



RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE  
الجمهورية الجزائرية الديمقراطية الشعبية  
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE  
SCIENTIFIQUE  
وزارة التعليم العالي والبحث العلمي  
FACULTÉ DE TECHNOLOGIE  
DÉPARTEMENT DE GÉNIE BIOMÉDICAL

## MEMOIRE

Présenté pour l'obtention du diplôme de:

### MASTER

En: GÉNIE BIOMÉDICAL

Spécialité: Imagerie Médicale

Par:

**BOUDJEMAA Hadjar**

Sujet

---

## Diagnostic automatique des pathologies pulmonaires par l'analyse des images radiologiques thoraciques

---

soutenu publiquement le 25 juin 2025, devant le jury composé de :

Mr HADJ SLIMANE Zinne Eddine	Pr	Université de Tlemcen	Président
Mme HEDEILI Nawel	MAA	Université de Tlemcen	Examinatrice
Mr Youbi Ridha	MAA	Université de Tlemcen	Encadreur

Année universitaire 2024/2025



## *Remerciements*

Tout d'abord Je remercie Allah de m'avoir donné la force et le courage pour réaliser ce travail.

Je remercie aussi toutes les personnes qui ont soutenu mon idée et m'ont accompagné dans la réalisation de ce projet.

Un grand merci à mes parents pour leur amour, leur patience et leur soutien constant.

Je tiens à remercier Monsieur Youbi Reda, mon encadrant, pour son aide, ses conseils et son accompagnement tout au long de ce projet.

Enfin, je remercie du fond du cœur ma famille et mes amies pour leur présence constante, leurs encouragements et leur soutien tout au long de ce parcours.

– *Hadjar*

## *Dédicace*

Je dédie ce travail à toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce projet

- À mes parents, pour leur soutien constant et leurs sacrifices tout au long de mon parcours. Merci du fond du cœur.
- À mes frères, pour leurs encouragements et leur présence dans les moments difficiles.
- À mes amies, pour leur aide, leurs conseils et leurs sourires qui m'ont beaucoup apporté.

– *Hadjar*

## *Résumé*

Les pathologies pulmonaires infectieuses représentent un enjeu majeur de santé publique mondiale, causant chaque année une forte morbidité et mortalité. La radiographie thoracique (CXR), bien que couramment utilisée pour son accessibilité, présente des limites liées à la difficulté d'interprétation des images. Pour mieux résoudre ces problèmes, l'intelligence artificielle, notamment l'apprentissage profond, offre des solutions prometteuses.

L'objectif de ce travail est de développer des modèles d'apprentissage profond pour détecter et classifier automatiquement des pathologies pulmonaires infectieuses (pneumonie bactérienne, pneumonie virale, tuberculose) à partir de radiographies thoraciques. Quatre architectures CNN ont été proposées : un modèle classique et trois modèles pré-entraînés (ResNet50, EfficientNetB0, DenseNet121) appliqués à des bases de données médicales, produisant des résultats encourageants. Les modèles visent à assister les cliniciens dans leurs décisions diagnostiques, contribuant ainsi à une meilleure prise en charge des patients.

**mots-clés:** Intelligence Artificielle, apprentissage profond, Réseaux neuronaux convolutifs (CNN), Radiographie thoracique, Modèles pré-entraînés (ResNet50, EfficientNetB0, DenseNet121).

# *Abstract*

Pulmonary pathologies, particularly infectious diseases, represent a major challenge of global public health, causing high morbidity and mortality each year. The chest X-ray (CXR), although commonly used for its accessibility, presents limitations related to the difficulty of interpreting images. To better solve these problems, artificial intelligence, notably Deep learning offers promising solutions.

The objective of this work is to develop deep learning models to automatically detect and classify pulmonary pathologies infectious (bacterial pneumonia, viral pneumonia, tuberculosis) from chest X-rays. Four CNN architectures have been proposed: a classic model and three pre-trained models (ResNet50, EfficientNetB0, DenseNet121) applied to medical databases, producing encouraging results. The models aim to assist clinicians in their diagnostic decisions, thereby contributing to better management of patients.

**keywords:** Artificial Intelligence, deep learning, Convolutional Neural Networks (CNN), chest X-ray, Pre-trained models (ResNet50, EfficientNetB0, DenseNet121).

## مُلخَص

تمثل الأمراض الرئوية المعدية تحديًا كبيرًا للصحة العامة العالمية، مما يسبب كل عام معدلات عالية من المرض والوفيات. الأشعة السينية للصدر (CXR) على الرغم من استخدامها بشكل شائع لالوصولية، تواجه حدودًا تتعلق بصعوبة تفسير صور. لحل هذه المشاكل بشكل أفضل، الذكاء الاصطناعي، لا سيما التعلم العميق، يقدم حلولاً واعدة. في هذا العمل، الهدف هو تطوير نماذج تعلم عميق قادرة على اكتشاف وتصنيف تلقائي لبعض الأمراض الرئوية المعدية (الالتهاب الرئوي البكتيري، الالتهاب الرئوي الفيروسي والسل) من صور الأشعة السينية للصدر. لقد اقترحنا أربع هياكل لشبكات الأعصاب التلافيفية: نموذج (CNNclassique)، بالإضافة إلى ثلاثة نماذج مدربة مسبقًا (ResNet50, EfficientNetB0, DenseNet121)، المطبقة على قواعد بيانات طبية، والتي سمحت بالحصول على نتائج مشجعة تهدف النماذج إلى مساعدة الأطباء في عملهم القرارات التشخيصية، مما يساهم في تحسين الرعاية المرضى

**الكلمات المفتاحية:** الذكاء الاصطناعي، التعلم العميق، الشبكات العصبية التلافيفية، الأشعة السينية للصدر، نماذج مسبقة التدريب (ResNet50, EfficientNetB0, DenseNet121).

# Table des matières

<b>Remerciements</b>	<b>ii</b>
<b>Dédicace</b>	<b>iii</b>
<b>Table des matières</b>	<b>vii</b>
<b>Liste des Figures</b>	<b>xii</b>
<b>Liste des Tableaux</b>	<b>xvi</b>
<b>Introduction générale</b>	<b>1</b>
<b>Chapitre 01 :</b>	
<b>Les pathologies pulmonaires et l'imagerie médicale : étude théorique</b>	<b>3</b>
1 Introduction . . . . .	4
2 Les pathologies pulmonaire . . . . .	4
2.1 Anatomie des poumons humains . . . . .	4
2.2 Les types des pathologies pulmonaires . . . . .	5
2.2.1 Pathologies des voies respiratoires chroniques . . . . .	5
2.2.2 Pathologies du tissu pulmonaire . . . . .	6
2.2.3 Pathologies de la circulation pulmonaire . . . . .	6
2.3 Les pathologies pulmonaires plus fréquentes . . . . .	6
2.3.1 Asthme . . . . .	6
2.3.2 La broncho-pneumopathie chronique obstructive (BPCO) . . . . .	7
2.3.3 Pneumonie . . . . .	8
2.3.4 infection pulmonaire chronique (tuberculoise ) . . . . .	9
2.3.5 Coronavirus . . . . .	10
2.3.6 Bronchite . . . . .	11
2.3.7 Cancer des poumons . . . . .	12
2.3.8 L'emphysème . . . . .	13

3	L'imagerie médicale . . . . .	15
3.1	Les principaux types d'imagerie médicale . . . . .	15
3.1.1	La Radiographie standard . . . . .	15
3.1.2	Tomodensitométrie . . . . .	16
3.1.3	Imagerie par Résonance Magnétique . . . . .	18
3.1.4	L'échographie . . . . .	19
4	Conclusion . . . . .	21

**Chapitre 02 :**

	<b>Applications des approches de l'intelligence artificielle : État de l'art</b>	<b>22</b>
1	Introduction . . . . .	23
2	L'intelligence artificielle . . . . .	23
2.1	Définition et historique de l'intelligence artificielle . . . . .	23
3	L'apprentissage machine (machine Learning) . . . . .	24
3.1	Définition de l'apprentissage machine . . . . .	24
3.2	Fonctionnement De l 'apprentissage machine . . . . .	24
3.3	Les différents type de machine Learning . . . . .	24
3.3.1	Apprentissage supervisé . . . . .	24
3.3.2	Apprentissage non-supervisé : . . . . .	24
3.3.3	Apprentissage par renforcement . . . . .	25
4	Les réseaux neuronaux artificiels . . . . .	25
4.1	Définition des réseaux de neurones . . . . .	25
4.2	L'architecture d'un réseau neuronale . . . . .	25
4.3	Les neurones biologiques . . . . .	26
4.4	Des neurones biologiques vers les neurones artificiels . . . . .	27
4.5	L'apprentissage . . . . .	28
5	L'apprentissage profond (deep Learning) . . . . .	28
5.1	Définition et fonctionnement de l'apprentissage profond . . . . .	28
5.2	Types des réseaux de neurones profonds . . . . .	29
5.2.1	Réseau neuronal feedforward . . . . .	29
5.2.2	Les réseaux de neurones récurrents(RNN) . . . . .	30
5.2.3	Les réseaux de neurones convolutifs (CNN) . . . . .	30
5.3	L'apprentissage profond vs. L'apprentissage automatique . . . . .	30
6	Réseaux neurones convolutif (Convolutional Neural Networks) . . . . .	31
6.1	L'architecture des réseaux convotutif (CNN) . . . . .	31
6.2	Les couches de réseaux de neurone convolutif (CNN) . . . . .	32
6.2.1	Couches convolitionnelle (Convolutional layer) : . . . . .	32

	6.2.2	La couche pooling (Pooling Layer):	33
	6.2.3	Fully connected layer	34
6.3		Les fonctions d'activation	34
	6.3.1	Fonction ReLU(Rectified Linear Unit )	34
	6.3.2	Fonction Sigmoid	34
	6.3.3	Fonction Softmax	35
	6.3.4	Fonction Tanh	35
6.4		Les architectures les plus courants	36
	6.4.1	leNet-5	36
	6.4.2	VGGNet	37
	6.4.3	GoogLeNet	37
	6.4.4	ResNet	38
7		État de l'art	40
	7.1	Introduction	40
	7.2	Les travaux connexes	40
	7.2.1	Rahul Hooda et al :	40
	7.2.2	Ferhat Ucar, Deniz Korkmaz	40
	7.2.3	Bar, Diamant , Wolf , Lieberman , Konen et Greenspan	41
	7.2.4	Ayaz M, Shaukat F et Raja G:	42
	7.2.5	R Sivaramakrishnan et al:	42
	7.2.6	Goram Mufarah M. Alshmrani et al	43
	7.2.7	T. Mahmud et al	43
	7.2.8	Syeda Shaizadi Meraj	43
	7.2.9	Jianpeng Zhang et al	44
	7.2.10	Dipayan Das, K.C. Santosh et Umapada Pal	44
	7.2.11	I.Khan, J. L. Shah, et M. M. Bhat	45
	7.2.12	M. Chetoui et al	45
	7.2.13	S. Toraman, T. B. Alakus et I. Turkoglu	46
	7.2.14	Eduardo Luz et al	46
	7.2.15	Sagar Kora Venu and Sridhar Ravula	47
	7.2.16	C. Ouchicha, O. Ammor et M. Mekkassi	47
	7.2.17	Harsh Sharma, Jai Sethia Jain, Priti Bansal et Sumit Gupta	48
	7.2.18	Alexander Wong, Zhong Qiu Lin et Linda Wan	48
	7.2.19	D.Apostolopoulos et T.A. Mpesiana	49
	7.2.20	R. Sarki, K. Ahmed, H. Wang, Y. Zhang, and K. Wang	49
	7.2.21	Khairul Munadi, et al	50
	7.2.22	Vo Trong Quang Huy et Chih-Min Lin	50

7.2.23	Nada M. Elshennawy et Dina M. Ibrahim . . . . .	51
7.2.24	Lingga Aji Andika, Hasih Pratiwi, et Sri Sulistijowati Handajani . . . . .	51
7.2.25	Ahmed Iqbal, Muhammad Usman et Zohair Ahmed . . . . .	52
7.2.26	Yuting Yang, Gang Mei et Francesco Piccialli . . . . .	52
8	Conclusion . . . . .	53
Chapitre 03 :		
Conception, méthodologie et mise en œuvre d'un système de diagnostic automatique		
54		
1	Introduction . . . . .	55
2	Environnement et outils de travail . . . . .	55
2.1	Google Colaboratory . . . . .	55
2.2	Langage de programmation Python . . . . .	55
2.3	Les bibliothèques utilisées . . . . .	56
2.3.1	Pytorch . . . . .	56
2.3.2	Pandas . . . . .	56
2.3.3	NumPy . . . . .	57
2.3.4	Torchvision . . . . .	57
2.3.5	Sklearn . . . . .	58
2.3.6	Matplotlib . . . . .	58
2.3.7	Opendatasets . . . . .	58
2.3.8	PIL (python image Library) . . . . .	59
2.3.9	Torchsummary . . . . .	59
3	Présentation du modèle proposé . . . . .	59
3.1	Architecture global du système . . . . .	61
4	Description du dataset . . . . .	62
5	Prétraitement des données . . . . .	63
6	Architecture des modèles: . . . . .	64
6.1	CNN classique: . . . . .	64
6.2	ResNet50 . . . . .	65
6.3	EfficientNetB0 . . . . .	66
6.4	Densnet121 . . . . .	67
7	Choix des hyper-paramètres . . . . .	67
7.1	Taux d'apprentissage (Learning Rate) . . . . .	67
7.2	Nombre époques (epoch) . . . . .	68
7.3	Batch size . . . . .	68
8	Conclusion . . . . .	68

<b>Chapitre 04 :</b>		
<b>Implémentation, Résultats expérimentaux et évaluation</b>		<b>69</b>
1	Introduction . . . . .	70
2	Évaluation du modèle . . . . .	70
2.1	Matrice de confusion . . . . .	70
2.2	Évaluation des performances . . . . .	71
2.2.1	Accuracy (ACC) . . . . .	71
2.2.2	Précision . . . . .	71
2.2.3	Recall . . . . .	71
2.2.4	F1-score . . . . .	71
3	Implémentation et processus d'entraînement . . . . .	72
3.1	L'importation des bibliothèques . . . . .	72
3.2	L'importation et utilisation des données . . . . .	72
3.3	Initialisation des paramètres . . . . .	74
4	Résultats expérimentaux et représentation graphique . . . . .	75
4.1	Classification de la Pneumonie (Multi-Classes) : modèle 01 . . . . .	75
4.1.1	CNN classique . . . . .	75
4.1.2	Resnet50 . . . . .	78
4.1.3	EfficientNetB0 . . . . .	79
4.1.4	DenseNet121 . . . . .	80
4.2	Tableau Récapitulatif (Classification de la Pneumonie multi-classe) . . . . .	81
4.3	Classification de la tuberculose (Binaire) : modèle 02 . . . . .	82
4.3.1	CNN classique . . . . .	82
4.3.2	Resnet50 . . . . .	83
4.3.3	EfficientNetB0 . . . . .	84
4.3.4	DenseNet121 . . . . .	85
4.4	Tableau Récapitulatif (Classification binaire de la Tuberculose ) . . . . .	86
5	Comparaison avec les travaux connexes et discussion . . . . .	87
5.1	Comparaison avec l'état de l'art . . . . .	87
5.1.1	Classification de la Pneumonie (Multi-Classes) : modèle 01 . . . . .	87
5.1.2	Classification de la tuberculose (Binaire) : modèle 02 . . . . .	88
6	Discussion et synthèse des résultats obtenus . . . . .	88
7	Conclusion . . . . .	89
<b>Conclusion</b>		<b>90</b>
<b>References</b>		<b>92</b>

## *Liste des Figures*

1	Anatomie des poumons humains (extrait de [7]). . . . .	5
2	la différence entre branche sain et asthmatique (extrait de [13]) . . . . .	7
3	l'effet de BPCO sur les branches (extrait de [[16]]) . . . . .	7
4	L'effet de la pneumonie sur les poumons (extrait de [18]) . . . . .	8
5	poumons infectés par la tuberculose (extrait de [22]) . . . . .	9
6	structure du coronavirus (extrait de [26]) . . . . .	10
7	L'effet de la bronchite (extrait de [28]) . . . . .	11
8	cancer du poumon (extrait de [29]) . . . . .	12
9	L'effet de l'emphysème sur les alvéoles (extrait de [32]) . . . . .	14
10	principe de fonctionnement de radiologie (extrait de [35]) . . . . .	16
11	Image radiographique thoracique (extrait de [35]) . . . . .	16
12	principe de fonctionnement de la tomодensitométrie (extrait de [36]) . . . . .	17
13	scanner (TDM) thoracique (extrait de [38]) . . . . .	17
14	principe de fonctionnement de la tomодensitométrie (extrait de [40]) . . . . .	18
15	image IRM du corps entier (extrait de [41]) . . . . .	19
16	les composants d'échographie (extrait de [43]) . . . . .	20
17	image radiographique pulmonaire (extrait de [44]) . . . . .	20
18	l'architecture d'un réseau neuronale (extrait de [47]) . . . . .	25
19	schéma d'un neurone biologique (extrait de [48]). . . . .	26
20	structure d'une synapse neuronale (extrait de [48]) . . . . .	26

---

21	schéma d'un neurone artificiel (extrait de [48]) . . . . .	27
22	schéma qui montre la position de chaque approche . . . . .	28
23	l'architecture de réseau de neuronal profond (extrait de [50]) . . . . .	29
24	l'architecture de réseau de neurones convolutif (extrait de [51]) . . . . .	31
25	Fonctionnement de la couche convolutif ( extrait de [54]) . . . . .	32
26	exemple de Fonctionnement de la couche de convolution supplémentaire (extrait de [54] . . . . .	33
27	fonction d'activation ReLU (extraite de [53]) . . . . .	34
28	fonction Sigmoidé (extrait de [55]) . . . . .	35
29	fonction Tanh (extrait de [57]) . . . . .	36
30	l'architecture de leNet-5 (extrait de [58]) . . . . .	36
31	l'architecture de VGG-16 (extrait de [60]) . . . . .	37
32	l'architecture de google net (extrait de [61]) . . . . .	38
33	L'architecture de ResNet-34 (extrait de [62] . . . . .	39
34	L'architecture de SqueezeNet( extrait de [64]) . . . . .	41
35	DeepCCXR architecture for COVID-19 detection [74] . . . . .	46
36	Architecture des couches ResNet-50 (extrait de [91]) . . . . .	60
37	Architecture des couches du modèle efficientNetB0 (extrait de [92]) . . .	60
38	Architecture des couches de modèle DensNet121 (extrait de [95]) . . . .	61
39	Figure 3.1: schema architecture global du système . . . . .	62
40	Architecture du CNN bisque . . . . .	65
41	L'architecture de ResNet 50 . . . . .	66
42	L'architecture de EfficientNetB0 . . . . .	66
43	L'architecture de DensNet121 . . . . .	67
44	matrice de confusion (extrait de [100]) . . . . .	70
45	les bibliothèques importées . . . . .	72

---

46	chargement des données du premier modèle . . . . .	72
47	dossier train de la base de données chest xray pneumonia (extrait de [96])	73
48	organisation initiale du dossier train (extrait de [96]) . . . . .	73
49	processus d'organisation des données . . . . .	74
50	chargement des données du premier modèle . . . . .	74
51	Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement . . . . .	75
52	Rapport de classification et matrice de confusion classification multi-classe . . . . .	76
53	Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement . . . . .	77
54	Rapport de classification et matrice de confusion classification multi-classe . . . . .	77
55	Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement . . . . .	78
56	Rapport de classification et matrice de confusion classification multi-classe . . . . .	78
57	Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement . . . . .	79
58	Rapport de classification et matrice de confusion classification multi-classe . . . . .	79
59	Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement . . . . .	80
60	Rapport de classification et matrice de confusion classification multi-classe . . . . .	80
61	Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement . . . . .	82
62	Rapport de classification et matrice de confusion classification multi-classe . . . . .	82

---

63	Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement . . . . .	83
64	Rapport de classification et matrice de confusion classification multi-classe . . . . .	83
65	Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement . . . . .	84
66	Rapport de classification et matrice de confusion classification multi-classe . . . . .	84
67	Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement . . . . .	85
68	Rapport de classification et matrice de confusion classification multi-classe . . . . .	85

## *Liste des Tableaux*

1	Paramètres d'entraînement selon les bases de données et les modèles utilisés . . . . .	74
2	Tableau Récapitulatif de la Classification de la Pneumonie . . . . .	81
3	Tableau Récapitulatif de la Classification de la Tuberculose . . . . .	86
4	Comparaison des performances de modèle 1 avec des travaux connexes	87
5	Comparaison des performances de modèle 2 avec des travaux connexes	88

# *Introduction générale*

Les maladies pulmonaires constituent un ensemble de troubles qui affectent les poumons et perturbent leur bon fonctionnement. Elles touchent des personnes de tous âges et de tous sexes, ce qui en fait un véritable enjeu de santé publique à l'échelle mondiale.

La radiographie du thorax, ou radiographie pulmonaire (CXR), est une modalité d'imagerie bien établie qui est largement utilisée pour rechercher des pathologies pulmonaires, pleurales et médiastinales [1]. La radiographie thoracique est le type d'imagerie médicale que les médecins demandent le plus souvent pour poser un diagnostic, car elle est efficace pour détecter les maladies des poumons ou les complications d'autres problèmes de santé. Cet examen aide à observer les symptômes et les soucis dans la zone de la poitrine. Étant non invasif et abordable, c'est donc un excellent outil pour diagnostiquer [2].

Cependant, l'interprétation des radiographies thoraciques peut être complexe. De nombreuses pathologies présentent des caractéristiques visuelles similaires, rendant leur différenciation difficile et augmentant le risque d'erreurs diagnostiques. Pour résoudre ces problèmes, des systèmes informatiques d'aide au diagnostic ont été créés pour soutenir les médecins dans l'analyse des images médicales et dans la détection des anomalies avec davantage de précision [3].

Dernièrement, les méthodes d'apprentissage profond, notamment les réseaux de neurones convolutifs (CNN), ont démontré un succès impressionnant dans le domaine de l'analyse d'images médicales. Ces réseaux profonds sont capables

d'extraire automatiquement des caractéristiques pertinentes à partir de grandes quantités de données, surpassant souvent les méthodes traditionnelles en termes de précision et d'efficacité [4].

L'objectif de ce travail est de fournir une analyse automatique des images radiologiques des pathologies pulmonaires : pneumonie(bactérienne, virale )et tuberculose en présentant quelques modèles établis sur des réseaux neuronaux convolutifs pour aider les médecins et radiologues à différencier ces pathologies avec une précision élevée et améliorer la prise en charge à partir des radiographies thoraciques. Ce mémoire est organisé de la manière suivante :

Chapitre 01 : Ce chapitre analyse l'anatomie et les pathologies pulmonaires. Il explore les méthodes d'imagerie médicale utilisées pour l'identification et le suivi et la prise de décision clinique.

Chapitre 02 : Ce chapitre présente l'intelligence artificielle et ses différentes approches, en mettant particulièrement l'accent sur celles qui constituent le fondement de notre étude. Il est également consacré à la présentation de plusieurs travaux connexes.

Chapitre 03 : Ce chapitre décrit l'architecture du système ainsi que les différentes étapes de sa conception et méthodologie.

Chapitre 04 : Ce chapitre expose les résultats obtenus de ce travail. Il inclut une analyse et discussion des performances.

*Chapitre 01:*  
*Les pathologies pulmonaires et l'imagerie*  
*médicale : étude théorique*

## 1 Introduction

Les poumons jouent un rôle fondamental dans le maintien de l'équilibre vital du corps humain, en assurant une oxygénation continue de tout l'organisme de la naissance à la mort. En raison de leur interaction directe avec l'environnement extérieur, ils sont constamment exposés à divers agents infectieux et polluants, ce qui les rend particulièrement susceptibles de développer une variété de maladies.

Ce chapitre présente une analyse théorique des principales pathologies pulmonaires, soulignant leurs mécanismes, leur effet sur la respiration et leur pertinence en matière de santé. De plus, nous examinerons les principales méthodes d'imagerie médicale utilisées pour leur identification, leur suivi et leur caractérisation, en mettant en évidence l'importance cruciale qu'elles ont dans le diagnostic et la prise de décision clinique.

