

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne démocratique et populaire

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

جامعة سعد دحلب البلدية
Université SAAD DAHLAB de BLIDA

كلية التكنولوجيا
Faculté de Technologie

قسم الإلكترونيك
Département d'Électronique



Mémoire de Projet de Fin d'Études

Présenté par :

Beloufa Dania

Pour l'obtention du diplôme de Master en Électronique

Option : Instrumentation

Thème

Analyse de radiographies du thorax par apprentissage profond pour la catégorisation de pneumopathies infantiles

Proposé et dirigé par : Dr. Reguieg F. Zohra & Pr. Benblidia Nadja

Année Universitaire 2024-2025

Dédicaces

*Je dédie ce modeste travail, fruit de plusieurs mois d'efforts, de
recherche et de persévérance :*

À ceux qui ont cru en moi,

À ceux qui m'ont soutenue dans les moments de doute,

À ceux qui ont partagé mes joies et mes peines,

À ceux qui m'ont inspirée à aller plus loin,

À mes chers parents,

qui m'ont toujours soutenue,

guidée et encouragée tout au long de mon parcours.

*Merci pour votre amour inconditionnel, vos sacrifices silencieux,
votre patience infinie et votre confiance en mes capacités, même dans
les moments de doute.*

*Ce mémoire est le reflet de vos valeurs que vous m'avez transmises :
le respect, l'honnêteté, la rigueur et le goût de l'effort.*

*Vous êtes ma source d'inspiration, mes repères et mes piliers dans
cette vie. Que Dieu vous protège et vous garde.*

*À mes deux frères, pour leur amour, leur soutien discret mais
constant. Vos paroles réconfortantes et votre présence m'ont apporté
la force de continuer et de persévérer malgré les difficultés.*

*Merci pour les instants de partage, d'humour et de légèreté qui ont
apaisé mon esprit dans les moments de stress.*

*À mes amis les plus fidèles, qui ont su m'apporter de la bonne humeur,
de la motivation et du réconfort tout au long de cette aventure
académique. Vos conseils, vos encouragements et votre écoute ont été
d'un grand soutien dans les moments les plus exigeants. Merci pour
votre bienveillance, votre amitié précieuse et votre présence sincère.*

*À ma directrice de mémoire, madame Reguieg F. Zohra,
Votre guidance, votre patience et votre expertise ont été des piliers
essentiels dans la réalisation de ce mémoire. Vous avez su éclairer
mon chemin avec vos conseils avisés et votre soutien constant, même
dans les moments les plus difficiles.*

*Je vous exprime ma profonde gratitude pour avoir cru en moi et pour
m'avoir accompagnée tout au long de cette aventure académique. Ce
mémoire est en partie le reflet de votre engagement et de votre
générosité.*

*Et enfin, à toutes les personnes qui, de près ou de loin, ont contribué à
la réalisation de ce mémoire, que ce soit par un conseil, un
témoignage, une source partagée ou un simple mot d'encouragement.
Recevez ici l'expression de ma profonde reconnaissance.*

Dania Beloufa

Remerciement

*Je tiens à commencer par exprimer ma profonde gratitude envers **Dieu**, dont la lumière et la guidance m'ont accompagnée tout au long de ce parcours. Sans Sa bénédiction, rien de tout cela n'aurait été possible.*

*Je souhaite remercier chaleureusement ma promotrice, **Dr. Reguieg F. Zohra**, pour son encadrement de qualité, son soutien indéfectible, son aide précieuse et ses conseils inestimables. Sa passion pour l'enseignement et son engagement envers la recherche, m'ont été une source d'inspiration constante. Son expertise dans le domaine médical, a été un pilier essentiel dans la réalisation de ce mémoire. Sa direction a été un véritable atout dans la concrétisation de ce projet.*

*Je n'oublie pas de remercier ma co-promotrice, **Pr. Benblidia Nadjia**, dont les remarques éclairées et le soutien moral, ont enrichi ce travail.*

Je tiens également à exprimer ma reconnaissance aux membres du jury, qui ont pris le temps d'évaluer mon travail.

*Je souhaite remercier notre chef de filière, **M. Ykhlef**, pour sa direction et son engagement envers nos études. Son leadership et sa vision ont grandement contribué à notre épanouissement académique.*

À toutes les personnes qui m'aiment et m'ont aidé tout au long de ce chemin, je vous adresse un immense merci. Votre soutien moral et vos encouragements ont été essentiels pour surmonter les défis rencontrés.

Merci à tous pour votre soutien inestimable. Ce mémoire est le fruit de nos efforts collectifs et de votre bienveillance.

ملخص : يُعد تشخيص أمراض الرئة لدى الأطفال، مثل الالتهاب الرئوي، مهمة معقدة بسبب تنوع صور الأشعة السينية للصدر. في هذا العمل، قمنا بتطوير نظام دعم للتشخيص يعتمد على تقنيات التعلم العميق، باستخدام عدة نماذج متقدمة من الشبكات العصبية الالتفافية (CNN) مثل VGG16، VGG19، ResNet50، ResNet101، DenseNet121، DenseNet201، EfficientNetB0، و MobileNetV2. تمكّن هذه النماذج من تصنيف صور الأشعة السينية إلى موثوقة النهج المقترح للكشف المبكر عن اضطرابات الرئة لدى الأطفال

الكلمات المفتاحية: الالتهاب الرئوي عند الأطفال، أشعة الصدر، التعلم العميق، الشبكات العصبية الالتفافية، دعم التشخيص

Résumé

Le diagnostic des maladies pulmonaires pédiatriques, telles que les pneumopathies, est une tâche complexe pour le clinicien, en raison de la variabilité des images radiographiques thoraciques. L'objectif de ce mémoire, est la conception d'un système d'aide au diagnostic basé sur les techniques de l'apprentissage profond, suivant plusieurs architectures avancées de réseaux de neurones convolutifs (CNN) : VGG16, VGG19, ResNet50, ResNet101, DenseNet121, DenseNet201, EfficientNetB0 et MobileNetV2. Ces modèles permettent de classifier automatiquement les images radiographiques issues de la base de données étiquetée 'chest X-ray', en deux classes : normale et pathologique. Les résultats obtenus, avec un F1-score dépassant 95 % et une AUC supérieure à 97 %, démontrent la fiabilité de l'approche proposée pour la détection précoce des anomalies pulmonaires chez l'enfant.

