1.3). Elle a pour symptômes ; une toux chronique avec émission de sang, une fièvre intense avec des sueurs nocturnes et une perte de poids. Cette pathologie est dérivée du latin, tubercu qui signifie nodule et, lose qui correspond à condition [4].



Figure 1. 3 :Macroscopie de la tuberculose nodulaire avec beaucoup petits et grands nodules avec nécrose caséuse [4]

Le bacille de Koch (souvent abrégé BK) est la bactérie responsable de la tuberculose. Appartenant au genre des mycobactéries, la souche du complexe de *Mycobacterium tuberculosis*, est découverte par Robert Koch en 1882 [5].

Le complexe *Mycobacterium tuberculosis*, comprend le *Mycotuberculosis*, le *mycobovis*, le *mycoaffricanum*, le *mycomicroti* et le *mycocanetti*. Ces souches bactériennes peuvent provoquer la "tuberculose" (TB) chez l'homme. Les cas de TB sont dus en grande majorité à la bactérie *mycotuberculosis*, les autres organismes étant relativement rares. Leur traitement est similaire [5].

Le complexe Mycotuberculosis se multiplie plus lentement que la majorité des bactéries. C'est pourquoi l'évolution de la TB est plus lente. La maladie se déclare des semaines voire des mois, ou des années après l'infection, que celle de la plupart des autres infections bactériennes.

Le mycotuberculosis est une bactérie aérobique stricte ; elle se multiplie mieux dans les tissus pulmonaires, en particulier au niveau de l'apex, où les concentrations en oxygène sont plus élevées que dans les organes plus profonds.

Ces souches bactériennes représentant un mésophile, dont les dimensions d'environ 0,2 à 0,6 × 2,4 µm³, vit entre 20 et 40 degrés. Il a un temps de génération lent d'environ 15-20 h, quand il contribue à la virulence [5].

a Transmission de la maladie

La transmission se fait essentiellement par voie aérienne, occasionnellement par voie orale ou digestive. La bactérie provoque des lésions qui sont très riches en germes, ce qui permet une dissémination importante de l'agent infectieux par les voies respiratoires, lors des violentes quintes de toux qui accompagnent la maladie dans sa forme pulmonaire. La tuberculose pulmonaire résulte de l'inhalation de particules (« nuclei ») suffisamment petites (égales ou inférieures à 8 microns), pour atteindre les alvéoles. *M. tuberculosis* a la particularité d'être très résistant dans l'air et les poussières, ce qui fait de la tuberculose, une maladie très contagieuse [5].

b Symptômes

Les symptômes les plus communs dus à la tuberculose, sont les suivants :

- Toux persistante ;
- Douleur thoracique ;
- Toux avec des expectorations sanglantes ;
- Essoufflement ;
- Décoloration de l'urine ;
- Urine trouble et rougeâtre.
- Fièvre avec frissons ;
- Fatigue.

c Types de tuberculose

La tuberculose pulmonaire [6], comprend principalement deux types :

- Tuberculose primaire : appelée encore tuberculose d'enfance, la tuberculose pulmonaire se déclare lorsque les mycobactéries, atteignent les alvéoles des poumons. La tuberculose pulmonaire initiale (primaire) est le plus souvent localisée dans les segments supérieurs des lobes pulmonaires inférieurs. La lésion se formant après l'infection, est périphérique et peut ne pas être détectable sur la radiographie.
- Tuberculose secondaire : ce type appelé encore post-primaire ou réinfection, représente le cas pathologique d'une personne qui a déjà été infectée. Une tuberculose réactivée se manifeste généralement, par des lésions cavitaires localisées aux segments supérieurs des lobes inférieurs, ou aux apex pulmonaires (segment apico-dorsal).

d Mesures préventives contre la tuberculose

La prévention de la tuberculose, repose principalement, sur la vaccination par le BCG et sur l'isolement des patients contagieux [6].

1.3.5 Pneumonie

La pneumonie se définit comme une infection respiratoire aiguë, qui touche directement les poumons. Les alvéoles présents dans ces dernières, se retrouvent remplis de pus et de liquide, entraînant des douleurs lors de la respiration et limitant l'absorption d'oxygène [7] [8].

a Causes les plus récurrentes de la pneumonie

Les maladies pneumologiques peuvent être de cause bactérienne ou virale.

- *Streptococcus pneumoniae* : est un agent pathogène, qui est à l'origine de la pneumonie bactérienne chez l'enfant.
- *Haemophilus influenzae* type b (Hib) : est l'une des bactéries les plus courantes causant la pneumonie.
- Syncytial : est la cause la plus fréquente, d'une pneumonie virale.

b Symptômes

Les maladies pneumologiques ont d'énormes symptômes, que nous citons :

- Une fièvre d'emblée importante avec des frissons.
- Une toux sèche.
- Un essoufflement.
- Une douleur thoracique intense.
- Un malaise général.
- Des nausées, des vomissements et des diarrhées.

c Pneumonie précoce avec hémorragie

On classe la pneumonie (figure 1.4) selon les types de germes, qui la provoquent.

- La pneumonie aiguë communautaire : la forme la courante de pneumonie. Son infection survient hors du milieu hospitalier.
- La pneumonie nosocomiale (acquise à l'hôpital). Ce type de pneumonie est souvent due à des micro-organismes résistants aux antibiotiques, couramment utilisés à l'hôpital.

- La pneumonie d'aspiration, qui est due à l'inhalation accidentelle de substances irritantes. Elle est généralement observée chez les personnes, qui ont du mal à avaler.



Figure 1. 4 : Pneumonie précoce avec hémorragie [8]

1.4 Cancer du poumon

Le cancer est l'une des maladies les plus fréquentes et les plus dangereuses, dans le monde, avec un nombre de décès de plus de 1 millions 3 par an [9] [10]. En effet, le cancer est dû à une prolifération anarchique de cellules issues, de notre organisme. Une cellule normale, sous l'effet de différents facteurs dits <carcinogènes>, va accumuler des erreurs dans son code génétique la transformant au final en cellule cancéreuse (figure 1.5).

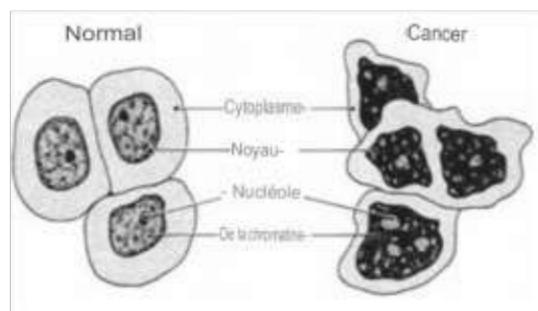


Figure 1. 5 : Différence entre les cellules saines et les cellules cancéreuses [9]

Le cancer du poumon, est extrêmement menaçant, car les cellules cancéreuses issues de la paroi des bronches ou des alvéoles pulmonaires, prolifèrent sans cesse, envahissant les tissus du voisinage.

Ces cellules pénètrent dans les vaisseaux lymphatiques et sanguins, pouvant entraîner une extension de la maladie, se propageant dans toutes les parties du corps (produisant des métastases).

Bien que qu'il soit difficile de déceler le cancer aux premiers abords et aux premiers stades de la maladie, il existe néanmoins certains symptômes qui nous mettent sur la piste.

- Apparition de toux ou majoration de bronchite chronique.
- Une fatigue inhabituelle ou persistante.
- Une infection pulmonaire (bronchite ou pneumonie)
- Un crachat sanglant.
- Une perte de poids.
- Une perte d'appétit.
- Des douleurs importantes aiguës ou chroniques.

Ces derniers sont principalement causés par le tabagisme, l'exposition à la fumée secondaire, l'exposition à des particules cancérogènes présentes dans l'air.

1.4.1 Nodule pulmonaire

Un nodule pulmonaire est une petite région du tissu anormal, sous forme de petit boule, observée dans le poumon. La plupart des nodules pulmonaires, sont très petits (moins de 10 mm de diamètre) et bénins. Mais il se peut que ces derniers soit cancéreux, dépendamment de leurs tailles. En effet, plus le diamètre d'un nodule est grand, plus il aura de chance d'être cancéreux. Les nodules pulmonaires sont divisés en deux catégories selon leurs tailles ; un nodule de moins de 10mm de diamètre, est dit micronodule et sera dans la majorité des cas bénins, alors qu'un nodule de plus de 3cm de diamètre, est dit masse pulmonaire et sera cancéreux (malin) [10] [11].

1.4.2 Type des cancers du poumon

Les cancers bronchiques non à petites cellules (CBNPC) représentent la grande majorité des cancers des poumons, avec un peu plus de 85%. Ils se développent initialement, dans les plus grosses cellules des poumons [11].

Ces cancers se divisent en trois types :

a Adénocarcinome

Apparaissant généralement chez les femmes, les non-fumeurs et chez les plus jeune, il représente environ 40% des cas. Il se développe de façon progressive, sur les parties externes des poumons.

b Carcinome épidermoïde

Souvent provoqué par le tabagisme et représentant 25 à 30% des CBNPC, ce cancer se développe à partir de cellules plates situées, à l'intérieur des voies respiratoires.

- **Carcinome à grandes cellules**

Représentant aux environs de 10% des CBNPC, ce cancer est à croissance rapide qui se développe dans toutes les zones des poumons.

1.4.3 Classification TNM

La classification TNM est la classification internationale, qui permet de déterminer le stade d'un cancer. La lettre 'T', l'initiale de la tumeur, correspond à la taille de la tumeur. La lettre 'N' correspondant au nœud, indique si les ganglions lymphatiques, ont été ou non envahis. La lettre M l'initiale de métastase, correspond à la présence ou non des métrasses.

Les tumeurs (T) prouvant la présence de cellules malignes, sont classées suivant leurs tailles dans plusieurs catégories [12].

- T0 : Absence de tumeur
- T1 : Tumeur de 3 cm ou moins
 - T1a \leq 1cm
 - 1cm > T1b \geq 2cm

- 2cm>T1c>=3cm
- T2 : Les tumeurs supérieures à 3cm et inférieures à 5cm ou qui comportent l'une des spécifications suivantes :
 - Envahissement d'une bronche souche mais sans envahissement de la carène.
 - Envahissement de la plèvre viscérale.
 - Présence d'une atélectasie ou pneumonie.
 - 3cm >T2a<=4cm
 - 4cm >T2b<=5cm
- T3 : Les tumeurs supérieures à 5cm et inférieures à 7cm ou qui envahissent ;
 - La paroi thoracique.
 - Le nerf phrénique.
 - La plèvre pariétale.
- T4 : les tumeurs supérieures à 7cm ou qui envahissent ;
 - Le médiastin.
 - Le cœur.
 - La trachée.
 - Le diaphragme.
 - Le nerf récurrent
- N Adénopathies (l'atteinte des ganglions lymphatiques)
 - N0 : absence de métastase.
 - N1 : métastases ganglionnaires péri-bronchiques homolatérales.
 - N2 : métastases médiastinaux homolatéraux ou dans les ganglions sous-carnaires.
 - N3 : métastases médiastinales controlatérales.
- M Métastase :
 - M0 : absence de métastase à distance.
 - M1 :
 - M1a : nodules tumoraux séparés dans un lobe controlatéral.
 - M1b : une seule métastase extra-thoracique dans un seul organe.

- M1c : plusieurs métastases extra-thoraciques dans un ou plusieurs organes.

1.4.4 Stade du cancer du poumon

Grâce la classification NTM, il est possible de déterminer le stade du cancer. Cette dernière peut être résumée dans le tableau 1.1.

	N0	N1	N2	N3	M1a-b	M1c
T1a	IA-1	IIB	IIIA	IIIB	IV-A	IV-B
T1b	IA-2	IIB	IIIA	IIIB	IV-A	IV-B
T1c	IA-3	IIB	IIIA	IIIB	IV-A	IV-B
T2a	IB	IIB	IIIA	IIIB	IV-A	IV-B
T2b	IIA	IIB	IIIA	IIIB	IV-A	IV-B
T3	IIB	IIIA	IIIB	IIIC	IV-A	IV-B
T4	IIIA	IIIA	IIIB	IIIC	IV-A	IV-B

Tableau 1. 1 : Classification NTM des stades d'un cancer [12]

1.5 Systèmes d'acquisition en imagerie médicale

1.5.1 Introduction à l'imagerie médicale

Apparues, au tournant du XXe siècle, l'imagerie médicale est une discipline à visée tant diagnostique que thérapeutique, regroupant les moyens d'acquisition et de restitution d'images du corps humain, à partir de différents phénomènes physiques.

Cette dernière utilise des techniques qui ont révolutionné la médecine, permettant de visualiser indirectement l'anatomie, la physiologie ou le métabolisme du corps humain, afin d'obtenir des informations sur une éventuelle pathologie. Ce qui joue un rôle important, lors de la prise en charge des patients et de leurs diagnostics [13].

Parmi les techniques et les méthodes de l'imagerie médicale les plus fréquemment utilisées, on cite :

- Les méthodes à base de rayons x (radiographies).
- Les méthodes à base de tomodensitométrie.
- Les méthodes à base de résonance magnétique nucléaire (IRM).

1.5.2 Rayons X

Les rayons X appartiennent au groupe des rayons électromagnétiques. Par conséquent, ils suivent la règle du rayonnement électromagnétique. Ils transportent les rayons électromagnétiques de l'énergie radiante, à travers l'espace par les photons, tout comme les ondes radio, la lumière visible ou les micro-ondes. Ils peuvent être soit représentés par les photons, ou par un modèle d'onde.

Les rayons X se situent dans la gamme de 0.01nm jusqu'à 10nm. En tant que lumière visible, les rayons X perdent une certaine quantité d'énergie, lorsqu'ils passent à travers différents matériaux, générant un certain contraste dans l'image. Par exemple, la radiographie d'une image, montre des intensités élevées pour les tissus mous et des intensités plus faibles, pour les os. Il faut savoir aussi que l'énergie absorbée, est directement liée à la dose, qui est administrée au patient lors d'une acquisition [13].

a Historique

Des radiographies ont été découvertes par Wilhelm Conrad Röntgen à Würzburg, en Allemagne en 1895 [14]. Il cherche à élucider la nature de l'électricité et étudie la lumière fluorescente émise, lors du passage d'un courant électrique dans une ampoule contenant un gaz à basse pression (tube de Crookes). Dans une expérience réalisée en chambre noire, Röntgen observe un phénomène de fluorescence de la plaque photographique à distance du tube de Crookes, alors même que celui-ci est recouvert de carton noir. Il observe aussi que ce phénomène persiste, s'il interpose des objets entre le tube et la plaque : quand une main vivante est interposée, son squelette devient visible (figure 1.6). Röntgen en déduit qu'un rayonnement invisible d'origine inconnue est émis et lui donne le nom de rayons X (dénomination d'une inconnue en mathématiques).

Elle représente la main de Mme Röntgen où nous pouvons clairement voir la bague, qu'elle portait sur son doigt annulaire. Aujourd'hui, les rayons X sont couramment utilisés dans l'imagerie médicale.



Figure 1. 6 : Main de Rontgen [14]

➤ **Avantage**

L'imagerie par rayons X est très utile pour examiner les os et d'autres tissus durs, comme les calculs biliaires.

➤ **Risque**

Les rayonnements sont capables de léser l'ADN et peuvent en conséquence potentiellement, contribuer au développement d'une pathologie comme un cancer.

1.5.3 Systèmes de détection moderne

a Intensificateur d'images à rayons X

La fonction globale d'un intensificateur d'image, est de convertir les photons de rayons X incidents en photons lumineux, d'une intensité suffisante pour fournir une image visible. Le principe schématique de ce processus est montré dans la figure 1.7.

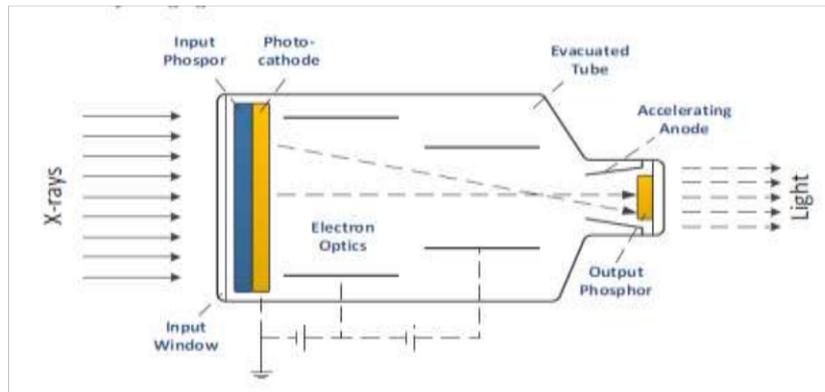


Figure 1. 6 : Processus de conversion de rayons X en lumière visible [15]

La première étape de ce processus, est la conversion des photons de rayons X, en photons lumineux par le phosphore d'entrée. L'iodure de césium activé par le sodium, est généralement utilisé en raison de son efficacité de conversion élevée, grâce à son numéro atomique et son coefficient d'atténuation de masse élevé. Les photons lumineux sont ensuite convertis en électrons, par une photocathode. Une différence de potentiel (25-35 kilovolts) créée entre l'anode et la photocathode, accélère alors ces photoélectrons tandis que les lentilles électroniques, focalisent le faisceau jusqu'à la taille de la fenêtre de sortie.

Cette dernière étant généralement constituée de sulfure de zinc-cadmium activé par l'argent, reconvertit les électrons incidents en photons de lumière visible. Aux luminophores d'entrée et de sortie, le nombre de photons est multiplié par plusieurs milliers, de sorte que globalement il y a un grand gain de luminosité [15].

b Radiographie pulmonaire

La radiographie pulmonaire (figure 1.8) est un examen qui permet de visualiser les poumons, la trachée, les bronches et la plèvre (feuillet qui entoure le poumon). Elle a pour but de détecter une infection, une inflammation, un cancer, une pleurésie ou encore un pneumothorax [16].



[16]

Figure 1. 7 : Appareil de radiographie pulmonaire

Son principe consiste à impressionner sur un film radiographique, les différences de densité du poumon. Le film sera plus ou moins noirci, selon les structures rencontrées. Les os apparaîtront blancs, les tissus mous seront dans différents tons de gris et l'air sera noir. La figure 1.9 présente le cas d'une image radiographique des poumons, illustrant un pneumothrax.



Figure 1. 8 : Image radiographique des poumons [16]

c Tomodensitométrie

La tomodensitométrie (TDM) utilise des radiations ionisantes, pour générer des images en émettant des rayons X à partir d'une source propageant un faisceau ouvert en éventail, qui tourne autour du patient (figure 1.10). Après son passage dans le patient, le faisceau atteint une couronne de détecteurs de rayons X, qui enregistre une valeur du degré d'atténuation du faisceau de rayons X, appelée unité Hounsfield. Ces valeurs reflètent la densité du tissu, dans de minuscules volumes d'espace du patient nommés voxels, qui sont alors objectivés dans l'image résultante (scan) [17].