## 2 Les pathologies pulmonaire

### 2.1 Anatomie des poumons humains

Le poumon est un organe intra-thoracique pair de l'appareil respiratoire situés au-dessus du diaphragme permettant le transfert de l'oxygène présent dans l'air vers le sang, et l'évacuation du dioxyde de carbone du sang vers l'air. Les poumons, gauche et droit, sont entourés de la plèvre, une membrane composée de deux couches qui les maintient adhérents à la paroi thoracique. Ils sont distincts et séparés par le médiastin au centre, où passent l'œsophage, la trachée et les bronches, et où se trouvent le cœur, les gros vaisseaux ainsi que les vaisseaux lymphatiques et les ganglions. Chaque poumon est composé de lobes, trois du côté droit et seulement deux du côté gauche en raison de la place occupée par le cœur. Chacun est relié à la trachée, par laquelle l'air circule, via la bronche principale.[5]. Chaque bronche se divise dans le poumon en bronches plus petites qui se dirigent vers les lobes pulmonaire puis elles continuent à se ramifier jusqu'à se terminer en bronchioles dans les alvéoles pulmonaires, celles-ci formant de petits sacs à l'extrémité de chacune assurent une fonction cruciale dans le système respiratoire. Figure 1 Collectivement, les millions de ces alvéoles couvrent une surface de plus de 100 mètres carrés. La surface interne des parois alvéolaires est traversée par un réseau dense de minuscules vaisseaux sanguins, appelés capillaires. La membrane extrêmement fine qui sépare l'air des capillaires facilite le transfert de l'oxygène des alvéoles vers le sang, tandis que le dioxyde de carbone passe des

capillaires sanguins vers les alvéoles. [6]

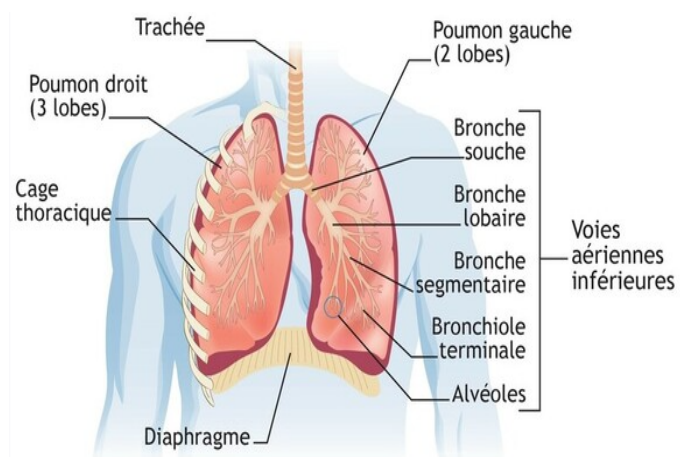


Figure 1: Anatomie des poumons humains (extrait de [7]).

## 2.2 Les types des pathologies pulmonaires

Les pathologies pulmonaires représentent des problèmes qui altèrent le bon fonctionnement des poumons. On distingue trois catégories principales de pathologies pulmonaires [8] :

### 2.2.1 Pathologies des voies respiratoires chroniques

Aussi appelées maladies obstructives des voies respiratoires, ces pathologies affectent les poumons ainsi que les voies respiratoires inférieures ou supérieures par lesquelles transitent l'oxygène et d'autres gaz. L'obstruction survient lorsque l'inflammation et le gonflement entraînent un rétrécissement ou une obstruction des voies respiratoires [9], rendant plus difficile l'expulsion de l'air des poumons. Les maladies respiratoires incluent l'asthme (d'après l'Organisation mondiale de la santé, elle touche 300 millions de personnes et a causé 255 000 décès en 2005 [10]), la broncho-pneumopathie chronique obstructive (BPCO) (sa prévalence mondiale atteignait 251 millions de cas en 2016 selon l'OMS. D'après les estimations de l'OMS en 2004, 64 millions de personnes en sont atteintes et 3 millions en meurent. L'OMS prévoit qu'en 2030 la BPCO deviendra la troisième cause de mortalité mondiale [11]), la bronchiolite et la bronchiectasie (qui est aussi la principale maladie des personnes atteintes de mucoviscidose). Ceux qui souffrent de ces maladies disent souvent qu'ils ont l'impression « d'expirer à travers une paille » [8].

### **2.2.2 Pathologies du tissu pulmonaire**

Ces pathologies altèrent la configuration du tissu pulmonaire. La cicatrisation ou l'inflammation de ce tissu limite la capacité des poumons à se dilater pleinement, caractérisant ainsi une maladie pulmonaire restrictive. De ce fait, les poumons éprouvent des difficultés à absorber l'oxygène et à expulser le dioxyde de carbone. Les individus atteints de telles affections décrivent fréquemment une sensation similaire à celle de « porter un vêtement trop serré ». Par conséquent, ils ne parviennent pas à respirer profondément. La fibrose pulmonaire et la sarcoïdose illustrent des exemples de pathologies du tissu pulmonaire[8].

### **2.2.3 Pathologies de la circulation pulmonaire**

Ces pathologies impactent les vaisseaux sanguins pulmonaires. Elles résultent de la coagulation, de la cicatrisation ou de l'inflammation des vaisseaux sanguins. Elles compromettent la capacité des poumons à assimiler l'oxygène et à expulser le dioxyde de carbone. Ces maladies peuvent aussi altérer la fonction cardiaque. L'hypertension pulmonaire constitue un exemple de maladie de la circulation pulmonaire. Les individus atteints de ces pathologies ressentent souvent une dyspnée accentuée lors d'efforts physiques[8].

## **2.3 Les pathologies pulmonaires plus fréquentes**

Les pathologies pulmonaires plus fréquentes comprennent :

### **2.3.1 Asthme**

L'asthme est une affection chronique caractérisée par l'inflammation et le rétrécissement des voies aériennes des poumons conduisant à des troubles respiratoires tels qu'une respiration sifflante, un essoufflement, une constriction thoracique et une toux [8].

Un individu souffrant d'asthme possède une muqueuse bronchique irritée et épaissie, ce qui rend les bronches réactives et prédisposées à des réponses exagérées lorsqu'elles sont exposées à des éléments déclencheurs. Cela peut provoquer une crise d'asthme : le flux d'air est entravé en raison de la contraction des muscles bronchiques et de la production abondante de mucus en réponse à un agent déclencheur, exacerbée par l'inflammation chronique[12].

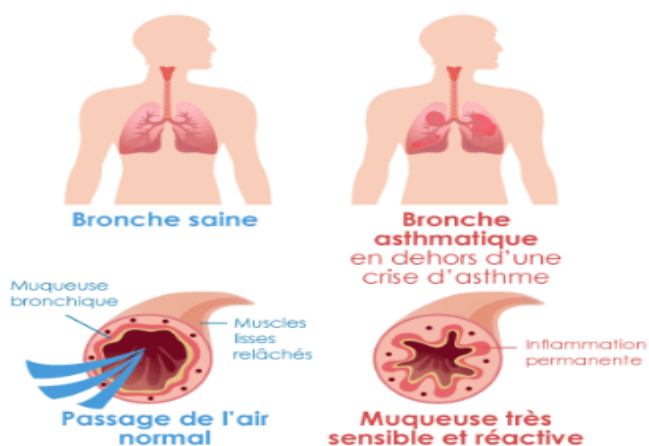


Figure 2: la différence entre branche sain et asthmatique (extrait de [13])

Une crise d'asthme peut durer de quelques minutes à plusieurs heures si elle n'est pas traitée. Elle peut survenir à n'importe quel moment, jour ou nuit. La fréquence et l'intensité des crises diffèrent selon le patient. Si l'asthme est causé par des allergies, comme durant la saison des pollens, les crises peuvent être plus courantes [14].

### 2.3.2 La broncho-pneumopathie chronique obstructive (BPCO)

C'est une maladie chronique du système respiratoire, Il s'agit d'une bronchite chronique peut progressivement s'aggraver et mener à une défaillance respiratoire caractérisée par une toux persistante et des problèmes de respiration principalement causée par le tabagisme dans 80% des cas [15].




Figure 3: l'effet de BPCO sur les branches (extrait de [[16]])

La broncho-pneumopathie chronique obstructive (BPCO) est due à une inflammation persistante des voies respiratoires, conduisant à :

- Un épaissement des structures bronchiques et bronchiolaires ;
- Une hausse de la sécrétion de mucus ;
- Une altération et une réduction de l'élasticité des bronchioles ;
- La dégradation des alvéoles des poumons, résultant en un emphysème pulmonaire [17].

### 2.3.3 Pneumonie

La pneumonie, également connue sous le nom de pneumopathie infectieuse, est une infection qui affecte spécifiquement les alvéoles pulmonaires, ces petites structures sphériques situées à l'extrémité des bronchioles par du liquide ou du pus. Elle concerne généralement un seul des cinq lobes pulmonaires (trois dans le poumon droit et deux dans le gauche), ce qui explique le terme de pneumonie lobaire. Lorsque l'infection s'étend également aux bronches, le terme bronchopneumonie est utilisé [18].

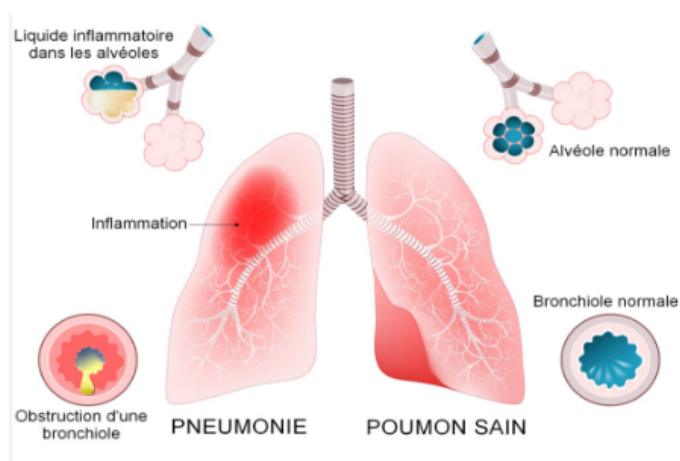


Figure 4: L'effet de la pneumonie sur les poumons (extrait de [18])

La pneumonie peut être provoquée par des microbes, des virus ou des moisissures. Les signes peuvent aller de légers à graves, et dépendent du type (pneumonie virale ou bactérienne). Ils peuvent inclure une toux avec ou sans sécrétions (une matière épaisse), de la fièvre, des frissons et des problèmes de respiration [19].

La pneumonie regroupe plusieurs types d'infections qui peuvent être légères ou dangereuses. Parfois, elle survient comme complication lors d'une maladie grave ou chez une personne âgée, et peut alors être mortelle. Il est très rare qu'une personne en bonne santé en décède, mais cela peut arriver [18].

### 2.3.4 infection pulmonaire chronique (tuberculeuse )

Les affections La tuberculose est une maladie contagieuse causée par le bacille tuberculeux (*Mycobacterium tuberculosis*), également connu sous le nom de bacille de Koch, qui appartient au groupe des mycobactéries. La transmission se fait par voie aérienne, affectant aussi bien les enfants que les adultes. Bien qu'elle affecte principalement les poumons (tuberculose pulmonaire), elle est également susceptible de toucher les reins, le cerveau, le tube digestif, la colonne vertébrale et la peau [20]. La tuberculose peut être mortelle si elle n'est pas traitée, mais la prise de médicaments conformément aux instructions permet presque toujours de guérir[21].




Figure 5: poumons infectés par la tuberculose (extrait de [22])

Il existe deux formes de la tuberculose : la première est la tuberculose latente, tandis que la seconde est la tuberculose active, également appelée tuberculose pathologique pour la tuberculose latente la bactérie reste au repos dans l'organisme pendant l'infection tuberculose latente. La personne ne présente aucun symptôme et n'est pas contagieuse.

La progression lente des signes de la tuberculose rend le contrôle de la diffusion difficile, et pour une tuberculose active la bactérie se développe dans le corps et dissémine dans l'organisme par les bronches, le sang ou la lymphe. Les personnes avec tuberculose pathologique sont très contagieuses entre deux et quatre semaines après l'infection. [23].

Les signes de la tuberculose peuvent être légers au début pendant plusieurs mois, puis devenir plus graves petit à petit comprennent une toux persistante avec du mucus et du sang, des douleurs dans la poitrine, difficulté à respirer et la fatigue. Dans le cadre de la réaction du corps contre la bactérie, les personnes avec la tuberculose ont souvent de la fièvre, moins envie de manger, et perdent du poids [24].

### 2.3.5 Coronavirus

Les coronavirus (CoV) représentent une vaste catégorie de virus responsable d'affections allant du simple rhume à des pathologies plus sévères telles que le syndrome respiratoire du Moyen-Orient (MERS-CoV) et le syndrome respiratoire aigu sévère (SRAS-CoV). Un nouveau coronavirus (nCoV) désigne une souche inédite qui n'a pas été précédemment identifiée chez l'être humain. Les coronavirus sont de nature zoonotique, signifiant qu'ils se transmettent de l'animal à l'homme. Des études approfondies ont démontré que le SRAS-CoV et le MERS-CoV ont été transmis à l'homme par les civettes et les dromadaires respectivement [25].




Figure 6: structure du coronavirus (extrait de [26])

Le COVID-19 peut facilement se transmettre entre les personnes. Quand le virus circule, il peut changer et de nouvelles versions du virus peuvent apparaître. Ces versions peuvent se diffuser plus vite ou être plus difficiles à traiter. Cette maladie (virus) nouvellement reconnu est récemment arrivée en tête de liste des maladies pulmonaires, car il est hautement transmissible et aucun vaccin ou médicament antiviral cliniquement approuvé n'est encore disponible. Depuis son apparition, le nombre d'infections a atteint 506 700 624 cas, dont 6 207 035 décès dans tout le monde [27].

### 2.3.6 Bronchite

Pendant la respiration, l'air arrive par la trachée, passe dans les bronches, puis les petites branches appelées bronchioles, et enfin dans les alvéoles. Dans les alvéoles, l'oxygène dans l'air inspiré traverse la paroi pour aller dans le sang et être distribué à tout le corps. À l'inverse, le dioxyde de carbone, évacué par les cellules du corps, passe par les alvéoles puis les bronches pour sortir via la trachée, la bouche et le nez. C'est ce qu'on appelle l'expiration.

La bronchite est une maladie courante en hiver. Elle est provoquée par une inflammation des bronches due à un virus, qui se soigne d'elle-même en environ dix jours. On utilise souvent le terme bronchite aiguë pour la différencier de la bronchite chronique (ou BPCO) qui est fréquente chez les fumeurs.

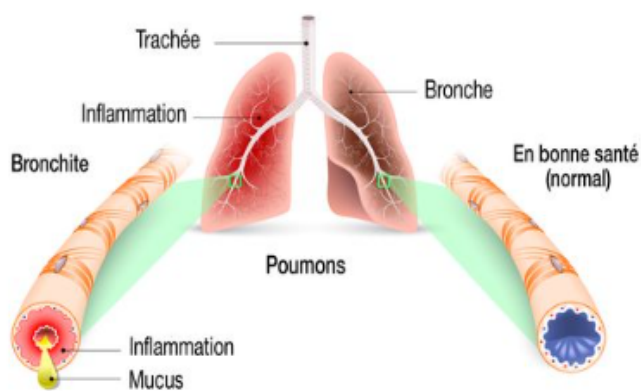


Figure 7: L'effet de la bronchite (extrait de [28])

La bronchite commence souvent par un rhume ou une inflammation du nez et de la gorge. Elle se manifeste d'abord par une toux sèche qui devient une toux grasse au bout de quelques jours. La toux sèche est dite non productive et s'accompagne de douleurs au niveau de la poitrine, derrière le sternum. Le patient ressent une sensation de brûlure lors des accès de toux et quand il inspire profondément [7].

### 2.3.7 Cancer des poumons

Le cancer du poumon se développe à partir des cellules des bronches. Il résulte de la conversion d'une cellule pulmonaire ordinaire en cellule cancéreuse [29]. Ce dernier est parmi les plus courants chez les hommes et se manifeste de plus en plus chez les femmes. Environ 40 000 nouveaux cas sont identifiés chaque année. Ce genre de cancer, responsable du nombre le plus élevé de mortalités à l'échelle mondiale (1,8 million en 2020), est également le deuxième cancer le plus répandu, juste après le cancer du sein [5].




Figure 8: cancer du poumon (extrait de [29])

On identifie deux catégories principales selon le type de cellules concernées :

- Les cancers bronchiques non à petites cellules (CBNPC), qui sont les plus courants (représentant 80 à 85 % des cas). Cette catégorie inclut les adénocarcinomes, fréquemment localisés en périphérie des poumons, les carcinomes épidermoïdes, dérivés des grosses bronches situées dans la partie centrale du poumon, ainsi que les carcinomes à grandes cellules, qui sont plus rares.

- Les cancers bronchiques à petites cellules, qui sont plus agressifs et moins fréquents. Ils constituent environ 15 % des cas et sont presque toujours associés au tabagisme.

Le cancer du poumon ne provoque pas toujours de douleur, ce qui fait que son détection est souvent à un stade avancé. En outre, ses signes ne sont pas clairement définis. Il est essentiel de consulter, et plus encore rapidement si l'on est fumeur, en présence d'une toux persistante, d'infections pulmonaires récurrentes, de douleurs thoraciques durables, d'un souffle court ou de crachats sanguinolents. À certains moments, ce sont des manifestations générales qui trahissent sa présence : épuisement, perte d'appétit... [30].

### **2.3.8 L'emphysème**

Un emphysème pulmonaire, ou simplement emphysème, est une maladie caractérisée par une expansion ou une dilatation des alvéoles pulmonaires (ces petites structures en forme de sacs situées dans les poumons qui facilitent les échanges gazeux pendant la respiration), conduisant à la dégradation de leurs parois.

En cas d'emphysème, les alvéoles des poumons se dilatent progressivement et ne peuvent plus fonctionner correctement. Lorsqu'on expire, elles ne parviennent pas à se vider complètement de l'air qu'elles contiennent. Cela réduit la quantité d'oxygène envoyée au corps et rend la respiration difficile. Il peut être causé par plusieurs facteurs. Il se développe souvent après une inflammation chronique des poumons et des voies respiratoires, comme la bronchite chronique ou la BPCO (Broncho-pneumopathie chronique obstructive). Ces maladies sont généralement dues au tabagisme. En effet, l'inflammation attire des globules blancs qui contiennent de l'élastase, une enzyme qui abîme l'élastine des alvéoles. L'élastine est essentielle car elle donne aux alvéoles leur souplesse nécessaire pour bien fonctionner [31].




Figure 9: L'effet de l'emphysème sur les alvéoles (extrait de [32])

Il existe plusieurs types d'emphysème :

- Le panlobulaire se manifeste quand il détruit les alvéoles et les vaisseaux sanguins qui les entourent. Ce type est lié au vieillissement des poumons et apparaît chez les personnes âgées.
- Le centrolobulaire affecte uniquement les alvéoles. Cette forme d'emphysème est une complication de la BPCO, souvent due au tabagisme.
- Le paralésionnel survient quand l'emphysème se développe à l'endroit d'une cicatrice indiquant une ancienne maladie pulmonaire, comme la tuberculose par exemple.

Un emphysème pulmonaire se manifeste par des difficultés respiratoires, parfois invalidantes. Différents signes cliniques peuvent indiquer l'atteinte pulmonaire causée par un emphysème : Dyspnée (sensation de manque d'air) qui évolue vers un essoufflement même avec un effort minimal, limitant ainsi toute activité physique, sensation de compression thoracique, asthénie, toux persistante, respiration rapide et peu complète et expiration de durée prolongée. Lorsque l'emphysème s'aggrave, d'autres symptômes typiques se manifestent : Coloration bleutée (cyanose) des lèvres en raison d'un déficit en oxygène, sifflements ou « râles bronchiques » audibles durant l'auscultation, distension thoracique visible sur une radiographie pulmonaire. Le thorax présente une forme d'entonnoir due au blocage des muscles respiratoires lors de l'inspiration [31].

### 3 L'imagerie médicale

L'imagerie médicale regroupe l'ensemble des techniques permettant de visualiser l'intérieur du corps humain à partir des images. Elle occupe une place centrale dans la médecine, en contribuant à l'identification, à la localisation, et au suivi de diverses affections.

#### 3.1 Les principaux types d'imagerie médicale

L'imagerie médicale est un ensemble de techniques consistant à mettre en image différentes régions ou différents organes de l'organisme. Il existe plusieurs types d'imageries médicales qui sont plus ou moins adaptées en fonction des zones à examiner. Prenons l'exemple le domaine de la pneumologie: la radiographie thoracique est utilisée pour détecter des affections comme la pneumonie, la tuberculose (l'objectif de cette étude) ou des anomalies comme un pneumothorax (collapsus pulmonaire). Le scanner thoracique permet de repérer des nodules pulmonaires, des tumeurs ou encore d'évaluer la présence d'une embolie pulmonaire. Il est également utilisé pour suivre des maladies chroniques telles que la fibrose pulmonaire ou la bronchopneumopathie chronique obstructive (BPCO). L'IRM thoracique, bien que moins courante pour les poumons, peut être utilisée pour évaluer des anomalies liées au médiastin ou des tumeurs situées près des grandes voies respiratoires. Enfin, l'échographie pleurale est utile pour identifier et guider le traitement d'un épanchement pleural, souvent lié à des maladies infectieuses.

##### 3.1.1 La Radiographie standard

L'imagerie médicale a débuté avec la radiographie, après la découverte des rayons X par Wilhelm Röntgen en 1895[33].

La radiographie standard numérique, également dite radiographie conventionnelle, permet l'étude de différentes parties du corps grâce à l'exposition à des rayons X et à la transmission de leur image sur une surface photosensible. Pour le fonctionnement de la radiographie conventionnelle, un faisceau de rayon X est généré et traverse le patient pour atteindre un film ou un détecteur qui enregistre la quantité de rayonnements reçue, produisant ainsi une image [34].




Figure 10: principe de fonctionnement de radiologie (extrait de [35])

L'image obtenue repose sur l'atténuation des rayons X par les tissus du corps. Chaque tissu absorbe ces rayons de façon différente selon sa densité. Plus un tissu est dense, plus il bloque les photons X, ce qui le fait apparaître en blanc sur l'image (par exemple, les os). À l'inverse, les tissus moins denses, comme les muscles ou les liquides, apparaissent en gris, les graisses en gris plus sombre et pour les zones remplies d'air ou de gaz, comme les poumons, sont noirs [34].



Figure 11: Image radiographique thoracique (extrait de [35])

### 3.1.2 Tomodensitométrie

Tomodensitométrie, Le scanner, en anglais Computed Tomography (CT scans), Inventé par le Britannique Godfrey Hounsfield dans les années 1970 [36], c'est une méthode de diagnostic radiologique tomographique permettant d'obtenir des coupes transversales reconstruites à partir de la mesure du coefficient d'atténuation du faisceau de rayons X dans le volume étudié A l'aide d'une source de rayons X et un détecteur de

rayons X sont placés dans un dispositif circulaire qui tourne autour du patient allongé sur une table motorisée se déplaçant à travers la machine. Généralement, on utilise une TDM à plusieurs détecteurs (multibarrettes, de 4 à 64 ou plus de rangées de détecteurs) car plus il y a de détecteurs, plus l'acquisition des images est rapide et leur résolution améliorée [37].




Figure 12: principe de fonctionnement de la tomodensitométrie (extrait de [36])

Les détecteurs transmettent des données correspondant à une série d'images de rayons X, prises sous différents angles autour du patient. Ces images ne sont pas visualisées directement mais sont envoyées à un ordinateur qui en reconstruit rapidement des images en montrant une coupe du corps dans n'importe quel plan souhaité. Les données peuvent également être utilisées pour créer des images en trois dimensions détaillées [37].



Figure 13: scanner (TDM) thoracique (extrait de [38])

### 3.1.3 Imagerie par Résonance Magnétique

L'imagerie par résonance magnétique (IRM) est le résultat d'une série de découvertes scientifiques réalisées tout au long du XXe siècle. Elle a pu se développer grâce à la découverte du phénomène de résonance magnétique nucléaire par Felix Bloch et Edward Purcell en 1946 [39].




Figure 14: principe de fonctionnement de la tomographie par résonance magnétique (extrait de [40])

L'IRM utilise des champs magnétiques et des ondes radio pour créer des images détaillées des tissus en fines tranches. Les protons dans les tissus tournent normalement et génèrent de faibles champs magnétiques non orientés .

quand un appareil d'IRM les entoure d'un champ magnétique puissant, ces petits champs s'alignent avec le champ principal. En envoyant des impulsions radio, on force temporairement les protons à s'orienter différemment, avec plus d'énergie. Une fois l'impulsion passée, les protons retournent à leur position initiale dans le champ magnétique de l'IRM [41].