Mots clés : Pneumopathies infantiles, Radiographie thoracique Chest X-ray, Apprentissage profond, Réseaux de Neurones Convolutifs, Aide au diagnostic.

Abstract

The diagnosis of pediatric lung diseases such as pneumonia is a challenging task, due to the variability in chest X-ray images. In this dissertation, we developed a deep learning-based diagnosis support system using several advanced convolutional neural network (CNN) architectures: VGG16, VGG19, ResNet50, ResNet101, DenseNet121, DenseNet201, EfficientNetB0, and MobileNetV2. These models automatically classify images provided from chest X-ray labeled database into two categories: normal and pathological. The obtained results, with an F1-score exceeding 95% and an AUC over 97%, demonstrate the reliability of the proposed approach for early detection of children's pulmonary anomalies.

Keywords: Pediatric Pneumonia, Chest X-ray, Deep Learning, Convolutional Neural Network, Diagnosis support.

Listes des acronymes et abréviations

Accuracy : Taux de précision

Adam : Adaptive Moment Estimation (algorithme d'optimisation)

AUC : Area Under the Curve (Aire sous la courbe ROC)

CNN : Convolutional Neural Network (Réseau de neurones convolutifs)

DL : Deep Learning (Apprentissage profond)

DenseNet : Densely Connected Convolutional Networks

F1-score : Moyenne harmonique entre précision et rappel

FC : Fully Connected (couches entièrement connectées)

FNN : Feed-Forward Neural Network (Réseau de neurones à propagation avant)

GPU : Graphics Processing Unit

IA : Intelligence Artificielle

Loss : Fonction de coût

ML : Machine Learning (Apprentissage automatique)

NumPy : Numerical Python, bibliothèque pour les calculs scientifiques

ResNet : Residual Network

RNN : Recurrent Neural Network (Réseau de neurones récurrents)

SE : Squeeze-and-Excitation (technique d'optimisation dans les réseaux de neurones)

TPR : True Positive Rate (Taux de vrais positifs)

VGG16 / VGG19 : Visual Geometry Group

XAI : Explainable Artificial Intelligence (Intelligence artificielle explicable)

Table des matières

Introduction générale	1
Chapitre 1: Contexte Médical.....	3
1.1 Introduction	3
1.2 Système respiratoire	3
1.3 Structure pulmonaire.....	5
1.3.1 Fonctionnement respiratoire	6
1.3.2 Echanges gazeux	6
1.3.3 Fonctions du système respiratoire	6
1.3.4 Contrôle de la respiration	7
1.4 Spécificités anatomiques et physiologiques de l'enfant.....	7
1.4.1 Anatomie des voies aériennes	7
1.4.2 Physiologie respiratoire.....	8
1.5 Pathologies pulmonaires.....	8
1.5.1 Chez l'adulte.....	8
1.5.2 Chez l'enfant.....	13
1.5.3 Différences pathologiques entre adultes et enfants.....	14
1.6 Imagerie médicale pulmonaire	15
1.6.1 Radiographie thoracique.....	15
1.6.2 Tomodensitométrie thoracique	17
1.6.3 Imagerie par résonance magnétique (IRM) thoracique	19
1.6.4 Scanner à émission de positrons (TEP-TDM)	19
1.6.5 Echographie thoracique	20
1.6.6 Scintigraphie ventilation-perfusion.....	20
1.6.7 Choix de l'examen	21
1.7 Épidémiologie	21
1.7.1 Facteurs influençant l'épidémiologie pulmonaire	21
1.7.2 Tendances épidémiologiques.....	22
1.7.3 Épidémiologie des maladies respiratoires chez les enfants en Algérie	23
1.8 Conclusion.....	24
Chapitre 2: Apprentissage automatique et profond	25
2.1 Introduction	25

2.2 Introduction à l'intelligence artificielle (IA)	25
2.2.1 Principe de l'intelligence artificielle	25
2.2.2 Fonctionnement de l'IA.....	26
2.2.3 Types d'intelligence artificielle.....	26
2.3 Apprentissage automatique.....	28
2. 4 Notions d'apprentissage profond.....	30
2.4.1 Principe de l'apprentissage profond	30
2.4.2 Fonctionnement de l'apprentissage profond.....	31
2.4.3 Différence entre l'apprentissage automatique et l'apprentissage profond	33
2.5 Introduction aux réseaux de neurones	33
2.5.1 Neurone Biologique	33
2.5.2 Neurone artificiel	35
2.5.3 Fonction d'activation.....	36
2.5.4 Applications pratiques des différentes fonctions d'activation	40
2.5.4 Choix de la bonne fonction d'activation pour un modèle donné	41
2.6. Architecture des réseaux de neurones	41
2.6.1. Perceptron.....	42
2.6.2 Réseaux de neurones multicouches	43
2.6.3 Réseaux de neurones récurrents	43
2.6.4 Différence entre les RNNs et les réseaux de neurones Feed-Forward	44
2.6.4 Réseaux de neurones Convolutifs	45
2.7 Concours d'ImageNet.....	50
2.8 Apprentissage par transfert	51
2.9 Fine tuning dans l'apprentissage par transfert	52
2.9.1 Fine tuning total.....	52
2.9.2 Fine tuning partiel.....	53
2.10 Conclusion.....	53
Chapitre 3 Étude conceptuelle pour la catégorisation des données pneumologiques infantiles	54
3.1 Introduction	54
3.2 Travaux réalisés	55
3.3 Conception de système "PneumoCNN 4"	59