Figure 1. 9 : Appareil de tomodensitométrie [17]

Des modèles informatiques sont utilisés pour attribuer une échelle de gris, aux voxels individuels et construire une image bidimensionnelle (2D), en coupe. Les voxels contiennent une information tridimensionnelle (3D) pouvant être reconstruits, dans une image dans le plan orthogonal désiré (reformatages multi planaires).

➤ Avantages

- La TDM produit des images en 2D et 3D et, fournit une évaluation rapide de l'os et des parties molles.
- C'est la modalité de choix pour la majorité des pathologies abdominales et thoraciques, aussi bien que pour le cerveau dans le bilan des traumatismes crâniens et des accidents vasculaires cérébraux.
- Elle fournit une excellente évaluation en 3D de l'os dans le bilan des traumatismes.

- Comme alternative à l'IRM, elle peut être combinée avec l'arthrographie, pour évaluer les troubles intra-articulaires des articulations.
- Désavantages
 - La TDM peut être gênée par les artéfacts du mouvement du patient. Du fait que certains examens TDM servent de référence, il est important que le patient soit capable d'être couché, immobile et de retenir sa respiration.
- Le contraste des parties molles en TDM est inférieur à celui en IRM et en échographie. La TDM a dès lors, une valeur limitée dans l'évaluation des maladies des parties molles et dans l'imagerie de la moelle osseuse.
- Risques
 - Le scanner implique une exposition aux rayons X. La dose efficace de radiation pour cette procédure, est d'environ 10 mSv, ce qui correspond à ce qu'une personne reçoit en moyenne, par le rayonnement naturel en trois ans.
 - Les femmes doivent toujours informer leur médecin ou leur manipulateur, si elles croient être enceintes.
 - Le risque de réaction allergique grave à un agent de contraste contenant de l'iode existe, mais est très faible.

1.5.4 Diagnostic médical

En médecine, le diagnostic est la démarche par laquelle divers praticiens du corps médical, déterminent l'affection dont souffre le patient, afin de proposer un traitement. La façon la plus efficace d'effectuer un diagnostic, est d'établir un tableau clinique. Ce dernier représente la liste la plus précise des caractéristiques et, des symptômes observables [13].

De manière générale, un diagnostic classique se déroule en deux parties :

- Anamnèse : elle permet d'en apprendre plus sur le patient, ses antécédents, les symptômes actuels, l'évolution de la maladie et les traitements déjà pris.

- Examen physique : suivant l'anamnèse et l'état du patient, l'examen physique est un examen permettant de rechercher des signes physiques, pour appuyer et assurer le diagnostic.

Le diagnostic du pneumothorax est suspecté chez les patients stables, qui présentent une dyspnée ou une douleur thoracique pleurétique en étant confirmé, par une radiographie du thorax debout en inspiration. La présence d'air radio-transparent et l'absence des marques du poumon juxtaposées, entre un lobe ou un poumon condensé et la plèvre pariétale, représentent un pneumothorax. Une déviation de la trachée et un refoulement médiastinal, peuvent se produire en cas de grands pneumothorax.

1.5.5 Introduction au diagnostic par les systèmes informatiques

Depuis quelques années une nouvelle technique a vu le jour dans le domaine médical et plus précisément, lors du diagnostic d'un patient. Pour aider les médecins, et pour leur faciliter la tâche lors d'un diagnostic, il est de bon sens d'utiliser un système informatique automatisé d'aide à la décision. Ce dernier comme son nom l'indique permet d'effectuer un diagnostic préliminaire automatiquement. Il se repose sur le concept du « l'apprentissage automatique ou profond » qui permet grâce à une base de données médicales, d'apprendre à détecter la présence d'anomalies de façon automatique. Plus de détails sur ce sujet, seront vus dans le prochain chapitre.

1.6 Conclusion

L'appareil respiratoire et plus précisément le poumon, a une importance primordiale chez l'homme car il est responsable de sa survie. De ce fait les maladies qui touchent cet organe, sont prises très au sérieux. Dans ce chapitre, nous avons donc pu observer l'anatomie du poumon ainsi que ses pathologies, les moyens de les détecter suivant, l'imagerie médicale, afin que le médecin établisse un diagnostic.

Le prochain chapitre abordera le concept du deep learning, ainsi que les différentes opérations réalisées par les réseaux de neurones convolutifs.

Chapitre 2 Notions d'apprentissage automatique et profond

2.1 Introduction

Depuis quelques années maintenant, l'importance de l'imagerie médicale, ne cesse d'augmenter du fait de l'importance de la classification des données médicales, qui permettent d'aider grandement le médecin, lors de l'élaboration du diagnostic. Cette classification, se base sur le concept de l'apprentissage automatique et profond.

Ce chapitre abordera le concept de l'apprentissage automatique (machine learning) et profond (deep learning). L'étude faite, introduira les réseaux de neurones de manière générale puis de manière plus spécifique, avec les différents types des réseaux convolutifs.

2.2 Introduction à l'apprentissage automatique

L'apprentissage automatique (machine learning) est une branche de l'intelligence artificielle, qui englobe de nombreuses méthodes, permettant de créer automatiquement des modèles, à partir des données. Ces méthodes sont en fait des algorithmes très efficaces, dans les situations où les insights, doivent être mises en avant, à partir de larges ensembles de données diverses et changeantes : le Big Data. Pour l'analyse de telles données, il se révèle nettement plus efficace que les méthodes traditionnelles, en termes de précision et de vitesse.

Un programme informatique traditionnel effectue une tâche, en suivant des instructions précises et donc, systématiquement de la même façon. Au contraire, un système basé sur l'apprentissage automatique, ne suit pas d'instructions, mais apprend à partir de l'expérience. Par conséquent, ses performances s'améliorent au fil de son " apprentissage " à mesure que, l'algorithme est exposé à davantage de données. Parmi les principaux types d'apprentissage automatique, nous citons : le supervisé et le non supervisé [18].

- L'algorithme d'apprentissage supervisé englobe les données déjà " étiquetées ". Par conséquent, le modèle du classifieur adopté, sait déjà ce qu'il doit chercher dans ces données. À la fin de l'apprentissage, le modèle ainsi entraîné sera capable de retrouver les mêmes éléments, sur des données non étiquetées. Ce dernier se compose de deux algorithmes, celui de la classification (prédiction non-numérique) et celui de la régression (prédiction numérique).
- L'algorithme de l'apprentissage non supervisé, au contraire, consiste à entraîner le modèle, sur des données sans étiquettes. La machine parcourt les données sans aucun indice et, tente d'y découvrir des motifs ou des tendances récurrentes. Cette approche est couramment utilisée dans le domaine de la cyber sécurité.

Aujourd'hui, le machine learning (ML) a rendu possible les concepts de voitures intelligentes, de reconnaissance automatique de la parole et de recherche internet efficace. Google est l'un des acteurs technologiques, ayant travaillé sans relâche pour faire du ML, une réalité. Cette réalité consiste à « enseigner » aux ordinateurs, comment apprendre comme l'homme, pour progresser vers ce que certains considèrent comme étant la prochaine révolution technologique, à savoir des machines qui pensent comme des êtres humains [18]. Les techniques du ML sont largement utilisées dans les secteurs de la finance, pour lutter contre la fraude, de l'industrie, de la robotique et de la santé, pour détecter des anomalies ou des maladies, le cas de notre étude.

2.3 Apprentissage profond

L'apprentissage profond (Deep Learning) est une méthode spécifique du machine learning, qui intègre des réseaux neuronaux en couches successives, afin d'apprendre des données de manière itérative [19]. En effet, les réseaux neuronaux complexes du deep learning, sont conçus pour émuler le fonctionnement du cerveau humain, de sorte que les ordinateurs peuvent être entraînés, pour faire face à des abstractions et des problèmes complexes, comme dans la médecine, pour la détection d'anomalies pulmonaires ou, de tumeurs.

Ceci est réalisé, en effectuant plusieurs opérations comme : la segmentation, la détection et la classification des données. Dans ce cadre, le deep learning est particulièrement nécessaire, lorsqu'il est exploité dans le domaine de l'imagerie médicale.

2.3.1 Historique

L'apprentissage profond a connu une grande évolution, depuis le siècle passé, jusqu'à aujourd'hui, avec les challenges organisés, pour la classification de données dans plusieurs domaines.

Le tableau 2.1 :résume l'évolution du deep learning jusqu'à l'année 2019 [19] [20].

Année	Fondateur	Apport
300 AC	Aristote	Introduction de l'associationnisme, début de l'histoire des humains qui essayent de comprendre le cerveau.
1873	Alexander Bain	Introduction du Neural Grouping comme les premiers modèles de réseaux de neurones.
1943	McCulloch and Pitts	Introduction du McCulloch–Pitts (MCP) modèle considéré comme l'ancêtre des réseaux de neurones artificielles.
1949	Donald Hebb	Considéré comme le père des réseaux de neurones, l'auteur cité introduit la règle d'apprentissage de Hebb, qui servira de fondation pour les réseaux de neurones modernes.
1958	Frank Rosenblatt	Introduction du premier perceptron.
1974	Paul Werbos	Introduction de la rétro propagation.
1980	Teuvo Kohonen	Introduction des cartes auto organisatrices.

1998	Kunihiko Fukushima	Introduction du Neocognitron, qui a inspiré les réseaux de neurones convolutifs.
1982	John Hopfield	Introduction des réseaux de Hopfield.
1985	Hilton and Sejnowski	Introduction des machines de Boltzmann
1986	Paul Smolensky	Introduction de 'Harmonium', qui sera connu plus tard, comme les machines de Boltzmann restreintes.
1986	Michael I. Jordan	Définition et introduction des réseaux de neurones récurrents.
1990	Yann LeCun	Introduction de LeNet qui montra la capacité des réseaux de neurones profonds.
1997	Schuster and Paliwal	Introduction des réseaux de neurones récurrent bidirectionnelles
1997	Hochreiter and Schmidhuber	Introduction de LSTM, qui ont résolu le problème du vanishing gradient dans les réseaux de neurones récurrents.
2006	Geoffrey Hinton	Introduction du 'Deep belief Network'
2009	Salakhutdinov and Hinton	Introduction des Deep Boltzmann Machines.
2012	Alex Krizhevsky	Introduction de AlexNet qui remporta le challenge fac à ImageNet avec une précision de 84%.
2016	Demis Hassabis, Shane Legg, et Mustafa Suleyman	Le modèle d'apprentissage par renforcement profond de 'Deep mind' bat le champion humain, dans le jeu complexe de Go. Le jeu est beaucoup plus complexe que les

		échecs, donc cet exploit capture l'imagination de tout le monde et porte la promesse de l'apprentissage profond à un tout autre niveau.
2019	Yoshua Bengio, Geoffrey Hinton et Yann LeCun	Les auteurs cités, remportent le prix Turing 2018 pour leur immense contribution aux progrès dans le domaine de l'apprentissage profond et de l'intelligence artificielle. C'est un moment décisif pour ceux qui avaient travaillé sans relâche sur les réseaux de neurones lorsque toute la communauté de l'apprentissage automatique s'en était éloignée dans les années 1970.

Tableau 2. 1 : résumé l'évolution du deep learning jusqu'à l'année 2019 [20]

2.3.2 Principe du deep learning

Le modèle du deep learning doit être entraîné à l'aide d'un grand nombre d'images, pour réaliser des systèmes précis. Prenons l'exemple d'une base de données, représentant des chiens. Ce type de réseau neuronal tire son apprentissage des pixels contenus, dans les images reçues. Il peut classer des groupes de pixels, en fonction des caractéristiques du chien ; telles que les griffes, les oreilles et les yeux, indiquant la présence de l'animal dans l'image. Ces caractéristiques, sont déterminées dans ce cas, à partir d'une suite d'opérations de convolution [19].

2.4 Réseaux de neurones classiques

Ils sont conçus à l'origine, dans le but de modéliser mathématiquement, le traitement de l'information par les réseaux de neurones biologiques, à l'aide d'un paradigme biologique [21].

Le principe n'est rien d'autre, qu'une façon de construire des modèles paramétriques. Ceci signifie que la fonction de décision, est explicite contrairement aux autres algorithmes. Ce qui explique que de nos jours, leur réalisme biologique, importe peu et c'est leur efficacité à modéliser des relations complexes et non linéaires, qui fait leur succès [22].

Le système de neurones doté de la capacité d'apprendre par expérience, est optimisé par les méthodes d'apprentissage. En effet, ces approches s'associent avec un système de décision intégré, qui se caractérise par le nombre de cas d'apprentissage rencontrés. La capacité de classification et de généralisation des réseaux de neurones, permet leur utilisation dans des problèmes de nature statistique, comme par exemple, lors de la classification d'images radiographiques.

2.4.1 Neurone biologique

Avant d'étudier les réseaux de neurones convolutifs, il est judicieux de comprendre les réseaux de neurones basiques, en prenant en compte la relation naissant du neurone biologique (figure 2.1).

Notre cerveau est composé d'environ 10 milliards de neurones, chacun d'eux connecté, à environ 10000 d'autres neurones. Le corps cellulaire du neurone est appelé le péricaryon (ou soma), où les entrées (dendrites) et les sorties (axones) le relient à d'autres soma [21].

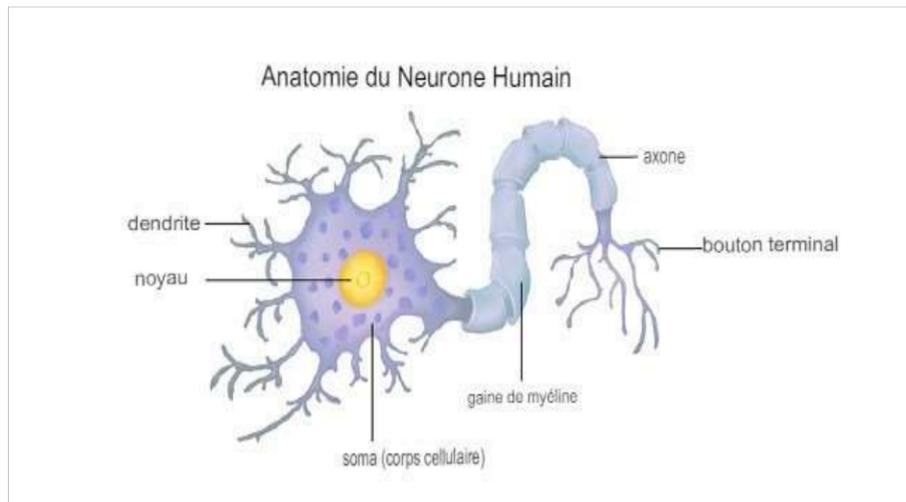


Figure 2. 1 : Structure d'un neurone biologique [21]

Les neurones sont connectés à d'autres neurones, par leurs dendrites. Chaque neurone reçoit des entrées électrochimiques, d'autres neurones à leurs dendrites. Si les entrées électriques sont suffisamment puissantes, le neurone sera activé, puis transmet le signal le long de son axone, en le transmettant aux dendrites d'autres neurones. Ces neurones attachés peuvent également se déclencher, poursuivant ainsi le processus de transmission du message.

La clé à retenir ici est qu'un neurone impulsionnel, est une opération binaire. En effet, le neurone peut soit déclencher une impulsion ou pas. Il n'y a pas de « grades » de déclenchements différents. En termes simples, un neurone ne fera que se déclencher si le signal total reçu au niveau du soma, dépasse un seuil donné.

Cependant, il ne faut pas oublier que les réseaux de neurones artificiels, sont simplement inspirés par le cerveau humain. L'objectif de l'apprentissage profond, n'est pas d'imiter le fonctionnement de notre cerveau, mais plutôt de prendre des pièces que nous comprenons et nous permettons de faire des parallèles similaires dans notre propre travail.

2.4.2 Neurone artificiel

Commençons par jeter un coup d'œil sur un réseau de neurones de base (figure 2.3), qui effectue une simple somme pondérée des entrées. Les valeurs x_1 , x_2 et x_3 sont les entrées de notre réseau de neurones [22].

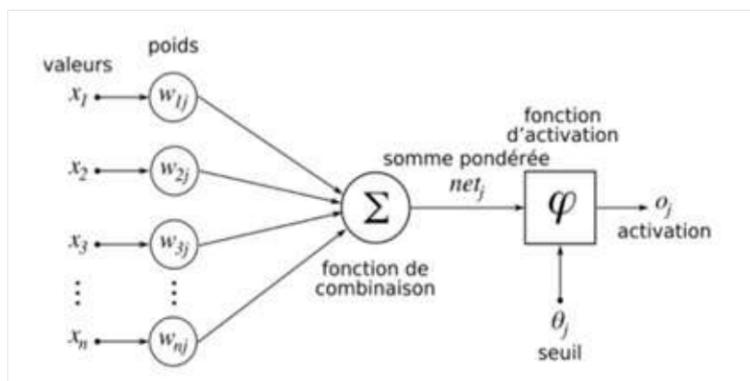


Figure 2. 2 : Simple réseau de neurones [22]

Au niveau du neurone, si la somme des impulsions dépasse un certain seuil, l'influx électrique reçu est transformé, dans le corps du neurone, en une nouvelle impulsion électrique, que l'on peut modéliser comme un 1 ou un 0 (activation ou non activation). Cette activation est ensuite transmise par l'axone, aux neurones connectés à celui-ci [22].

On construit, en calquant sur cette modélisation, un neurone formel où :

- les **entrées** x du neurone, se présentent comme un vecteur de dimension N .
- Un ensemble de poids W , modélisent les poids variables des différentes entrées. W est un vecteur de dimension N également. Chaque entrée x est connectée à un neurone, via un vecteur de poids W constitué de w_1 , w_2 jusqu'à w_n . Ce qui signifie que pour chaque entrée x , un poids lui est associé.
- Un **biais** b représente le seuil d'activation du neurone.
- La somme à des N "impulsions électriques" reçues est donc obtenue, par l'équation 2.1.

$$a = \sum_{i=0}^N W_i x_i + b \quad 2.1$$

Une fonction d'activation, rendant compte de l'influx électrique de sortie, est appliquée à la somme des entrées pondérées par les poids W et le biais b . Le nœud de sortie, génère une valeur correspondant au nœud de sortie déclenché.