La brillance des tissus sur une image IRM dépend de plusieurs facteurs, tels que :

- Les modèles des impulsions de radiofréquence et de gradient utilisés pour créer l'image.
- Les propriétés T1 et T2 propres aux différents tissus.
- La quantité de protons présente dans divers tissus.

En ajustant les impulsions de radiofréquences et la forme des ondes de gradient, des logiciels spécialisés génèrent des séquences d'impulsions qui déterminent le type d'image (pondéré) produit et l'apparence des tissus. Les images peuvent être :

- Pondérées en T1.
- Pondérées en T2.
- Pondérées selon la densité protonique.

Par exemple, sur les images pondérées en T1, la graisse est lumineuse (signal intense), tandis que sur les images pondérées en T2, elle apparaît plus sombre (signal faible). L'eau et les liquides, en revanche, sont sombres sur les images T1 et lumineuses sur les images T2. Les images T1 sont idéales pour montrer l'anatomie et la graisse des tissus normaux (comme pour confirmer la présence d'une masse graisseuse). Les images T2 sont meilleures pour détecter les anomalies liquides (comme les tumeurs, inflammations ou blessures). En pratique, les images T1 et T2 apportent des informations complémentaires, rendant les deux essentielles pour identifier les pathologies. L'énergie émise pendant ce retour (relaxation T1) et pendant l'oscillation de leur rotation (relaxation T2) est captée sous forme de signaux qui sont localisés avec précision grâce à une antenne intégrée à l'IRM. Des programmes informatiques traitent ces signaux pour générer des images anatomiques détaillées [[41]].



Figure 15: image IRM du corps entier (extrait de [41])

### 3.1.4 L'échographie

En échographie, un générateur est relié à un transducteur. Les cristaux piézoélectriques de ce générateur transforment l'électricité en sons de haute fréquence qui traversent les tissus. Ces derniers dispersent, renvoient et absorbent les sons de manière variée. Les échos, c'est-à-dire les sons renvoyés, sont reconvertis en impulsions électriques. Un ordinateur interprète ces impulsions et projette une image anatomique sur un écran [42].

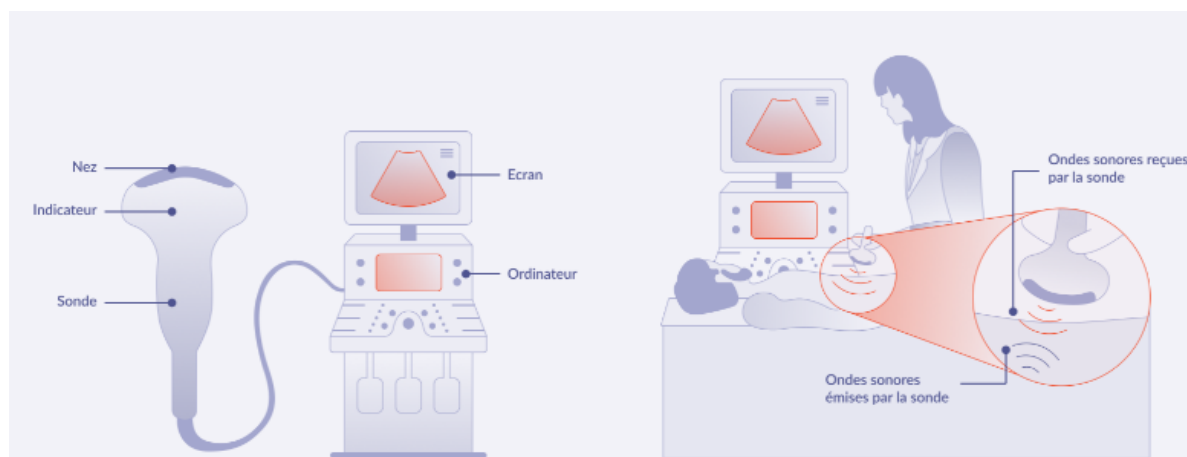


Figure 16: les composants d'échographie (extrait de [43])

Les informations issues de l'échographie peuvent être présentées sous divers formats:

- Mode A : est le plus basique; les signaux y apparaissent sous forme de pointes sur un graphique. L'axe vertical (Y) de l'écran représente l'intensité de l'écho, tandis que l'axe horizontal (X) illustre la profondeur ou la distance au sein du patient.
- Mode B (nuances de gris) : est principalement employé pour l'imagerie diagnostique; les signaux y sont retranscrits en images anatomiques en deux dimensions.
- L'échographie en mode B : est assez rapide pour illustrer des mouvements en direct, tels que le battement du cœur ou la pulsation des vaisseaux sanguins. Mode M : est destiné à l'imagerie des structures en mouvement; les signaux réfléchis par celles-ci se transforment en ondes qui s'affichent en continu sur un axe vertical[44].



Figure 17: image radiographique pulmonaire (extrait de [44])

## 4 Conclusion

Dans ce premier chapitre, nous avons présenté les différentes pathologies des poumons, en mettant en avant l'importance de l'imagerie médicale pour leur prise en charge. Nous avons d'abord exploré les infections pulmonaires, comme la pneumonie et la tuberculose, qui restent fréquentes et peuvent être graves si elles ne sont pas détectées à temps. Nous avons abordé les maladies chroniques comme la broncho-pneumopathie chronique obstructive (BPCO), une maladie progressive ayant un impact notable sur la qualité de vie. Le cancer des poumons a aussi été discuté, avec un accent sur son taux d'occurrence élevé, ses facteurs de risque et les particularités de son diagnostic par imagerie. Pour compléter cet aperçu, nous avons également mentionné les maladies d'origine vasculaire, telles que l'embolie pulmonaire, ainsi que les maladies pulmonaires interstitielles.

Toutes ces maladies montrent à quel point le diagnostic en pneumologie peut être complexe, ce qui met en lumière l'importance essentielle de l'imagerie médicale. Les techniques comme la radiographie, le scanner thoracique ou l'IRM permettent désormais de détecter des lésions souvent invisibles cliniquement, de suivre leur évolution et de guider le traitement. Connaître les signes radiologiques précis de chaque maladie est donc un atout majeur pour les professionnels de santé.

En somme, une connaissance approfondie des maladies pulmonaires, alliée à une analyse minutieuse des images médicales, est cruciale pour garantir une prise en charge rapide, efficace et adaptée à chaque patient. Cette combinaison de savoir clinique et de compétences techniques est au cœur de la médecine moderne.

*Chapitre 02:*  
*Applications des approches de*  
*l'intelligence artificielle : État de l'art*

## 1 Introduction

L'intelligence artificielle est vue comme l'une des avancées technologiques les plus importantes du XXI<sup>e</sup> siècle. Elle représente des méthodes et des systèmes informatiques capables d'imiter certaines fonctions humaines.

L'IA a joué un rôle crucial dans le progrès de nombreux domaines, notamment la santé où elle provoque des changements importants. Elle permet aux médecins d'établir des diagnostics plus rapides et précis, surveiller l'état de santé des patients à distance, et découvrir de nouveaux traitements. Ainsi, elle contribue non seulement à sauver des vies, mais également à améliorer la qualité des soins pour tous.

Dans ce chapitre, nous allons explorer tout ce qu'il faut savoir sur l'intelligence artificielle, incluant sa définition, son historique, ses différentes approches et son application dans des travaux sur les pathologies pulmonaires.

## 2 L'intelligence artificielle

### 2.1 Définition et historique de l'intelligence artificielle

L'intelligence artificielle (AI) c'est un domaine de l'informatique qui vise à développer des systèmes capables d'effectuer des tâches qui demanderaient normalement l'intelligence humaine.

Cependant l'AI débute en 1943 avec la publication de l'article « A Logical Calculus of Ideas Immanent in Nervous Activity » par Warren McCulloch et Walter Pitts. Dans ce texte, les chercheurs présentent le premier modèle mathématique pour développer un réseau de neurones. En 1950, Snarc, le premier ordinateur à réseau de neurones, est créé par Marvin Minsky et Dean Edmonds, deux étudiants de Harvard. La même année, Alan Turing publie le Test de Turing, qui est toujours utilisé pour évaluer les intelligences artificielles. Ce test pose les bases de l'intelligence artificielle, de ses objectifs et de sa vision .

Le fonctionnement d'une intelligence artificielle s'appuie sur des algorithmes avancés capables de traiter de vastes quantités de données pour reproduire des comportements humains. Les systèmes d'IA utilisent l'apprentissage machine et le l'apprentissage pour constamment se perfectionner en se basant sur les informations qu'ils reçoivent à travers des réseaux neuronaux artificiels [45].

## **3 L'apprentissage machine (machine Learning)**

### **3.1 Définition de l'apprentissage machine**

Le Machine Learning, ou apprentissage automatique, est une branche de l'intelligence artificielle qui permet aux machines d'apprendre à partir de données et d'améliorer leurs compétences sans avoir besoin d'instructions spécifiques pour chaque tâche. Cela repose sur des formules qui repèrent des tendances dans les données et les utilisent pour faire des prévisions [45].

### **3.2 Fonctionnement De l 'apprentissage machine**

La première étape pour créer un modèle d'apprentissage automatique consiste à choisir et à préparer des données pour l'entraînement. Ces données peuvent être annotées ou non, et doivent être nettoyées pour éviter des erreurs. Ensuite, le choix d'un algorithme qui convient au type de données et au problème à résoudre. L'entraînement de l'algorithme est un processus de répétition pour ajuster les "poids" et erreurs, afin d'améliorer la précision. Pour finir, le modèle est utilisé sur de nouvelles données, ce qui augmente son efficacité avec le temps[46].

### **3.3 Les différents type de machine Learning**

#### **3.3.1 Apprentissage supervisé**

L'apprentissage supervisé repose sur l'utilisation de données étiquetées pour enseigner à un modèle les patterns qu'il doit reconnaître. Le système s'entraîne sur ces données, qui comportent déjà les classifications recherchées. Cette méthode demande moins de données d'entraînement comparée à d'autres approches et simplifie le processus d'évaluation, car les résultats peuvent être directement comparés aux étiquettes existantes [46].

#### **3.3.2 Apprentissage non-supervisé :**

L'apprentissage non supervisé explore des données sans étiquettes, identifiant des motifs et relations invisibles aux humains. La machine traite de grandes quantités de données, utilisant des algorithmes pour extraire des caractéristiques utiles à la classification en temps réel, sans intervention humaine, moins simple à appliquer. En revanche, l'apprentissage semi-supervisé mixe données étiquetées et non étiquetées, aidant à l'extraction de caractéristiques et contournant le manque de données étiquetées nécessaires pour l'apprentissage supervisé[46].

### 3.3.3 Apprentissage par renforcement

L'apprentissage par renforcement implique qu'un programme fasse des essais et apprenne de ses erreurs afin de réussir une tâche. Le programme essaiera plusieurs méthodes pour atteindre son objectif. Selon ses résultats, il recevra des récompenses ou des punitions qui le motiveront à continuer ou à modifier son approche [46].

## 4 Les réseaux neuronaux artificiels

### 4.1 Définition des réseaux de neurones

Un réseau neuronal est une technique d'intelligence artificielle qui apprend aux ordinateurs à analyser des informations en s'inspirant du cerveau humain. C'est une forme d'apprentissage automatique appelée apprentissage profond, utilisant des nœuds ou neurones connectés entre eux dans une structure à plusieurs couches similaire au cerveau. Il construit un système évolutif que les ordinateurs utilisent pour apprendre de leurs erreurs et s'améliorer constamment. Les réseaux neuronaux artificiels tentent de résoudre des problèmes complexes tels que la synthèse de documents ou la reconnaissance de visages, avec une précision accrue [47].

### 4.2 L'architecture d'un réseau neuronale

Un réseau neuronal se compose de neurones interconnectés répartis en trois couches principales. La couche d'entrée recueille et traite les données externes, les transmettant ensuite à la couche cachée. Les couches cachées analysent et retravaillent ces informations, le passant de l'une à l'autre. Enfin, la couche de sortie délivre le résultat final du traitement, avec un ou plusieurs nœuds selon le type de classification (binaire ou multi-classes)[47].

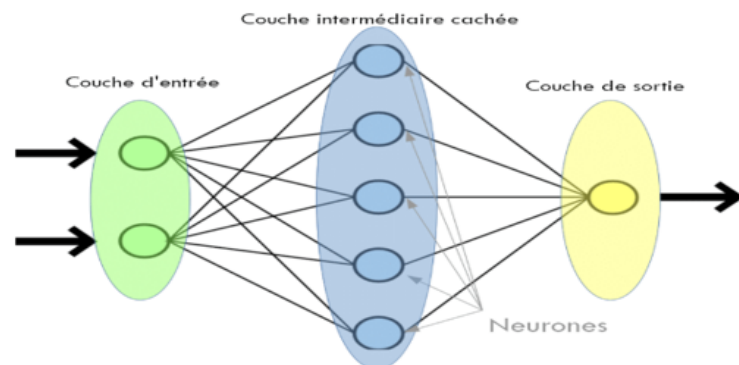


Figure 18: l'architecture d'un réseau neuronale (extrait de [47])

### 4.3 Les neurones biologiques

Le système nerveux comporte des milliards de cellules formant un réseau de neurones biologiques. Les neurones ne fonctionnent pas isolément; ils se connectent les uns aux autres pour former des réseaux simples ou complexes. Il se compose de trois parties principales :

- Le corps cellulaire : qui agit comme le centre de contrôle pour traiter les informations reçues par les dendrites.
- Les dendrites : qui sont les principaux fils conducteurs par lesquels l'information venant de l'extérieur est transmise.
- L'axone : qui sert de fil conducteur pour envoyer le signal du corps cellulaire vers d'autres neurones.




Figure 19: schéma d'un neurone biologique (extrait de [48]).

En ce qui concerne les synapses, elles agissent comme des connecteurs et des régulateurs entre les neurones, facilitant ainsi leur dialogue et leur interaction [48].




Figure 20: structure d'une synapse neuronale (extrait de [48])

Les signaux neuronaux passent d'un neurone à l'autre par des réactions électrochimiques complexes. Les substances chimiques libérées par les synapses modifient le potentiel électrique du neurone, et lorsqu'il atteint un certain seuil, une impulsion électrique est envoyée dans l'axone. Le réseau neuronal montre une plasticité, avec des changements durables dans la force des connexions et la formation de nouvelles connexions entre neurones. Parfois, des groupes de neurones migrent pour créer de nouvelles connexions, ce qui sous-tend l'apprentissage [49].

#### 4.4 Des neurones biologiques vers les neurones artificiels

Premièrement Les neurones biologiques possèdent un centre de contrôle (appelé corps cellulaire) qui rassemble les informations collectées par les dendrites. Ensuite, ce centre de contrôle génère un potentiel d'action selon les règles suivantes :

- Si la somme des signaux reçus est inférieure au seuil d'activation : aucun message n'est transmis par l'axone.
- Si la somme dépasse ce seuil : un message nerveux est envoyé par l'axone. Faisons une comparaison simple des étapes clés de l'algorithme du perceptron avec les composants des neurones biologiques. L'algorithme a été sélectionné car il imite le mieux le fonctionnement des neurones biologiques.
- Connexions dendrites analyse de de chaque élément en entrée  $i \cdot x_i$
- Cellules : application d'une fonction d'activation ( $f$  la somme des entrée)
- Axone : résultat du modèle [48].

$$\text{Output} = f\left(\sum_{i=1}^n w_i \cdot x_i\right) = f(\langle \mathbf{w}, \mathbf{x} \rangle) \quad (1)$$




Figure 21: schéma d'un neurone artificiel (extrait de [48])

- vecteur  $w$  Est désigné sous le nom de vecteur de poids).
- Le vecteur  $x$  Est désigné sous le nom de vecteur d'entrée.
- $f$  Est désigné sous le nom de de fonction d'activation [48]

## 4.5 L'apprentissage

L'apprentissage se présente comme un mécanisme essentiel où un réseau de neurones artificiels ajuste peu à peu les liens entre ses éléments, en réaction aux informations qu'il reçoit. Ce mécanisme s'appuie sur la modification des poids qui connectent les neurones, permettant ainsi au système de s'adapter à son environnement et de tirer des leçons de divers exemples. L'objectif de l'apprentissage est ainsi d'améliorer la performance du réseau en augmentant sa capacité à analyser de nouvelles données, en s'appuyant sur les expériences antérieures. Cette approche, qui est une des clés du modèle connexionniste, s'inspire du fonctionnement du cerveau humain et met en lumière la création de comportements intelligents à partir de structures simples mais fortement interconnectées [49].

## 5 L'apprentissage profond (deep Learning)

### 5.1 Définition et fonctionnement de l'apprentissage profond

L'apprentissage profond est une branche de l'apprentissage automatique qui se concentre sur l'utilisation de réseaux neuronaux artificiels pour apprendre de manière autonome et pour effectuer des prédictions sans qu'il soit nécessaire de programmer chaque étape. Inspiré par le fonctionnement du cerveau humain [49].




Figure 22: schéma qui montre la position de chaque approche

Le deep Learning utilise des réseaux de neurones artificiels organisés en différentes couches : une couche d'entrée, des couches cachées et une couche de sortie. Chaque neurone dans ces couches traite les informations reçues, réalise des calculs, et transmet les résultats à la couche suivante. Pendant l'apprentissage, les modèles de deep Learning ajustent les poids et les biais des neurones pour réduire les erreurs de sortie, à l'aide d'algorithmes comme la descente de gradient stochastique, ce qui améliore la précision des prédictions. Les modèles développent des représentations hiérarchiques des données ; les premières couches identifient les caractéristiques simples alors que les couches profondes captent les schémas plus complexes.




Figure 23: l'architecture de réseau de neuronal profond (extrait de [50])

L'apprentissage profond est particulièrement efficace pour examiner des données non structurées telles que des images, des sons et du texte, évitant ainsi la nécessité de définir manuellement les traits caractéristiques. Il nécessite de vastes quantités de données pour l'apprentissage mais est également capable de se calibrer à de nouvelles informations pour produire des prédictions précises [51].

## 5.2 Types des réseaux de neurones profonds

Les réseaux de neurones profonds peuvent être divisés en plusieurs catégories, nous indiquerons parmi les types de réseaux neuronaux artificiels les plus couramment utilisés :

### 5.2.1 Réseau neuronal feedforward

Le réseau neuronal feedforward est le modèle de réseau neuronal artificiel le plus basique. Dans ce type de réseau, les informations passent dans un sens unique, de la couche initiale jusqu'à la couche finale. Les réseaux feedforward traitent une entrée en

la faisant traverser plusieurs couches intermédiaires. Chaque couche est composée de plusieurs unités appelées neurones, et chaque neurone est relié à toutes les unités de la couche précédente. La dernière couche, également complètement connectée, fournit les résultats prédits.

### **5.2.2 Les réseaux de neurones récurrents(RNN)**

Les réseaux neuronaux récurrents sont un genre de réseau neuronal artificiel souvent employé. Ils conservent le résultat d'une étape et le renvoient à l'étape de début pour aider à prévoir l'issue de l'étape. Les réseaux neuronaux récurrents ont des compétences d'apprentissage remarquables. Ils sont fréquemment utilisés pour réaliser des tâches difficiles comme la prédiction de séries temporelles, l'apprentissage de l'écriture manuscrite et la compréhension des langues.

### **5.2.3 Les réseaux de neurones convolutifs (CNN)**

Un réseau de neurones convolutif est un type de réseau de neurones artificiel très performant avec une structure spéciale. Les couches sont disposées en trois dimensions : largeur, hauteur et profondeur. Les neurones d'une couche ne sont pas reliés à tous les neurones de la couche suivante, mais seulement à une petite partie de ceux-ci. Le résultat final est simplifié sous forme d'un vecteur unique de scores de probabilité, alignés selon la dimension de la profondeur [52].

## **5.3 L'apprentissage profond vs. L'apprentissage automatique**

Le Deep Learning est une branche du Machine Learning centrée sur les réseaux neuronaux artificiels, caractérisée par des architectures à plusieurs couches. Ces couches, comprenant des unités spécifiques, transforment les données d'entrée en informations exploitables pour des tâches prédictives. Ce mécanisme permet aux machines d'apprendre de leurs propres traitements de données. En revanche Le Machine Learning, élément de l'intelligence artificielle, utilise diverses techniques, dont le Deep Learning, pour aider les machines à s'améliorer par l'expérience. Le processus implique l'alimentation en données, l'entraînement du modèle, son test et déploiement, pour ensuite automatiser les tâches prédictives via le modèle employé.

Pour établir une comparaison entre ces deux approches, Le Machine Learning fonctionne bien avec peu de données, contrairement au Deep Learning qui requiert beaucoup de données pour s'entraîner. Le Machine Learning peut tourner sur des ordinateurs simples, mais le Deep Learning à besoin de processeurs graphiques puissants

pour traiter ses calculs complexes. Pour la personnalisation, le Machine Learning utilise des caractéristiques fixées par l'utilisateur, tandis que le Deep Learning arrive à apprendre seul à partir des données. Le processus d'apprentissage en Machine Learning est divisé en plusieurs étapes, alors que le Deep Learning aborde le problème dans son ensemble. Le temps nécessaire pour entraîner le Machine Learning est plus court, mais il est long pour le Deep Learning à cause de ses réseaux complexes [52].

## 6 Réseaux neurones convolutif (Convolutional Neural Networks)

### 6.1 L'architecture des réseaux convolutif (CNN)

Les réseaux CNN (Convolutional Neural Networks) représentent un type spécifique de réseaux de neurones et sont considérés comme l'un des modèles les plus efficaces pour la classification d'image. Leur principe de fonctionnement semble simple : l'utilisateur fournit une image en entrée, qui est sous forme de matrice de pixels. Cette image possède trois dimensions :

- Deux dimensions pour une image en niveaux de gris.
- Une troisième dimension, de profondeur de 3, pour représenter les couleurs de base (Rouge, Vert, Bleu).

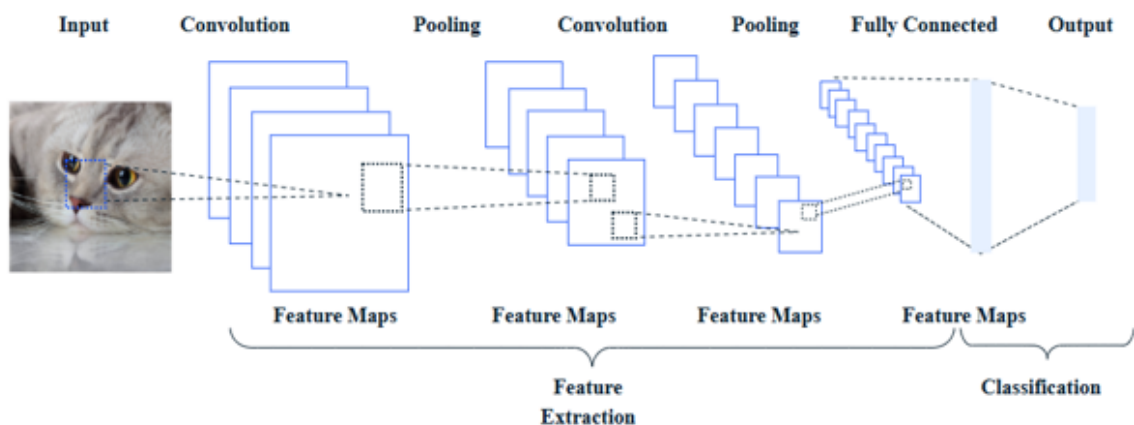


Figure 24: l'architecture de réseau de neurones convolutif (extrait de [51])

L'architecture du Réseau de Neurones Convolutifs possède en premier lieu une section convolutive et se compose donc de deux :

- Une partie convolution : Son but est d'extraire des caractéristiques spécifiques à chaque image en les compressant pour réduire leur taille initiale. L'image d'entrée

passe à travers une série de filtres, créant ainsi de nouvelles images appelées cartes de convolutions. Ces cartes sont ensuite rassemblées dans un vecteur de caractéristiques appelé code CNN.

- Une partie classification : Le code CNN produit à l'issue de la partie convolution est utilisé en entrée dans une seconde section, faite de couches entièrement connectées nommées perceptron multicouche (MLP). Cette section a pour rôle de combiner les caractéristiques du code CNN afin de classifier l'image [53].