3.3.1 Base de données	60
3.3.2 Préparation des données	60
3.3.3 Architectures des réseaux de neurones explorés	62
3.3.4 Classification	72
3.4 Optimisation & Paramètres d'entraînement du système	72
3.4.1 Fonction coût	72
3.4.2 Optimiseur Adam	73
3.4.3 Couche Dropout	73
3.4.4 Paramètres d'entraînement	74
3.5 Métriques d'évaluation	75
3.5.1 Exactitude	75
3.5.2 Aire sous la courbe (AUC)	75
3.5.3 Précision	76
3.5.4 F1 Score	76
3.5.5 Matrice de confusion	77
3.6 Conclusion	78
Chapitre 4 Mise en œuvre du système PneumoCNN4	79
4.1 Introduction	79
4.2 Environnement de travail	79
4.2.1 Matériel utilisé	79
4.2.2 Langage de programmation	79
4.2.3 Bibliothèques utilisées	80
4.3 Système développé	82
4.3.1 Présentation de la base utilisée	82
4.3.2 Préparation des données	84
4.3.3 Modèles utilisés	85
4.4 Application PneumoCNN4 et Résultats	91
4.4.1 Résultats suivant la première répartition	91
4.4.2 Résultats de la deuxième répartition	118
4.4.3 Troisième répartition	120
4.4.3 Comparaison entre les modèles et identification du meilleur	122
4.5 Conclusion	122

Conclusion générale.....	123
Bibliographie	125

Liste des figures

Chapitre 1 Contexte Médical

Figure 1.1	Système respiratoire humain.....	3
Figure 1.2	Trachée et ses ramifications.....	4
Figure 1.3	Alvéoles pulmonaires et échanges gazeux.....	5
Figure 1.4	Anatomie pulmonaire.....	5
Figure 1.5	Phénomène respiratoire pulmonaire.....	6
Figure 1.6	Bronchopneumopathie chronique obstructive.....	9
Figure 1.7	Asthme.....	10
Figure 1.8	Fibrose pulmonaire.....	10
Figure 1.9	Sarcoïdose au stade radiologique primaire.....	11
Figure 1.10	Cancer du poumon.....	12
Figure 1.11	Pneumonie.....	12
Figure 1.12	Embolie pulmonaire.....	13
Figure 1.13	Bronchiolite.....	14
Figure 1.14	Radiographie thoracique.....	16
Figure 1.15	Tomodensitométrie thoracique.....	18
Figure 1.16	Imagerie par résonance magnétique thoracique.....	19
Figure 1.17	Scanner à émission de positrons (TEP-TDM).....	20
Figure 1.18	Échographie thoracique.....	21

Chapitre 2 Apprentissage automatique et profond

Figure 2.1	Interaction du deep learning avec l'intelligence artificielle.....	31
Figure 2.2	Autoapprentissage.....	32
Figure 2.3	Schéma d'un neurone biologique.....	34
Figure 2.4	Synapses entre deux neurones.....	34
Figure 2.5	Composition d'un neurone artificiel.....	35
Figure 2.6	Fonction sigmoïde.....	38
Figure 2.7	Fonction ReLu.....	38
Figure 2.8	Fonction Tangente hyperbolique.....	39

Figure 2.9	Architecture d'un réseau neuronal monocouche.....	42
Figure 2.10	Architecture d'un réseau neuronal multicouche.....	43
Figure 2.11	Réseaux de neurones récurrents.....	44
Figure 2.12	RNNs VS FNNs.....	45
Figure 2.13	Réseau de neurones convolutif.....	46
Figure 2.14	Schéma du parcours de la fenêtre de filtre sur l'image.....	47
Figure 2.15	Opération de convolution.....	47
Figure 2.16	Carte d'activation (Feature Map).....	48
Figure 2.17	Opération de pooling.....	49
Figure 2.18	Couche fully connected.....	50
Figure 2.19	Exemple d'un modèle d'apprentissage par transfert.....	52

Chapitre 3 Étude conceptuelle pour la catégorisation des données pneumologiques infantiles

Figure 3.1	Schéma synoptique du système "PneumoCNN 4"	59
Figure 3.2	Architecture du VGG 16.....	64
Figure 3.3	VGG 16.....	64
Figure 3.4	Architecture du VGG 19.....	65
Figure 3.5	Bloc résiduel.....	66
Figure 3.6	Architecture du MobileNet.....	68
Figure 3.7	Architecture du modèle DenseNet.....	68
Figure 3.8	Architecture du réseau EfficientNetB0.....	71
Figure 3.9	: Réseau de Neurones Standard.....	74
Figure 3.10	: Après avec Dropout.....	74

Chapitre 4 Mise en œuvre du système PneumoCNN4

Figure 4.1	Exemples d'images radiographiques thoraciques des deux classes	
	(a) Normal, (b) Pneumonie.....	83
Figure 4.2	Exemples d'augmentation des données.....	85
Figure 4.3	Architecture de mobilenetV2 affinée	87
Figure 4.4	Architecture d'EfficientNetB0 affinée.....	87
Figure 4.5	Architecture de VGG16 affinée.....	88