Cette association neuronale s'exprime mathématiquement, suivant la fonction 2.2.

$$f(w_1x_1 + w_2x_2 + \dots + w_nx_n + b) \quad 2.2$$

Quelle que soit la valeur de la sortie exprimée, il faut prendre en considération simplement la somme pondérée des entrées, suivie de l'application d'une fonction d'activation f .

a Fonction d'activation step

La fonction d'activation la plus simple est la « fonction pas à pas », utilisée par l'algorithme du perceptron.

$$f(net) = \begin{cases} 1 & \text{si } net > 0 \\ 0 & \text{si non} \end{cases} \quad 2.3$$

$$\text{où } net = \sum_{i=1}^n w_i x_i$$

Comme nous pouvons le voir dans l'équation ci-dessus, il s'agit d'une fonction de pas à pas, très simple. Si la somme $\sum_{i=1}^n w_i x_i > 0$ on met un 1, sinon elle est mise à 0. Ainsi cette fonction, ressemble à un escalier.

b Fonction sigmoïde

La fonction d'activation la plus utilisée dans l'histoire de la littérature des réseaux de neurones, est la sigmoïde (2.4).

$$s(t) = 1/(1+e^{-t}) \quad 2.4$$

$$\text{où } t = \sum_{i=1}^n w_i x_i$$

Elle est le meilleur choix pour l'apprentissage que la fonction step car elle :

1. est continu et différentiable partout.
2. Est symétrique autour de l'axe des y.

3. S'approche asymptotiquement de ses valeurs de saturation.

Le principal avantage ici est que la fonction sigmoïde facilite la tâche de concevoir des algorithmes d'apprentissage. Cependant, il y a deux inconvénients avec la sigmoïde :

1. Les sorties de la fonction sigmoïde ne sont pas centrées sur zéro.
2. Les neurones saturés négligent essentiellement le gradient, car le delta du gradient sera extrêmement petit.

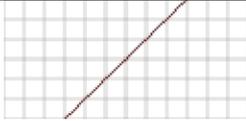
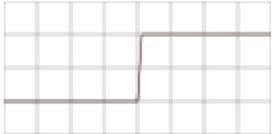
c **Fonction ReLU**

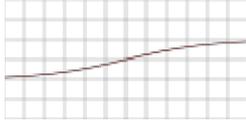
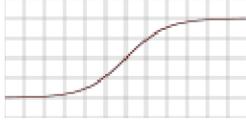
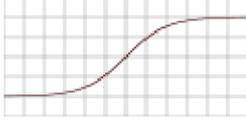
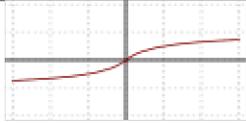
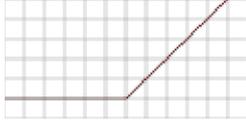
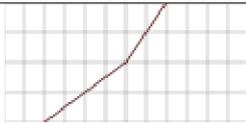
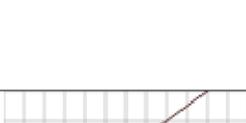
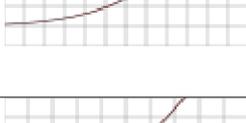
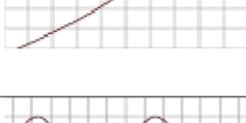
La fonction ReLU (non-linear activation function) est également appelée « fonction de rampe », en raison de son apparence lorsqu'elle est tracée. La fonction est nulle (2.5) pour les entrées négatives, mais augmente ensuite linéairement pour les entrées positives. La fonction ReLU n'est pas saturable et est également extrêmement efficace, sur le plan informatique.

$$f(x) = \max(0, x)$$

2.5

Il existe d'autres fonctions d'activation, mentionnées dans le tableau 2.2.

Nom	Equation	Graphe
Identite / Rampe --	$f(x)=x$	
Marche / Heaviside	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$	

Sigmoïde (Logistique)	$F(x) = 1/(1+e^{-t})$	
Tangente Hyperbolique	$F(x) = \tanh(x) = 2/(2e^{-2t}) - 1$	
Arc Tangente	$f(x) = \tan^{-1}(x)$	
Signe doux	$F(x) = x/(1+ x)$	
Unite de Rectification Lineaire (ReLU)	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$	
Unite de Rectification Lineaire Parametrique (PreLu)	$f(x) = \begin{cases} ax & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$	
Unite Exponentielle Lineaire(ELU)	$f(x) = \begin{cases} a(e^x - x) & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$	
Unite de Rectification Lineaire Douce (SoftPlus)	$F(x) = \ln(1+e^x)$	
Identite courbee	$F(x) = (\sqrt{x^2 + 1} - 1)/(2) + x$	
Sinusoïde	$F(x) = \sin(x)$	

2.5 Architectures des réseaux de neurones

L'architecture des réseaux de neurones (figure 2.3) varie selon l'objet, la complexité et la méthode de traitement des données [22, 23][24, 25, 26]. De ce fait, il existe plusieurs types d'architectures pouvant être divisées en 4 familles :

2.5.1 Réseaux de neurones feed forwarded

Ce type de RN fait que la donnée, traverse le réseau d'entrée à la sortie, sans feed back. Ce dernier peut être résumé en deux catégories :

- Le réseau monocouche ou perception simple (figure 2.3). Celui-ci possède seulement deux couches (entrée/sortie). Ce réseau ne dispose que d'une matrice de poids, ce qui limite ce dernier, à un classificateur linéaire (deux catégories distinguées).

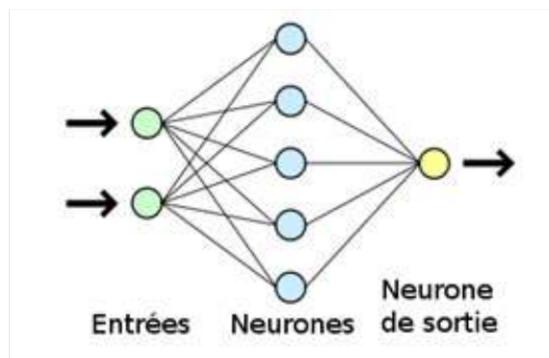


Figure 2. 3 : Architecture d'un réseau neuronal monocouche [22]

- Les réseaux multicouches (figure 2.4) dans la structure est la même que celle du monocouche, à la seule exception que ce réseau, possède une 3ème couche dite « cachée », ce qui en fait un réseau plus adapté, lors de la classification non-linéaire.

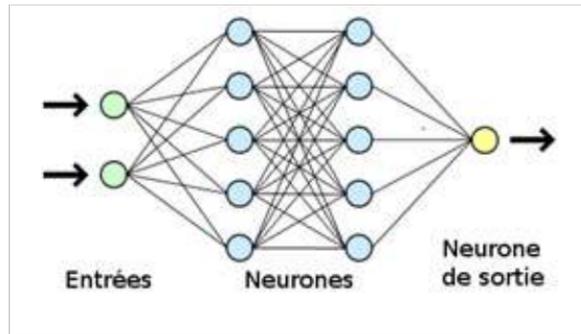


Figure 2. 4 : Architecture d'un réseau multicouches [22]

2.5.2 Réseaux de neurones récurrents (RNN)

Contrairement à un réseau de neurones acyclique (Feed-Forward Neural Network, FFNN), un réseau de neurones récurrent (Recurrent Neural Network), est un réseau de neurones dont le graphe de connexion contient au moins un cycle.

Ces réseaux de neurones permettent aux prédictions antérieures, d'être utilisées comme entrées, par le biais d'états cachés (en anglais *hidden states*).

Ces modèles étaient souvent plébiscités notamment pour le traitement automatique de la parole et plus généralement de séquences, car leurs caractéristiques leur permettent d'apprendre, de stocker et de prendre en compte l'information contextuelle passée lors de traitement de l'information à l'instant présent [24].

2.5.3 Réseaux de neurones à résonance

Dans ce type de réseaux, l'activation de tous les neurones est renvoyée à tous les autres, ce qui provoque des oscillations au sein du système (figure 2.5).

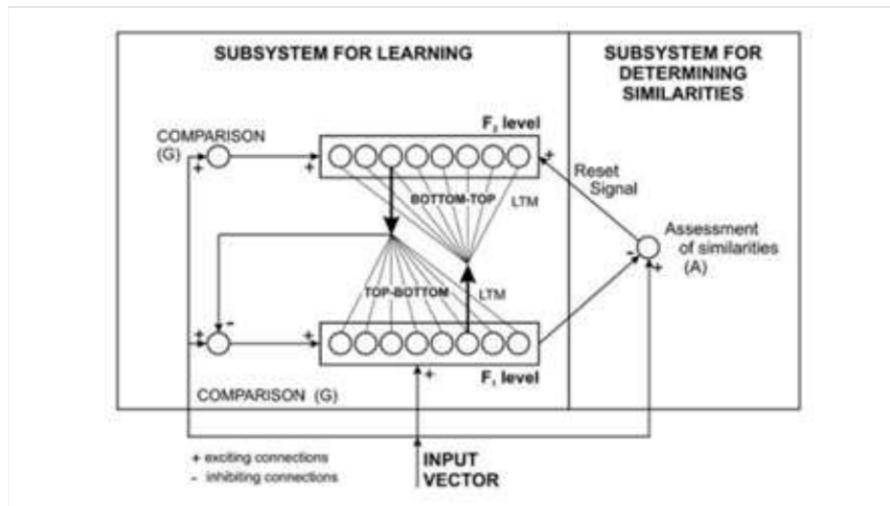


Figure 2. 5 : Réseaux de neurones à résonance [23]

2.5.4 Réseaux de neurones auto-organisés

Inspirés de l'organisation du cortex, les réseaux auto-organisés, se distinguent par une connectivité locale. Ils sont surtout adaptés pour le traitement d'informations spatiales. Le modèle le plus connu de ce type, est la carte auto-organisatrice de Kohonen appelée aussi carte auto-adaptative ou SOM pour *self organizing map*.

Ces réseaux utilisent des méthodes d'apprentissage non-supervisé. Ils peuvent être utilisés pour cartographier un espace réel, ou encore étudier la répartition de données dans un espace de grandes dimensions, comme dans le cas de clusterisation ou de classification [23].

2.5.5 Apprentissage

L'apprentissage peut se résumer en deux mots : mémorisation et généralisation.

La mémorisation est pour l'assimilation des données, sous forme dense.

La généralisation, est réalisée pour sa capacité de traiter des données différentes, mais pourtant similaires.

Dans le cas des réseaux de neurones, l'apprentissage est une étape de développement qui permet de modifier le modèle, afin d'obtenir un comportement souhaité [23][26].

a Apprentissage supervisé

L'apprentissage le plus populaire dans le cas de la machine et du deep learning (figure 2.6). Les données d'entrée de ce processus, sont déjà catégorisées (étiquetées). Par conséquent, les algorithmes doivent s'en servir pour prédire un résultat, après un entraînement des exemples.

L'apprentissage neuronal fait appel à des exemples de comportement. Durant cette phase les poids synaptiques seront modifiés, donc d'une manière plus simple. On peut alors dire, que l'apprentissage est une action de mise à jour des poids des connexions, dans le but d'atteindre la sortie du réseau suivant les exemples étudiés [26].

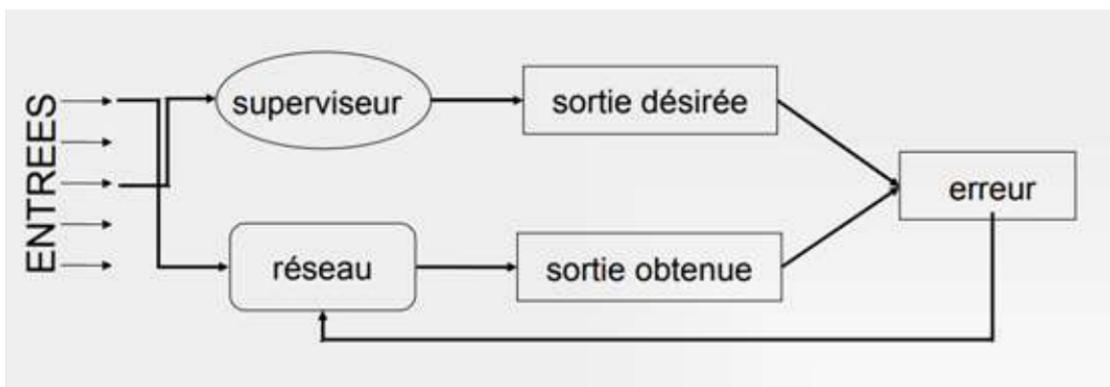


Figure 2. 6 : Apprentissage supervisé[26]

b Apprentissage non supervisé

L'apprentissage supervisé opère à partir de données non annotées. L'apprentissage repose alors sur un « critère interne » de conformité du comportement du réseau, par rapport à des spécifications générales et non sur des observations [23][26].

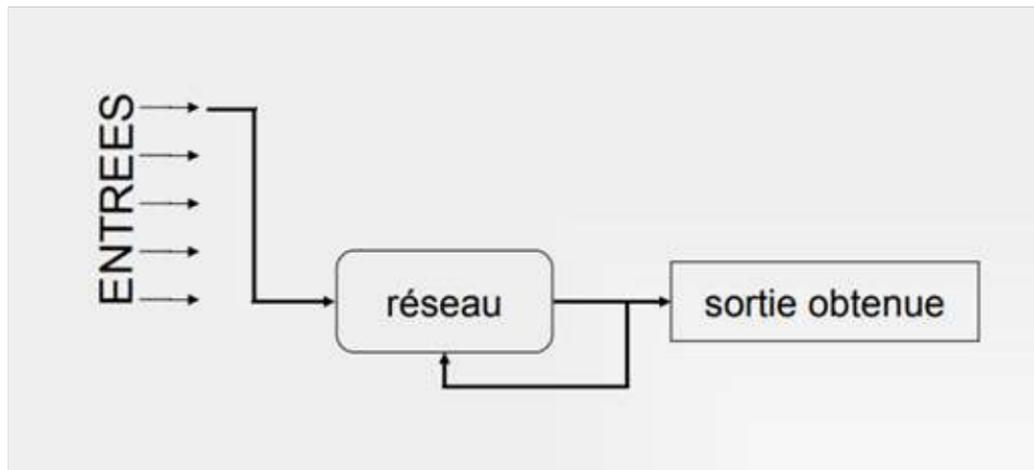


Figure 2. 7 : Apprentissage non supervisé [26]

2.6 Réseaux de neurones convolutifs

Les réseaux convolutifs (figure 2.8) (CNN, 'Convolutional Neural Network'), sont une forme particulière des réseaux neuronaux multicouches, dont l'architecture des connexions, est inspirée des mécanismes visuels des organismes vivants, spécialement conçus pour le traitement des images [27, 28, 29].

Ce type de réseaux est une puissante application de l'intelligence artificielle (IA) qui s'appuie sur l'apprentissage profond, pour effectuer des tâches descriptives et génératives.

Le modèle utilisé par les CNN, est comparable aux perceptrons multicouches. Cependant, son principal objectif, est de réduire la quantité de calcul. On distingue dans ce cadre, deux parties ; la première est la partie convolutive du modèle. Elle fonctionne comme un extracteur de caractéristiques des images et, la seconde est la classification du modèle constituée d'autres couches, dont les couches entièrement connectées [25]..

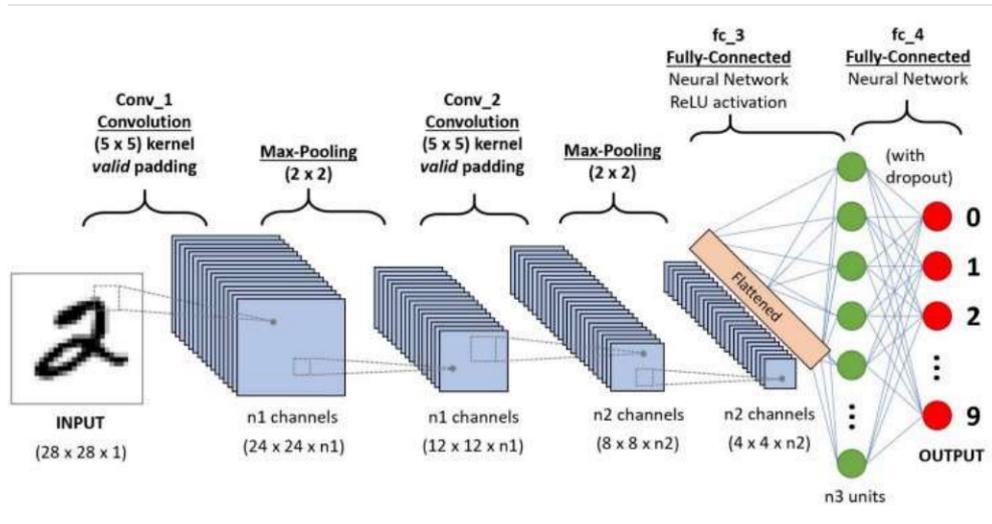


Figure 2. 8 : Réseau de neurones convolutif [29]

2.6.1 Couche de convolution

La première couche (figure 2.9) et la composante clé des réseaux de neurones convolutifs, elle est responsable de la détection de la présence d'un ensemble de caractéristiques dans les images reçues en entrée, grâce à un filtrage par convolution. Pour chaque paire, une carte de descripteurs (features map) est obtenue indiquant les différentes caractéristiques de l'image. Ainsi, plus la valeur est élevée, plus l'emplacement indiqué dans l'image, se conforme à la caractéristique pertinente [27].

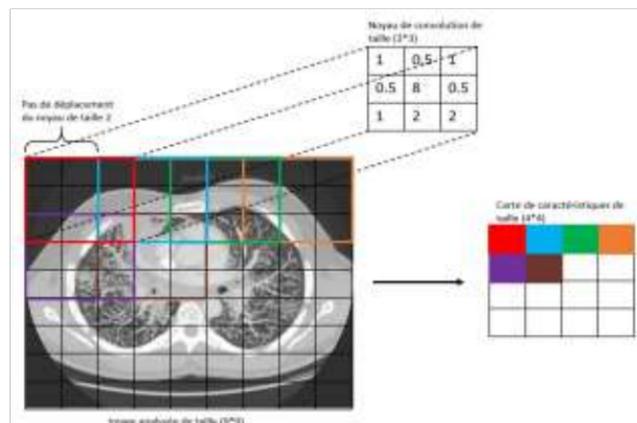


Figure 2. 9 : Couche convolutive [28]

Trois hyperparamètres déterminent le volume de la couche de convolution :

- ❖ La profondeur de la couche « K (nombre de noyaux de convolution) » ;
- ❖ Le pas « S » contrôle le chevauchement des descripteurs ;
- ❖ Le zero padding « P » : permet de contrôler la dimension spatiale du volume de sortie.