## 6.2 Les couches de réseaux de neurone convolutif (CNN)

### 6.2.1 Couches convolutionnelle (Convolutional layer) :

Une couche de convolution joue un rôle essentiel dans un réseau de neurones convolutif (CNN), effectuant la majorité des calculs. Elle comprend des données d'entrée, un filtre, et une carte de caractéristiques. Pour une image en couleur, l'entrée est une matrice en 3D (hauteur, largeur, profondeur) pour les composantes RVB. Un filtre, ou détecteur de caractéristiques, parcourt l'image pour identifier des éléments par le biais de la convolution. Ce filtre, souvent une matrice 2D de taille 3x3, représente une partie de l'image et détermine la taille de la zone analysée. En appliquant le filtre, un produit scalaire est calculé entre les pixels d'entrée et le filtre, puis inséré dans une matrice de sortie. Ce processus est répété en déplaçant le filtre jusqu'à ce que l'image entière soit couverte. Le résultat est une carte de caractéristiques ou carte d'activation.

Comme vous pouvez le constater dans la figure 25, chaque valeur de sortie de la carte de caractéristiques n'a pas besoin d'être reliée à chaque pixel de l'image d'entrée. Elle doit seulement être connectée au champ réceptif, là où le filtre est utilisé.

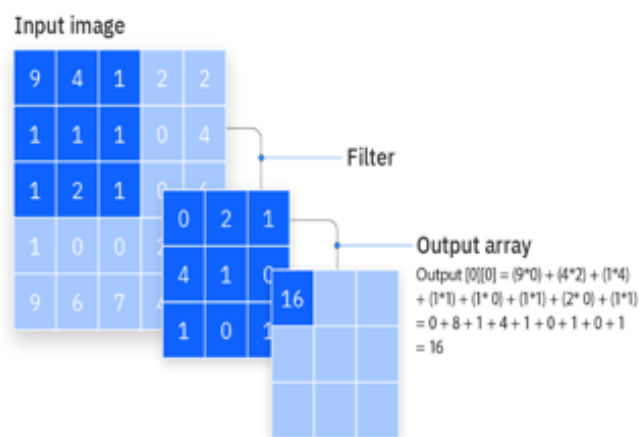


Figure 25: Fonctionnement de la couche convolutif ( extrait de [54])

Une seconde couche de convolution supplémentaire peut suivre la première, rendant la structure du CNN organisée comme un système de niveaux. Les couches suivantes regardent les pixels dans les zones couvertes par les précédentes. Par exemple, pour repérer un vélo dans une image, on étudie ses parties : cadre, guidon, roues, pédales, etc. Chaque partie est un motif de base dans le réseau, et leur association crée un motif plus complexe, établissant ainsi une série de caractéristiques dans le CNN , comme vous pouvez l'observer dans la figure 26.



Figure 26: exemple de Fonctionnement de la couche de convolution supplémentaire (extrait de [54])

En fin, La couche de convolution change l'image en valeurs numériques pour que le réseau puisse identifier et comprendre les motifs importants [54].

### 6.2.2 La couche pooling (Pooling Layer):

Les couches poolings, aussi connues sous le nom de Le sous-échantillonnage , diminuer la dimensionnalité en réduisant le nombre de paramètres d'entrée. Tout comme la couche convolutive, le regroupement examine l'ensemble de l'entrée, mais sans appliquer de pondération. Le noyau exécute une fonction d'agrégation sur les valeurs du champ récepteur, fournissant ainsi les données de sortie. Il existe principalement deux formes de regroupement :

- Max pooling layer : tandis que le filtre parcourt l'entrée, il choisit le pixel ayant la valeur la plus élevée pour être transféré au tableau de sortie. Cette méthode est souvent préférée par rapport au average pooling layer.
- Average Pooling layer : lorsque le filtre parcourt l'entrée, il calcule la moyenne des valeurs du champ récepteur pour la transmettre au tableau de sortie [54].

### 6.2.3 Fully connected layer

La dénomination de couche entièrement connectée est très appropriée. Comme mentionné auparavant, dans les couches partiellement connectées, les valeurs des pixels de l'image d'entrée ne sont pas reliées directement aux couches de sortie. À l'inverse, dans une couche entièrement connectée, chaque nœud de la couche de sortie est lié directement à un nœud de la couche précédente.

Cette couche réalise la classification en se basant sur les caractéristiques extraites par les couches antérieures et leurs divers filtres. Tandis que les couches de convolution et de pooling utilisent souvent des fonctions ReLU, les couches FC emploient généralement une fonction d'activation softmax pour correctement classifier les entrées, produisant une probabilité entre 0 et 1 [54].

## 6.3 Les fonctions d'activation

### 6.3.1 Fonction ReLU(Rectified Linear Unit )

Cette fonction remplace toutes les valeurs négatives en entrée par des zéros. L'intérêt de ces couches d'activation est de rendre le modèle non linéaire et donc plus complexe. Elle est définie par :




Figure 27: fonction d'activation ReLU (extraite de [53])

### 6.3.2 Fonction Sigmoidé

La fonction sigmoïde représente l'une des fonctions d'activation les plus anciennes et couramment employées. Sa formulation génère une sortie dans l'intervalle (0, 1)

définie par :

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

La courbe de cette fonction est en forme « S » elle est régulière et ininterrompue, ce qui permet de traiter les valeurs de manière fluide. Cette fonction est particulièrement précieuse pour les couches de sortie dans les modèles de classification binaire, car elle convertit les entrées en probabilités.




Figure 28: fonction Sigmoide (extrait de [55])

### 6.3.3 Fonction Softmax

La fonction Softmax est principalement utilisée dans les couches de sortie pour les tâches de classification multi-classes. Sa formule est la suivante :

$$\text{softmax}(\mathbf{x})_i = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}.$$

Il transforme les valeurs de sortie en probabilités, chaque valeur étant comprise entre 0 et 1 et la somme de toutes les sorties étant égale à 1. Cela permet de déterminer avec un certain degré de certitude la classe à laquelle appartient une entrée donné [56]

### 6.3.4 Fonction Tanh

La fonction Tanh, ou tangente hyperbolique, se représente par l'expression :

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}.$$

Elle produit une sortie dans la plage (-1, 1) et sa courbe en forme de « S » est centrée sur l'origine. La fonction Tanh est souvent utilisée dans les réseaux neuronaux récurrents et peut être plus performante que la Sigmoide, car ses sorties sont centrées autour de zéro, ce qui peut faciliter la convergence pendant l'apprentissage[56].




Figure 29: fonction Tanh (extrait de [57])

## 6.4 Les architectures les plus courants

### 6.4.1 leNet-5

LeNet-5 représente l'un des premiers modèles de réseaux de neurones convolutionnels (CNN), initié par Yann LeCun, Léon Bottou, Yoshua Bengio et Patrick Haffner en 1998. Ce réseau a été introduit dans le cadre de l'étude intitulée "Gradient-Based Learning Applied to Document Recognition". Il a été spécifiquement conçu pour reconnaître de manière automatisée les caractères manuscrits.

Le modèle LeNet-5 se distingue par son architecture simple et efficace pour la classification d'images. Ce réseau convolutionnel inclut trois couches de convolution, suivies d'une mise en commun moyenne, permettant de réduire la dimension tout en préservant les informations essentielles. Ensuite, les informations passent par deux couches entièrement connectées qui agissent comme classificateur. Enfin, le réseau utilise Softmax pour estimer la probabilité qu'une image appartienne à chaque catégorie.




Figure 30: l'architecture de leNet-5 (extrait de [58])

Le modèle fonctionne via un apprentissage supervisé. Chaque image d'entrée traverse les couches du réseau et une prédiction est réalisée. Cette prédiction est comparée à la réponse correcte (étiquette) et l'erreur est évaluée [58].

### 6.4.2 VGGNet

VGGNet est un réseau neuronal introduit par Karen Simonyan et Andrew Zisserman en 2014 dans l'étude "Very Deep Convolutional Networks for Large-Scale Image Recognition". Mis au point au sein du Visual Geometry Group (VGG) de l'Université d'Oxford, ce modèle a obtenu d'excellents résultats lors de la compétition ILSVRC. Le but de VGGNet était d'améliorer les performances des réseaux de neurones convolutifs pour la reconnaissance d'images, par augmentation de la profondeur du réseau tout en utilisant des filtres de taille 3x3. Cette méthode a permis de saisir une plus grande complexité tout en contrôlant le nombre de paramètres.

VGGNet se caractérise par 16 à 19 couches de poids, incluant des couches de convolution et de pooling, suivies de trois couches pleinement connectées. Les couches de convolution appliquent des filtres de 3x3 avec un pas de 1 et utilisent du padding. Des couches de max-pooling 2x2 diminuent la taille des cartes de caractéristiques. Ensuite, les données sont transformées en un vecteur avant d'atteindre une activation Softmax pour la classification. Le VGG-16 se compose de 13 couches convolutionnelles et de trois couches entièrement connectées (FC)[59]:

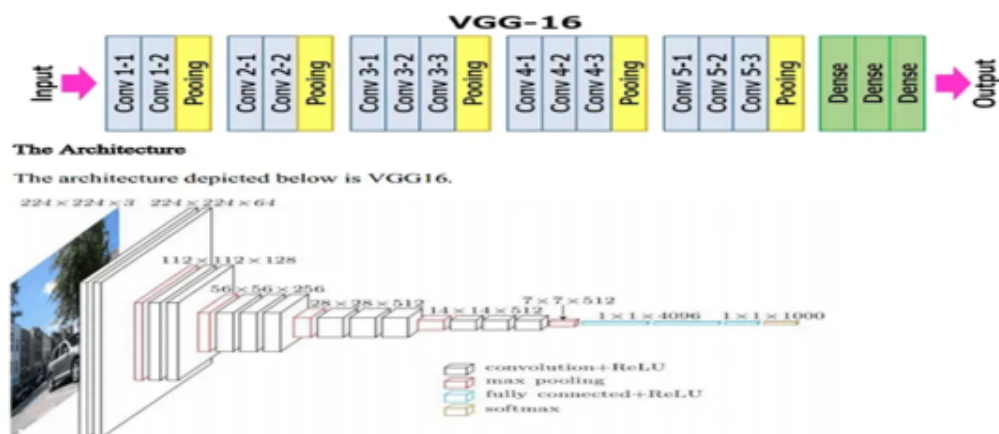


Figure 31: l'architecture de VGG-16 (extrait de [60])

### 6.4.3 GoogleNet

GoogLeNet, également connu sous le nom d'Inception v1, est un réseau de neurones convolutifs développé par Christian Szegedy et son équipe, et a été présenté en

2015 dans l'étude "Going Deeper with Convolutions". Ce modèle s'est distingué en remportant le concours ILSVRC 2014 pour la classification d'images. Il a introduit une approche unique avec le module Inception, qui intègre des convolutions de différentes tailles (1x1, 3x3, 5x5) et des couches de pooling. Cette stratégie permet d'attraper à la fois des détails précis et des contextes plus larges à différentes échelles simultanément. Les convolutions en 1x1 aident à réduire la dimensionnalité, baissant ainsi le coût de calcul et la complexité tout en préservant la profondeur du réseau.




Figure 32: l'architecture de google net (extrait de [61])

Avec ses 22 couches, GoogLeNet reste léger et performant en évitant les couches entièrement connectées, préférant un pooling moyen global. Cette approche contribue à limiter le risque de surapprentissage. L'entraînement est effectué via la rétropropagation et la descente de gradient. De plus, des classifieurs auxiliaires ont été ajoutés pour stabiliser et améliorer la propagation du gradient à travers les couches profondes. GoogLeNet a prouvé qu'il est possible d'atteindre une grande profondeur et performance sans complications ni inefficacité excessives, marquant un tournant important dans l'évolution des réseaux convolutifs [61].

#### 6.4.4 ResNet

ResNet, introduit par Kaiming He et Microsoft Research en 2015, est un modèle de réseau de neurones convolutifs qui a transformé le domaine de l'apprentissage profond en remportant le concours ILSVRC 2015 avec des performances exceptionnelles en classification d'images. Cette architecture a été conçue pour résoudre le problème de baisse de performances souvent observé lorsque les réseaux deviennent plus profonds. Avant l'arrivée de ResNet, ajouter des couches supplémentaires pouvait en fait réduire

la précision du réseau en le rendant plus difficile à optimiser. La solution apportée par ResNet repose sur les connexions résiduelles (également appelées "skip connections"), qui permettent au réseau d'apprendre à corriger la différence entre l'entrée et la sortie attendue d'un bloc de couches. Au lieu de tenter d'apprendre directement une fonction  $F(x)$ , le réseau s'attache à apprendre  $F(x) + x$ , ce qui simplifie l'entraînement des réseaux très profonds en facilitant la circulation du gradient lors de la rétropropagation.

Chaque bloc de ResNet est constitué de deux ou trois couches de convolution, suivies par l'addition des résultats des convolutions avec l'entrée du bloc (via la connexion résiduelle), et enfin une activation (ReLU).

Il existe plusieurs variantes de ResNet : ResNet-18 et ResNet-34, destinées à des applications moins exigeantes, et ResNet-50, ResNet-101, ResNet-152 pour des modèles beaucoup plus profonds. Le modèle s'appuie sur des convolutions en 3x3, la normalisation par lots, le max-pooling, et se termine par une couche de pooling global assortie d'un classifieur Softmax [62].

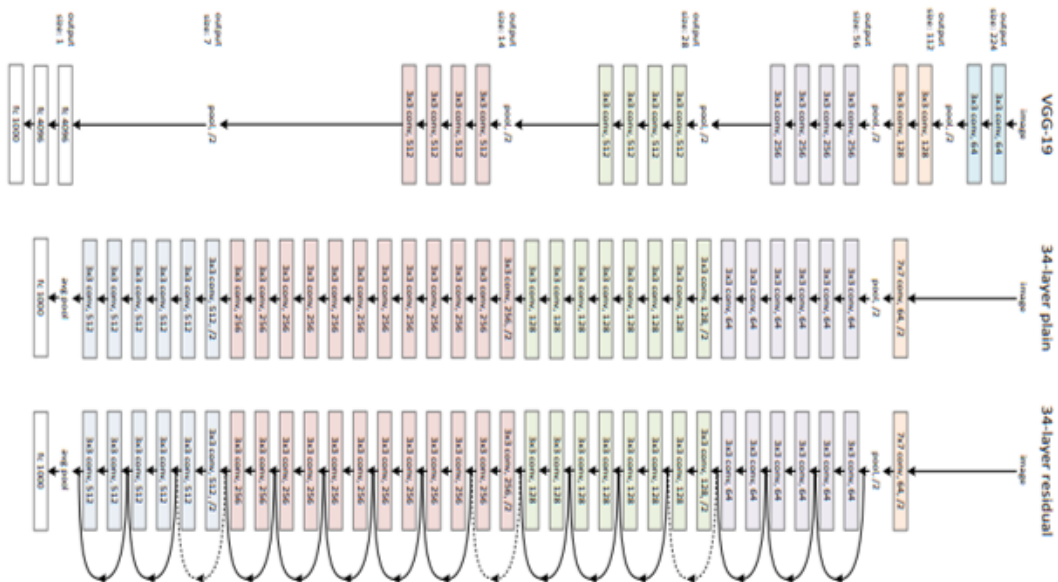


Figure 33: L'architecture de ResNet-34 (extrait de [62])

## 7 État de l'art

### 7.1 Introduction

Avec le développement des nouvelles technologies dans le domaine de la médecine, beaucoup de recherches ont été menées pour améliorer les méthodes d'analyse et de diagnostic à partir des images médicales. L'imagerie par rayons X, souvent utilisée pour examiner divers problèmes au niveau thoracique, reste l'une des techniques les plus répandues et accessibles. Dans ce contexte, de l'intelligence artificielle est apparu comme une solution prometteuse, capable de traiter automatiquement de grandes quantités d'images tout en offrant des résultats impressionnants en termes de classification et de détection.

Ce chapitre examine les recherches antérieures qui ont utilisé ces approches basées sur l'intelligence artificielle pour améliorer l'analyse des images radiographiques.

### 7.2 Les travaux connexes

#### 7.2.1 Rahul Hooda et al :

Hooda et al [63]. ont développé un système de détection de la tuberculose (TB) basé sur l'apprentissage profond. Leur approche repose sur un ensemble de trois architectures de réseaux neuronaux (AlexNet, GoogleNet et ResNet) entraînées à partir de zéro. Le modèle a été évalué sur un ensemble de 1133 images combiné issu de bases de données publiques (Montgomery County, Shenzhen, Belarus et JSRT), avec une répartition de 70 % pour l'entraînement (793 images), 15 % pour la validation (170 images) et 15 % pour les tests (170 images). Grâce à l'augmentation des données, leur méthode atteint une précision de 88,24 % et une aire sous la courbe (AUC) de 0,93, surpassant les performances de nombreuses approches existantes pour la détection automatique de la TB.

#### 7.2.2 Ferhat Ucar, Deniz Korkmaz

Dans leurs étude [64], F. Ucar et D. Korkmaz proposent une approche pour le diagnostic automatisé de la COVID-19 à partir d'images radiographiques thoraciques, à travers le modèle COVIDiagnosis-Net. Ce dernier repose sur une architecture de réseau de neurones profonds dérivée de SqueezeNet, optimisée à l'aide de techniques bayésiennes. L'objectif principal de cette méthode est de classer les radiographies en trois catégories : cas normaux, pneumonies non liées à la COVID-19 (bactériennes

ou virales), et infections à la COVID-19. L'étude s'appuie sur la base de données COVIDx, caractérisée par un déséquilibre important entre les classes, notamment une représentation relativement faible des cas de COVID-19 par rapport aux autres catégories. Afin de compenser cette distribution inégale, les auteurs ont mis en œuvre une stratégie rigoureuse d'augmentation de données hors ligne, ciblant spécifiquement les images de la classe COVID-19. Cette procédure comprend la création de versions symétriques des images originales par retournement horizontal, suivie de l'application de plusieurs transformations : injection de bruit gaussien, cisaillement affine, ainsi que des modifications de luminosité consistant à assombrir les images en réduisant les valeurs de pixels de 30 unités ou, inversement, à les éclaircir en ajoutant 30 unités. Les performances évaluées sur l'ensemble de test révèlent une précision globale de 98,26 %, avec une sensibilité équivalente.

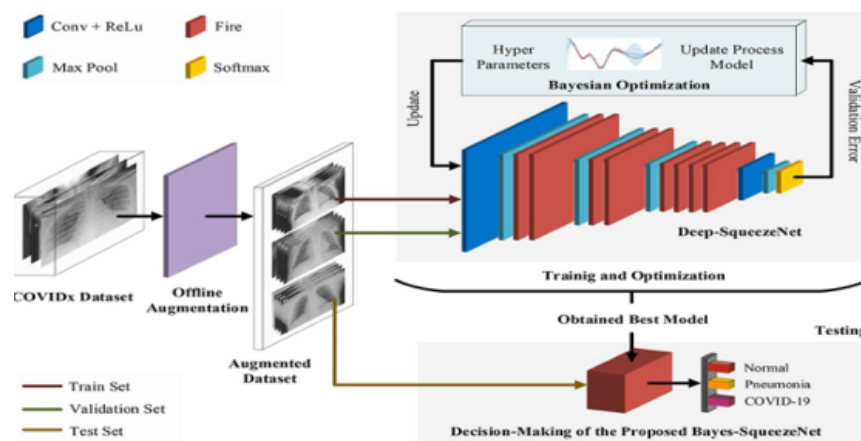


Figure 34: L'architecture de SqueezeNet( extrait de [64])

### 7.2.3 Bar, Diamant , Wolf , Lieberman , Konen et Greenspan

Bar, Diamant , Wolf , Lieberman , Konen et Greenspan [65]. ont exploré l'utilisation de réseaux de neurones convolutifs (CNN) entraînés sur des ensembles de données non médicales pour détecter différentes pathologies dans les radiographies thoraciques. Leur approche repose sur l'apprentissage profond pour extraire des représentations d'images de niveau intermédiaire et avancé. L'algorithme a été testé sur un ensemble de 433 images et a obtenu les meilleures performances en combinant les caractéristiques des CNN avec celles de GIST. Les résultats montrent une aire sous la courbe (AUC) variant entre 0,87 et 0,94 selon les pathologies détectées. Cette étude démontre la faisabilité d'une détection automatique des pathologies thoraciques à l'aide d'un apprentissage basé sur des images non médicales. Il s'agit d'une première dans le

domaine, suggérant que l'utilisation d'ImageNet, une vaste base de données d'images non médicales, pourrait servir d'alternative efficace aux représentations spécifiques au domaine médical, encore peu disponibles pour la reconnaissance des images radiologiques.

#### **7.2.4 Ayaz M, Shaukat F et Raja G:**

Ayaz M, Shaukat F et Raja G [66] ,ont proposé une méthode de détection automatique de la tuberculose (TB) basée sur l'apprentissage par ensemble, combinant des caractéristiques élaborées manuellement et des caractéristiques profondes extraites via un réseau de neurones convolutionnels. L'objectif est de faciliter le diagnostic précoce de la TB et de réduire la dépendance aux spécialistes. L'étude utilise un filtre de Gabor pour extraire des caractéristiques manuelles et des modèles d'apprentissage profond pré-entraînés pour les caractéristiques profondes. La méthodologie a été validée en utilisant un schéma de validation croisée en k sur deux ensembles de données disponibles publiquement, Montgomery et Shenzhen, atteignant des aires sous les courbes caractéristiques opératoires du récepteur de 0,99 et 0,97, respectivement.

#### **7.2.5 R Sivaramakrishnan et al:**

L'étude [67] de Sivaramakrishnan et ses collaborateurs ont développé une architecture basée sur un réseau de neurones convolutifs (CNN) et ont exploité cinq modèles pré-entraînés (AlexNet, VGG-16, VGG-19, Xception et ResNet-50) comme extracteurs de caractéristiques afin de classer les radiographies thoraciques en deux catégories : images positives à la tuberculose et images normales. Leur travail s'appuie sur deux bases de données publiques, Montgomery County et Shenzhen, fournies par la National Library of Medicine (NLM).L'architecture CNN conçue comprend 12 couches, chaque bloc étant constitué d'une couche de convolution, suivie d'une normalisation par lot (Batch Normalization) et d'une fonction d'activation ReLU. Le jeu de données a été divisé en deux : 80 % pour l'entraînement et 20 % pour le test, les images étant redimensionnées à 224×224 pixels.

Cette architecture a permis d'obtenir une précision de 82 % et une AUC de 0,89 sur le jeu de données Shenzhen, tandis que sur le jeu Montgomery, la précision était de 65,80 % avec une AUC de 0,74. Parmi les modèles pré-entraînés, AlexNet s'est révélé le plus performant, atteignant 84,20 % de précision et une AUC de 0,91 sur Shenzhen, et 72,50 % de précision avec une AUC de 0,80 sur Montgomery.

### 7.2.6 Goram Mufarah M. Alshmrani et al

L'étude de Goram Mufarah M. Alshmrani et al [68]. propose un modèle d'apprentissage profond basé sur EfficientNet v2-M pour la classification multi-classes des maladies pulmonaires à partir d'images de radiographies thoraciques (CXR). L'étude repose sur deux bases de données : celle des National Institutes of Health (NIH), ciblant trois classes (normal, pneumonie, pneumothorax), et un jeu de données interne provenant de l'hôpital Soonchunhyang de Cheonan (SCH), incluant également la tuberculose. Les résultats démontrent une performance compétitive, avec une précision de 82,15 % sur le jeu NIH et 82,20 % sur SCH, ainsi qu'une spécificité allant jusqu'à 94,48 %. Ces performances soulignent la capacité du modèle à identifier efficacement diverses pathologies pulmonaires et renforcent son potentiel en tant qu'outil clinique d'aide au diagnostic.

### 7.2.7 T. Mahmud et al

L'article [69] sur CovXNet a été réalisé par T. Mahmud, M. A. Rahman, and S. A. Fattah Leur étude propose un modèle de réseau de neurones convolutionnel (CNN) conçu pour détecter automatiquement la COVID-19 et d'autres types de pneumonie à partir d'images de radiographies pulmonaires. Ce modèle repose sur une architecture multi-dilatation, permettant d'extraire des caractéristiques variées des images, et utilise le transfert d'apprentissage en pré-entraînant le réseau sur un large ensemble de radiographies avant un affinement spécifique à la COVID-19. L'optimisation des caractéristiques est réalisée grâce à un algorithme d'empilement et des techniques de localisation discriminatives. CovXNet a été évalué sur plusieurs tâches de classification, atteignant une précision de 97,4 % pour différencier la COVID-19 des images normales, 96,9 % par rapport à la pneumonie virale, 94,7 % par rapport à la pneumonie bactérienne et 90,2 % en classification multiclasse.