Figure 4.6	Architecture de VGG19 affinée.....	88
Figure 4.7	Architecture de Resnet50 affinée.....	89
Figure 4.8	Architecture de resnet101 affinée.....	89
Figure 4.9	Architecture de densenet121 affinée.....	90
Figure 4.10	Architecture de densenet201 affinée.....	90
Figure 4.11	Courbe de Accuracy et perte du modèle VGG16 pour différentes valeurs dropout.....	93
Figure 4.12	Courbe ROC du modèle VGG16 avec différentes valeurs du Dropout.....	94
Figure 4.13	Matrice de confusion du modèle VGG16 avec différentes Valeurs du Dropout...	95
Figure 4.14	Courbe de l'exactitude et de la perte du modèle VGG19 pour différentes valeurs du dropout.....	98
Figure 4.15	Courbe ROC du modèle VGG19 avec différentes valeurs du dropout.....	99
Figure 4.16	Matrice de confusion du modèle VGG19 avec différentes valeurs Dropout.....	100
Figure 4.17	Accuracy et perte du modèle ResNet50 pour différentes valeurs du dropout...	101
Figure 4.18	Courbe ROC du modèle Resnet50 avec différentes valeurs du dropout.....	102
Figure 4.19	Matrice de confusion du modèle ResNet50 pour différentes valeurs du Dropout.....	102
Figure 4.20	Accuracy et perte du modèle ResNet50 pour différentes valeurs Dropout.....	104
Figure 4.21	Courbe ROC du modèle ResNet101 avec différentes valeurs du Dropout.....	105
Figure 4.22	Matrice de confusion du modèle ResNet101 avec différentes valeurs du Dropout.....	106
Figure 4.23	Courbe de l'exactitude et de la perte du modèle MobileNetV2 pour différentes valeurs du dropout.....	108
Figure 4.24	Courbe ROC du modèle MobileNetV2 avec différentes valeurs Dropout.....	109
Figure 4.25	Matrice de confusion du modèle MobileNetV2 avec différentes valeurs Dropout.....	110
Figure 4.26	Courbe de l'exactitude et la perte du modèle EfficientNetB0.....	111
Figure 4.27	Courbe ROC du modèle EfficientNetB0 avec différentes valeurs du dropout....	112
Figure 4.28	Matrice de confusion du modèle EfficientNetB0 avec différents Dropout.....	112
Figure 4.29	Courbe de l'exactitude et la perte du modèle DenseNet121 pour différentes valeurs Dropout.....	114
Figure 4.30	Courbe ROC du modèle DenseNet121 avec différentes valeurs Dropout.....	115
Figure 4.31	Matrice de confusion du modèle DenseNnet121.....	115
Figure 4.32	Courbe de l'exactitude et la perte du modèle DenseNet201	116
Figure 4.33	Courbe ROC du modèle Densenet201.....	117
Figure 4.34	Matrice de confusion du modèle Densenet201.....	117

Liste des tableaux

Chapitre 2 Apprentissage automatique et profond

Tableau 2.1	Différence entre l'apprentissage automatique et l'apprentissage profond.....	33
--------------------	--	----

Tableau 2.2	Passage du neurone biologique vers le neurone formel.....	36
--------------------	---	----

Chapitre 3 Étude conceptuelle pour la catégorisation des données pneumologiques infantiles

Tableau 3.1	Résultats obtenus par Helena Liz et al.....	55
--------------------	---	----

Tableau 3.2	Résultats obtenus par Liang et al.....	56
--------------------	--	----

Tableau 3.3	Résultats obtenus par Jain et al.....	57
--------------------	---------------------------------------	----

Tableau 3.4	Structure du réseau.....	66
--------------------	--------------------------	----

Tableau 3.5	Structure du réseau resnet101.....	67
--------------------	------------------------------------	----

Tableau 3.6	Modèle de mobilenetV2.....	68
--------------------	----------------------------	----

Tableau 3.7	Structure de densenet121.....	70
--------------------	-------------------------------	----

Tableau 3.8	Structure du réseau Densenet201.....	70
--------------------	--------------------------------------	----

Tableau 3.9	Matrice de confusion.....	77
--------------------	---------------------------	----

Chapitre 4 Mise en œuvre du système PneumoCNN4

Tableau 4.1	Première distribution de la base chest X-ray.....	83
--------------------	---	----

Tableau 4.2	Seconde distribution de la base chest X-ray.....	83
--------------------	--	----

Tableau 4.3	Troisième distribution de la base chest X-ray.....	83
--------------------	--	----

Tableau 4.4	Résultats de l'entraînement du modèle VGG16.....	94
--------------------	--	----

Tableau 4.5	Performances du modèle VGG16.....	95
--------------------	-----------------------------------	----

Tableau 4.6	Résultats de l'entraînement du modèle VGG19.....	97
--------------------	--	----

Tableau 4.7	Performances du modèle VGG19.....	99
--------------------	-----------------------------------	----

Tableau 4.8	Résultats de l'entraînement du modèle ResNet50.....	101
--------------------	---	-----

Tableau 4.9	Performances du modèle ResNet50.....	102
--------------------	--------------------------------------	-----

Tableau 4.10	Résultats de l'entraînement du modèle ResNet101.....	103
---------------------	--	-----

Tableau 4.11	Performances du modèle ResNet101.....	105
---------------------	---------------------------------------	-----

Tableau 4.12	Résultats de l'entraînement du modèle MobileNetV2.....	107
---------------------	--	-----

Tableau 4.13	Performances du modèle MobileNetV2.....	107
Tableau 4.14	Résultats de l'entraînement du modèle EfficientNetB0.....	111
Tableau 4.15	Performances du modèle EfficientNetB0.....	112
Tableau 4.16	Résultats de l'entraînement du modèle EfficientNetB0.....	113
Tableau 4.17	Performances du modèle DenseNet121.....	113
Tableau 4.18	Résultats de l'entraînement du modèle DenseNet201.....	117
Tableau 4.19	Performances du modèle DenseNet201.....	117
Tableau 4.20	Performances de PnetmoCNN4 pour la seconde répartition.....	119
Tableau 4.21	Performances de PnetmoCNN4 pour la troisième répartition.....	121