2.6.2 Couche de pooling

Souvent placé entre deux couches convolutionnelles (figure 2.10), la couche de pooling reçoit en entrée plusieurs cartes de caractéristiques et applique à chacune d'elles, l'opération de pooling. Cette dernière consiste à réduire la taille des images, mais en préservant leurs caractéristiques. Pour cela, l'image est découpée en cellules régulières, en gardant dans chaque cellule, la valeur maximale ou moyenne.

En pratique, on utilise souvent des cellules carrées de petite taille, pour ne pas perdre trop d'informations. Les choix les plus communs sont des cellules adjacentes de taille 2×2 pixels qui ne se chevauchent pas, ou des cellules de taille 3×3 pixels, distantes les unes des autres, d'un pas de 2 pixels.

La couche de pooling permet de réduire le nombre de paramètres et de calculs, dans le réseau. On améliore ainsi l'efficacité du réseau et, on évite le sur-apprentissage. Ainsi, la couche de pooling rend le réseau moins sensible à la position des caractéristiques [29].

Le fait qu'un descripteur se situe un peu plus en haut ou en bas, ou même qu'elle ait une orientation légèrement différente, ne devrait pas provoquer un changement radical dans la classification de l'image.

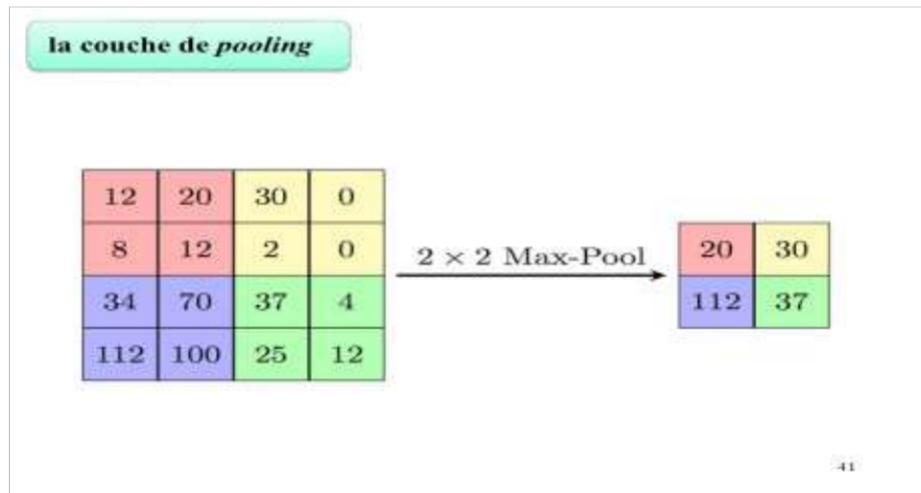


Figure 2. 10 : Couche de max pooling[29]

Il est possible d'utiliser d'autres fonctions de pooling que le maximum comme :

- Le « mean pooling » (ou average pooling), soit la moyenne des pixels de la sélection. On calcule la somme de toutes les valeurs et on les divise, par le nombre de valeurs de la fenêtre.
- Le « sum pooling », c'est la moyenne sans avoir à la diviser par le nombre de valeurs (on ne calcule que leur somme).

2.6.3 Couche de correction ReLU

Cette couche désigne la fonction réelle non-linéaire, déjà définie dans la présentation des fonctions d'activation (paragraphe 2.4.2 c). Cette dernière remplace toutes les valeurs négatives en entrée par des zéros, obligeant les neurones à retourner des valeurs positives.

2.6.4 Couche fully-connected

Il s'agit d'une couche non convolutive, qui constitue la dernière couche d'un réseau de neurones (figure 2.11). Elle reçoit un vecteur en entrée et génère un nouveau vecteur, en sortie.

La dernière couche fully-connected permet de classifier les images. Elle envoie un vecteur de taille N, où N est le nombre de classes dans notre problème de classification

d'images. Chaque élément du vecteur indique la probabilité pour l'image en entrée, d'appartenir à une classe. Dans ce cadre, chaque valeur du tableau en entrée "vote" en faveur d'une classe. Les votes n'ont pas tous la même importance : la couche leur accorde des poids, qui dépendent de l'élément du tableau et de la classe. Pour calculer les probabilités, la couche fully-connected multiplie donc chaque élément en entrée par un poids, fait la somme, puis applique une fonction d'activation (logistique si $N=2$, soft max si $N>2$). Ce traitement revient à multiplier le vecteur en entrée, par la matrice contenant les poids. Le fait que chaque valeur en entrée soit connectée avec toutes les valeurs en sortie, explique le terme fully-connected.

Le réseau de neurones convolutif apprend les valeurs des poids de la même manière qu'il apprend les filtres de la couche de convolution : lors de la phase d'entraînement, par rétropropagation du gradient. La couche fully-connected détermine le lien, entre la position des caractéristiques dans l'image et une classe. En effet, le tableau en entrée résultant de la couche précédente, correspond à une carte d'activation pour une caractéristique donnée (les valeurs élevées indiquent la localisation (plus ou moins précise selon le pooling) de cette caractéristique dans l'image). Si la localisation d'un descripteur à un certain emplacement de l'image, est caractéristique d'une certaine classe, alors un poids est accordé suivant le tableau [29].

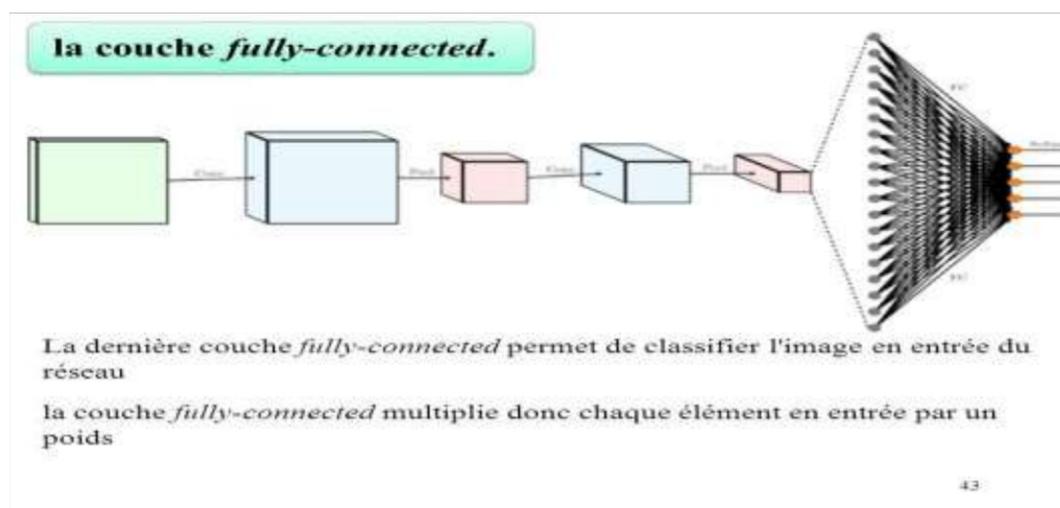


Figure 2. 11 : Couche fully-connected [29]

2.6.5 Couche de perte

La couche de perte (loss) suit la couche entièrement connectée et gère les ajustements des poids, sur le réseau. Avant le début de l'apprentissage du réseau, les poids de la couche convolutionnelle et de la couche entièrement connectée, sont spécifiés sous forme de valeurs aléatoires.

Pendant le processus d'entraînement ; la couche de perte vérifie en permanence les suppositions de la couche entièrement connectée, par rapport aux valeurs réelles pour minimiser autant que possible, la différence entre l'estimation et la valeur réelle, en ajustant les poids, à la fois dans la couche de convolution et, dans les couches entièrement connectées. Diverses fonctions de perte adaptées à différentes tâches, peuvent y être utilisées. La fonction « Softmax » permet de calculer la distribution des probabilités sur les classes de sortie [27].

2.7 Augmentation des données

L'augmentation des données englobe un large éventail de techniques utilisées, pour générer de nouveaux échantillons d'apprentissage des originaux en appliquant des opérations géométriques aléatoires, telles que les étiquettes de classes soient non modifiées. L'objectif de l'application de l'augmentation des données, est d'augmenter la précision de l'entraînement du modèle.

Parmi les opérations classiques utilisées pour l'augmentation des données, on peut trouver : la translation, la rotation, l'agrandissement, le changement d'échelle et d'autres transformations plus avancées comme La modification de la luminosité ou du contraste de l'image, qui peuvent être également ajoutées selon les besoins de l'utilisateur. L'injection du bruit à l'entrée d'un réseau de neurones, peut également être considérée comme une forme d'augmentation des données [27].

2.8 Conclusion

Ce chapitre a eu pour but de mettre en avant, le concept de la machine et du deep learning. Dans ce cadre, quelques types de réseaux de neurones basiques et ceux consacrés à l'apprentissage profond, ont été présentés. Le réseau convolutif appliqué à la classification d'images, a été particulièrement explicité, suivant les différentes couches le constituant.

Le troisième chapitre est consacré aux différentes architectures des réseaux de neurones convolutifs ainsi qu'à quelques travaux en imagerie pulmonaire.

Chapitre 3 Architectures des réseaux de neurones convolutifs

3.1 Introduction

L'utilisation des différents modèles du deep learning dans le domaine de l'imagerie médicale, augmente de façon exponentielle pour l'aide au diagnostic médical. En effet, le modèle du réseau neuronal convolutif, se popularise de plus en plus du fait des précisions, qu'il génère lors de la classification d'images.

Ce chapitre aborde le réseau neuronal convolutif, suivant ses différents d'architectures (denseNet , VGG 16 , resnet... etc.).

3.2 Architecture des réseaux neuronaux convolutifs

Dans le cadre de la résolution de différentes tâches, telles que la classification d'images, ou la détection d'objets, plusieurs architectures CNN permettent la réalisation de ces opérations [30]. Parmi ces architectures, on cite les modèles suivants :

3.2.1 Modèle VGG 16

VGG est un réseau de neurones convolutionnels proposés par K. Simonyan et A. Zisserman de l'université d'Oxford [30]. Il est devenu populaire en gagnant la compétition ILSVRC en 2014. Le modèle a atteint une précision de 92.7% sur Imagenet, ce qui est un des meilleurs scores obtenus. Il a marqué une progression par rapport aux modèles précédents, en proposant, dans les couches de convolution, des noyaux de convolution de plus petites dimensions (3×3) que ce qui avait été fait jusque-là [30]. Dans les faits, il existe deux algorithmes disponibles : VGG16 [31, 32] et VGG19 [33, 34].

La figure 3.1 illustre le modèle VGG16.

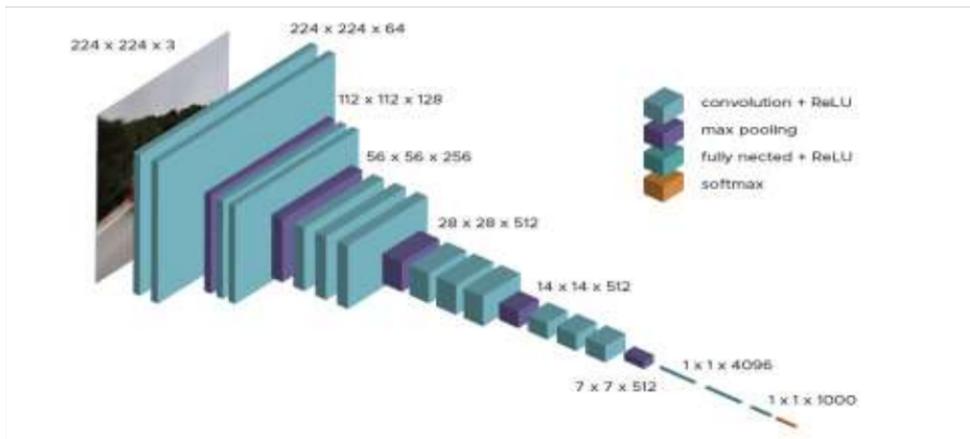


Figure 3. 1 : Architecture globale du VGG16 [32]

Le modèle VGG16 est constitué de plusieurs couches, dont 13 couches de convolution et 3 couches entièrement connectées (figure 3.2).

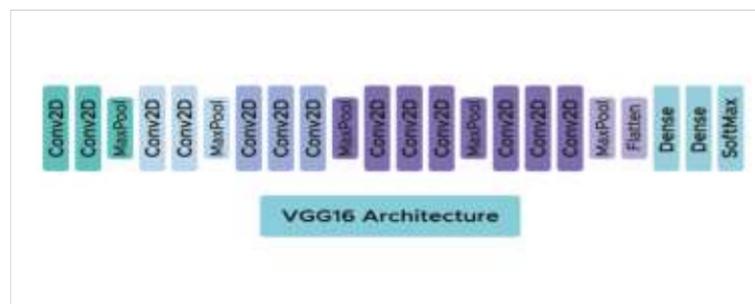


Figure 3. 2 : Architecture du VGG16 [32]

Les images d'entrée de ce modèle, sont des images RGB de taille 224 x 224. Les couches de convolution utilisent des filtres dont le noyau, est de taille 3x3. Il s'agit de la plus petite dimension, pour capturer les notions de haut, bas, gauche/droite et le centre. C'était une spécificité établie par le modèle, au moment de son challenge.

Les couches de convolution ont pour but de filtrer l'image, en ne gardant que des informations discriminantes. Elles s'accompagnent de couches de Max-Pooling, chacune d'elles de taille 2x2, pour réduire celle des filtres au cours de l'apprentissage.

Toutes les couches cachées, sont équipées de la non-linéarité de rectification (ReLU). Les cartes de caractéristiques (maps features) de la couche finale, sont représentées sous forme de vecteurs avec des valeurs scalaires, suivant la fonction de classification soft-max.

En sortie des couches de convolution et du pooling, le modèle VGG16, adopte 3 couches de neurones Fully-Connected. Les deux premières sont composées de 4096 neurones et la dernière de 1000 neurones représentant les classes dans imagenet, avec une fonction d'activation softmax, pour déterminer la classe de l'image [30].

3.2.2 VGG19

Le modèle VGG19 étant très similaire et respectant la même logique que VGG16, présente toutefois, un plus grand nombre de couches de convolution. En effet (figure 3.3), ce dernier se compose de 19 couches dont 16 couches de convolution ainsi que 3 couches connectées, 5 couches de MaxPool et pour finir une couche SoftMax [33, 34].

La taille des images d'entrée est de 224x224.

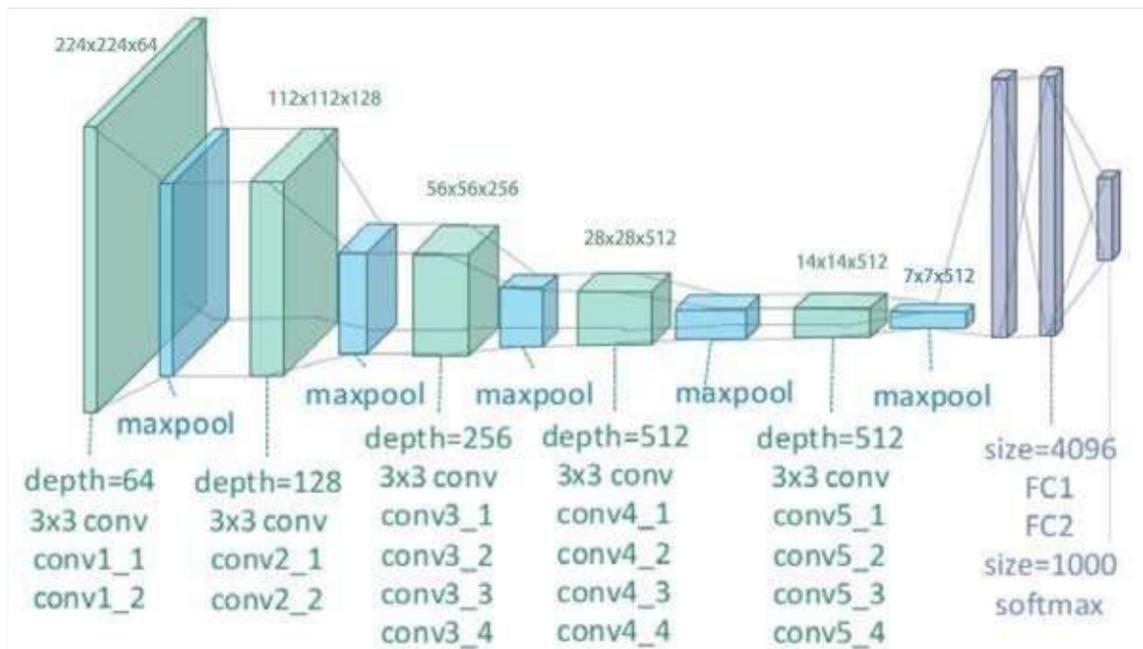


Figure 3. 3 : Architecture du VGG19 [33]

3.2.3 ResNet

ResNet étant l'abréviation de 'Residual Networks' est un réseau neuronal classique, utilisé, dans de nombreuses tâches de la vision par ordinateur. Ce modèle a remporté le défi ImageNet en 2015 [30].

Les modèles ResNet ont énormément contribué à l'utilisation des réseaux de neurones profonds ; en limitant la perte du gradient dans les couches les plus profondes de celui-

ci, par l'ajout d'une liaison résiduelle entre chaque couche de convolution : c'est le bloc résiduel [30]. Dans le bloc résiduel (figure 3.4), l'entrée x est directement ajoutée à la sortie du réseau, ($F(x) + x$), où ce chemin est connu sous le nom de **saut de connexion** ou de raccourci.

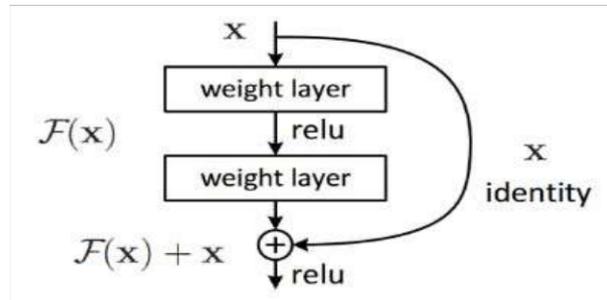


Figure 3. 4 : Bloc résiduel [30]

Les avantages de ces réseaux sont leur capacité à réduire la fuite du gradient, dans les couches inférieures du réseau et la possibilité de leur mise à l'échelle, en profondeur. Cette dernière permet l'ajustement de l'architecture, à la tâche de la classification à accomplir. Bien que coûteux en ressources de calcul, ils obtiennent de très bonnes performances en classification sur tous les niveaux de détails de l'image, même les plus fins comme les nodules pulmonaires, ou les hémorragies intracrâniennes.