### 7.2.8 Syeda Shaizadi Meraj

Meraj et al [70]. ont évalué la performance de quatre modèles pré-entraînés VGG-16, VGG-19, ResNet50 et GoogleNet sur deux bases de données publiques : Shenzhen Dataset et Montgomery Dataset. L'ensemble des images a été réparti en 75 % pour l'entraînement et 25 % pour la validation. L'unique technique de prétraitement appliquée a été l'augmentation des données, incluant des opérations de retournement, de rotation et de zoom, sans autres transformations. Sur le Shenzhen Dataset, le

modèle VGG-16 a obtenu la meilleure précision avec 86,74 % et une AUC de 0,92. Concernant le Montgomery Dataset, les modèles VGG-16 et VGG-19 ont affiché une précision maximale de 77,14 %, démontrant leur efficacité pour la classification des pathologies pulmonaires.

### **7.2.9 Jianpeng Zhang et al**

Jianpeng Zhang et al [71]. ont développé des modèles d'apprentissage profond pour la détection de la pneumonie virale, notamment du COVID-19, à partir d'images radiologiques. l'équipe a introduit un modèle basé sur la détection d'anomalies avec prise en compte de la confiance (Confidence-Aware Anomaly Detection - CAAD), qui considère la pneumonie virale comme une classe unique d'anomalie, sans nécessiter un entraînement spécifique pour chaque type de virus. Cette approche est particulièrement efficace pour détecter de nouvelles infections émergentes et s'adapter aux épidémies futures. Lors des tests, le modèle CAAD a atteint une AUC de 87,57 % sur le X-VIRAL dataset (5 977 cas de pneumonie virale et 37 393 cas non viraux) et une AUC de 83,61 % avec une sensibilité de 71,70 % sur le X-COVID dataset.

### **7.2.10 Dipayan Das, K.C. Santosh et Umapada Pal**

Dipayan Das, K.C. Santosh et Umapada Pal [72] ont conçu une solution d'apprentissage profond particulièrement sophistiquée, reposant sur l'architecture InceptionNet V3, dans le but d'automatiser le dépistage de la tuberculose à partir de radiographies pulmonaires. Leur méthode s'appuie sur des modules Inception multiscalaires capables d'extraire des caractéristiques visuelles et texturales fines, propres aux lésions tuberculeuses, et d'effectuer une analyse hiérarchique en profondeur des images médicales. Afin d'optimiser la qualité des données en entrée, les radiographies sont soumises à une phase de prétraitement incluant la segmentation automatique (à l'aide de masques générés par un CNN pré-entraîné), un recadrage ciblé de la région d'intérêt, ainsi qu'une égalisation du contraste via la méthode CLAHE. Le modèle a été rigoureusement évalué sur deux bases de données réelles et hétérogènes – Shenzhen (Chine) et Montgomery County (États-Unis) – ce qui lui a permis de faire preuve d'une grande robustesse face aux variations anatomiques et aux différences d'acquisition. Les performances obtenues sont remarquables, avec une précision de 96,17%, une sensibilité de 97,34%, une spécificité de 94,73% et une AUC de 0,983, confirmant l'efficacité du système comme outil d'aide au diagnostic dans des contextes cliniques réels.

### 7.2.11 I.Khan, J. L. Shah, et M. M. Bhat

Le travail [73] de A. I. Khan, J. L. Shah, et M. M. Bhat, présente un réseau neuronal convolutif profond (CNN) pour détecter le COVID-19 à partir d'images de radiographie thoracique. CoroNet est basé sur l'architecture Xception, pré-entraînée sur ImageNet, et a été entraîné sur un dataset composé d'images de patients atteints de COVID-19 et d'autres types de pneumonie. Le modèle classe les images en quatre catégories: COVID-19, pneumonie bactérienne, pneumonie virale, et normale. Les résultats montrent une précision globale de 89,6 %, avec une précision de 93 % et un rappel de 98,2 % pour les cas de COVID-19 en classification à quatre classes. En classification à trois classes (COVID-19, pneumonie, normale), le modèle atteint une précision de 95 %.

### 7.2.12 M. Chetoui et al

Cette recherche [74] propose le développement d'un algorithme d'apprentissage profond destiné à l'identification automatique de la COVID-19, de la pneumonie et des cas normaux à partir d'images radiographiques thoraciques (CXR). Deux approches de classification ont été mises en œuvre : l'une binaire, distinguant les cas de COVID-19 des cas normaux, et l'autre multiclasse pour COVID-19, pneumonie et normal. En s'appuyant sur plus de 3 200 images issues de neuf bases de données incluant notamment le COVID-19 Image Data Collection, RSNA, NIH, BIMCV COVID19+, sont utilisées pour l'entraînement et le test. Les systèmes sont basés sur le fine-tuning d'un CNN récent appelé EfficientNet-B5. L'architecture proposée, appelée DeepCCXR (Deep Covid-19 CXR detection) .Les performances obtenues sont particulièrement élevées, avec une aire sous la courbe (AUC) de 0,98 pour la classification binaire et de 0,97 pour la classification multiclasse. La sensibilité moyenne atteint 0,97, tandis que celle dédiée à la détection de la COVID-19 s'élève à 0,99.

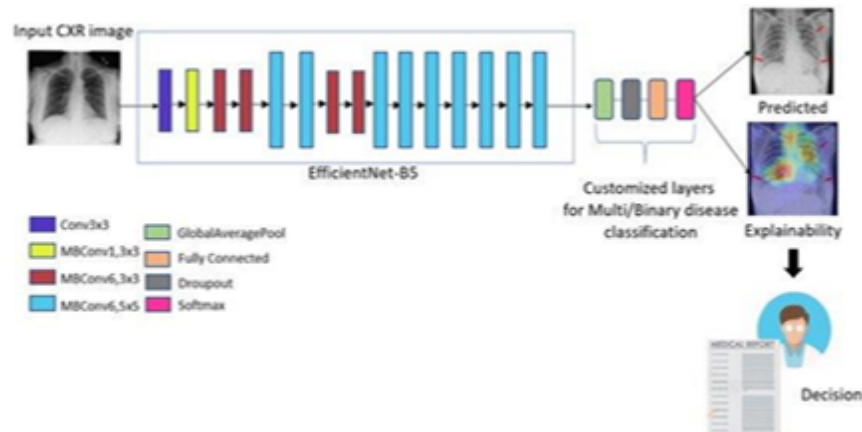


Figure 35: DeepCCXR architecture for COVID-19 detection [74]

### 7.2.13 S. Toraman, T. B. Alakus et I. Turkoglu

L'article [75] de S. Toraman, T. B. Alakus et I. Turkoglu présente une approche innovante de détection de la COVID-19 à partir d'images radiographiques, reposant sur l'intégration d'un réseau de capsules (CapsNet) avec des couches convolutionnelles. Cette architecture permet d'extraire efficacement les caractéristiques discriminantes des images tout en conservant les relations spatiales entre les pixels. L'approche a été conçue pour fournir un diagnostic rapide et précis, aussi bien en classification binaire (COVID-19 vs No-Findings) qu'en classification multi-classes (COVID-19, No-Findings, Pneumonie). Les performances obtenues sont particulièrement remarquables : 97,24 % de précision pour la classification binaire et 84,22 % pour la classification à trois classes, démontrant ainsi le potentiel des réseaux CapsNet dans le domaine du diagnostic automatisé à partir d'images médicales.

### 7.2.14 Eduardo Luz et al

Eduardo Luz, Pedro Silva, Rodrigo Silva, Ludmila Silva, João Guimarães, Gustavo Miozzo, Gladston Moreira et David Menotti [76]proposent une méthode pour la détection de la COVID-19 à partir d'images radiographiques thoraciques. Ils exploitent les architectures de réseaux neuronaux convolutifs EfficientNet, reconnues pour leur précision élevée et leur faible empreinte mémoire, combinées à une approche de classification hiérarchique pour mieux refléter la taxonomie des affections pulmonaires. En utilisant un ensemble de données de 13 569 images X-ray, réparties entre patients sains, pneumonies non liées à la COVID-19 et cas de COVID-19, les auteurs ont entraîné leur modèle ainsi que cinq autres architectures concurrentes. Les résultats obtenus

démontrent l'efficacité de leur approche, avec une précision globale de 93,9 %, une sensibilité de 96,8 % pour la détection de la COVID-19 et une prédiction positive de 100 %. De plus, leur modèle présente une efficacité computationnelle remarquable, nécessitant de 5 à 30 fois moins de paramètres que les architectures testées, ce qui facilite son intégration dans des dispositifs médicaux ou des applications mobiles pour les professionnels de santé.

#### **7.2.15 Sagar Kora Venu and Sridhar Ravula**

L'article [77] de Sagar Kora Venu et Sridhar Ravula évalue l'efficacité des réseaux antagonistes génératifs convolutifs profonds (DCGAN) combinés à des réseaux de neurones convolutifs (CNN) pour améliorer la détection de la pneumonie dans les radiographies thoraciques. L'étude utilise le jeu de données pédiatrique Chest X-ray de Stanford, présentant un déséquilibre entre les classes "normale" et "pneumonie". Pour pallier ce déséquilibre, des images synthétiques ont été générées par le DCGAN, puis intégrées à l'entraînement d'un CNN. Cette méthode d'augmentation de données permet d'enrichir le jeu d'apprentissage sans recourir uniquement aux transformations classiques. Les résultats montrent une amélioration notable des performances, avec une précision atteignant 95,5 % et une AUC de 93,6 % pour la détection de la pneumonie, surpassant les approches traditionnelles d'augmentation. L'étude conclut que l'utilisation conjointe de DCGAN et CNN constitue une approche prometteuse pour renforcer la fiabilité des systèmes d'aide au diagnostic médical.

#### **7.2.16 C. Ouchicha, O. Ammor et M. Meknassi**

C. Ouchicha, O. Ammor et M. Meknassi [78] propose une approche innovante utilisant une architecture de deep learning appelée CVDNet Cette méthode repose sur un réseau neuronal convolutif (CNN) avec des structures résiduelles et des noyaux de tailles diverses, permettant de capturer à la fois des caractéristiques locales et globales dans les images. L'entraînement a été réalisé sur un ensemble de 2905 images de radiographies, réparties entre trois catégories: images normales, pneumonie virale et COVID-19. Les résultats du modèle montrent une précision de 97,20 % pour la détection du COVID-19 et 96,69 % pour la classification des trois types d'images, des performances qui surpassent celles d'autres modèles existants

### **7.2.17 Harsh Sharma, Jai Sethia Jain, Priti Bansal et Sumit Gupta**

L'article [79] de Harsh Sharma, Jai Sethia Jain, Priti Bansal et Sumit Gupta, présenté lors de la conférence IEEE Confluence 2020, explore l'utilisation de réseaux de neurones convolutifs (CNN) pour la détection automatique de la pneumonie à partir de radiographies thoraciques. Les auteurs ont développé deux architectures CNN personnalisées, l'une intégrant une couche de régularisation par dropout et l'autre sans, afin d'extraire des caractéristiques discriminantes des images. L'étude a été menée sur le jeu de données public « Chest X-ray (Pneumonia) » de Kaggle, comprenant des cas de pneumonie et des cas normaux. Les images ont été prétraitées et divisées en ensembles d'entraînement et de validation. Les résultats indiquent que le modèle CNN avec dropout a surpassé celui sans dropout, atteignant une précision de 90,68 % dans la classification des images. Cette recherche démontre que l'intégration de techniques de régularisation dans les architectures CNN peut améliorer la performance des systèmes de diagnostic assisté par ordinateur pour la détection de la pneumonie.

### **7.2.18 Alexander Wong, Zhong Qiu Lin et Linda Wan**

Dans cette étude [80] les auteurs Alexander Wong, Zhong Qiu Lin et Linda Wang proposent COVID-Net, un réseau neuronal convolutif profond spécialement conçu pour la détection des cas de COVID-19). Ce modèle fait partie des premières architectures open source développées spécifiquement pour ce type de diagnostic à partir d'imagerie médicale. Afin de l'entraîner et de l'évaluer, les chercheurs ont créé COVIDx, un ensemble de données accessible au public, regroupant 13 975 images CXR issues de 13 870 patients, provenant de cinq bases de données ouvertes, incluant notamment

1. la COVID-19 Image Data Collection
2. COVID-19 Chest X-Ray Dataset Initiative,
3. RSNA Pneumonia Detection challenge dataset,
4. ActualMed COVID-19 Chest X-Ray Dataset Initiative,
5. COVID-19 radiography database.

Le modèle a été conçu pour effectuer une classification multi-classes, distinguant les cas normaux, les infections pulmonaires non liées au COVID-19, et les cas confirmés de COVID-19. Grâce à cette approche, COVID-Net a atteint un taux de précision de 93,3 sur le résultat de la classification multi-classes (COVID vs No-COVID vs Pneumonie)

### **7.2.19 D.Apostolopoulos et T.A. Mpesiana**

D.Apostolopoulos et T.A. Mpesiana [81] ont mené une étude visant à automatiser la détection de la COVID-19 à partir d'images radiographiques thoraciques en s'appuyant sur l'apprentissage profond, et plus particulièrement sur l'apprentissage par transfert appliqué à des réseaux de neurones convolutifs pré-entraînés. L'objectif était d'évaluer l'efficacité de différentes architectures de classification d'images médicales, dont VGG19, MobileNet V2, Inception, Xception et Inception ResNet V2. Pour cela, deux ensembles de données radiographiques ont été utilisés, chacun comprenant des cas de COVID-19 confirmés, de pneumonie bactérienne ou virale, ainsi que des images de patients sans pathologie pulmonaire.

Le premier ensemble contenait 1 427 radiographies, dont 224 associées à la COVID-19, 700 à une pneumonie bactérienne, et 504 à des cas normaux. Le second comprenait également 224 images de COVID-19, mais intégrait 714 cas de pneumonies (bactériennes et virales confondues) et les mêmes 504 images de patients sains. Ces données ont été collectées à partir de référentiels médicaux publics. Grâce à cette approche, les modèles MobileNet V2 et VGG19 se sont démarqués en atteignant des taux de précision respectifs de 97,40 % et 98,75% en classification binaire (COVID-19/Normal ou COVID-19/Pneumonie), et de 92,85 % et 93,48% en classification à trois classes

### **7.2.20 R. Sarki, K. Ahmed, H. Wang, Y. Zhang, and K. Wang**

Dans le cadre de cette étude [82] les chercheurs ont conçu un système de détection automatisée du COVID-19 à partir d'images radiographiques pulmonaires, en s'appuyant sur des techniques avancées d'apprentissage profond. Après avoir comparé plusieurs architectures de réseaux neuronaux convolutifs (CNN) couramment utilisées pour la classification d'images médicales, ils ont entraîné leur propre modèle personnalisé à partir de zéro, à l'aide d'une base de données publique enrichie. Celle-ci rassemblait des radiographies provenant de patients atteints de COVID-19, de pneumonies bactériennes et virales, ainsi que de sujets sains. Afin d'assurer la fiabilité des résultats, ils ont procédé à un nettoyage minutieux des données, écartant les images de mauvaise qualité, puis ont équilibré le jeu d'entraînement en sélectionnant

un nombre égal d'images pour chaque classe. En parallèle, ils ont également testé une approche d'apprentissage par transfert à l'aide du modèle pré-entraîné VGG16. Les performances obtenues étaient remarquables : une précision de 100 % pour la classification binaire (COVID-19 vs normal) et de 87,5 % pour la classification à trois classes (Normal/COVID-19/Pneumonie). Le CNN conçu depuis zéro a quant à lui atteint une précision de 93,75 % pour cette dernière. Ces résultats ont été confirmés par une évaluation rigoureuse, incluant l'analyse des courbes ROC et des matrices de confusion.

#### **7.2.21 Khairul Munadi, et al**

Dans l'étude [83] Khairul Munadi, Kahlil Muchtar, Novi Maulina, et Biswajeet Pradhan ont exploré l'amélioration d'images radiographiques pour optimiser la détection de la tuberculose pulmonaire à l'aide de techniques d'apprentissage profond. L'approche méthodologique repose sur l'utilisation d'une étape de prétraitement basée sur l'amélioration d'images par des techniques comme l'histogramme adaptatif (CLAHE) et le redimensionnement normalisé, dans le but d'accentuer les zones pulmonaires pertinentes pour le diagnostic. Le modèle principal employé dans cette étude est un réseau de neurones convolutif profond (CNN), entraîné pour classifier les radiographies thoraciques comme positives ou négatives à la tuberculose. Les expériences ont été réalisées à partir d'une base de données composée de 800 images issues du Montgomery County et du Shenzhen Hospital, deux ensembles de données largement utilisés dans la détection automatisée de la tuberculose. Les résultats montrent une amélioration significative des performances après l'étape d'amélioration d'image, avec une précision atteignant 84 %, soulignant l'impact du prétraitement visuel sur l'efficacité des modèles de deep learning dans les tâches de classification médicale.

#### **7.2.22 Vo Trong Quang Huy et Chih-Min Lin**

L'article [84] de Vo Trong Quang Huy et Chih-Min Lin, propose un modèle de deep learning amélioré, nommé CBAMWDnet, pour la détection de la tuberculose à partir d'images de radiographie thoracique de Tuberculosis chest X-ray images, MC, Shenzhen. Ce modèle combine l'architecture Wide DenseNet (WDnet) avec le Convolutional Block Attention Module (CBAM), permettant de capturer efficacement les informations spatiales et contextuelles des images. Évalué sur un large ensemble de données de radiographies thoraciques, le CBAMWDnet a surpassé plusieurs modèles

de pointe, atteignant une précision de 98,80 %, une sensibilité de 94,28 %, une précision (au sens statistique) de 98,50 %, une spécificité de 95,7 % et un score F1 de 96,35 %. Ces résultats indiquent que le CBAMWDnet est un outil prometteur pour le diagnostic précoce de la tuberculose, offrant des performances supérieures à celles des modèles existants.

### **7.2.23 Nada M. Elshennawy et Dina M. Ibrahim**

L'article [85] de Nada M. Elshennawy et Dina M. Ibrahim, publié en 2020 dans *Diagnostics*, présente un cadre nommé Deep-Pneumonia pour la détection automatique de la pneumonie à partir de radiographies thoraciques en utilisant des modèles d'apprentissage profond. Les auteurs ont utilisé la base de données Chest X-ray (Pneumonia) disponible sur Kaggle, qui contient des images classées comme normales ou atteintes de pneumonie. Quatre modèles ont été développés et évalués : un CNN personnalisé, un modèle combine un réseau de neurones convolutifs (CNN) avec une mémoire à long terme (LSTM) : le modèle CNN + LSTM. Dans cette architecture, le CNN est utilisé pour extraire des caractéristiques spatiales pertinentes des images, tandis que le LSTM, généralement utilisé pour des données séquentielles, permet ici de capturer des relations plus profondes et contextuelles entre les régions de l'image, en modélisant des dépendances spatiales étendues, ainsi que deux réseaux profonds pré-entraînés, MobileNetV2 et ResNet152V2. Les résultats montrent que le CNN personnalisé a atteint une précision de 91,52 %, le CNN + LSTM a obtenu 93,73 %, tandis que MobileNetV2 a atteint 95,84 %. Le meilleur résultat a été obtenu avec ResNet152V2, qui a atteint une précision remarquable de 99,22 %.

### **7.2.24 Lingga Aji Andika, Hasih Pratiwi, et Sri Sulistijowati Handajani**

Dans cette étude [86] les auteurs ont utilisé une base de données composée de 663 images radiographiques thoraciques, réparties en deux catégories : poumons normaux et cas de tuberculose pulmonaire (PTB). Ces données proviennent d'une collaboration entre la National Library of Medicine (Maryland, USA) et le Shenzhen No.3 People's Hospital (Guangdong Medical College, Shenzhen, Chine). Le modèle de réseau de neurones convolutif (CNN) développé a été entraîné sur ces images en utilisant l'optimiseur Adam sur 75 itérations (epochs). Les performances obtenues sont les suivantes : une précision de 99,19 % sur les données d'entraînement 80,60 % sur les données de validation et une précision globale de 84 % sur les données de test. Ces résultats indiquent que le modèle est capable de différencier efficacement les cas

normaux des cas de tuberculose pulmonaire

### **7.2.25 Ahmed Iqbal, Muhammad Usman et Zohair Ahmed**

Dans cette étude [87] les chercheurs ont développé une méthode étude repose sur une approche hybride combinant segmentation et classification pour améliorer la détection de la tuberculose à partir de radiographies thoraciques. Tout d'abord, les poumons sont segmentés à l'aide d'un modèle appelé TB-UNet, une version améliorée de U-Net intégrant des blocs de fusion dilatée et des blocs d'attention, permettant de localiser avec précision les régions pulmonaires, même en présence d'anomalies. Ensuite, les images segmentées sont utilisées comme entrée pour le modèle de classification TB-DenseNet, qui est construit à partir de Dual Convolution Blocks suivis d'un extracteur de caractéristiques profondes basé sur DenseNet-169. Le modèle fusionne les informations provenant à la fois des images originales et segmentées pour renforcer la performance de la classification. Cette combinaison permet une détection plus fiable des cas de tuberculose, atteignant une Accurcy de 95,10 %, ce qui montre l'efficacité du système dans le contexte du dépistage assisté par intelligence artificielle.

### **7.2.26 Yuting Yang, Gang Mei et Francesco Piccialli**

Dans cette étude [88] Yuting Yang et al ,ont utilisé des réseaux de neurones convolutifs profonds pour identifier la pneumonie à partir de radiographies thoraciques, en s'appuyant sur la base de données Chest X-ray Pneumonia de Kaggle. Deux approches ont été comparées : l'une utilisant les images originales, incluant l'arrière-plan, et l'autre utilisant des images prétraitées, où l'arrière-plan a été supprimé pour ne conserver que la région pulmonaire. Pour interpréter les décisions du modèle, les auteurs ont intégré la technique Grad-CAM, une méthode d'intelligence artificielle explicable (XAI), permettant de visualiser les zones activées par le réseau. Les résultats montrent que la suppression de l'arrière-plan améliore significativement la précision du modèle, avec un score d'accuracy allant jusqu'à 95,6 % en utilisant le modèle VGG16, démontrant ainsi l'intérêt de combiner prétraitement ciblé et explicabilité pour renforcer la fiabilité du diagnostic assisté par IA.

## 8 Conclusion

Dans ce chapitre, nous avons présenté un aperçu des bases de l'intelligence artificielle appliquée à l'analyse des images médicales. Nous avons exploré différentes architectures et méthodes, ainsi que leur utilisation dans des travaux sur des systèmes automatiques pour la classification des maladies pulmonaires.

*Chapitre 03:  
Conception, méthodologie et mise en  
œuvre d'un système de diagnostic  
automatique*

## 1 Introduction

Dans ce chapitre, nous vous présentons en détail les étapes que nous avons suivies pour développer nos systèmes de détection automatique des pathologies pulmonaires à partir d'images radiologiques depuis la mise en place de notre environnement de travail et la sélection des outils, jusqu'au choix des hyperparamètres. Nous passerons ainsi en revue les étapes clés du processus : préparation des données, conception du modèle.

## 2 Environnement et outils de travail

### 2.1 Google Colaboratory

C'est une plateforme gratuite proposée par Google permettant d'écrire et d'exécuter du code Python directement depuis notre navigateur. Elle permet d'utiliser des notebooks Jupyter sans nécessiter de configuration complexe, et offre un accès à des ressources de calcul puissantes, telles que les GPU et TPU, idéales pour l'apprentissage automatique ou le traitement d'images. Un autre avantage important est qu'elle inclut déjà la plupart des bibliothèques courantes en science des données et en intelligence artificielle, comme Pandas, TensorFlow ou PyTorch, sans qu'il soit nécessaire de les installer manuellement. Colab simplifie également le partage de nos notebooks.



### 2.2 Langage de programmation Python

Python est un langage de programmation performant et simple à comprendre. Il offre des structures de données avancées et facilite la programmation orientée objet de manière claire et efficace. Grâce à sa syntaxe propre, son typage flexible et son interprétation directe, Python est parfait pour créer des scripts et développer rapidement des applications dans divers domaines et sur presque toutes les plateformes [89].



## **2.3 Les bibliothèques utilisées**

### **2.3.1 Pytorch**

PyTorch est une bibliothèque open source pour le calcul scientifique et l'apprentissage automatique. Elle facilite la réalisation, l'entraînement et l'évaluation de modèles grâce à son mode d'opération dynamique. Ce Framework. Elle permet de faire passer des données à travers des réseaux de neurones. C'est un peu comme le cerveau de ton programme IA.