Introduction générale

Les pathologies respiratoires constituent l'une des principales causes de morbidité et de mortalité infantile, dans le monde. Selon l'Organisation mondiale de la santé (OMS), la pneumonie seule est responsable de près de 15 % des décès d'enfants, de moins de cinq ans [1]. En Algérie, les maladies respiratoires représentent également un enjeu majeur de santé publique chez la population infantile. Les hôpitaux reçoivent régulièrement des cas de pneumonie, de bronchiolite ou d'autres infections pulmonaires aiguës, en particulier durant les saisons froides. Dans ce cadre, un diagnostic précoce et précis, serait essentiel pour améliorer le pronostic de ces pathologies. Néanmoins, la classification automatique des images thoraciques pédiatriques soulève plusieurs défis : la forte variabilité anatomique entre les enfants d'âges différents, ainsi que les difficultés de détection, dues à la faible résolution dans les clichés radiographiques. Ces contraintes nécessitent le développement de modèles robustes, capables de généraliser sur des données peu nombreuses et parfois déséquilibrées. Dans ce cadre, la solution est le recours à des outils d'intelligence artificielle capables d'assister les professionnels de santé, dans l'interprétation des radiographies thoraciques pédiatriques. A cet effet, l'exploration des réseaux de neurones convolutifs (CNN), pré-entraînés, pourrait offrir des perspectives prometteuses, pour assister les cliniciens, dans la détection automatique de pneumopathies infantiles, notamment dans les structures où le personnel médical, est débordé.

Ce mémoire s'inscrit dans cette dynamique, en se basant sur plusieurs architectures des réseaux de neurones convolutifs pré-entraînés ; telles que densenet, efficientnet, mobilenet, resnet et VGG, ayant pour objectif de classifier automatiquement et efficacement les radiothorax infantiles.

Cette étude vise ainsi à contribuer au développement d'un système d'aide au diagnostic pneumo-pathologique, en tenant compte des spécificités cliniques et techniques liées à la population pédiatrique.

Ce mémoire est organisé suivant quatre chapitres :

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

Le second chapitre introduit des notions de base sur l'apprentissage automatique et l'apprentissage profond, pour présenter les réseaux de neurones.

Le troisième chapitre est consacré l'étude conceptuelle proposée, pour la classification des pneumopathies infantiles, suivant les différentes architectures adoptées autour de leurs paramètres et, décrit quelques travaux antérieurs, dans le domaine de l'imagerie pulmonaire.

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

Chapitre 1: Contexte Médical

1.1 Introduction

La pneumologie occupe une place centrale dans le domaine médical, étant consacrée à l'étude des maladies qui affectent l'un des systèmes les plus vitaux de notre organisme : le système respiratoire. Ce chapitre propose une exploration approfondie de l'anatomie et de la physiologie respiratoires, en mettant en lumière les spécificités propres aux adultes et aux enfants, ainsi que les diverses pathologies qui peuvent affecter cet appareil complexe.

De la structure microscopique des alvéoles pulmonaires, aux techniques d'imagerie médicale les plus avancées, nous examinerons comment le système respiratoire assure sa fonction essentielle d'échange gazeux, permettant l'approvisionnement en oxygène de toutes les cellules de l'organisme. Cette compréhension fondamentale est cruciale, pour appréhender les différentes maladies respiratoires, afin de concevoir un système d'aide à la classification des radiographies infantiles.

1.2 Système respiratoire

Le système respiratoire (figure 1.1) comprend l'ensemble des organes, permettant à notre corps, d'absorber l'oxygène de l'air et d'éliminer le dioxyde de carbone, un déchet produit par nos cellules. Cet échange gazeux est essentiel à la vie, car il fournit l'énergie nécessaire à toutes les fonctions du corps humain [2].




Figure 1.1 : Système respiratoire humain [2]

L'air parcourt le corps humain à travers :

1. **Les voies aériennes supérieures** : L'air entre par le nez ou la bouche, puis passe par le pharynx et le larynx. Ce dernier, contenant les cordes vocales, permet la phonation [3].
2. **La trachée** : Un tube rigide (figure 1.2), renforcé par des anneaux de cartilage, conduit l'air vers les poumons [4].




Figure1. 2: Trachée et ses ramifications [4]

3. **Les bronches** : La trachée se divise en deux bronches principales, une pour chaque poumon, se ramifiant ainsi, à l'intérieur des poumons en bronchioles, de plus en plus fines.
4. **Les alvéoles pulmonaires** : À l'extrémité des bronchioles se trouvent les alvéoles, de minuscules sacs entourés de capillaires sanguins. C'est au niveau des alvéoles (figure 1.3), que se produisent les échanges gazeux [5].




Figure 1.3: Alvéoles pulmonaires et échanges gazeux [5]

1.3 Structure pulmonaire

Les poumons sont deux organes spongieux situés dans la cage thoracique (figure 1.4). Ils sont protégés par les côtes et séparés par le médiastin, qui contient le cœur et d'autres organes. Chaque poumon est divisé en lobes : trois pour le poumon droit et deux pour le gauche [5, 6].




Figure 1.4: Anatomie pulmonaire [6]

1.3.1 Fonctionnement respiratoire

Le fonctionnement respiratoire relève de l'inspiration et de l'expiration (figure 1.5). A cet effet, lorsque nous inspirons, le diaphragme (un muscle en forme de coupole) se contracte et s'aplatit, augmentant le volume de la cage thoracique. Cela crée une dépression, qui aspire l'air dans les poumons.