De par leur architecture en module, ils appartiennent à la famille de modèles appelés, "Network in Network". Ces réseaux sont un ensemble de micro-architectures, ou de blocs de traitement. Cet ensemble permet d'obtenir la macro-architecture (c'est-à-dire le réseau final lui-même). Toutefois, l'augmentation de la profondeur du réseau, ne fonctionne pas simplement en empilant les couches ensemble. Les réseaux profonds sont difficiles à entraîner en raison du problème notoire de la disparition du gradient. Comme le gradient est rétro-propagé aux couches antérieures, une multiplication répétée, peut rendre le gradient extrêmement petit. En conséquence, à mesure que le réseau s'approfondit, ses performances sont saturées ou même commencent à se dégrader rapidement.

3.2.4 Architecture Inception et ses dérivées

L'architecture Inception (figure 3.5), a pour but de réduire la consommation de ressources des réseaux de neurones convolutionnels très profonds (Deep Convolutional Neural Networks, DCNN), qui est courante pour les modèles de type 'Network in Network'. Pour capturer la variabilité du jeu de données, tout en évitant d'exploser la consommation de ressources, l'architecture Inception repose sur l'utilisation de blocs de traitement suivants [30].

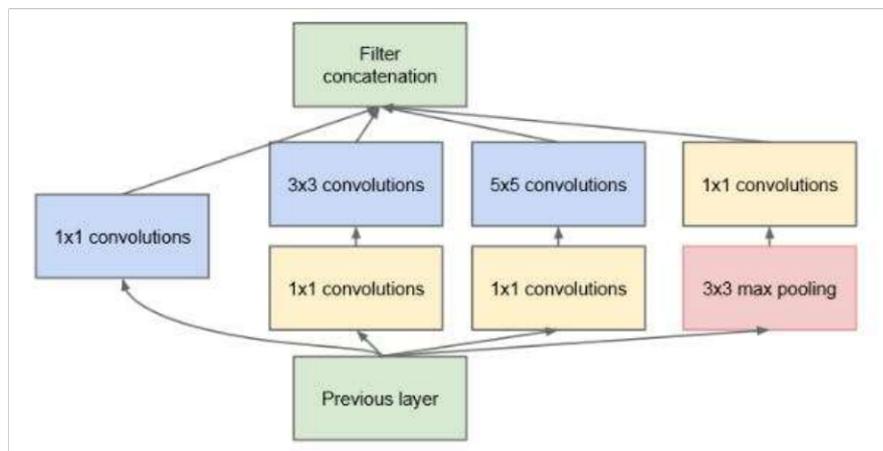


Figure 3. 5 : Architecture Inception [30]

En combinant plusieurs filtres de tailles différentes à un même niveau du réseau, il est possible de capturer des informations d'échelles différentes. Néanmoins, cette technique implique une augmentation de consommation de ressources, car il y a un plus grand nombre de paramètres, calculés à cette étape que s'il n'y avait qu'un seul filtre. Pour réduire la consommation des ressources qu'implique l'utilisation de plusieurs filtres, une astuce mathématique est utilisée pour réduire la dimension de l'image analysée par les filtres 3*3 et 5*5, en ajoutant une étape de filtrage 1*1 avant. De cette façon, la convolution de taille 1*1 effectue une opération de pooling, sur les valeurs d'un pixel dans l'espace des dimensions de l'image. Par exemple si l'image en entrée possède 3 canaux (RGB), alors après convolution 1*1, l'image de sortie aura 1 canal. La réduction des dimensions, permet de conserver l'information, tout en réduisant le coût des ressources lors de l'étape de convolution suivante avec un filtre de taille 3*3. En imagerie médicale, l'architecture Inception est souvent utilisée pour la classification des anomalies, notamment pour définir le stade de la maladie (ex : cancer des poumons,

cancer des reins, inflammation du complexe ostioméatal). Des dérivés de cette architecture ont rapidement vu le jour, comme Inception-ResNet (figure 3.6), qui permet l'obtention de bons résultats en classification d'images médicales (ex : classification d'images TDM des poumons pour la détection du covid-19, ou des nodules pulmonaires) [36, 37].

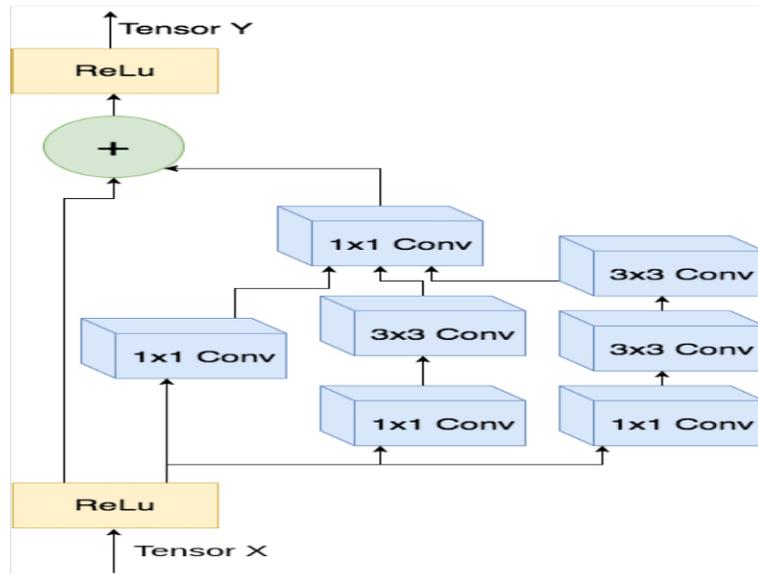


Figure 3. 6 : Architecture de Inception ResNet [30]

3.2.5 Architecture DenseNet

Les modèles de type DenseNet (figure 3.7) s'inscrivent dans la lignée des DCNN [30]. Chacune des couches du réseau, a en entrée les sorties des couches précédentes. Cette particularité augmente le nombre de connexions du réseau de 'L', pour un CNN traditionnel de 'L' couches avec une connexion entre chaque couche.

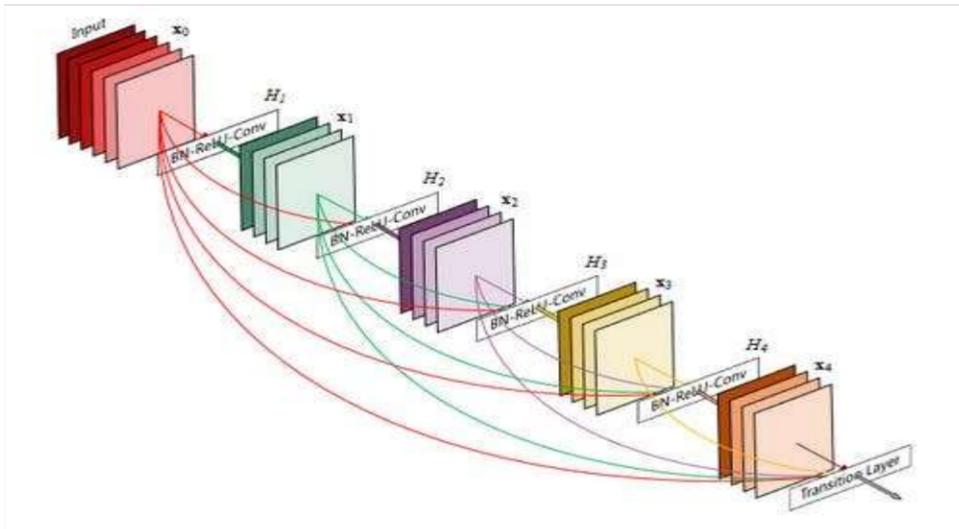


Figure 3. 7 : Architecture DenseNet [30]

Bien que l'architecture DenseNet ait une approche similaire à l'architecture ResNet, avec l'ajout de connexions courtes entre les couches, elle diffère significativement dans la façon, dont l'information des couches précédentes, est prise en compte.

La concaténation de l'information faite dans l'architecture DenseNet, permet de réduire par un facteur de 3, le nombre de paramètres par rapport à l'architecture ResNet, tout en conservant le même niveau de performance en termes de précision.

L'architecture DenseNet est aussi bien utilisée pour la classification de pathologies (ex : les kystes pancréatiques ou encore les thymomes de niveau I et II, que pour la segmentation multi-organes, quand elle est assemblée avec d'autres architectures spécifiques à cette tâche [30].

3.2.6 Architecture Squeeze-and-Excitation

Les modèles de type Squeeze-and-Excitation (SE) (figure 3.8) proposent de modéliser explicitement, les interdépendances entre les dimensions de l'image, afin d'améliorer le codage spatial de ses caractéristiques [30].

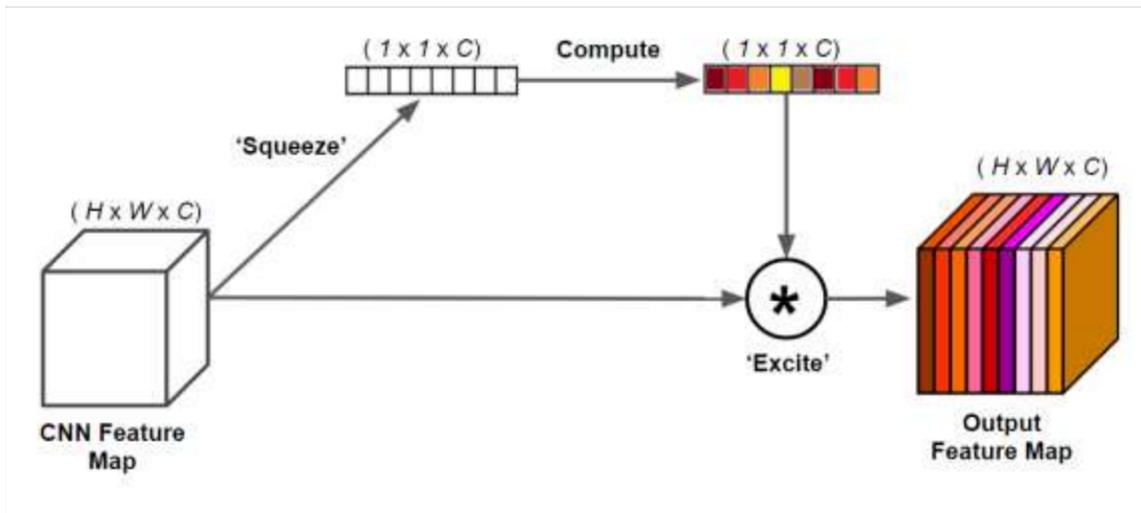


Figure 3. 8 : Architecture du modèle squeeze-and-Extinction [30]

Les blocs de traitement SE sont composés de deux parties successives : Squeeze, Excitation. Les convolutions sont en forme de convolutions factorisées, où une convolution standard est factorisée en une convolution en profondeur et, une convolution 1*1 est appelée convolution ponctuelle.

Cette factorisation réduit drastiquement, le temps de calcul et la taille du modèle. A ces convolutions, deux hyperparamètres globaux simples, qui font un compromis efficace entre la latence et la précision sont ajoutés : le multiplicateur de largeur (en anglais width multiplier) pour un modèle plus fin et, le multiplicateur de résolution (en anglais resolution multiplier) pour une représentation réduite. Ce type de modèle a été développé pour une utilisation sur support nomade (smartphone, tablette), ou dans un système embarqué. En imagerie médicale, il est intéressant pour une utilisation en routine clinique, pour la détection et la classification d'anomalies, tels que les nodules pulmonaires malins.

3.2.7 Architecture de MobileNet

Cette architecture (figure 3.9) utilise les convolutions séparables en profondeur, de même que pour le modèle SE. Ces convolutions sont une forme de convolutions factorisées, où une convolution standard est factorisée en une convolution en profondeur et, une convolution 1*1 est appelée convolution ponctuelle, pour une représentation réduite [30].

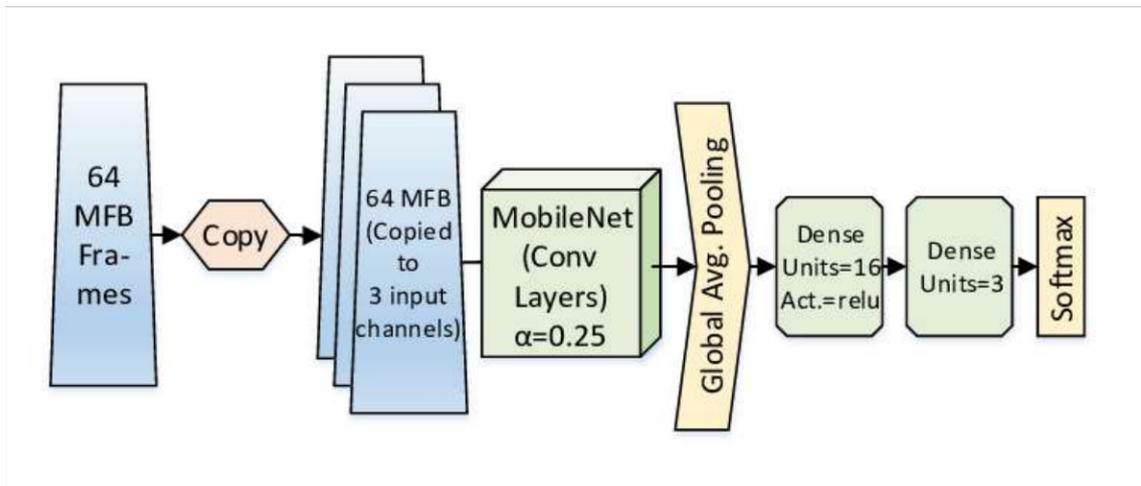


Figure 3. 9 : Architecture de MobileNet [30]:

3.3 Critique documentaire de quelques travaux connexes

Plusieurs travaux en imagerie pulmonaire, ont été réalisés dans la littérature scientifique ainsi que par l'équipe 'IMAD' (imagerie pour l'aide à la décision), du laboratoire 'LATSIS' du département d'électronique de l'université de Blida 1.

3.3.1 Travaux de Khemis et Meradi

Dans le cadre du mémoire de Master de S. Khemis et Y. Meradi [35], un système de la classification des pathologies pulmonaires, a été réalisé en se basant sur des images thoraciques.

L'objectif principal de ce système a été de classifier les tumeurs pulmonaires d'une part et les pneumopathies d'autre part, à l'aide de modèles à base de CNN.

Ces travaux reposent sur deux types de bases de données : la première base de données « Luna16 », utilise l'ensemble de données du défi 'Lung Nodule Analysis 2016' où, 1186 nodules ont été classés comme malins pour les nodules ≥ 3 mm, ou bénins pour les nodules < 3 mm.

La deuxième base de données surnommée « Pneumonia », utilise quant à elle, un ensemble de radiographies pédiatriques. Cette base se compose de 5856 radiographies du thorax d'enfants âgés de 1 à 5 ans.

La classification des nodules cancéreux, a été effectuée par les modèles VGG16 et VGG19. Le système réalisé par VGG16, a obtenu une précision de 97.5%, une sensibilité de 90% ainsi qu'un taux de perte de 0.07 après 30 itérations.

Pour le modèle VGG19, le système a généré une précision de 98.5%, une sensibilité de 91% et un taux de perte de 0.05 après 25 itérations.

3.3.2 Introduction aux travaux de F. Demir

Les travaux de F. Demir [36] étudiés, présentent une solution à la détection du covid19, grâce au DeepCoroNet et l'architecture LSTM (long short term memory).

Dans ce cadre, LSTM est une architecture neuronale récurrente avec la spécificité de l'existence d'un feed back, qui permet non seulement de traiter des points de données uniques (image), mais également des séquences entières. Mais, cette approche demande une bande passante et une mémoire énorme.

Dans ce cas de ce travail, les images radiographiques pulmonaires utilisés, se composent de 361 données de personnes atteintes de la covid-19 (200 hommes et 161 femmes, avec une moyenne d'âge de 45 ans), de 200 images montrant des pneumonies et de 500 images appartenant à personnes saines (figure 3.10).

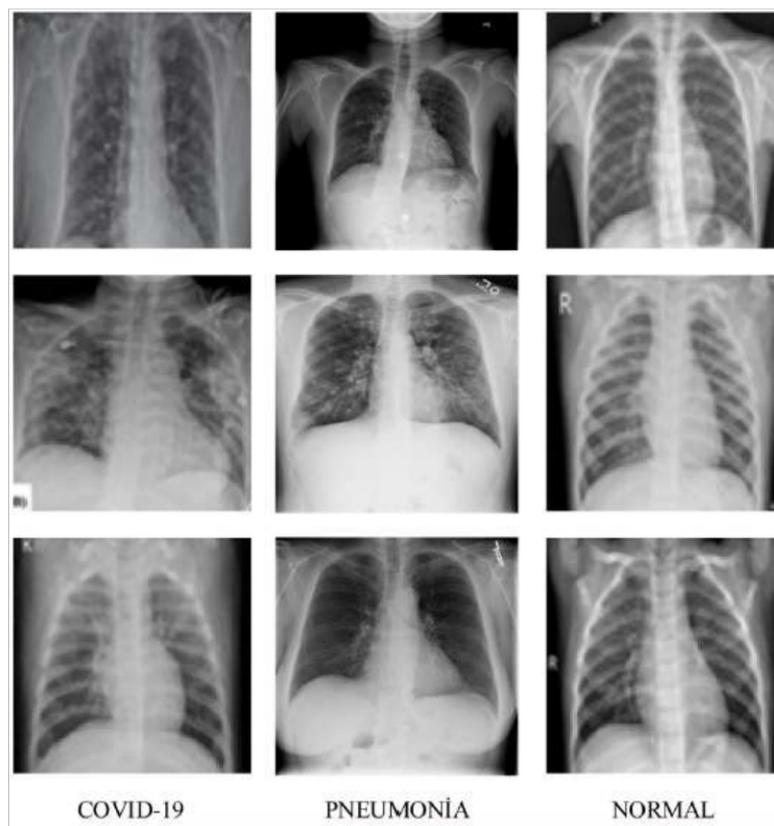


Figure 3. 10 : Images radiographiques des 3 catégories [36]

La méthode **de détection LSTM** utilisée dans cet article (figure 3.11), se résume en deux étapes. La première qui consiste au prétraitement, permet d'augmenter les performances de classification des images, à l'aide du gradient. Ces données sont ensuite, remodelées afin de convenir à l'architecture LSTM. Lors de la deuxième étape, des blocs de données de l'architecture LSTM, sont créés pour l'évaluation de l'étape précédente.

Cette dernière est constituée de couches du réseau de neurones convolutif (CNN) et de couches LSTM. Lors de cette création, les images remodelées, seront converties afin d'être utilisées, comme les entrées du module LSTM.