PyTorch est reconnu pour sa souplesse, sa simplicité d'utilisation, ainsi que sa capacité à s'adapter aux besoins de la recherche. Il permet de créer, d'entraîner et de déployer des modèles complexes de manière efficace, notamment grâce à sa compatibilité avec les GPU. Il est utilisé dans de nombreux domaines comme la classification d'images, le traitement de texte, la reconnaissance vocale et les séries temporelles.

### **2.3.2 Pandas**

Pandas est une bibliothèque puissante conçue pour l'analyse et la manipulation de données en Python. Elle fournit deux structures de données principales : séries pour les

données unidimensionnelles et DataFrame pour les tableaux à deux dimensions. Grâce à Pandas, il est possible d'importer, de filtrer, de convertir et de scruter aisément des ensembles de données issus de diverses origines telles que CSV, Excel, SQL.



### 2.3.3 NumPy

NumPy est une bibliothèque fondamentale pour le calcul scientifique en Python. Elle propose un objet tableau à dimensions multiples et des objets dérivés tels que les tableaux masqués et les matrices. NumPy met à disposition un ensemble de routines permettant d'exécuter rapidement des opérations sur les tableaux, englobant des opérations mathématiques, logiques, de manipulation de formes, de tri, de sélection d'E/S, de transformées de Fourier discrètes, d'algèbre linéaire, d'opérations statistiques et de et de simulation aléatoire.



### 2.3.4 Torchvision

Torchvision est un module complémentaire à PyTorch destiné au traitement d'images. Il fournit des ensembles de données standards prêts à l'emploi, des modèles déjà entraînés, et une série d'outils pour transformer les images. Torchvision est largement utilisé dans les projets de reconnaissance et de détection d'objets.



### 2.3.5 Sklearn

sklearn est une bibliothèque libre Python destinée à pour l'apprentissage automatique en Python. Elle propose un large éventail d'algorithmes pour la classification, la régression, le clustering, la réduction de dimensions et l'évaluation de modèles. Sklearn se distingue par sa simplicité d'utilisation et son intégration fluide avec NumPy et Pandas



### 2.3.6 Matplotlib

Matplotlib est une bibliothèque du langage de programmation Python Elle permet de générer des graphiques variés comme des courbes, des histogrammes, des barres, ou des images. Très flexible, elle est souvent utilisée pour explorer et présenter des résultats de manière visuelle. Elle peut être combinée avec les bibliothèques python de calcul scientifique NumPy et SciPy.

### 2.3.7 Opendatasets

Opendatasets est une librairie Python qui facilite l'acquisition des bases de données accessibles au public provenant de plateformes telles que Kaggle. Cette librairie offre un accès rapide aux ensembles de données sans nécessiter l'usage de l'interface web.

### 2.3.8 PIL (python image Library)

PIL c'est une bibliothèque permettant de travailler avec des images en Python. Elle permet de charger, afficher, redimensionner, convertir, ou encore appliquer des filtres sur des images.

### 2.3.9 Torchsummary

Torchsummary est un utilitaire destiné aux utilisateurs de PyTorch, qui permet d'afficher un résumé détaillé de l'architecture d'un modèle. Il indique pour chaque couche le type, la taille des entrées et sorties, ainsi que le nombre de paramètres. Cela permet d'avoir une vue d'ensemble rapide de la complexité du réseau.

## 3 Présentation du modèle proposé

Notre modèle s'appuie sur l'analyse des images radiologiques thoraciques pour détecter et différencier deux pathologies pulmonaires infectieuses : la pneumonie (bactérienne et virale) et la tuberculose. Pour cela, nous utilisons des techniques avancées de deep learning, qui permettent d'extraire automatiquement des caractéristiques complexes à partir des images. Bien plus que ce que l'œil humain peut voir. L'objectif principal est de comparer les performances de quatre architectures de réseaux de neurones convolutifs (CNN). Nous étudions un CNN classique, ainsi que trois modèles pré-entraînés : ResNet50, EfficientNetB0, DenseNet121. Chacune de ces architectures a ses spécificités :

**ResNet-50 :** est un réseau de neurones convolutifs (CNN) composé de 50 couches. Il est conçu pour effectuer des tâches de classification d'images, de détection d'objets et de segmentation sémantique. L'innovation majeure de ResNet-50 réside dans l'introduction de blocs résiduels (structure dans un réseau de neurones qui permet de "sauter" une ou plusieurs couches, en ajoutant directement l'entrée du bloc à sa sortie) qui permettent au réseau d'apprendre des fonctions résiduelles plutôt que des fonctions directes, facilitant ainsi l'entraînement de réseaux très profonds [90].




Figure 36: Architecture des couches ResNet-50 (extrait de [91])

**EfficientNetB0** : est une architecture de réseau de neurones convolutifs (CNN) conçue pour maximiser les performances tout en réduisant le nombre de paramètres et la charge computationnelle. Développé par les chercheurs de Google, ce modèle repose sur une stratégie novatrice appelée scaling composé (compound scaling), qui ajuste de manière équilibrée et simultanée trois dimensions fondamentales d'un réseau : la profondeur (nombre de couches), la largeur (nombre de canaux) et la résolution des images d'entrée. Le cœur d'EfficientNetB0 est constitué de blocs MBConv (Mobile Inverted Bottleneck Convolution), dérivés de MobileNetV2. Chaque bloc MBConv suit une structure spécifique : il commence par une couche d'expansion, suivie d'une convolution depthwise (par canal), puis d'une couche de projection. Ces blocs intègrent également des modules Squeeze-and-Excitation (SE) qui permettent d'ajuster dynamiquement l'importance des canaux en fonction de leur contribution à la tâche. Cette combinaison favorise une extraction riche et hiérarchique des caractéristiques tout en restant légère en termes de calculs.

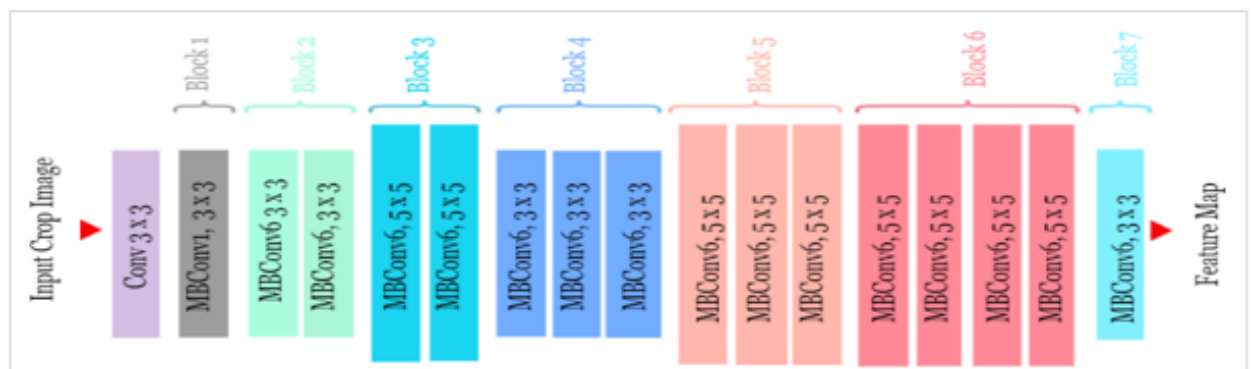


Figure 37: Architecture des couches du modèle efficientNetB0 (extrait de [92])

Par ailleurs, EfficientNetB0 utilise la fonction d'activation Swish ( $x * \text{sigmoid}(x)$ ), plus souple que la fonction ReLU, et qui améliore la capacité du réseau à modéliser des relations complexes dans les données [93].

**DenseNet121** : est un réseau de neurones convolutifs profond qui compte 121 couches, conçu pour optimiser la propagation de l'information entre les couches tout en réduisant le nombre de paramètres. Son architecture repose sur l'utilisation de blocs denses, où chaque couche reçoit en entrée les sorties de toutes les couches précédentes du bloc. Cette connectivité dense favorise une meilleure réutilisation des caractéristiques et résout en grande partie le problème du gradient qui disparaît dans les réseaux très profonds. DenseNet121 est structuré en 4 blocs denses séparés par des couches de transition, qui combinent des opérations de normalisation, de convolution 1x1 et de pooling pour réduire la taille des cartes de caractéristiques tout en maintenant leur richesse. Le réseau commence par une convolution initiale suivie d'un max pooling, puis enchaîne avec les blocs denses et se termine par une couche de pooling global et une couche entièrement connectée pour la classification. Grâce à cette organisation, DenseNet121 atteint un très bon compromis entre profondeur, efficacité en calcul, et capacité d'apprentissage, le rendant particulièrement adapté à la classification d'images, y compris dans des contextes médicaux comme l'analyse de radiographies [94].



Figure 38: Architecture des couches de modèle DenseNet121 (extrait de [95])

### 3.1 Architecture global du système

Dans notre système de détection des pathologies pulmonaires, nous commençons par le chargement de deux bases de données radiographiques: **Chest X-Ray Images Pneumonia (CXRP)** et **Tuberculosis Chest X-ray Database** qui seront divisées en trois parties (train/validation/teste). Ces données sont ensuite

soumises à un prétraitement, comprenant le redimensionnement, la normalisation ainsi que des techniques d'augmentation de données, afin de renforcer la robustesse de l'apprentissage. Après cette étape, plusieurs modèles d'apprentissage profond sont entraînés séparément sur chaque base de données. Parmi les architectures utilisées, nous comptons un réseau neuronal convolutif (CNN) classique, ResNet50, EfficientNetB0 et DenseNet121. Chaque modèle apprend à classifier les images à partir des données d'entraînement, tandis que les performances sont ensuite évaluées à l'aide d'indicateurs tels que la matrice de confusion, le rapport de classification et des représentations graphiques permettant une analyse visuelle claire des résultats.

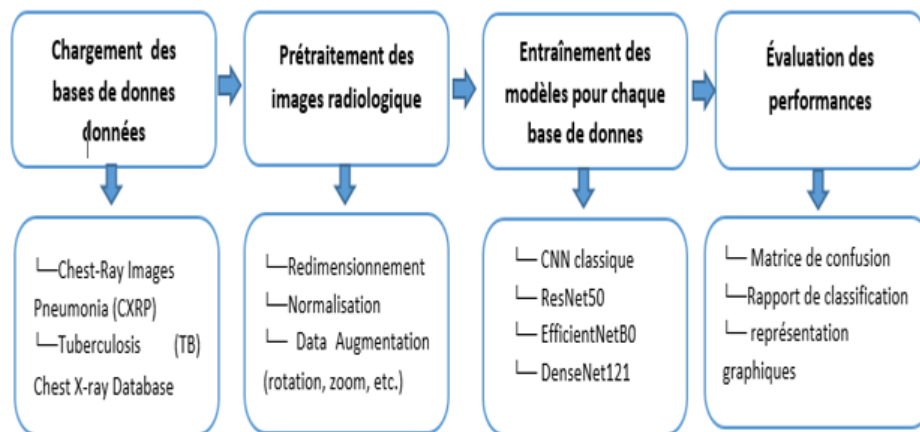


Figure 39: Figure 3.1: schema architecture global du système

## 4 Description du dataset

Nous avons utilisé 2 bases de données open source de kaggle :

**"Chest X-Ray Images Pneumonia (CXRP) "** : [96] La base de données est divisée en trois dossiers principaux : train, test et val. Chaque dossier regroupe des sous-dossiers correspondant aux catégories d'images : Pneumonie et Normal. En tout, elle contient 5 863 radiographies thoraciques au format JPEG. Dans notre travail, nous avons utilisé le dossier train, qui contient 5216 images radiologiques thoraciques. Ce dossier est lui-même divisé en deux sous-dossiers :

- Le sous-dossier Normal, qui contient 1 341 images de cas sains et le sous-dossier Pneumonie, qui regroupe 3 875 images, réparties en :
  - 2530 images de pneumonie bactérienne.
  - 1345 images de pneumonie virale.

Les radiographies du thorax ont été choisies à partir de groupes de patients pédiatriques âgés de un à cinq ans du Guangzhou Women and Children's Medical Center. Toutes ces radiographies ont été faites pendant les soins habituels des patients. Pour examiner les images des poumons, chaque radiographie a été vérifiée pour enlever celles de mauvaise qualité ou illisibles. Deux médecins experts ont ensuite évalué les diagnostics avant de les utiliser pour entraîner le système d'IA. Pour éviter les erreurs, un troisième expert a aussi vérifié l'ensemble d'évaluation.

**"Tuberculosis (TB) Chest X-ray Database":** [97] Cette base de données a été collectée par une équipe de chercheurs de l'Université du Qatar (Doha, Qatar) et de l'Université de Dhaka (Bangladesh), en collaboration avec leurs partenaires en Malaisie et des médecins de la Hamad Medical Corporation ainsi que du Bangladesh. Elle comprend à la fois des cas positifs de tuberculose (TB) et des images thoraciques normales.

Au total, la base contient 4 200 images radiologiques thoraciques au format PNG, réparties en 3 500 images de cas normaux et 700 images de cas de tuberculose accessibles au public.

## 5 Prétraitement des données

**Modèle 1 (Pneumonie bactérienne / Pneumonie virale / Normal) :** Pour ce modèle, nous avons utilisé la base de données **"Chest X-Ray Images Pneumonia (CXRP)"**. Nous avons travaillé à partir du dossier "train", qui contient 5216 image en deux catégories d'images : "normal" et "pneumonie". Pour différencier les types de pneumonie, nous avons créé deux sous-dossiers séparés, l'un pour les cas de pneumonie virale "virus" et l'autre pour les cas de pneumonie bactérienne "bacteria" Afin de structurer notre jeu de données pour l'entraînement et l'évaluation du modèle, nous l'avons divisé en trois sous-ensembles : 70 % donc 3651 images ont été utilisées pour l'entraînement du modèle le reste 1565 sont divisé 15 % ont servi à la validation et les 15 % restants ont été réservés pour tester la performance finale du modèle . Après avoir obtenu de nouveaux ensembles de données nous avons appliqué un prétraitement:

- Retournement horizontal
- Rotation aléatoire jusqu'à  $\pm 10^\circ$
- Rééchantillonner les pixels (mise à l'échelle entre 0 et 1)

Après avoir appliqué ce prétraitement, nous avons ajouté un traitement spécifique aux images du sous-dossier "virus", dans le but d'améliorer la performance du modèle sur cette classe souvent plus difficile à distinguer. Ce prétraitement spécial comprend :

- Retournement horizontal
- Rotation aléatoire jusqu'à  $\pm 20^\circ$
- Ajustement aléatoire de la luminosité et du contraste (jusqu'à  $\pm 20\%$ )
- Transformation affine aléatoire (translation jusqu'à  $5\%$ )

**Modèle 2 (Tuberculose / Normal) :** Pour ce modèle, nous avons utilisé la base de données **Tuberculosis (TB) Chest X-ray Database** cette base de données contient 4200 images radiologiques nous l'avons divisé en trois sous-ensembles :  $70\%$  donc 2940 images ont été utilisées pour l'entraînement du modèle le reste 1260 sont divisé  $15\%$  ont servi à la validation et les  $15\%$  restants ont été réservés pour tester la performance finale du modèle Nous avons appliqué un prétraitement :

- Retournement horizontal
- Rotation aléatoire jusqu'à  $\pm 10^\circ$
- Rééchelonner les pixels (mise à l'échelle entre 0 et 1)

## 6 Architecture des modèles:

### 6.1 CNN classique:

Le modèle est composé de 3 blocs, chaque bloc est composé d'une couche de convolution de taille  $1 \times 1$ , suivie d'une couche de MaxPooling  $2 \times 2$ , puis d'une fonction d'activation ReLU qui force les neurones à retourner des valeurs positives. La différence entre les blocs réside dans le nombre de filtres utilisés dans la couche de convolution :

- Le premier bloc est composé d'une couche convolutionnelle avec 32 filtres.
- Le deuxième bloc est composé d'une couche convolutionnelle avec 64 filtres.
- Le troisième bloc est composé d'une couche convolutionnelle avec 128 filtres.

L'image en entrée a une taille de  $(128, 128, 1)$ , elle passe d'abord dans la première couche de convolution. Cette couche utilise 32 filtres de taille  $1 \times 1$ , ce qui génère 32 cartes de caractéristiques (feature maps) de taille  $128 \times 128$ . Ensuite, un MaxPooling de taille  $2 \times 2$  est appliqué avec un pas de 2 pour réduire la taille de l'image et diminuer

le nombre de paramètres et de calculs. À la sortie de ce premier bloc, nous obtenons 32 cartes de caractéristiques de taille 64x64 qui sont transmises au bloc suivant.

Le même processus se répète dans les blocs suivants avec une augmentation du nombre de filtres, comme expliqué précédemment. Le deuxième bloc génère 64 cartes de caractéristiques, puis le troisième 128 cartes, avec la taille qui est divisée par deux à chaque étape grâce au MaxPooling, jusqu'à obtenir des cartes de taille 16x16 à la sortie du dernier bloc.

Après ces trois blocs, les cartes de caractéristiques sont aplaties en une seule liste. Cette liste passe ensuite dans une couche entièrement connectée composée de 128 neurones. Enfin, une dernière couche linéaire génère le nombre de sorties égal au nombre de classes présentes dans les données, permettant la classification finale.




Figure 40: Architecture du CNN bisque

## 6.2 ResNet50

Ce modèle repose sur l'architecture ResNet50, pour laquelle nous avons utilisé les poids préentraînés sur ImageNet. Afin de préserver les connaissances acquises lors de cet entraînement initial, l'ensemble des couches du modèle a été fixé ce qui signifie que leurs poids ne sont pas modifiés au cours de l'apprentissage. Ensuite, nous avons remplacé la couche fully connected finale du modèle par un nouveau classifieur personnalisé : nous avons d'abord intégré une couche linéaire réduisant la dimension de 2048 à 512 neurones, suivie d'une fonction d'activation ReLU, puis nous avons appliqué un dropout de 20 % afin de limiter le surapprentissage. Enfin, nous avons ajouté une dernière couche linéaire comportant 2 ou 3 neurones, correspondant aux nombre des classes à prédire.

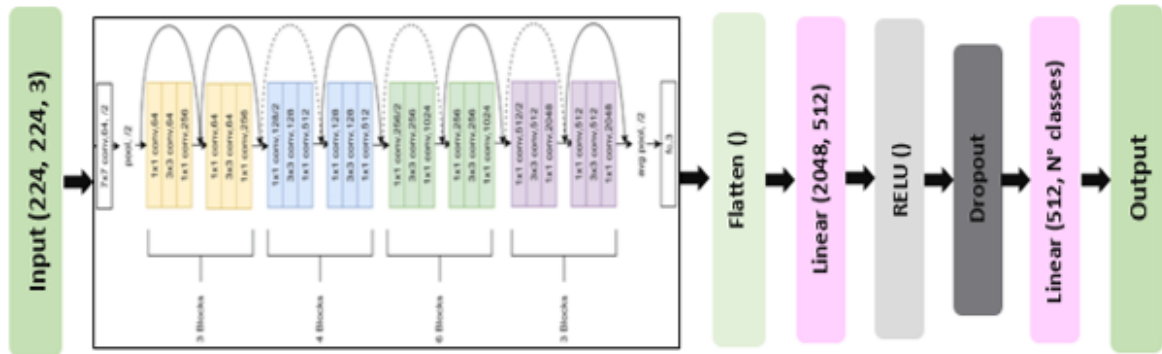


Figure 41: L'architecture de ResNet 50

### 6.3 EfficientNetB0

Ce modèle est basé sur l'architecture EfficientNetB0, pour laquelle nous avons utilisé les Poids pré-entraînés sur ImageNet. Toutes les couches du modèle ont été verrouillées (autrement dit, leurs poids sont conservés inchangés pendant l'entraînement) afin de préserver les connaissances générales acquises lors de l'apprentissage initial. Ensuite, nous avons modifié la tête de classification initiale en y ajoutant un nouveau classifieur constitué de plusieurs couches entièrement connectées : une première couche linéaire de 512 neurones, suivie d'une fonction d'activation ReLU, d'un dropout de 20 % pour éviter le surapprentissage, puis d'une dernière couche linéaire contenant 2 ou 3 neurones correspondant au nombre de classes à prédire .

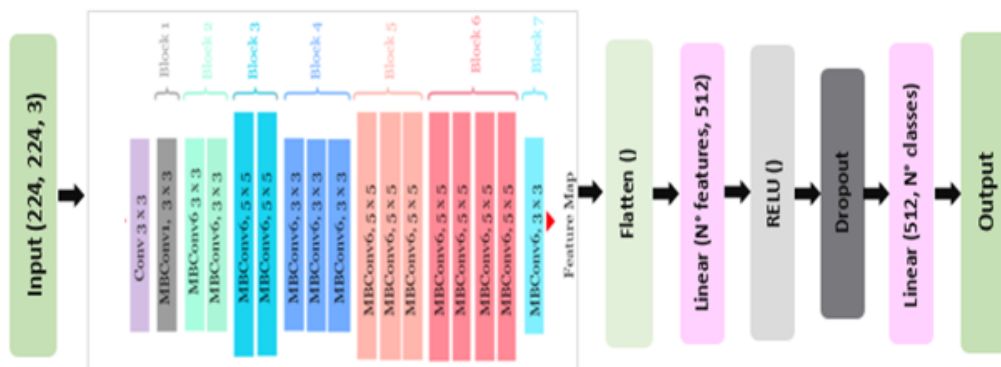


Figure 42: L'architecture de EfficientNetB0

## 6.4 Densnet121

Dans ce modèle, nous avons utilisé l'architecture DenseNet121, chargée avec des poids Préentraînés sur ImageNet afin de profiter de ses capacités d'extraction de caractéristiques riches. Pour éviter de modifier les représentations apprises durant ce préentraînement, les paramètres de toutes les couches existantes ont été désactivés pour l'entraînement. Seule la couche de classification finale a été modifiée pour correspondre à notre tâche spécifique. Celle-ci a été remplacée par une séquence de couches entièrement connectées, incluant une couche linéaire de 1024 vers 512 neurones, une fonction d'activation ReLU, un Dropout de 20 %, puis une dernière couche linéaire avec un nombre de neurones égal au nombre de classes

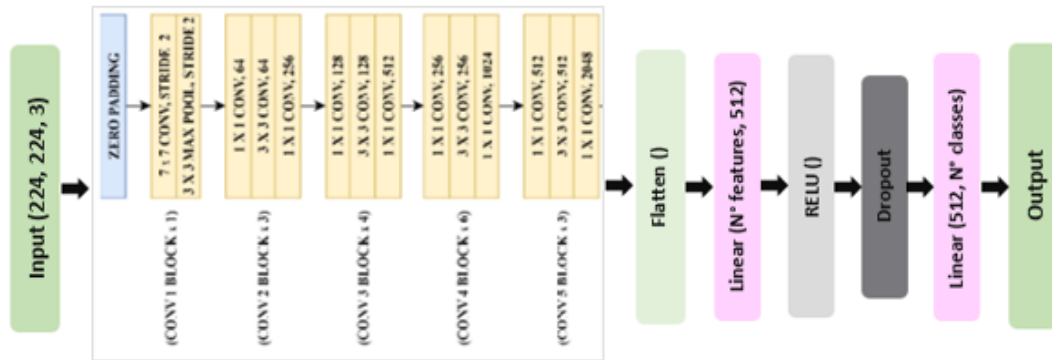


Figure 43: L'architecture de DenseNet121

## 7 Choix des hyper-paramètres

Les algorithmes d'apprentissage profond impliquent l'optimisation des hyper-paramètres. Il s'agit de faire le choix d'un ensemble d'hyper-paramètres optimaux qui configure l'entraînement du modèle de Deep Learning. Nous allons, définir dans ce qui suit, quelques fonctions, optimiseurs et hyper-paramètres que nous utilisons pour notre modèle.

### 7.1 Taux d'apprentissage (Learning Rate)

Le taux d'apprentissage est l'un des hyper paramètres les plus cruciaux dans l'entraînement d'un réseau de neurones. Il détermine la vitesse à laquelle le modèle ajuste ses poids en réponse à l'erreur calculée sur les données d'entraînement. Un taux d'apprentissage trop élevé peut entraîner une instabilité, tandis que un taux trop faible ralentit considérablement l'apprentissage [98].

## 7.2 Nombre époques (epoch)

Une epoch correspond à un passage complet de l'algorithme d'apprentissage sur l'ensemble de la base de données d'entraînement. En d'autres termes, c'est le nombre de fois que le modèle parcourt entièrement les données pour ajuster ses paramètres internes [99].