Dans le cas de l'expiration, le diaphragme se relâche et remonte, réduisant le volume de la cage thoracique. L'air est alors expulsé des poumons [4, 7].




Figure 1.5: Phénomène respiratoire pulmonaire [7]

1.3.2 Echanges gazeux

Au niveau des alvéoles, l'oxygène de l'air inspiré passe dans le sang, tandis que le dioxyde de carbone présent dans le sang, traverse les alvéoles pour être éliminé lors de l'expiration. Ces échanges sont rendus possibles grâce à la différence de pression des gaz, entre l'air alvéolaire et le sang [5, 7].

1.3.3 Fonctions du système respiratoire

Les principales fonctions du système respiratoire [7] permettent :

- ✚ **De fournir de l'oxygène aux cellules** : L'oxygène est indispensable au métabolisme cellulaire, qui produit l'énergie nécessaire à toutes les fonctions de l'organisme.

- ✚ **D'éliminer le dioxyde de carbone** : Le dioxyde de carbone est un déchet produit par le métabolisme cellulaire. Il doit être éliminé de l'organisme pour éviter une acidification du sang.
- ✚ **De réguler le pH sanguin** : Le système respiratoire contribue à maintenir un pH sanguin stable, en éliminant ou en retenant du dioxyde de carbone.
- ✚ **De participer à la thermorégulation** : La respiration permet d'éliminer une partie de la chaleur produite par l'organisme.

1.3.4 Contrôle de la respiration

La respiration est un processus automatique, contrôlé inconsciemment par le centre respiratoire situé à la base du cerveau.

La respiration continue pendant le sommeil et généralement, même pendant les états d'inconscience. Les personnes peuvent également contrôler leur respiration quand elles le souhaitent, par exemple, lorsqu'elles parlent, chantent ou retiennent leur respiration volontairement. Des organes sensoriels situés dans le cerveau, dans l'aorte et dans les carotides permettent de réguler le flux sanguin et décèlent les taux d'oxygène et de dioxyde de carbone. L'augmentation de la concentration en dioxyde de carbone est le stimulus le plus puissant pour approfondir et accélérer la fréquence de la respiration. Inversement, quand la concentration en dioxyde de carbone diminue, la respiration diminue. Le cerveau tend alors à diminuer la fréquence et la profondeur de la respiration. Dans des conditions de repos, une personne adulte inspire et expire environ 15 fois par minute [4, 7].

1.4 Spécificités anatomiques et physiologiques de l'enfant

Les enfants présentent des caractéristiques anatomiques et physiologiques distinctes des adultes ; ce qui les rend particulièrement, vulnérables aux infections respiratoires. Ces spécificités influencent la présentation clinique, l'évolution et la gravité des maladies respiratoires infantiles [8-10].

1.4.1 Anatomie des voies aériennes

Le développement des voies aériennes chez l'enfant, présente des particularités décelées suivant leurs caractéristiques [8, 9]. Ainsi, on remarque dans les voies aériennes supérieures :

- ✚ **Un pharynx** plus court et étroit, ce qui favorise l'obstruction par des hypertrophies adénoïdiennes ou des corps étrangers.
- ✚ **Une cavité nasale** plus petite et les cornets nasaux plus volumineux, ce qui augmente le risque d'obstruction.

Dans les voies aériennes inférieures, on observe :

- ✚ **Une trachée et des bronches** avec un diamètre plus petit, ce qui les rend plus sensibles aux obstructions.
- ✚ **Des poumons** moins lobulés, avec des alvéoles moins développées, limitant la réserve fonctionnelle respiratoire.

1.4.2 Physiologie respiratoire

La physiologie respiratoire infantile, est légèrement différente des adultes. En effet, la fréquence respiratoire étant plus élevée que chez l'adulte, tend à rendre les enfants, plus sensibles aux variations de l'oxygénation. Dans ce cas, la respiration thoracique montre une nette prédominance relativement à la respiration abdominale [10].

Les mécanismes de défense respiratoire infantiles [9, 10], présentent :

- ✚ **Une muqueuse respiratoire** moins efficace, avec un épithélium cilié moins développé et une production du mucus moins abondante.
- ✚ **Une immunité innée immature**, rend les jeunes sujets plus vulnérables aux infections.

1.5 Pathologies pulmonaires

Les poumons sont exposés à un large éventail de pathologies, allant des infections les plus courantes (comme la grippe ou la pneumonie) aux maladies chroniques (comme l'asthme ou la bronchopneumopathie chronique obstructive, BPCO) en passant par les cancers [11].

Ces maladies aiguës ou chroniques, touchent les deux genres humains, avec toutes tranches d'âges confondues, mais les symptômes peuvent être distincts [12].

1.5.1 Chez l'adulte

Les maladies respiratoires chez l'adulte sont souvent liées à des facteurs environnementaux, à des habitudes de vie et au vieillissement. Les plus courantes sont :

- a. Maladies obstructives** : Ces maladies réduisent le flux d'air en raison d'une obstruction des voies aériennes.

✚ **Bronchopneumopathie chronique obstructive (BPCO)** : Cette maladie est caractérisée par une inflammation chronique des bronches et une destruction des alvéoles pulmonaires (figure 1.6). Elle est souvent associée au tabagisme [13].




Figure 1.6: Bronchopneumopathie chronique obstructive [13]

✚ **Asthme** : C'est une maladie inflammatoire chronique des voies aériennes (figure 1.7), qui provoque des épisodes récurrents de sifflements, d'oppression thoracique, de toux et de difficultés respiratoires [14].




Figure 1.7 : Asthme [14]

b. Maladies restrictives : Ces maladies limitent l'expansion des poumons, réduisant ainsi la quantité d'air que les poumons peuvent contenir.