Le bloc créé sert pour l'apprentissage et les tests. Il est composé de 5 couches, LSTM, la couche fully connected, la couche rectified linera unit, la couche dropout et la couche softmax, pour l'activation des classes.

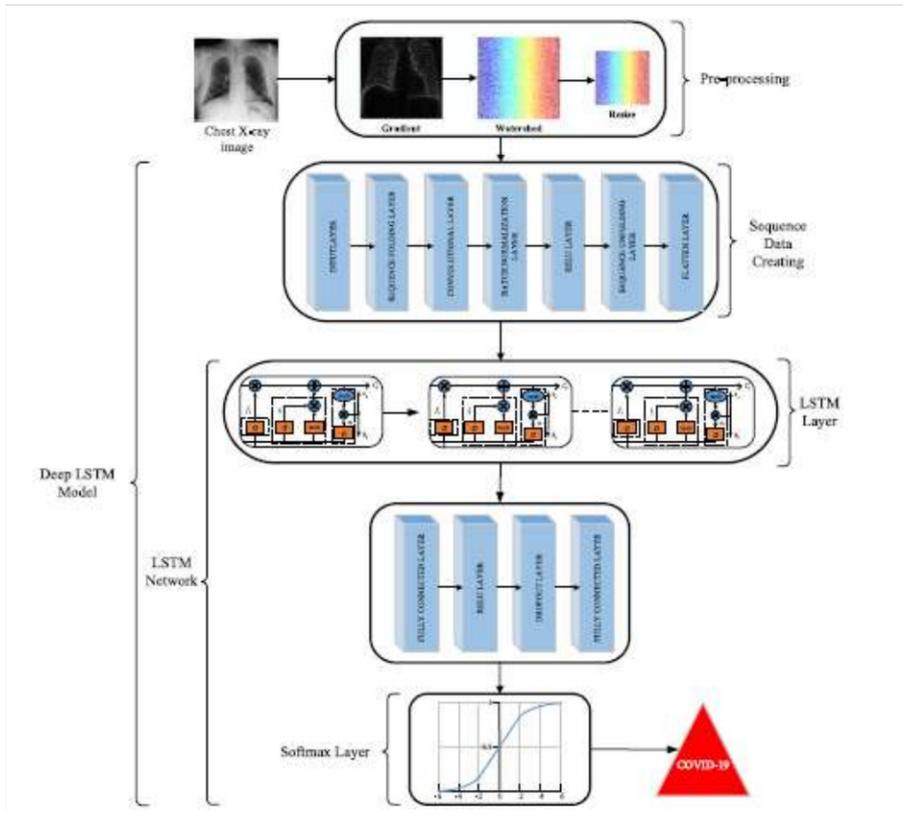


Figure 3. 11 : Représentation de la méthode utilisée [36]

Lors de la fin des 900 itérations effectuées (figure 3.12), Le système a généré une précision de 100% pour un temps d'exécution de 53 minutes et 22 secondes.

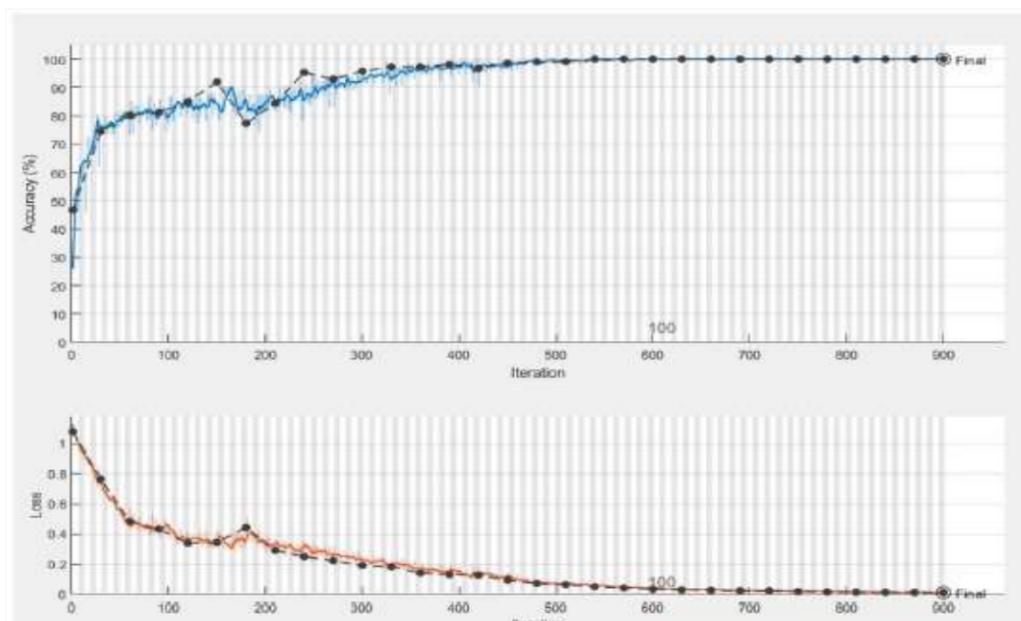


Figure 3. 12 : Résultats des travaux de Demir et al [36]

3.3.3 Travaux de T. Ozturk et al

Depuis le début de la pandémie le test le plus fréquemment utilisé lors de la détection du covid19 est le RT-PCR (real-time reverse transcription-polymerase chaine reaction), mais dès lors que ce dernier, n'a une sensibilité de 60% voire 70%, il est devenu difficile de détecter efficacement le virus. De ce fait, pour améliorer la détection de ce virus, T. Ozturk et al [37], ont utilisé les CNN, pour l'extraction d'informations pertinentes. Plus précisément la méthode proposée, est un modèle d'architecture de bout-en-bout sans aucune méthode d'extraction appliquée sur des images radiographiques pulmonaires. 125 images des poumons provenant de sources en open-access, sont utilisés dans cet article. Après 513 jours certains patients (figure 3.13), dits guéris montrent des résultats positifs, ce qui prouve que ces personnes peuvent toujours, propager le virus.

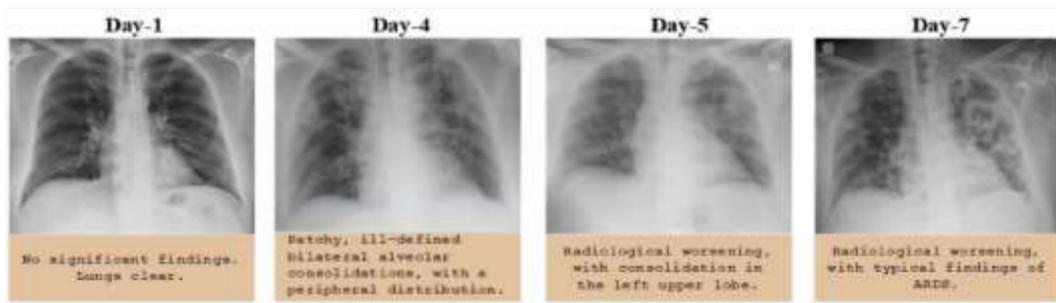


Figure 3. 13 : Images radiographiques d'un patient de 50 ans atteint du covid19 [37]

La détection aux premiers stades de la maladie, est difficile à partir d'images radiographiques. Cependant, ce désavantage peut être rectifié grâce au deep learning. Le modèle proposé dans cet article, est appelé 'DarkCovidNet', un modèle basé sur l'architecture CNN pour permettre la classification. Ce modèle est inspiré de Darknet-19, qui est la base d'un système de détection en temps réel appelé YOLO (you only look once). En partant de l'architecture originelle du DarkNet, plusieurs filtres sont ajoutés au fil du temps pour améliorer les critères souhaités (figure 3.14).

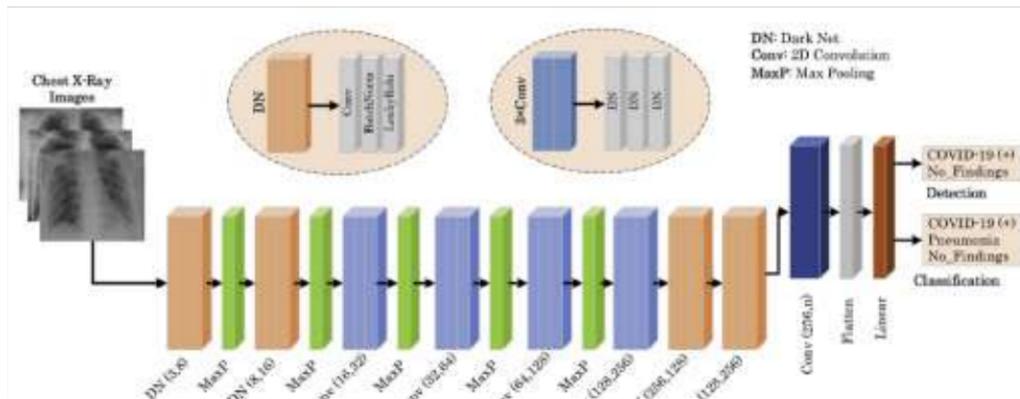


Figure 3. 14 : Architecture du modèle proposé [37]

En effet chaque couche Darknet, est une couche convolutive accompagnée de 'BatchNorm' et 'LeakyReLU', permettant de réduire le temps d'apprentissage et d'accroître la stabilité du modèle.

Le modèle d'architecture DarkCovidNet permet de classifier les images pulmonaires obtenues en trois catégories : covid19, classe normale, pneumonie ou bien, en classe binaire (covid-19, classe normale).

Le modèle DarkCovidNet a généré une précision de 87.02% lors de la triple classification (classe normale, COVID-19, Pneumonie) et une précision de 98.08% pour la classification binaire (sain, COVID-19).

3.4 Conclusion

Ce chapitre a présenté les réseaux de neurones convolutifs dans leurs ensembles et architectures, leurs utilités dans différentes utilisations et plus spécifiquement, dans la classification d'images. Ainsi, le choix du type d'architecture dépend des données et, de la tâche à effectuer.

Le prochain chapitre mettra en avant, l'application développée, ainsi que les résultats obtenus, suivant les modèles adoptés.

Chapitre 4 Mise en œuvre de ‘PneumoCNNV2.1’ & résultats

4.1 Introduction

L’objectif de ce chapitre, est de présenter le système ‘PneumoCNNV2.1’ mis en œuvre dans le cadre de ce projet, pour la classification d’images radiographiques de pathologies pneumologiques, en se basant sur les réseaux convolutifs CNN pré-entraînés. A cet effet, nous présentons l’environnement de travail établi suivant des outils spécifiques à l’apprentissage profond, la mise en œuvre de ‘PneumoCNNV2.1’, les différents résultats expérimentaux atteints, ainsi que les performances obtenues.

4.2 Environnement de travail

4.2.1 Matériel utilisé

Lors de l’élaboration de cette étude, deux PCs portables furent utilisés. Le premier est un intel(R) Core(TM) i7-8565U CPU @ 1.80GHz (8 CPUs), possédant une mémoire vive de 16 384 MB RAM avec un système d’exploitation 64bits ; quant au deuxième pc c’est un intel(R) Core(TM) i7-1065G7 CPU @ 1.30GHz (8 CPUs) possédant une mémoire vive de 8192 MB RAM, avec un système d’exploitation de 64 bits.

Nous avons utilisé les deux PCs dans l’entraînement du modèle, pour lesquels le temps d’exécution est très lent. Nous avons remarqué que l’utilisation du GPU, est beaucoup plus rapide, que le CPU.

4.2.2 Langage de programmation utilisé

Le langage utilisé lors de l’élaboration de cette étude, est le langage Python, qui est le langage le plus populaire et le plus pratique, lors de l’utilisation du deep learning. Créé par le programmeur Guido van Rossum en 1991, il tire son nom de l’émission Monty Python’s flyching Circus [38].

Python représente un langage de programmation interprété, qui ne nécessite pas d'être compilé pour fonctionner. Le langage Python se veut comme un langage de programmation, permettant à ses utilisateurs de mieux se concentrer sur ce qu'ils veulent faire, à la place de comment le faire. De plus, ce langage peut fonctionner sur tous les principaux systèmes d'exploitation et les plateformes informatiques et est souvent utilisé, lors de la création de logiciels de qualité professionnelle.

4.2.3 Anaconda

Anaconda représente le distributeur libre et open source, du langage de programmation de python, visant à simplifier son utilisation.

Le navigateur anaconda est une interface graphique incluse, lors de la distribution d'anaconda. Ce dernier permet de faciliter la gestion des librairies conda, sans avoir à intégrer des lignes de commandes [39].

4.2.4 Spyder

Fait par et pour des scientifiques, des ingénieurs et des data analysts, Spyder représente un environnement écrit, à l'intérieur de python. Il est équipé d'outils avancés permettant l'analyse, le debugging, l'exécution interactive ainsi que l'inspection approfondie [40].

4.2.5 Scipy

Cette bibliothèque consiste en différents outils scientifiques, pour python. Elle est assez simple à utiliser et fournit plusieurs modules pour l'optimisation, tels que, l'algèbre linéaire et les statistiques [41].

4.2.6 Numpy

Il s'agit d'une bibliothèque vitale, lors de l'utilisation de python. En effet, elle étend les capacités de Python, pour travailler sur des tableaux et matrices à n dimensions de façon bien plus optimisée. Elle offre ainsi, des fonctions mathématiques de haut niveau sur ces objets [42].

4.2.7 Tensorflow

Il s'agit d'une plateforme open source très utilisée, dans le domaine du machine learning. Elle est dotée d'un environnement compréhensif et flexible, qui permet à ses utilisateurs d'avancer plus facilement et plus rapidement, lors de la création d'applications utilisant le deep learning [43].

4.2.8 Keras

Keras représente un API de réseaux de neurones de haut niveau introduit dans python fonctionnant avec tensorflow, Keras a été pensé pour les expérimentations rapides permettant de partir de l'idée aux résultats en le moins de temps possible [44].

4.2.9 Matplotlib

Cette bibliothèque représente le meilleur outil de visualisation dans python, se focalisant sur le traçage en 2D. Elle fonctionne avec la majorité des interfaces et des formats, mais est un peu limitée en interactivité, dans le WEB [45].

4.2.10 Pandas

Pandas est une librairie python, qui permet de manipuler facilement des données à analyser. 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. Elle se veut comme la bibliothèque fondamentale lors des expériences utilisant des données réelles dans python [46].

4.3 Architecture du système 'PneumoCNNV2.1'

La conception de l'approche 'PneumoCNNV2.1', est réalisée pour classifier des pathologies pulmonaires, prises sur des images radiographiques thoraciques. L'objectif principal, est de répertorier les pneumopathies grâce à des modèles CNN. La figure 4.1, montre l'architecture globale du système proposé, appliqué sur des images pulmonaires, grâce à trois réseaux CNN, suivant deux optimisateurs différents.

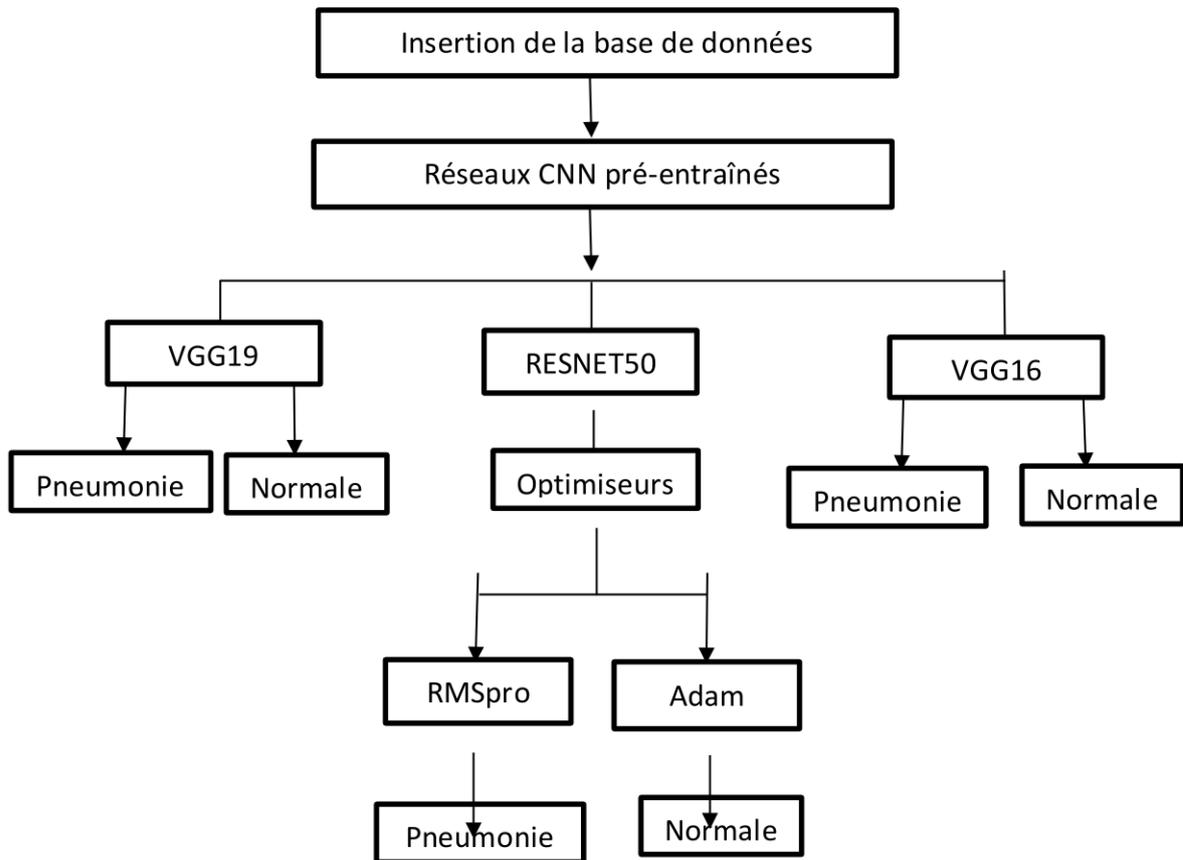


Figure 4. 1 : Architecture du système 'PneumoCNNV1.2'

4.4 Base de données

La base d'images pulmonaires utilisée (figure 4.2), représente 5 856 radiographies de thorax collectées, parmi des enfants âgés de 1 à 5 ans, du centre médical pour femmes et enfants de Guangzhou en Chine [47]. Dans cette étude, 2600 images ont été utilisés.

La base se compose de 3 catégories principales (test, entraînement, validation) classés en deux types : sains et pneumonies (tableau 4.1).