## 7.3 Batch size

Batch size ou taille de batch est le nombre d'échantillons de données. Elle détermine combien d'exemples le modèle traite avant de mettre à jour ses paramètres [99].

## 8 Conclusion

Dans ce chapitre, nous avons présenté la conception de notre système de diagnostic automatique des pathologies pulmonaires, ainsi que la méthodologie utilisée. Nous avons décrit l'environnement de développement, les outils logiciels, les bases de données, et les principales étapes de préparation des données, y compris les techniques de prétraitement et d'augmentation adaptées à chaque type de pathologie. Nous avons aussi expliqué en détail les architectures des modèles d'apprentissage profond utilisés. Ces choix méthodologiques et techniques sont la base de nos expérimentations, dont les résultats et les analyses seront présentés dans le chapitre suivant.

*Chapitre 04:*  
*Implémentation, Résultats expérimentaux*  
*et évaluation*

## 1 Introduction

Dans ce chapitre, nous avons présenté les résultats obtenus avec les modèles que nous avons développés pour la classification des pathologies pulmonaires à partir d'images radiographiques. Après avoir mis en place notre système et testé différentes architectures de réseaux de neurones d'un CNN classique à des modèles préentraînés. Il est nécessaire d'évaluer et de discuter sur les performances de chaque modèle.

## 2 Évaluation du modèle

### 2.1 Matrice de confusion

Une matrice de confusion est un tableau utilisé pour évaluer les performances d'un modèle de classification. Elle compare les prédictions du modèle avec les véritables classes des données. Elle est organisée de façon à montrer combien de fois le modèle a correctement ou incorrectement prédit chaque classe. Comme le montre la figure 100

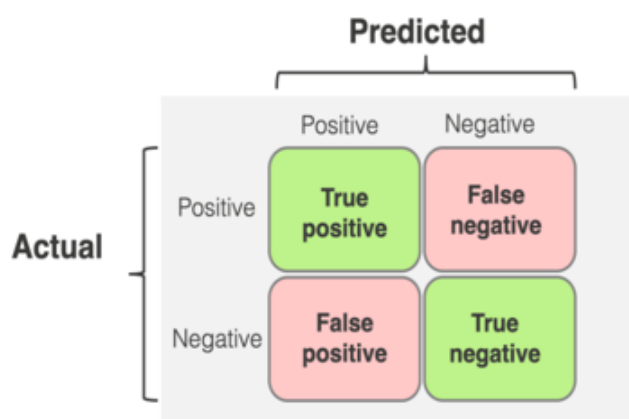


Figure 44: matrice de confusion (extrait de [100])

- True positive (TP) : nombre de cas où le modèle a correctement prédit la classe positive.
- False positive (FP) : nombre de cas où le modèle a prédit à tort la classe positive.
- True negative (TN) : nombre de cas où le modèle a correctement prédit la classe négative.
- False negative (FN) : nombre de cas où le modèle a prédit à tort la classe négative [100].

## 2.2 Évaluation des performances

Les mesures de performance d'un algorithme de classification sont accuracy, la précision, recall et le score F1, qui sont calculés à partir des valeurs VP, VN, FP et FN mentionnées précédemment [100].

### 2.2.1 Accuracy (ACC)

Donne la proportion du nombre total de prédictions qui étaient correctes :

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

### 2.2.2 Précision

Donne la proportion de résultats positifs par rapport au total des résultats positifs prédits. En d'autres termes, la précision correspond à la proportion de résultats positifs qui ont été correctement identifiés.

$$\text{Précision} = \frac{TP}{TP + FP} \quad (3)$$

### 2.2.3 Recall

Appelée aussi Sensitivity ou true positive rate s'agit du rapport entre le nombre de valeurs positives et le total des cas réellement positive

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

### 2.2.4 F1-score

Est la moyenne harmonique entre la précision et le rappel.

$$\text{F1 Score} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

### 3 Implémentation et processus d'entraînement

#### 3.1 L'importation des bibliothèques

Pour utiliser les bibliothèques citées avant et leurs classes, il est nécessaire de les appeler avec les instructions suivantes.

```
import torch
from torch import nn
import pandas as pd
import numpy as np
import os
import opendatasets as data_set_kaggle
from PIL import Image
from torch.optim import Adam
import torchvision.transforms as transforms
from torch.utils.data import Dataset, DataLoader
from sklearn.preprocessing import LabelEncoder
import matplotlib.pyplot as plt
from torchsummary import summary
from sklearn.metrics import classification_report, confusion_matrix, ConfusionMatrixDisplay
```

Figure 45: les bibliothèques importées

#### 3.2 L'importation et utilisation des données

**Pour le 1er modèle :** pneumonie (bactérienne/ viral) et Normal : Nous avons importé la base de données depuis Kaggle en utilisant la bibliothèque "opendatasets ". Pour cela, nous avons spécifié le lien du dataset "chest-xray-pneumonia " et fourni nos identifiants Kaggle (nom d'utilisateur et clé API). Une fois l'authentification effectuée, le téléchargement du fichier compressé s'est déroulé avec succès. Nous avons ainsi obtenu localement un dossier nommé chest-xray-pneumonia contenant l'ensemble des images radiographiques, qui seront utilisées pour l'entraînement, la validation et le test de notre modèle de classification."

```
kaggle_link = "https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia"
data_set_kaggle.download(kaggle_link)
```

Please provide your Kaggle credentials to download this dataset. Learn more: <http://bit.ly/kaggle-creds>  
Your Kaggle username: hadjerboudjemaa  
Your Kaggle Key: .....  
Dataset URL: <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>  
Downloading chest-xray-pneumonia.zip to ./chest-xray-pneumonia  
100%|██████████| 2.29G/2.29G [00:20<00:00, 121MB/s]

Figure 46: chargement des données du premier modèle

Nous avons extrait dossier "NORMAL" et "PNEUMONIA" situé dans le répertoire train du dataset.

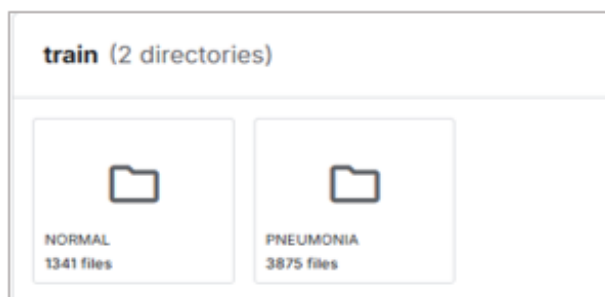


Figure 47: dossier train de la base de données chest xray pneumonia (extrait de [96])

Le répertoire train comprenait des images de pneumonie d'origine bactérienne et virale, sans une séparation en sous-dossiers. En d'autres termes, ces deux catégories de pneumonie étaient regroupées dans un même répertoire, rendant ainsi la structure désorganisée comme montre la figure 4.3 et nécessitant une réorganisation afin de faciliter l'apprentissage du modèle

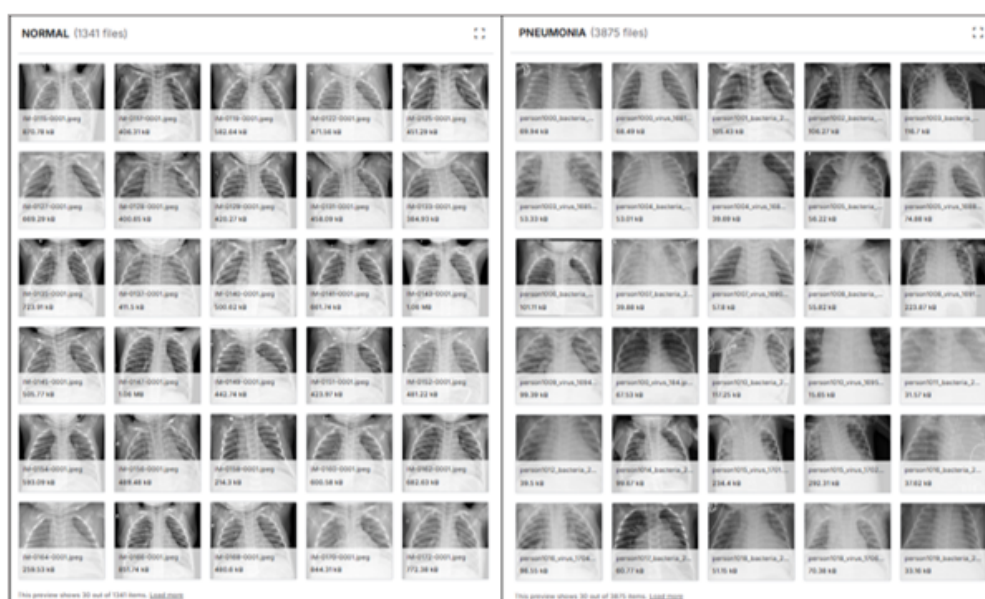


Figure 48: organisation initiale du dossier train (extrait de [96])

Donc, Nous avons créé un nouveau dossier intitulé " XRAY " afin d'y organiser les images de la base de données selon trois catégories distinctes : "Normal", "Bacteria" et "Virus". Ensuite, nous avons copié les images saines depuis le répertoire "NORMAL" vers le dossier "Normal". Nous avons également extrait les images de pneumonie bactérienne pour les placer dans le dossier " Bacteria", et enfin, nous avons transféré les images de pneumonie virale dans le dossier " Virus". Cette organisation nous permet

de mieux structurer les données en vue de l'entraînement d'un modèle de classification multi-classes.

```
[ ] mkdir XRAY
[ ] cd XRAY/
⇄ /content/XRAY
[ ] | mkdir Normal
| mkdir Bacteria
| mkdir Virus
[ ] cd /content/chest-xray-pneumonia/chest_xray/train/NORMAL
⇄ /content/chest-xray-pneumonia/chest_xray/train/NORMAL
[ ] cp * /content/XRAY/Normal
[ ] cd /content/chest-xray-pneumonia/chest_xray/train/PNEUMONIA
⇄ /content/chest-xray-pneumonia/chest_xray/train/PNEUMONIA
[ ]
cp *_bacteria*.jpeg /content/XRAY/Bacteria
cp *_virus*.jpeg /content/XRAY/Virus
```

Figure 49: processus d'organisation des données

**Pour le 2<sup>ém</sup> modèle** : Tuberculose et Normal : Nous avons importé la base de données depuis Kaggle en utilisant la bibliothèque "opendatasets " de même façon comme le premier modèle

```
kaggle_link = "https://www.kaggle.com/datasets/tawsifurrahman/tuberculosis-tb-chest-xray-dataset"
data_set_kaggle.download(kaggle_link)
```

Figure 50: chargement des données du premier modèle

### 3.3 Initialisation des paramètres

Avant de lancer l'entraînement des modèles, il est essentiel de bien initialiser les hyperparamètres, afin d'assurer une convergence stable et de réduire le risque de surapprentissage (overfitting).

Table 1: Paramètres d'entraînement selon les bases de données et les modèles utilisés

Base de Données	Modèles	LR	Batch Size	Epochs
X-Ray Pneumonia	CNN classique(prétraitement global)	0.0001	32	100
	CNN classique(prétraitement + virus)	0.0001	32	100
	ResNet50, EfficientNetB0, DenseNet121	0.0001	32	50
Tuberculosis Chest X-ray	CNN classique	0.0001	32	100
	ResNet50, EfficientNetB0, DenseNet121	0.0001	32	50

## 4 Résultats expérimentaux et représentation graphique

### 4.1 Classification de la Pneumonie (Multi-Classes) : modèle 01

Afin de mieux comprendre l'évolution de l'apprentissage de nos modèle et de suivre ses performances étape par étape, nous avons mis en place plusieurs outils de visualisation essentiels pendant la phase d'entraînement:

- Un graphique de l'accuracy : Ce graphe nous permet d'observer comment la capacité du modèle à classer correctement les images progresse d'époque en époque. Il donne une indication directe sur la qualité de l'apprentissage.
- Un graphique de loss sur les mêmes données. En suivant la diminution progressive de cette valeur au fil des époques.

Une fois la phase d'entraînement terminée, nous avons évalué les performances finales de chaque modèle Pour cela, nous avons généré une matrice de confusion représentant les prédictions du modèle par rapport aux vraies classes. Cette matrice nous a permis de calculer précisément les métriques de performance de classification Ces indicateurs nous ont aidés à comparer objectivement les performances de nos différentes architectures (CNN classique, ResNet50, EfficientNetB0, DenseNet121.) et à identifier les points forts et les faiblesses de chaque modèle.

#### 4.1.1 CNN classique

**Cas 1 : Application globale des prétraitements sur la base de données :**  
**Représentation graphique :**



Figure 51: Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement

## Evaluation des performances:




Figure 52: Rapport de classification et matrice de confusion classification multi-classe

**Accuracy = 78.42 %**

**Analyse :** Après avoir analysé la matrice de confusion, nous avons constaté que :

- Le modèle offre de très bonnes performances pour la détection de la pneumonie bactérienne, avec une précision (precision) de 93,02 %, un rappel (recall) de 97,09 %, et un score F1 de 0,9501. Ces valeurs traduisent une excellente capacité du modèle à identifier correctement cette classe tout en limitant les faux positifs.
- La classe "normal" est également bien détectée, avec une précision de 78,61 %, un recall de 82,99 % et un score F1 de 0,8074. Cependant, on observe une confusion avec la classe virale, illustrée par 61 images normales mal classées comme virales, ce qui peut poser problème dans un contexte médical où la fiabilité du modèle.
- En revanche, les performances du modèle pour la classe "virus" sont nettement inférieures. Le rappel n'est que de 47,54 %, ce qui signifie que plus de la moitié des cas viraux ne sont pas correctement détectés. La précision pour cette classe est de 57,24 %, et le score F1 chute à 0,5194. On note que 87 images virales ont été confondues avec la classe normale, ce qui confirme une confusion importante entre les deux catégories.

L'accuracy globale du modèle (taux de prédictions correctes sur l'ensemble du test) est de 78,42 %. Bien que ce résultat soit satisfaisant, il est en partie biaisé par les bonnes performances sur les classes "bacteria" et "normal", tandis que la classe "virus" reste mal reconnue.

C'est pour cela que nous avons ajouté un prétraitement spécifique pour les images appartenant à la classe "virus", afin d'améliorer leur représentation visuelle et d'aider le modèle à mieux les distinguer des autres classes.

**Cas 2 : Application d'un prétraitement spécifique à la classe "virus" : Représentation graphique :**




Figure 53: Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement

**Evaluation des performances:**




Figure 54: Rapport de classification et matrice de confusion classification multi-classe

**Accuracy = 97.45 %**

**Analyse :**

Suite à l'ajout d'un prétraitement ciblé sur les images de la classe "virus", nous avons observé une évolution considérable des résultats du modèle. Les performances globales ont augmenté, avec une accuracy passant de 78,42 % à 97,45 %, ce qui représente une

amélioration de la qualité des prédictions.

Pour le classe "virus", qui posait initialement problème, nous avons obtenu une précision (precision) de 98,46 %, un rappel (recall) de 97,21 % et un F1 score de 0,9783, contre respectivement 57,24 %, 47,54 % et 0,5194 . De plus, Les classes "normal" et "bacteria" conservent également d'excellentes performances, avec des f1-scores supérieurs à 0,96. Cela montre que l'amélioration ciblée sur une seule classe n'a pas dégradé les performances sur les autres, ce qui confirme l'efficacité de notre stratégie.

#### 4.1.2 Resnet50

##### Représentation graphique :

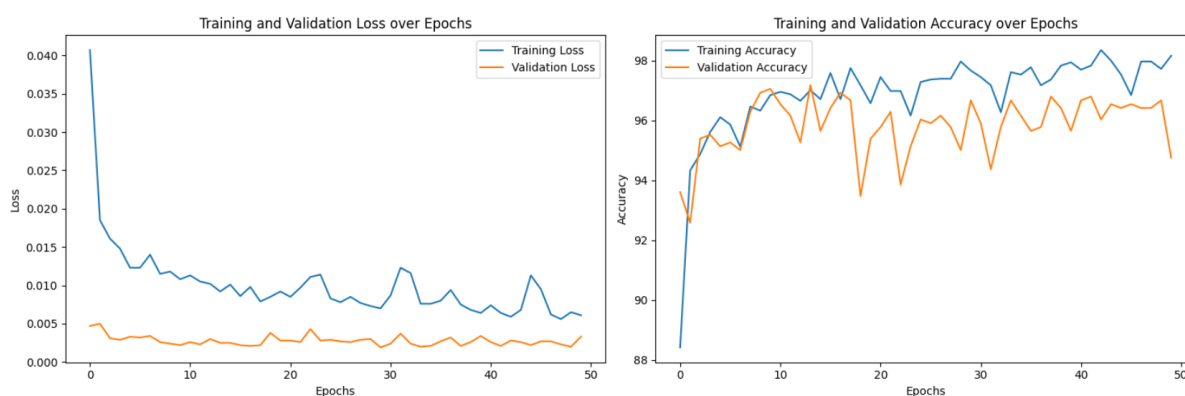


Figure 55: Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement

##### Evaluation des performances:




Figure 56: Rapport de classification et matrice de confusion classification multi-classe

**Accuracy = 97.57 %**

### 4.1.3 EfficientNetB0

Représentation graphique :




Figure 57: Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement

Evaluation des performances:




Figure 58: Rapport de classification et matrice de confusion classification multi-classe

Accuracy = 98.46 %

#### 4.1.4 DenseNet121

Représentation graphique :




Figure 59: Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement

Evaluation des performances:




Figure 60: Rapport de classification et matrice de confusion classification multi-classe

**Accuracy = 98.06 %**

## 4.2 Tableau Récapitulatif (Classification de la Pneumonie multi-classe)

Table 2: Tableau Récapitulatif de la Classification de la Pneumonie

Modèle	Accuracy	Précision moyenne	Rappel moyen	F1-score moyen	Observation Clé
CNN classique (prétraitement global)	78.42%	76.29%	75.80%	74.9%	Très bonne détection de la pneumonie bactérienne (F1=0.95). Confusion importante entre les classes "normal" et "virus" : plus de 60 cas "normaux" mal classés comme "virus" et 87 cas "virus" mal classés comme "normal". Faible rappel pour "virus" (47.54%).
CNN classique (prétraitement global + prétraitement sur la classe virus)	97.44%	97.92%	97.70%	97.83%	L'ajout d'un prétraitement ciblé pour la classe "virus" a considérablement amélioré les performances (F1=0.98), tout en maintenant une excellente classification des autres classes. Très peu de confusion entre classes.
ResNet50	97.57%	97.68%	97.59%	97.61%	Bonne stabilité d'apprentissage. Précision et rappel équilibrés sur toutes les classes.
EfficientNetB0	<b>98.46%</b>	<b>98.60%</b>	<b>98.42%</b>	<b>98.50%</b>	Meilleure performance globale. Très haute capacité de généralisation.
DenseNet121	98.08%	98.10%	97.95%	98.01%	Les résultats sont très similaires à ceux d'EfficientNetB0. Une légère diminution de performance, mais la détection des trois catégories reste excellente.

### 4.3 Classification de la tuberculose (Binaire) : modèle 02

#### 4.3.1 CNN classique

Représentation graphique :



Figure 61: Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement

Evaluation des performances:




Figure 62: Rapport de classification et matrice de confusion classification multi-classe

**Accuracy = 98.41 %**

### 4.3.2 Resnet50

Représentation graphique :




Figure 63: Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement

Evaluation des performances:




Figure 64: Rapport de classification et matrice de confusion classification multi-classe

Accuracy = 98.57 %

### 4.3.3 EfficientNetB0

Représentation graphique :




Figure 65: Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement

Evaluation des performances:




Figure 66: Rapport de classification et matrice de confusion classification multi-classe

Accuracy = 99.68 %

### 4.3.4 DenseNet121

Représentation graphique :




Figure 67: Graphe de Loss&Accuracy CNN Classique cas d'application globale des prétraitement

Evaluation des performances:




Figure 68: Rapport de classification et matrice de confusion classification multi-classe

Accuracy = 99.37 %

#### 4.4 Tableau Récapitulatif (Classification binaire de la Tuberculose )

Table 3: Tableau Récapitulatif de la Classification de la Tuberculose

Modèle	Accuracy	Précision	Rappel	F1-score	Observation Clé
CNN classique	98.41%	98.50%	98.30%	98.40%	Très bon taux de classification pour les deux classes. Légère confusion dans quelques cas de tuberculose mal détectés, mais les performances globales restent élevées.
ResNet50	98.67%	98.60%	98.50%	98.56%	Légère amélioration par rapport au CNN classique. Modèle robuste avec moins de confusion.
EfficientNetB0	<b>99.68%</b>	<b>99.70%</b>	<b>99.65%</b>	<b>99.68%</b>	Meilleures performances pour ce cas binaire. Aucune confusion significative observée dans la matrice de confusion.
DenseNet121	99.36%	99.40%	99.30%	99.35%	Excellente précision. Légère baisse par rapport à EfficientNetB0, mais toujours très fiable.

## 5 Comparaison avec les travaux connexes et discussion

### 5.1 Comparaison avec l'état de l'art

#### 5.1.1 Classification de la Pneumonie (Multi-Classes) : modèle 01

Le tableau 4.4 ci-dessous présente une comparaison des résultats de notre modèle de détection de la pneumonie. On constate que notre approche basée sur des architectures de deep Learning, notamment EfficientNetB0, surpasse les travaux récents dans la classification multi-classes (pneumonie bactérienne, virale et cas normaux). Le modèle atteint une précision (Accuracy) de 98,46 %

Table 4: Comparaison des performances de modèle 1 avec des travaux connexes

Article	Modèle	Dataset	Classe	Accuracy (%)
[66]	EfficientNet v2-M	NIH	3	82.15%
[67]	CovXNet	Données publiques	3	90.2%
[69]	CAAD	X-VIRAL dataset	2	87.57%
[72]	DeepCCXR	9 bases (RSNA, COVIDx, NIH, BIMCV, etc.)	3	97.0%
[73]	CapsNet	CIDC	3	97.24%
[75]	DCGAN+CNN	Chest X-ray (Pédiatrique)	2	95.5%
[76]	CVDNet	2 905 images (Normal, Pneumonie virale, COVID)	3	96.69%
[77]	CNN	X-ray (Pneumonia)	3	90.68%
[85]	MobileNet V2	X-ray (Pneumonia)	3	95.84%
	CNN personnalisé			91.52%
	CNN+LSTM			93.73%
	ResNet152V2			99.22%
[88]	VGG16	Chest X-ray (Pneumonia)	3	95.6%
Nos modèles	CNN classique	X-ray (Pneumonia)	3	97.44%
	ResNet50			97.57%
	EfficientNetB0			98.46%
	DenseNet121			98.08%

### 5.1.2 Classification de la tuberculose (Binaire) : modèle 02

Dans le tableau ci-dessous, nous avons comparé avec d'autres travaux la puissance modèle 2, qui classe les catégories tuberculose et normal. Les résultats montrent que notre approche, notamment avec le modèle EfficientNetB0, dépasse les performances des méthodes existantes. Elle atteint une précision (Accuracy) de 99,68% .

Table 5: Comparaison des performances de modèle 2 avec des travaux connexes

Article	Modèle	Dataset	Classe	Accuracy (%)
[60]	EfficientNet B4	Dataset Shenzhen	2	89.22%
[61]	Modèle ensembliste (AlexNet, GoogleNet, ResNet)	Montgomery county, dataset Shenzhen, Belarus, JSRT	2	88.24%
[64]	Ensemble Gabor + CNN	Montgomery county MC	2	95.71%
		Dataset Shenzhen	2	96.77%
[65]	CNN	Dataset Shenzhen	2	82%
	AlexNet			84.20%
	CNN	Montgomery county	2	65.80%
	AlexNet			72.50%
[66]	EfficientNet v2-M	SCH (jeu incluant TB)	3	96.48%
[68]	VGG-16	Dataset Shenzhen	2	86.74%
	VGG-19			84.33%
	ResNet50			81.92%
	GoogleNet			80.72%
[68]	VGG-16	Montgomery county	2	77.14%
	VGG-19			77.14%
	ResNet50			71.42%
	GoogleNet			71.42%
[70]	Inception-V3	Dataset Shenzhen	2	91.70%
	Inception-V3	Montgomery county	2	87.47%
[84]	CBAMWDnet	Tuberculosis chest X-ray images + MC + Shenzhen	2	98.80%
[86]	CNN	Shenzhen	2	84%
[87]	Dual convolution blocks + DenseNet169	Montgomery county (MC), dataset Shenzhen	2	95.10%
Notre Modèle	CNN classique	Tuberculosis Chest X-ray	2	98.41%
	ResNet50			98.57%
	EfficientNetB0			99.68%
	DenseNet121			99.36%

## 6 Discussion et synthèse des résultats obtenus

La comparaison de nos résultats avec ceux présents dans la littérature indique que notre approche est à la fois pertinente et performante. En combinant efficacement le prétraitement des données, une structuration adaptée des classes, et de modèles profonds pré-entraînés, nous avons atteint des niveaux de performance très compétitifs.