✚ **Fibrose pulmonaire** : Cette maladie (figure 1.8) est caractérisée par la formation du tissu cicatriciel dans les poumons, ce qui rend la respiration difficile [15].




Figure 1.8 : Fibrose pulmonaire [15]

✚ **Sarcoïdose** : C'est une maladie inflammatoire (figure 1.9), qui provoque la formation de granulomes (amas de cellules inflammatoires) dans les poumons et d'autres organes [16].




Figure 1.9 : Sarcoïdose au stade radiologique primaire [16]

La figure 1a représente des Lymphadénopathies bihilaires (flèche). La figure 1b via un examen scanner, illustre aussi des lymphadénopathies médiastinales (pointe de la flèche). Au scanner, il peut toujours y avoir de fines lésions interstitielles [16].

c. Autres maladies pulmonaires

✚ **Cancer du poumon :** C'est la principale cause de décès liés au cancer dans le monde [17]. Il s'agit d'une pathologie dans laquelle, les cellules se multiplient de façon anarchique et deviennent incontrôlables. Tous les tissus peuvent être touchés. Quand ces cellules sont au niveau du poumon, on parle de cancer du poumon (figure 1.10).



Figure 1.10 : Cancer du poumon [17]

✚ **Pneumonie** : C'est une Infection des alvéoles pulmonaires (figure 1.11), souvent causée par des bactéries, des virus ou des champignons [18].




Figure 1.11 : Pneumonie [18]

✚ **Embolie pulmonaire** : C'est une obstruction d'une artère pulmonaire (figure 1.12) déclenchée par un caillot de sang [19].




Figure 1.12 : Embolie pulmonaire [19]

1.5.2 Chez l'enfant

Les maladies respiratoires chez l'enfant sont souvent liées à des infections virales, à des allergies ou à des malformations congénitales [18-21]. Les plus fréquentes sont :

- ✚ **Bronchiolite** : Souvent causée par le virus respiratoire syncytial (VRS), la bronchiolite provoque une inflammation des petites voies aériennes. Les nourrissons sont les plus touchés (figure 1.13) [20].




Figure 1.13 : Bronchiolite [20]

- ✚ **Asthme** : C'est une maladie chronique inflammatoire des voies aériennes, qui se manifeste par des épisodes récurrents de sifflements, d'oppression thoracique et de difficultés respiratoires [21].
- ✚ **Pneumonie** : C'est une infection des poumons qui peut être causée par des bactéries, des virus ou des champignons [18].
- ✚ **Croup** : C'est une inflammation du larynx qui provoque une toux caractéristique et des difficultés respiratoires à l'inspiration.
- ✚ **Faux croup** : C'est une inflammation des voies aériennes supérieures, qui ressemble au croup mais est généralement moins grave.
- ✚ **Sinusite** : C'est une inflammation des sinus paranasaux.
- ✚ **Angine** : C'est une inflammation des amygdales [20].

1.5.3 Différences pathologiques entre adultes et enfants

Les maladies pulmonaires affectent à la fois les adultes et les enfants [18], mais il existe des différences notables telles que :

- ✚ **Causes** : Les causes des maladies respiratoires diffèrent souvent, en fonction de l'âge. Chez l'enfant, les infections virales sont plus fréquentes. Tandis que chez l'adulte, le tabagisme et les facteurs environnementaux jouent un rôle plus important.
- ✚ **Manifestations** : Les symptômes peuvent varier selon l'âge. Par exemple, les difficultés à respirer, une respiration rapide ou des rétractions thoraciques, alors que les adultes peuvent ressentir une toux chronique, une fatigue ou une douleur thoracique.
- ✚ **Traitements** : Les traitements peuvent également différer. Chez l'enfant, les traitements sont souvent plus axés sur le soulagement des symptômes et la prévention des complications. Chez l'adulte, les traitements peuvent être plus spécifiques à la maladie sous-jacente.

1.6 Imagerie médicale pulmonaire

Les systèmes d'acquisition d'images pulmonaires jouent un rôle crucial dans le diagnostic et le suivi des maladies respiratoires. Ils permettent d'obtenir des visualisations précises de l'intérieur des poumons, aidant ainsi les médecins à poser un diagnostic et à adapter le traitement, en conséquence [22].

Il existe plusieurs types d'imagerie médicale adaptés aux zones à étudier. On distingue notamment :

- ✚ La [radiologie](#), qui utilise les [rayons X](#) pour explorer les os, les [poumons](#), l'[abdomen](#) ou le [système digestif](#).
- ✚ L'[échographie](#), qui se sert des ultrasons pour explorer les organes pleins et qui permet d'observer le [fœtus](#) au cours de la [grossesse](#).
- ✚ L'imagerie par résonance magnétique ([IRM](#)) qui permet d'obtenir des images en coupes du corps.
- ✚ Le [scanner](#) qui donne également des images en coupe et qui permet de réaliser la représentation d'organes en 3D.

1.6.1 Radiographie thoracique

C'est l'examen d'imagerie le plus simple et le plus couramment utilisé, pour analyser les poumons. Dans ce cadre, un faisceau de rayons X traverse le thorax, créant une image en noir et blanc sur une plaque ou un écran numérique [23].

La radiologie pulmonaire par rayons X repose sur l'émission de rayons ionisants à travers la cage thoracique, qui sont absorbés différemment selon la densité des tissus : les os, plus denses, apparaissent blancs, les poumons remplis d'air apparaissent noirs, et les tissus mous en gris. Cette absorption différentielle permet de créer une image en deux dimensions sur un film ou un capteur numérique, révélant ainsi la structure des poumons, du cœur, des côtes et des vaisseaux thoraciques, afin de détecter des anomalies comme des infections, des tumeurs, ou des épanchements (figure 1.14). Ainsi, plusieurs types de clichés peuvent être extraits, tels que : le cliché de profil, le cliché de face, le cliché en inspiration et expiration, le cliché oblique, ainsi que le cliché de décubitus.