Figure 4. 2 Exemples d'images de la base 'pneumonia' [47]

Classe	Test	Entrainement	Validation
Saine	100	1000	200
Pneumonie	100	1000	200

Tableau 4. 1 : Division de la base de données 'pneumonia'

4.5 Classification des pneumonies par le modèle VGG19

L'application 'PneumoCNNV2.1' consiste à classer des radiographies thoraciques en deux catégories, classe de la pneumonie et les cas normaux suivant le modèle VGG19. Cette architecture est composée de 16 couches de convolution et 3 couches fully connecté, 5 couches de MaxPooling, et 2 couches FC. Chacune des couches FC, est suivie d'une fonction d'activation Softmax. Un Flatten est également appliqué à la première couche et une couche dense à la fin. Un synoptique global du modèle susmentionné, est illustré par la figure 4.3.

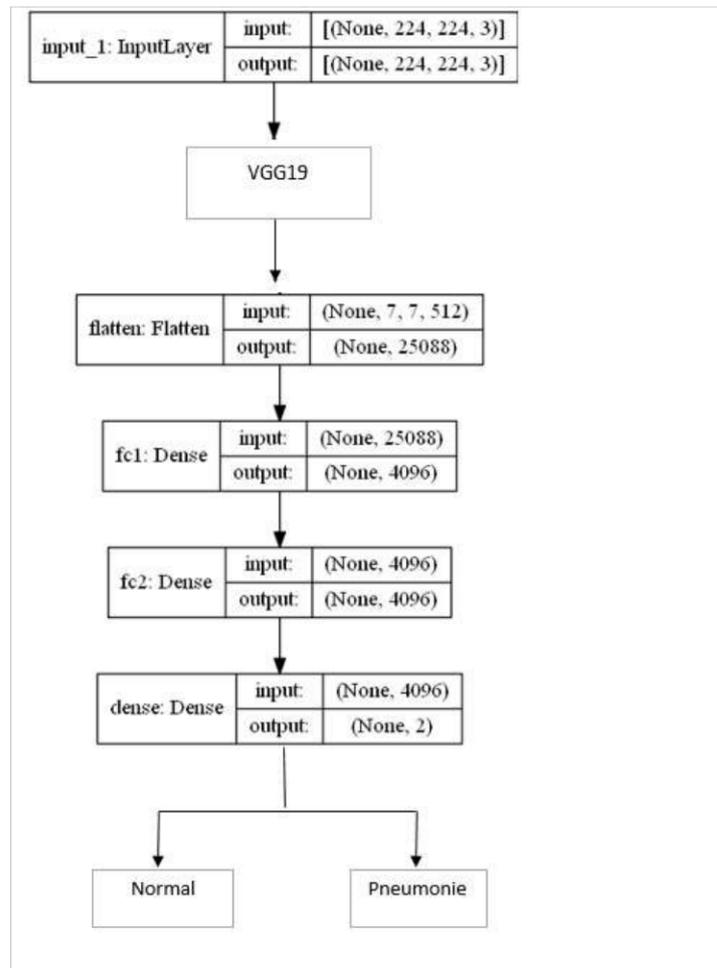


Figure 4. 3 : Classification des pneumonies par le modèle VGG19

4.6 Classification des pneumonies par le modèle VGG16

Cette architecture est composée de 13 couches de convolution, 3 couches 'fully connected', 5 couches de 'MaxPooling' et 2 couches FC. Chacune des couches FC, est suivie d'une fonction d'activation Softmax. Un Flatten est appliqué à la première couche et une couche dense à la fin (figure 4.4).

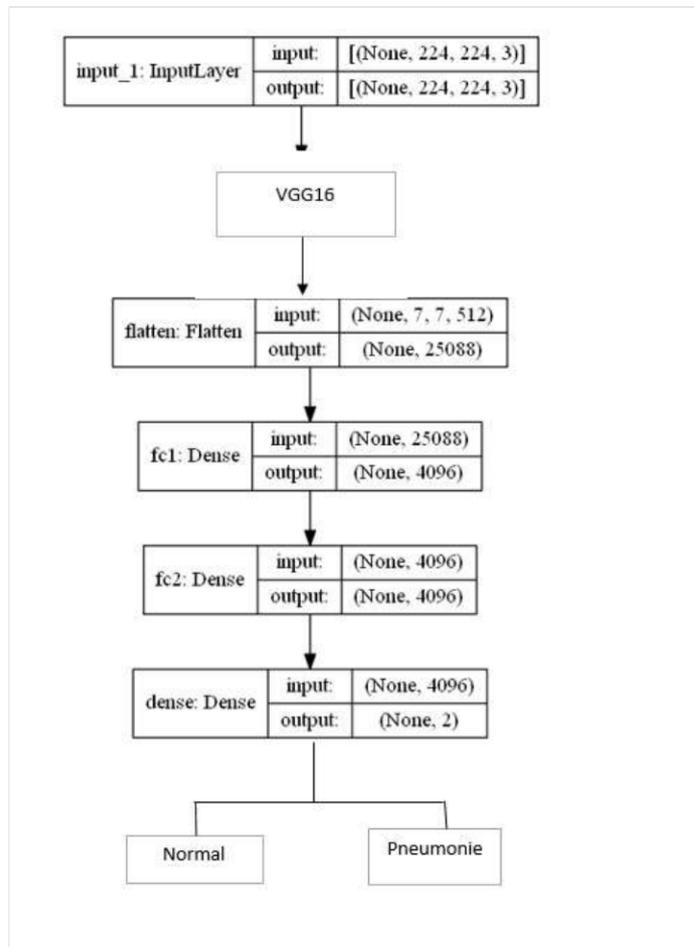


Figure 4. 4 : Classification des pneumonies par le modèle VGG16

4.7 Classification des pneumonies par le modèle Resnet50

Cette architecture est composée de 50 couches de convolution, une couche MaxPool, une Average Pooling et 2 couches Dense. Chacune des couches, 'dense' est suivie d'une fonction d'activation Relu et une Softmax. Un Flatten est appliqué à la première couche (figure 4.5).

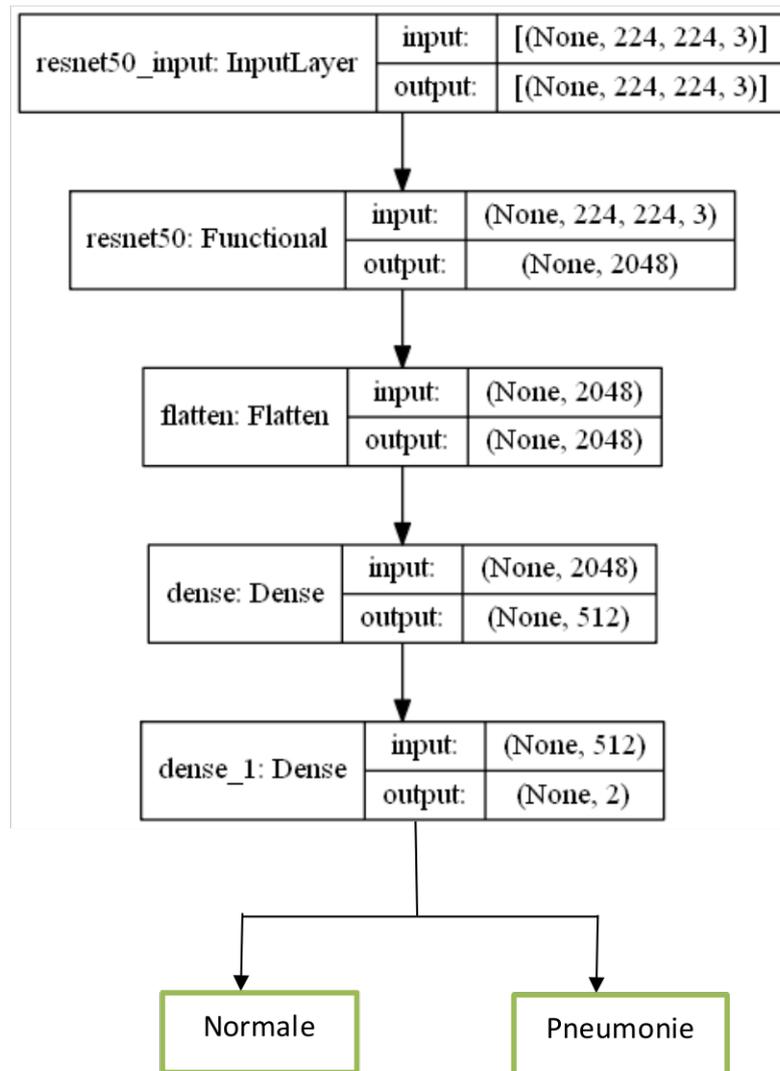


Figure 4. 5 : Classification des pneumonies par le modèle Resnet50

4.8 Paramètres d'évaluation des performances de 'PneumoCNNV2.1'

Pour évaluer les performances de cette étude, nous utilisons deux métriques ; la précision et la perte. Une matrice de confusion est également déterminée, pour identifier les faux résultats des vrais. Il s'agit dans ce cas, d'un tableau croisé entre les valeurs réelles et les prédictions. Cette matrice permet d'identifier 4 catégories de résultats.

➤ Bonnes prédictions

1. Vrais positifs : les personnes saines.
2. Vrais négatifs : les personnes infectées.

- Prédiction fautive
 1. Faux négatifs : les personnes infectées mais qui apparaissent comme saines.
 2. Faux positifs : les personnes saines mais qui apparaissent infectées.
- Précision : indique le pourcentage de bonnes de prédictions lors de la classification. Elle se calcule suivant la formule 4.1.

$$\text{Précision} = (\text{vrais positifs} + \text{vrais négatifs}) / \text{le total}$$

- Perte : une valeur qui indique l'erreur de performance du modèle de classification.

4.9 Résultats de la classification des pneumonies par le modèle VGG16

Le modèle 'PneumoCNNV2.1', permet la classification des pneumonies en deux catégories, saine ou bien infectée. Cette classification se fait par le modèle VGG16. A cet effet, lors de l'implémentation du CNN, plusieurs modifications ont été apportées, afin d'atteindre les résultats voulus (tableau 4.2). Parmi elles, nous citons principalement le ratio entre les ensembles du test, de l'entraînement ainsi que de la validation, pour optimiser au maximum le système. L'augmentation des données, l'ajout de la couche dropout, ainsi que le choix de l'optimiseur, ont permis l'obtention de résultats satisfaisants (figures 4.6, 4.7 et 4.8).

Modèle	Précision d'entraînement	Précision de la validation	Perte d'entraînement	Perte de la validation
VGG16	97.5%	94.2%	0.8%	1.7%

Tableau 4. 2 : Résultats de la classification des pneumonies par le modèle VGG16

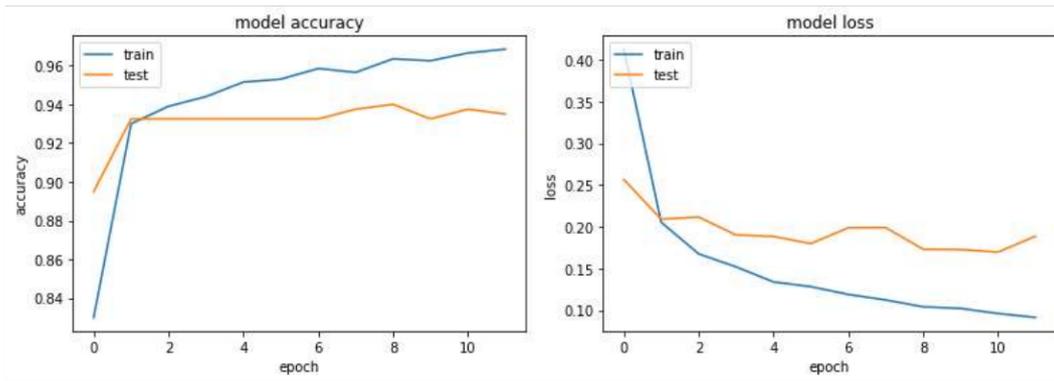


Figure 4. 7 : Courbe de la précision pour VGG16

Figure 4. 6 Courbe de la perte pour VGG16

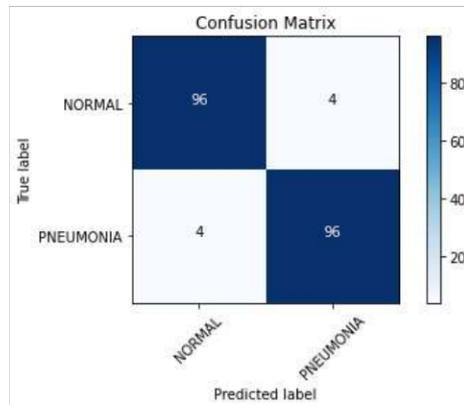


Figure 4. 8 : Matrice de confusion vgg16

4.10 Résultats de la classification des pneumonies par le modèle VGG19

La base de données radiographiques des poumons, est classifiée dans ce cas, par le modèle VGG19. En adoptant les mêmes métriques que précédemment, les résultats obtenus avec le VGG19, ont généré une précision de 97.7% (tableau 4.3, figures 4.9, 4.10 et 4.11).

Modèle	Précision d'entraînement	Précision de la validation	Perte d'entraînement	Perte de la validation
VGG19	97.7%	94.25%	0.713%	1.693%

Tableau 4. 3 : Résultats de la classification des pneumonies par le modèle VGG19

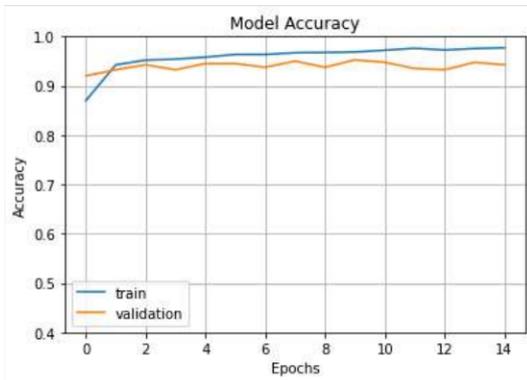


Figure 4. 10 : Courbe de la précision pour VGG19

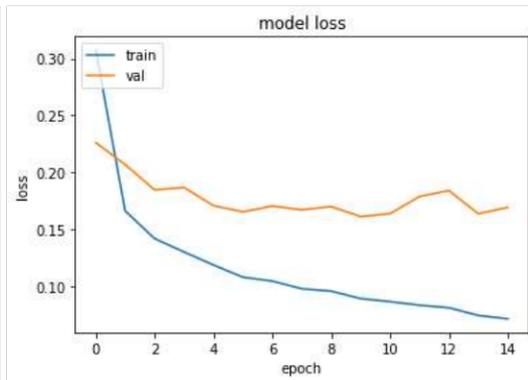


Figure 4. 9 : Courbe de la perte pour VGG19

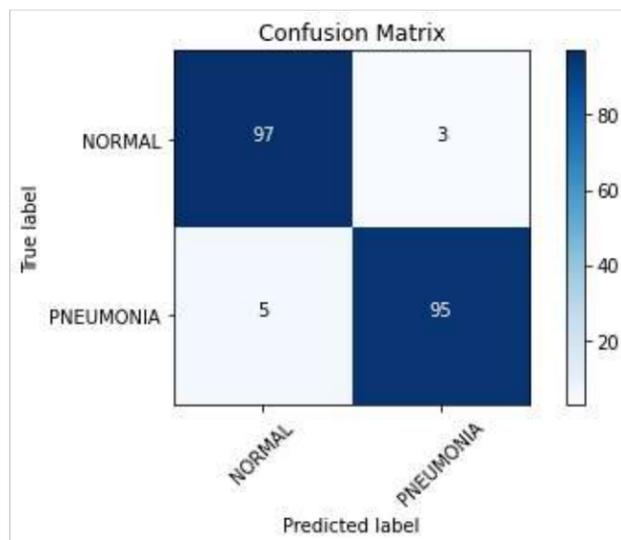


Figure 4. 11 : Matrice de confusion pour VGG19

4.11 Résultats de la classification des pneumonies par le modèle resnet50

La classification des pneumonies et des cas sains, avec le modèle Resnet50, a engendré une meilleure précision que pour les autres modèles (tableau 4.4, figures 4.12, 4.13 et 4.14).

Modèle	Précision d'entraînement	Précision de la validation	Perte d'entraînement	Perte de la validation
Resnet50	98.6%	96.25%	0.422%	1.068%

Tableau 4. 4 ; Résultats de la classification des pneumonies par le modèle Resnet50

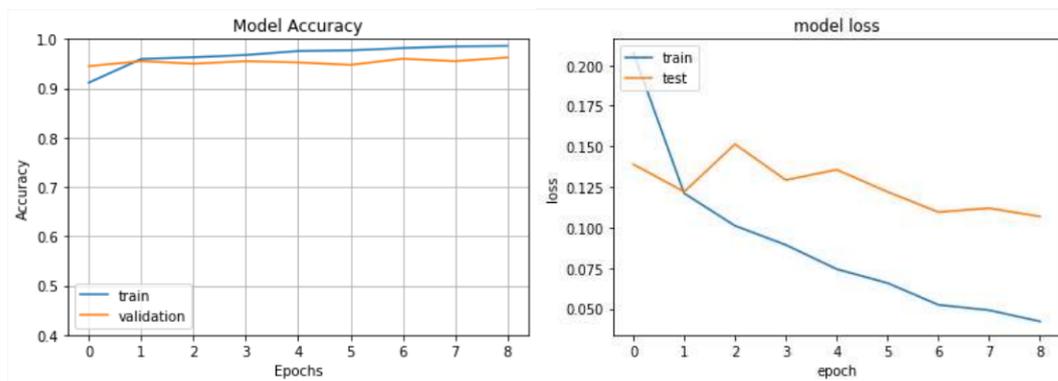


Figure 4. 13 : Courbe de la précision pour Resnet50

Figure 4. 12 : Courbe de la perte pour Resnet50

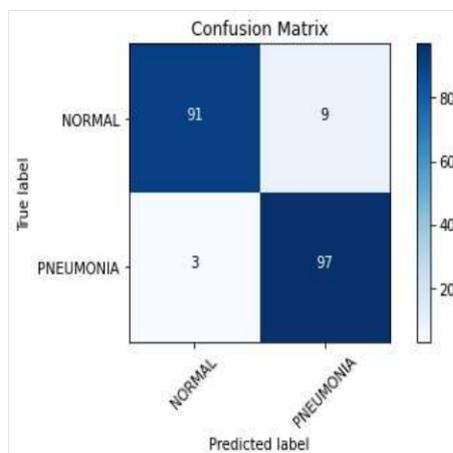


Figure 4. 14 Matrice de confusion pour Resnet50

4.12 Résultats de la classification des pneumonies par le modèle resnet50 (optimisateur RMSprop)

En changeant l'optimisateur ADAM par l'optimisateur RMSprop tout en gardant le même modèle resnet50, pour classifier les images radiographiques des pneumothorax, nous avons obtenu les résultats illustrés par les figures 4.15, 4.16, 4.17 et le tableau 4.5.