Dans le cadre de la classification multi-classes de la pneumonie, notre modèle EfficientNetB0 surpasse les méthodes existantes avec une précision de 98,46 %, devançant plusieurs architectures avancées publiées dans des études récentes. De même, pour la classification binaire de la tuberculose, ce même modèle atteint 99,68 %, démontrant son excellent pouvoir de généralisation.

Les résultats montrent également que des modèles simples comme le CNN classique peuvent obtenir de très bonnes performances lorsqu'ils sont correctement optimisés, notamment grâce à un prétraitement ciblé sur les classes les plus complexes, comme celles des infections virales.

Dans l'ensemble, notre travail met en évidence l'intérêt d'une démarche rigoureuse combinant une préparation fine des données, des choix architecturaux pertinents, et une analyse détaillée des performances par classe. Cette stratégie nous a permis non seulement d'améliorer les scores globaux, mais aussi de réduire significativement les erreurs de classification les plus critiques sur le plan médical.

## **7 Conclusion**

Dans ce chapitre, Nous avons détaillé les étapes d'évaluation expérimentale ainsi que l'analyse des performances des modèles testés. Les résultats obtenus ont montré une capacité satisfaisante à distinguer les différentes classes Nous avons aussi discuté les résultats obtenus et les avons comparés avec ceux de travaux connexes.

## *Conclusion générale*

Dans ce projet, nous avons développé et évalué plusieurs modèles d'apprentissage profond basés sur les réseaux de neurones convolutifs (CNN) pour la classification automatique d'images radiologiques pulmonaires. L'objectif était de proposer des outils capables d'identifier avec fiabilité différentes pathologies pulmonaires, telles que la pneumonie bactérienne, la pneumonie virale, et la tuberculose, à partir de radiographies thoraciques.

Les résultats obtenus montrent que ces modèles sont capables d'atteindre des performances élevées. En fonction de la complexité du jeu de données et du nombre de classes à distinguer, certaines architectures ont surpassé les autres. Notamment, EfficientNetB0 s'est révélée particulièrement performante, mais d'autres modèles comme ResNet50, DenseNet121 ou encore les CNN personnalisés ont également donné des résultats très satisfaisants, confirmant la pertinence de l'approche. Dans certains cas, la précision a dépassé les 97 %, et la sensibilité pour certaines classes pathologiques a atteint 100 %, ce qui souligne la capacité des modèles à détecter des maladies critiques de manière fiable.

Ce travail démontre le potentiel concret des technologies d'apprentissage profond pour aider les professionnels de santé dans l'analyse d'images médicales. Bien qu'ils ne remplacent pas les cliniciens, ces outils peuvent accélérer les processus de diagnostic et réduire les risques d'erreur, notamment dans les environnements où les ressources médicales sont limitées.

Pour les recherches futures, plusieurs pistes sont envisagées :

- Étendre la détection à d'autres types de maladies pulmonaires, afin de couvrir un spectre pathologique plus large
- Explorer l'utilisation d'images CT (scanner thoracique) en complément des radiographies, pour bénéficier d'une information anatomique plus détaillée
- Développer des modèles spécialisés pour chaque type de pathologie, en adoptant une approche hiérarchique, où un modèle général oriente vers des modèles experts
- Intégrer des techniques avancées de segmentation d'image, pour localiser plus précisément les zones pathologiques et renforcer la fiabilité du diagnostic
- Et enfin, exploiter de grandes bases de données médicales multicentriques, afin d'améliorer la robustesse et la capacité des modèles à s'adapter à des populations et des conditions d'acquisition variées.

En conclusion, cette étude ouvre la voie à une intégration raisonnée et efficace de l'intelligence artificielle dans les pratiques médicales, avec pour ambition de soutenir les efforts des radiologues et cliniciens, tout en garantissant la fiabilité, la reproductibilité et la sécurité des diagnostics.

# References

- [1] E. Quaia, E. Baratella, G. Poillucci, S. Kus, V. Cioffi, and M. Cova, “Digital tomosynthesis as a problem-solving imaging technique to confirm or exclude potential thoracic lesions based on chest x-ray radiography,” *Academic Radiology*, vol. 20, pp. 546–553, 2013.
- [2] A. Bush, H. Gray, and D. Denison, “Diagnosis of pulmonary hypertension from radiographic estimates of pulmonary arterial size,” *Thorax*, vol. 43, pp. 127–131, 1988.
- [3] “Computer-aided diagnosis for chest radiographs in intensive care,” <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6512406/>, consulté en 2025.
- [4] “Advances in deep learning-based medical image analysis,” <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10880179/>, consulté en 2025.
- [5] “Les poumons : définition, anatomie et maladies,” <https://www.doctissimo.fr/sante/atlas-corps-humain/question-corps-humain/role-poumons>, consulté sur Doctissimo en 2025.
- [6] “Présentation du système respiratoire,” <https://www.msdmanuals.com/fr/accueil/troubles-pulmonaires-et-des-voies-aeriennes/biologie-des-poumons-et-des-voies-respiratoires/pr%C3%A9sentation-du-syst%C3%A8me-respiratoire>, le manuel MSD, consulté en 2025.
- [7] “Bronchite,” <https://www.sante-sur-le-net.com/maladies/pneumologie/bronchite/>, santé sur le Net, consulté en 2025.
- [8] “Lung disease,” <https://medlineplus.gov/ency/article/000066.htm>, medlinePlus, consulté en 2025.
- [9] “Obstructive vs. restrictive lung diseases: Causes and treatment,” <https://www.verywellhealth.com/obstructive-and-restrictive-lung-diseases-914741>, verywellhealth, consulté en 2025.
- [10] “Asthme - région méditerranée orientale,” <https://www.emro.who.int/fr/health-topics/asthma/index.html>, organisation mondiale de la santé, consulté en 2025.
- [11] “Bronchopneumopathie chronique obstructive (bpcO),” <https://www.emro.who.int/fr/health-topics/chronic-obstructive-pulmonary-disease-copd/index.html>, organisation mondiale de la santé, consulté en 2025.

- [12] “Asthme et asthme allergique,” <https://www.sante-sur-le-net.com/maladies/pneumologie/asthme/>, santé sur le Net, consulté en 2025.
- [13] “Infographie sur l’asthme en france,” <https://www.sante-sur-le-net.com/wp-content/uploads/2021/06/Infographie-Asthme-france.png>, santé sur le Net, consulté en 2025.
- [14] “L’asthme,” [https://sante-respiratoire.com/les-maladies-respiratoires/asthme/#elementor-toc\\_\\_\\_heading-anchor-3](https://sante-respiratoire.com/les-maladies-respiratoires/asthme/#elementor-toc___heading-anchor-3), santé Respiratoire France, consulté en 2025.
- [15] “Bpco : causes, symptômes et traitements,” [https://www.doctissimo.fr/html/sante/encyclopedie/sa\\_1565\\_bcpc.htm](https://www.doctissimo.fr/html/sante/encyclopedie/sa_1565_bcpc.htm), doctissimo, consulté en 2025.
- [16] “La bpco et vous,” <http://aquirespi.fr/infobpco.org/bpco-et-vous.html>, bPCO Aquitaine, consulté en 2025.
- [17] “Bronchopneumopathie chronique obstructive (bpco),” <https://www.sante-sur-le-net.com/maladies/pneumologie/bpco/>, santé sur le Net, consulté en 2025.
- [18] “Présentation de la pneumonie et la covid-19,” <https://diagnostics.labosalem.dz/presentation-de-la-pneumonie-et-la-covid-19/>, laboratoires SALEM Diagnostics, consulté en 2025.
- [19] “Pneumonie : causes, symptômes et traitement,” <https://www.doctissimo.fr/sante/maladie-pulmonaire/pneumonie>, doctissimo, consulté en 2025.
- [20] “La tuberculose,” <https://sante-respiratoire.com/les-maladies-respiratoires/la-tuberculose/>, santé Respiratoire France, consulté en 2025.
- [21] “Learn about tuberculosis,” <https://www.lung.org/lung-health-diseases/lung-disease-lookup/tuberculosis/learn-about-tuberculosis>, american Lung Association, consulté en 2025.
- [22] “24 miljoner till forskning om tuberkulos och antibiotikaresistens,” <https://it-halsa.se/24-miljoner-till-forskning-om-tuberkulos-och-antibiotikaresistens/>, it-hälsa.se, consulté en 2025.
- [23] “Tuberculose : définition, fréquence et transmission,” <https://www.ameli.fr/assure/sante/themes/tuberculose/definition-frequence-transmission>, assurance Maladie Ameli, consulté en 2025.
- [24] “Tuberculosis symptoms and diagnosis,” <https://www.lung.org/lung-health-diseases/lung-disease-lookup/tuberculosis/symptoms-diagnosis>, american Lung Association, consulté en 2025.

- [25] “Au sujet de la covid-19,” <https://www.emro.who.int/fr/health-topics/corona-virus/about-covid-19.html>, organisation mondiale de la santé, consulté en 2025.
- [26] “Covid 19 : mise au point,” <https://urgences-serveur.fr/covid-19-mise-au-point-2022.html>, urgences-online, consulté en 2025.
- [27] “Covid-19 map,” <https://coronavirus.jhu.edu/map.html>, Johns Hopkins Coronavirus Resource Center, consulté en 2025.
- [28] “Bronchite : traitement, symptômes et prévention,” <https://www.doctissimo.fr/html/dossiers/maux-hiver/articles/10875-bronchite-aigue-infectieuse.htm>, doctissimo, consulté en 2025.
- [29] Santé Respiratoire France, “Le cancer du poumon.” [Online]. Available: <https://sante-respiratoire.com/les-maladies-respiratoires/le-cancer-du-poumon/>
- [30] “Cancer du poumon,” <https://www.ramsaysante.fr/vous-etes-patient-en-savoir-plus-sur-ma-pathologie/cancer-du-poumon>, ramsay Santé, consulté en 2025.
- [31] “Emphysème pulmonaire,” <https://www.sante-sur-le-net.com/maladies/pneumologie/emphyseme-pulmonaire/>, santé sur le Net, consulté en 2025.
- [32] “Illustration médicale des effets de l’emphysème pulmonaire,” <https://fr.dreamstime.com/image-libre-droits-emphys%C3%A8me-pulmonaire-image22050446>, note = Dreamstime, consulté en 2025, author= , key=.
- [33] D. Mariano-Goulart, N. Chu, and L. Montpellier, *Bases physiques de la radiologie pour le PCEM2*. Faculté de Médecine.
- [34] “Radiographie conventionnelle,” <https://www.msmanuals.com/fr/professional/sujets-spéciaux/principes-d-imagerie-radiologique/radiographie-conventionnelle>, le manuel MSD, version professionnelle, consulté en 2025.
- [35] “Application des réseaux de neurones pour la caractérisation géométrique et physique d’une plaque conductrice,” <https://www.researchgate.net/publication/333670710>, researchGate, consulté en 2025.
- [36] “Imagerie 3d en tomodensitométrie,” [https://www.utc.fr/master-qualite/public/publications/qualite\\_et\\_biomedical/UTC/master\\_mts/2004-2005/projets/reconstruction3d/trois.html](https://www.utc.fr/master-qualite/public/publications/qualite_et_biomedical/UTC/master_mts/2004-2005/projets/reconstruction3d/trois.html), université de Technologie de Compiègne, consulté en 2025.
- [37] “Tomodensitométrie (tdm),” <https://www.msmanuals.com/fr/professional/sujets-spéciaux/principes-d-imagerie-radiologique/tomodensitométrie-tdm>, le manuel MSD, version professionnelle, consulté en 2025.

- 
- [38] “Scanner thoracique,” <https://imageriemedicale.fr/examens/scanner/thoracique>, centres d’Imagerie Médicale de Neuilly-Puteaux, consulté en 2025.
- [39] “L’imagerie par résonance magnétique,” [https://fr.wikipedia.org/wiki/Imagerie\\_par\\_r%C3%A9sonance\\_magn%C3%A9tique](https://fr.wikipedia.org/wiki/Imagerie_par_r%C3%A9sonance_magn%C3%A9tique), wikipédia, consulté en 2025.
- [40] “Comment fonctionne l’irm,” <https://www.pourlascience.fr/sr/idees-physique/comment-fonctionne-l-irm-26431.php>, pour la Science, consulté en 2025.
- [41] “Imagerie par résonance magnétique nucléaire (irm),” <https://www.msmanuals.com/fr/professional/sujets-sp%C3%A9ciaux/principes-d-imagerie-radiologique/imagerie-par-r%C3%A9sonance-magn%C3%A9tique-nucl%C3%A9aire-irm>, le manuel MSD, consulté en 2025.
- [42] “Échographie,” <https://www.msmanuals.com/fr/professional/sujets-sp%C3%A9ciaux/principes-d-imagerie-radiologique/%C3%A9chographie>, le manuel MSD, consulté en 2025.
- [43] “Analyse de concordance entre l’échographie pulmonaire et la radiographie thoracique en réanimation,” *Science Direct*, 2010, consulté en 2025.
- [44] “Bien débiter en échographie clinique,” <https://www.echopen.com/ressources/articles/bien-debuter-en-echographie-clinique-prendre-en-main-une-sonde>, echopen, consulté en 2025.
- [45] “Intelligence artificielle : définition, histoire, enjeux,” <https://datascientest.com/intelligence-artificielle-definition>, datascientest, consulté en 2025.
- [46] “Machine learning : définition, fonctionnement, utilisation,” <https://datascientest.com/machine-learning-tout-sav>, datascientest, consulté en 2025.
- [47] “Réseaux de neurones artificiels : Qu’est-ce que c’est ?” <https://datascientest.com/reseaux-neurones-artificiels-tout-savoir>, datascientest, consulté en 2025.
- [48] “Deep learning ou apprentissage profond : qu’est-ce que c’est ?” <https://datascientest.com/deep-learning-definition>, datascientest, consulté en 2025.
- [49] T. Claude, *Les Réseaux de Neurones Artificiels, Introduction au Connexionnisme*, 1992, vol. 130.
- [50] “Qu’est-ce qu’un réseau neuronal ?” <https://aws.amazon.com/fr/what-is/neural-network/#:~:text=Un%20r%C3%A9seau%20neuronal%20est%20une,inspir%C3%A9%20par%20le%20cerveau%20humain>, amazon AWS, consulté en 2025.
- [51] “Deep learning: Models, enterprise applications, benefits, use cases, implementation and development,” <https://www.leewayhertz.com/what-is-deep-learning/>, leewayHertz, consulté en 2025.

- [52] “Apprentissage profond et apprentissage automatique dans azure machine learning,” <https://learn.microsoft.com/fr-fr/azure/machine-learning/concept-deep-learning-vs-machine-learning?view=azureml-api-2>, microsoft Learn, consulté en 2025.
- [53] “Convolutional neural network : Tout ce qu’il y a à savoir,” <https://datascientest.com/convolutional-neural-network>, datascientest, consulté en 2025.
- [54] “What are convolutional neural networks?” <https://www.ibm.com/think/topics/convolutional-neural-networks>, iBM, consulté en 2025.
- [55] “Sigmoid function image,” <https://humphryscomputing.com/Notes/Neural/Bitmaps/sigmoid.gif>, humphrys Computing, consulté en 2025.
- [56] “Activation function: a hidden pillar of neural networks,” <https://en.innovatiana.com/post/activation-function-in-ai>, innovatiana, consulté en 2025.
- [57] P. Josh and G. Adam, *Deep Learning*, non précisé, vol. 532.
- [58] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [59] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” <https://arxiv.org/pdf/1409.1556>, 2014, arXiv preprint.
- [60] “Understanding vgg16: A powerful deep learning model for image recognition,” <https://smuhabdullah.medium.com/understanding-vgg16-a-powerful-deep-learning-model-for-image-recognition-d40b074fd01c>, medium, consulté en 2025.
- [61] C. S. et al., “Going deeper with convolutions,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015.
- [62] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016.
- [63] R. Hooda, A. Mittal, and S. Sofat, “Automated tb classification using ensemble of deep architectures,” *Multimedia Tools and Applications*, vol. 78, no. 22, pp. 31 515–31 532, 2019.
- [64] F. Ucar and D. Korkmaz, “Covidagnosis-net: Deep bayes-squeezenet based diagnosis of the coronavirus disease 2019 (covid-19) from x-ray images,” *Medical Hypotheses*, vol. 140, 2020.
- [65] Y. Bar, I. Diamant, L. Wolf, S. Lieberman, E. Konen, and H. Greenspan, “Chest pathology detection using deep learning with non-medical training,” in *IEEE 12th International Symposium on Biomedical Imaging (ISBI)*, 2015, pp. 294–297.

- 
- [66] M. Ayaz, F. Shaukat, and G. Raja, "Ensemble learning based automatic detection of tuberculosis in chest x-ray images using hybrid feature descriptors," *Australasian College of Physical Scientists and Engineers in Medicine*, 2021, publié en ligne le 18 janvier 2021.
- [67] R. e. a. Sivaramakrishnan, "Comparing deep learning models for population screening using chest radiography," in *Medical Imaging 2018: Computer-Aided Diagnosis*, vol. 10575, 2018, pp. 322–332.
- [68] G. M. M. Alshmrani, Q. Ni, R. Jiang, H. Pervaiz, and N. M. Elshennawy, "A deep learning architecture for multi-class lung diseases classification using chest x-ray (cxr) images," *Alexandria Engineering Journal*, vol. 64, pp. 923–935, 2023.
- [69] T. Mahmud, M. A. Rahman, and S. A. Fattah, "Covxnet: A multi-dilation convolutional neural network for automatic covid-19 and other pneumonia detection from chest x-ray images with transferable multi-receptive feature optimization," *Computers in Biology and Medicine*, vol. 122, p. 103869, 2020.
- [70] S. S. e. a. Meraj, "Detection of pulmonary tuberculosis manifestation in chest x-rays using different convolutional neural network (cnn) models," *International Journal of Engineering and Advanced Technology (IJEAT)*, vol. 9, no. 1, pp. 2270–2275, 2019.
- [71] Z. et al., "Viral pneumonia screening on chest x-rays using confidence-aware anomaly detection," *IEEE Transactions on Medical Imaging*, vol. 40, no. 3, p. 879, 2021.
- [72] D. Das, K. C. Santosh, and U. Pal, "Inception-based deep learning architecture for tuberculosis screening using chest x-rays," in *2020 25th International Conference on Pattern Recognition (ICPR)*, 2021, pp. 3612–3619.
- [73] I. Khan, J. L. Shah, and M. M. Bhat, "Coronet: A deep neural network for detection and diagnosis of covid-19 from chest x-ray images," *Computer Methods and Programs in Biomedicine*, vol. 196, 2020.
- [74] M. Chetoui, M. A. Akhloufi, B. Yousefi, and E. M. Bouattane, "Explainable covid-19 detection on chest x-rays using an end-to-end deep convolutional neural network architecture," *Big Data and Cognitive Computing*, vol. 5, no. 4, p. 73, 2021.
- [75] S. Toraman, T. B. Alakus, and I. Turkoglu, "Convolutional capsnet: A novel artificial neural network approach to detect covid-19 disease from x-ray images using capsule networks," *Chaos, Solitons Fractals*, vol. 140, 2020.
- [76] E. e. a. Luz, "Towards an effective and efficient deep learning model for covid-19 patterns detection in x-ray images," *Published online*, 2021.
- [77] S. Kora Venu and S. Ravula, "Evaluation of deep convolutional generative adversarial networks for data augmentation of chest x-ray images," *Future Internet*, vol. 13, no. 1, p. 8, 2020.
- [78] C. Ouchicha, O. Ammor, and M. Meknassi, "Cvdnet: A novel deep learning architecture for

- detection of coronavirus (covid-19) from chest x-ray images,” *Chaos, Solitons and Fractals*, vol. 140, 2020.
- [79] H. Sharma, J. S. Jain, P. Bansal, and S. Gupta, “Feature extraction and classification of chest x-ray images using cnn to detect pneumonia,” in *2020 10th International Conference on Cloud Computing, Data Science Engineering (Confluence)*, 2020, pp. 227–231.
- [80] L. Wang, Z. Q. Lin, and A. Wong, “Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images,” *Scientific Reports*, vol. 10, no. 1, 2020.
- [81] D. Apostolopoulos and T. A. Mpesiana, “Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks,” *Physical and Engineering Sciences in Medicine*, 2020.
- [82] R. Sarki, K. Ahmed, H. Wang, Y. Zhang, and K. Wang, “Automated detection of covid-19 through convolutional neural network using chest x-ray images,” *PLOS ONE*, 2022.
- [83] K. Munadi, K. Muchtar, N. Maulina, and B. Pradhan, “Image enhancement for tuberculosis detection using deep learning,” *IEEE Access*, vol. 8, pp. 217 897–217 907, 2020.
- [84] V. T. Q. Huy and C.-M. Lin, “An improved densenet deep neural network model for tuberculosis detection using chest x-ray images,” 2023.
- [85] N. M. Elshennawy and D. M. Ibrahim, “Deep-pneumonia framework using deep learning models based on chest x-ray images,” *Diagnostics*, vol. 10, no. 9, p. 649, 2020.
- [86] L. A. Andika, H. Pratiwi, and S. S. Handajani, “Convolutional neural network modeling for classification of pulmonary tuberculosis disease,” in *Journal of Physics: Conference Series*, vol. 1490. IOP Publishing, 2020, p. 012020.
- [87] A. Iqbal, M. Usman, and Z. Ahmed, “Tuberculosis chest x-ray detection using cnn-based hybrid segmentation and classification approach,” *Biomedical Signal Processing and Control*, vol. 84, p. 104667, 2023.
- [88] Y. Yang, G. Mei, and F. Piccialli, “A deep learning approach considering image background for pneumonia identification using explainable ai (xai),” *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 2022.
- [89] “Le tutoriel python,” <https://docs.python.org/fr/3.10/tutorial/>, python.org, consulté en 2025.
- [90] “Resnet50: a pre-trained model for image recognition,” <https://en.innovatiana.com/post/discover-resnet-50>, innovatiana, consulté en 2025.
- [91] “An illustration of resnet-50 layers architecture,” [https://www.researchgate.net/figure/An-illustration-of-ResNet-50-layers-architecture\\_fig1\\_350421](https://www.researchgate.net/figure/An-illustration-of-ResNet-50-layers-architecture_fig1_350421), researchGate, consulté en 2025.

- [92] “Efficientnetb0 model architecture,” [https://www.researchgate.net/figure/EfficientnetB0-Model-Architecture\\_fig2\\_378395574](https://www.researchgate.net/figure/EfficientnetB0-Model-Architecture_fig2_378395574), researchGate, consulté en 2025.
- [93] “Efficientnetb0 architecture overview,” <https://www.geeksforgeeks.org/efficientnet-architecture/#efficientnetb0-architecture-overview>, geeksforGeeks, consulté en 2025.
- [94] “Densenet explained,” <https://www.geeksforgeeks.org/densenet-explained/>, geeksforGeeks, consulté en 2025.
- [95] “Densenet-121 architecture with custom classification head,” [https://www.researchgate.net/figure/DenseNet-121-Architecture-with-custom-classification-head\\_fig2\\_372204681](https://www.researchgate.net/figure/DenseNet-121-Architecture-with-custom-classification-head_fig2_372204681), researchGate, consulté en 2025.
- [96] “Chest x-ray images (pneumonia),” <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>, kaggle, consulté en 2025.
- [97] “Tuberculosis (tb) chest x-ray database,” <https://www.kaggle.com/datasets/tawsifurrahman/tuberculosis-tb-chest-xray-dataset>, kaggle, consulté en 2025.
- [98] “Hyperparameter tuning,” <https://www.geeksforgeeks.org/hyperparameter-tuning/>, geeksforGeeks, consulté en 2025.
- [99] “Epoch : Définition, mode de fonctionnement et utilisation,” <https://datascientest.com/qu-est-ce-qu-un-epoch-en-machine-learning>, datascientest, consulté en 2025.
- [100] “How to interpret a confusion matrix for a machine learning model,” <https://www.evidentlyai.com/classification-metrics/confusion-matrix>, evidently AI, consulté en 2025.