Modèle	Précision d'entraînement	Précision de la validation	Perte d'entraînement	Perte de la validation
Resnet50 (RMSprop)	98%	95%	0.8%	2.5%

Tableau 4. 5 : Résultats de la classification des pneumonies par le modèle resnet50 (optimisateur RMSprop)

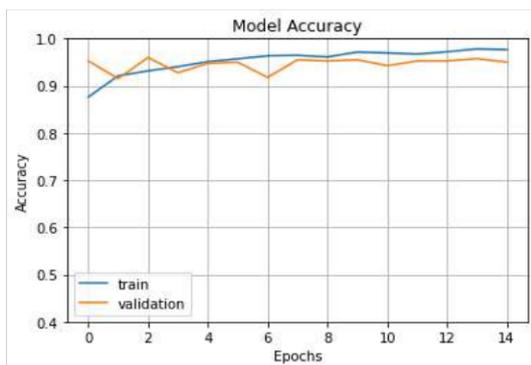


Figure 4. 16 : Courbe de la précision pour Resnet50 (rmsprop)

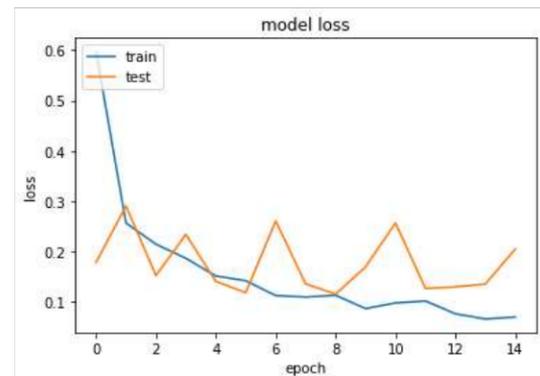


Figure 4. 15 : Courbe de la perte pour Resnet50 (rmsprop)

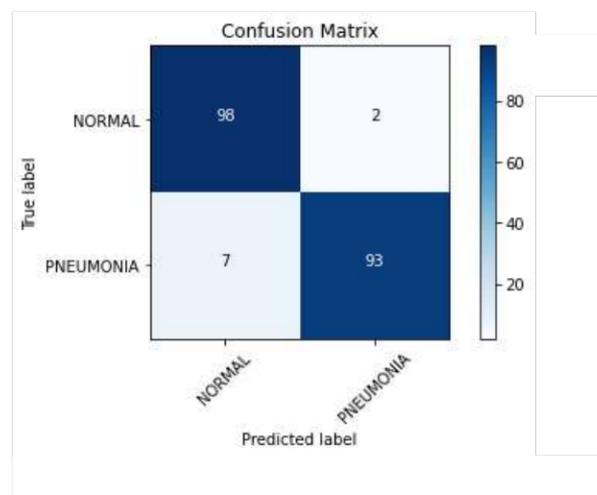


Figure 4. 17 Matrice de confusion

4.13 Comparaison des résultats obtenus entre les différents modèles utilisés

Le tableau 4.6 regroupe les résultats obtenus suivant les modèles adoptés, dans le système 'PneumoCNNV2.1'. Nous remarquons dans ce cas, des résultats à peu près similaires entre les différents modèles utilisés, avec une meilleure précision d'entraînement (98.6%) et de validation (96.25%), une perte moins importante pour l'entraînement (0.0422) ainsi que la validation (0.1068), en utilisant le modèle Resnet50. Le modèle VGG16 génère une précision d'entraînement de 97.5 % et de validation de 94.2%, une perte d'entraînement de 0.08 ainsi qu'une perte de validation de 0.17. Les résultats obtenus par le modèle VGG19, ont donné une précision d'entraînement de 97.7 et une validation de 94.25, une perte d'entraînement de 0.0713 ainsi que celle de la validation de 0.1693.

Les différents modèles adoptés, ont été générés avec des itérations, où chacune d'elles, est réalisée par un pas de 200.

Modèle	Précision d'entraînement	Précision de validation	Perte d'entraînement	Perte de validation	Nombre d'itérations	Temps d'exécution
VGG16	97.5%	94.2%	0.8%	1.7%	11	12 min
VGG19	97.7%	94.25%	0.713%	1.693%	14	14min
Resnet50	98.6%	96.25%	0.422%	1.068%	14	10min
Resnet50 (RMSprop)	98%	95%	0.8%	2.5%	14	10min

Tableau 4. 6 : Comparaison des résultats obtenus entre les différents modèles utilisés

Nous remarquons aussi, que lors de l'utilisation du modèle resnet50, en changeant l'optimisateur 'Adam' par 'RMSprop', les performances diminuent légèrement, au niveau de la précision. Mais nous constatons une grande différence au niveau des pertes atteintes qui représentent quasiment le double, qu'avec l'optimiseur 'ADAM'. En effet, le modèle 'Resnet50' (Adam) indique une perte de 0.0422 pour l'entraînement et de 0.1068, pour la validation ; alors que pour le même modèle mais avec l'optimisateur RMSprop, nous voyons une valeur de 0.08 pour la perte d'entraînement et, 0.25 pour la validation.

4.14 Comparaison des résultats de la classification avec des travaux connexes

Le tableau ci-dessous, permet de comparer les résultats obtenus, au niveau de la précision, de la perte et du nombre d'itérations, lors de la classification d'images pulmonaires, issus de notre étude avec d'autres travaux du laboratoire 'LATSI' [35].

Modèle	Précision d'entraînement	Précision de la validation	Perte d'entraînement	Perte de la validation	Nombre d'itérations
VGG16	97.5%	94.2%	0.8%	1.7%	11
VGG19	97.7%	94.25%	0.713%	1.693%	14
Resnet50	98.6%	96.25%	0.422%	1.068%	14
VGG19 [35]	94.35%	93%	1.58%	1.26%	25

Tableau 4. 7 : Comparaison des résultats de la classification avec des travaux connexes

Le tableau ci-dessus, nous permet de remarquer que les résultats obtenus par la nouvelle version de 'PneumoCNNV2.1, sont meilleurs que dans les travaux précédents [35], avec une différence d'environ 1 à 4% dans la précision d'entraînement et de validation. Nous remarquons aussi de meilleurs résultats au niveau de la perte d'entraînement, qui est un peu plus de 20 fois inférieure aux travaux cités. En revanche, la perte au niveau de la validation, est largement meilleure (10 fois inférieure au nouveau système), selon le projet précédent [35]. Ces résultats pourraient bien s'expliquer par la différence du nombre d'itérations utilisé lors des deux études. En effet, le nombre d'itérations suivant cette étude, est de 14 avec un pas de 200 par itération ; alors que pour les travaux de Meradi et Khemis [35], il est au nombre de 25, mais un nombre d'étapes inconnu, par manque d'information.

4.15 Conclusion

Dans ce chapitre nous avons présenté le système de classification réalisé, sur des images radiographiques pneumologiques réelles.

L'application 'PneumoCNNV2.1', a été développée en utilisant trois différents modèles de CNN pré-entraînés : VGG16, VGG19, ainsi que le ResNet50. Elle a permis la classification de plusieurs images radiographiques pulmonaires en deux classes : normale et pneumonie, en adoptant plusieurs paramètres. Les résultats obtenus sont prometteurs, puisqu'ils présentent une précision dépassant les 98% pour le modèle Resnet.

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 du département d'électronique de l'université de Blida 1, pour la conception de systèmes d'aide au diagnostic en imagerie médicale.

Lors de l'étude effectuée dans ce mémoire, un système d'aide au diagnostic a été réalisé, afin de détecter les anomalies pulmonaires, issues d'images réelles de radiographie pulmonaire pédiatrique. Le système 'PneumoCNNV2.1' a été implémenté avec les modèles VGG16, VGG19 et ResNet50, en tenant compte de la modification de certains paramètres, comme les optimiseurs, le nombre d'itérations, ou parfois l'ajout de couche 'drop out', pour la performance des résultats.

Cette approche a permis d'offrir une précision de 97.5% pour l'entraînement et 94.2% pour la validation, avec le modèle du VGG16. Le modèle VGG19 a généré une précision de 97.7% pour l'entraînement et 94.25% pour la validation.

Le modèle Resnet50 a généré une précision de 98.6% pour l'entraînement et 95% pour la validation.

Ces résultats sont satisfaisants et permettent d'indiquer une très bonne précision, lors de l'élaboration du diagnostic afin d'aider les radiologues, pour la classification de pneumologies.

Nous avons rencontré quelques problèmes lors de l'implémentation, tels qu'un temps d'exécution lent, à cause de l'utilisation de la CPU qui a été réglé heureusement, en utilisant le GPU qui contient des puces de calcul 'cœurs CUDA'. Ces puces nous ont permis d'optimiser et d'accélérer énormément le temps d'exécution, tout en gardant une fiabilité sans faille.

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

- Fournir davantage d'échantillons de données, afin d'améliorer les résultats.
- Utiliser d'autres modèles et d'autres réglages, pour améliorer la précision.
- Combiner deux CNN.
- Explorer d'autres modalités pour la détection de pneumonies.
- Etudier le Covid-19 et ses variants à travers le deep learning.

Bibliographie

[1] R. L. Newell. Anatomy of the post-laryngeal airways lungs and diaphragm, Surgery(Oxford), 29(5), 199-203, 2011.

[2] Dictionnaire francais. Définition de la pathologie, <https://www.larousse.fr/dictionnaires/francais/pathologie/58644>, date de consultation, décembre 2020.

[3] Institut canadien pour la sécurité des patients. Pneumothorax : Importance pour les patients et leurs familles, <https://www.patientsafetyinstitute.ca/fr/toolsresources/Hospital-Harm-Measure/Improvement-Resources/Pneumothorax/Pages/Importance-to-Patients-and-Families.aspx> date de consultation, décembre 2020.

[4] H.Popper. Pathology of lung disease. Springer-Verlag Berlin Heidelberg, doi:DOI 10.1007/978-3-662-50491-8, 2017.

[5] Université de la Sorbonne. Cours de Bactériologie, <http://www.chups.jussieu.fr/polys/bacterio/bacterio/POLY.Chp.12.html>, date de consultation, décembre 2020.

[6] F. X. Slosman Tuberculose pulmonaire, <https://www.info-radiologie.ch/tuberculose-pulmonaire.php>, date de consultation, décembre 2020.

[7] World health organization. Pneumonia, who: <https://www.who.int/fr/news-room/fact-sheets/detail/pneumonia>, 2019, date de consultation, décembre 2020.

[8] Dictionnaire Vidal. Pneumonie, <https://www.vidal.fr/maladies/voies-respiratoires/pneumonie.html>, date de consultation, juillet 2020, décembre 2020.

[9] World health organization. Cancer, who: <https://www.who.int/fr/news-room/fact-sheets/detail/cancer>, mars 2021, date de consultation, avril 2021.

[10] Société canadienne du cancer. Nodules pulmonaires, <https://www.cancer.ca/fr-ca/cancer-information/cancer-type/lung/lung-cancer/lung-nodules/?region=on>, date de consultation, décembre 2020.

[11] Mon réseau cancer du poumon. Les cancers du poumon "non à petites cellules" dits CBNPC, <https://www.monreseau-cancerdupoumon.com/dossiers/mieux-comprendre/les-differents-types-de-cancers-du-poumon/les-cancers-du-poumon-non-a-petites-cellules-dit-cbnp>, date de consultation, décembre 2020.

[12] A. Micheau. Classification TNM du cancer du poumon, <https://www.imaios.com/fr/imcases/training/186507/classification-tnm-du-cancer-du-poumon>, date de consultation, décembre 2020.

[13] A. Maier, S. Steidl, V. Christlein, . J. Hornegger. Medical Imaging Systems, an introductory guide, Springer nature, 2018.

[14] J. J Samuëli. Découverte des rayons X par Röntgen, <http://journals.openedition.org/bibnum/714>, date de consultation, 2009, décembre 2020.

[15] E. Angelini. Imagerie par rayons X, [https://perso.telecom-paristech.fr/bloch/P6Image/Cours ACIMED xray 2007.pdf](https://perso.telecom-paristech.fr/bloch/P6Image/Cours_ACIMED_xray_2007.pdf), Ecole nationale supérieure des télécommunications, Paris, France, 2017, date de consultation, décembre 2020.

[16] S. Ronze. La radiographie du thorax, https://www.doctissimo.fr/html/sante/imagerie/radiographie_poumon.html, 2017, date de consultation, décembre 2020.

[17] Info-radiologie. Tomodensitométrie du thorax (scanner thoracique), <https://www.info-radiologie.ch/but-scanner-thorax.php>, date de consultation, décembre 2020.

[18] Thales. Qu'est-ce que l'intelligence artificielle et le machine learning ?
<https://justaskthales.com/fr/quest-ce-que-lintelligence-artificielle-et-le-machine-learning/>, date de consultation, décembre 2020.

[19] K. Dahmane. Analyse d'images par méthodes de deep learning appliquée au contexte routier en conditions météorologiques dégradées, thèse de doctorat en électronique et systèmes, université Clermont, Auvergne, France, 2020.

[20] N. Salem. Analyse profonde d'images ultrasonores pour la détection du cancer du sein, mémoire de Master en Electronique, université de Blida 1, Algérie, 2020.

[21] Y. Djeriri. Les réseaux de neurones artificiels, université de Lyon,
https://www.researchgate.net/figure/Modele-dun-neurone-biologique_fig7_319939107, septembre 2017, date de consultation en juin 2021.

[22] D. Belhaouci. Démystifier le Machine Learning, Partie 2 : les Réseaux de Neurones artificiels,
<https://www.juripredis.com/fr/blog/id-19-demystifier-le-machine-learning-partie-2-les-reseaux-de-neurones-artificiels>, date de consultation en mai 2021.

[23] C. TOUZET, les reseaux de neuronesartificiels introduction au connexionnisme, cours, exercices et travaux pratiques. EC2, Collection de l'EERIE, N. Giambiasi, Juillet 1992.

[24] A. Amidi, S. Amidi. Réseaux de neurones récurrents,
<https://stanford.edu/~shervine/l/fr/teaching/cs-230/pense-bete-reseaux-neurones-recurrents>, date de consultation, janvier 2021.

[25] N. Neeta, K.V Santosh, R. Balasbramanian. Deep learning for computer vision, Springer, 2019, date de consultation juin 2021.

[26] M. héon. Application des réseaux de neurones dans le développement d'algorithmes de restauration d'images appliqués à la tomographie par émission de positrons, mémoire de master, université de Sherbrooke, Canada, 1998,
https://www.researchgate.net/figure/5-Diagramme-de-lapprentissage-supervise-Lapprentissage-par-renforcement-est-utilise_fig2_245024790, date de consultation, mai 2021.

[27] M. Mandal. Réseaux de neurones convolutifs, <https://ichi.pro/fr/reseaux-de-neurones-convolutifs-cnn-238106537306603>, date de consultation, avril 2021.

[28] M. Chane. Classification des images médicales : comprendre le réseau de neurones convolutifs (CNN), <https://www.imaios.com/fr/Societe/blog/Classification-des-images-medicales-comprendre-le-reseau-de-neurones-convolutifs-CNN>, février 2021, date de consultation, juin 2021.

[29] Y. S. Obam. Comprendre les réseaux de neurones convolutifs (CNN), <https://yannicksergeobam.medium.com/comprendre-les-r%C3%A9seaux-de-neurones-convolutifs-cnn-d5f14d963714>, 2019, date de consultation, juin 2021.

[30] M. Chane. Classification en imagerie médicale : mes architectures CNN les plus performantes en 2021, https://www.imaios.com/fr/Societe/blog/Classification-en-imagerie-medicale-les-architectures-CNN-les-plus-performantes-en-2021?fbclid=IwAR1mfWsSO9gBxskOqXoM_WgcYZVQwNagbT6JcEI_AW5U9K_h1bfhtldYFqU, 2021, date de consultation, mars 2021.

[31] VGG16 architecture, <https://iq.opengenus.org/vgg16/>, date de consultation avril, 2021.

[32] V. Thibault. Qu'est-ce que le modèle VGG ? <https://datascientest.com/quest-ce-que-le-modele-vgg> , date de consultation avril 2021.

[33] Understanding the VGG19 architecture. <https://iq.opengenus.org/vgg19-architecture/>, date de consultation, mai 2021.

[34] Y. Zheng, C. Yang, A. Merkulov. Breast cancer screening using convolution neural network and follow up digital mammography, Proceedings Volume 10669, Computational Imaging III; 1066905, https://www.researchgate.net/figure/illustration-of-the-network-architecture-of-VGG-19-model-conv-means-convolution-FC-means_fig2_325137356, 2018, date de consultation, mai 2021.

[35] Y. Meradi, S. Khemis. Analyse automatique d'images pulmonaires pour la détection de pathologies oncologiques et de pneumopathies, mémoire de master en Electronique, université de Blida 1, Algérie, 2020.

[36] F. Demir, DeepCoroNet: A deep LSTM approach for automated detection of COVID-19 cases from chest X-ray images, Applied Soft Computing Journal, Vol.103, 16.-170,2021.

[37] T. Ozturk, Muhammed Talo, Eylul Azra Yildirim, Ulas Baran Baloglu, Ozal Yildirim, U. R. Acharya, Automated detection of COVID-19 cases using deep neural networks with X-ray images, <http://www.elsevier.com/locate/combiomed>, date de consultation juin 2021.

[38] Python. <https://docs.python.org/3/>, date de consultation, janvier 2021.

[39] Anaconda: <https://anaconda.org/>, date de consultation, janvier 2021.

[40] spyder. (s.d.). spyder: <https://www.spyder-ide.org/>, date de consultation, janvier 2021.

[41] Scipy <https://www.scipy.org/docs.html>, date de consultation, janvier 2021.

[42] S. Bancal. Introduction à Numpy, <https://enacit.epfl.ch/cours/python/scientifique/numpy.html#numpy>, consulté en janvier 2021.

[43] EDUCBA. Introduction to Tensorflow, <https://www.educba.com/introduction-to-tensorflow>, consulté en janvier 2021.

[44] Keras. <https://keras.io/>, date de consultation, janvier 2021.

[45] Matplotlib. <https://matplotlib.org/stable/contents.html>, date de consultation, janvier 2021.

[46] Pandas. <https://pandas.pydata.org/pandas-docs/stable/>, date de consultation, janvier 2021.

[47] D. Kermany, K. Zhang, M. Goldbaum. Chest X-ray images for classification, <https://data.mendeley.com/datasets/rscbjbr9sj/2>, date de consultation, avril 2021.