Figure 1.14 : Radiographie thoracique [23]

a. Cliché de face

C'est le cliché le plus utilisé. L'enfant est debout ou assis, dos ou poitrine contre le détecteur. Il permet une vue générale des poumons, du médiastin et du squelette thoracique.

b. Cliché de profil

Ce cliché est utilisé en complément du cliché de face. Il aide à localiser une lésion invisible en cliché de face (ex. lobes moyens, rétrosternaux ou rétro-cardiaques). Cependant, il est plus difficile à réaliser chez les tout-petits, car il nécessite une bonne immobilisation.

c. Clichés en inspiration et expiration

Ces clichés permettent de diagnostiquer un corps étranger inhalé. L'enfant doit coopérer pour bien souffler ou inspirer à la demande, donc rarement faisable chez les plus jeunes.

d. Cliché en décubitus

Ce type de cliché est utilisé chez les nourrissons ou les enfants incapables de rester debout. Il peut être pris en décubitus dorsal (sur le dos) ou latéral, pour détecter un épanchement pleural (le liquide se décale selon la position).

e. Cliché oblique

Ce type de cliché est rarement utilisé, sauf pour des cas particuliers. Il aide à mieux voir certaines structures, ou à confirmer une suspicion diagnostique (ex. anomalies vasculaires).

f. Mise en évidence des lésions thoraciques infantiles et limites de la radiographie

Chez l'enfant, la radiographie pulmonaire permet de détecter plusieurs affections respiratoires et thoraciques fréquentes :

- ✚ **Infections pulmonaires** : pneumonie, bronchiolite sévère.
- ✚ **Malformations pulmonaires congénitales.**
- ✚ **Corps étranger inhalé.**
- ✚ **Épanchement pleural.**
- ✚ **Pneumothorax.**
- ✚ **Cardiomégalie.**
- ✚ **Fractures de côtes.**

Cette technique présente néanmoins des limites dans le cas de certaines lésions infantiles :

- ✚ Ne montre pas toujours clairement les **infections virales légères** (ex. bronchiolite modérée).
- ✚ Moins sensible que le scanner pour les **malformations complexes** ou **lésions profondes.**
- ✚ Peut **ne pas visualiser un corps étranger non radio-opaque** (comme du plastique).
- ✚ Ne fournit qu'une image 2D et manque parfois de précision anatomique.

1.6.2 Tomodensitométrie thoracique

La tomodensitométrie (TDM) utilise des rayons X et un ordinateur, pour produire des images en coupe transversale très détaillées des poumons (figure 1.15). Elle permet de visualiser les structures pulmonaires avec une grande précision et de détecter des lésions plus petites, que celles visibles à la radiographie.

Le principe de la tomodensitométrie thoracique (ou scanner thoracique) repose sur l'utilisation de rayons X émis en faisceau fin autour du thorax et captés par des détecteurs rotatifs, permettant de reconstituer des coupes transversales (images en 2D) très précises des structures internes du thorax. Contrairement à la radiographie classique qui donne une image plate, le scanner crée des images en coupe du poumon, du cœur, des vaisseaux, des os et des tissus mous, avec une résolution spatiale élevée. Ces coupes sont ensuite assemblées numériquement pour fournir des images en 3D, facilitant la détection de lésions pulmonaires, tumeurs, embolies pulmonaires, malformations, infections profondes ou traumatismes, souvent invisibles en radiographie standard [24].




Figure 1.15 : Tomodensitométrie thoracique [24]

Les légendes correspondant à la figure 1.15, représentent successivement 1. Coracoïde. 2, Clavicule droite. 3, Veine jugulaire droite. 4, Thyroïde. 5, Veine jugulaire interne gauche. 6, Clavicule gauche. 7, Veine sous-clavière gauche. 8, Tête humérale gauche. 9, épine de l'omoplate (Scapula). 10, Apophyse épineuse.

La TDM thoracique est particulièrement utile pour :

- ✚ Évaluer l'étendue d'une maladie pulmonaire.
- ✚ Détecter des nodules pulmonaires.
- ✚ Stadier un cancer du poumon.
- ✚ Guider des biopsies.

1.6.3 Imagerie par résonance magnétique (IRM) thoracique

L'IRM utilise un champ magnétique puissant et des ondes radio (figure 1.16), pour produire des images détaillées des tissus mous. Elle est particulièrement utile pour visualiser les vaisseaux sanguins pulmonaires et les tissus mous entourant les poumons [25].



Figure 1.16 : Imagerie par résonance magnétique thoracique [26]

L'IRM thoracique est utilisée pour :

- Évaluer les maladies vasculaires pulmonaires.
- Détecter les tumeurs.
- Évaluer les maladies inflammatoires.

1.6.4 Scanner à émission de positrons (TEP-TDM)

La TEP-TDM combine la TDM et la tomographie par émission de positrons (figure 1.17), pour produire des images fonctionnelles et anatomiques des poumons. Elle permet d'évaluer le métabolisme des tissus pulmonaires et de détecter les cellules cancéreuses [26].



Figure 1.17 : Scanner à émission de positrons (TEPTDM) [26]

La TEP-TDM est utilisée pour :

- ✚ Evaluer le stade d'un cancer du poumon.
- ✚ Évaluer la réponse au traitement.
- ✚ Détecter des récives.

1.6.5 Echographie thoracique

L'échographie thoracique (figure 1.18) repose sur l'utilisation d'ultrasons, émis par une sonde placée sur la paroi thoracique. Ces ondes sonores se propagent à travers les tissus et sont réfléchies de manière différente, selon les structures rencontrées (liquide, air, tissu solide). Les échos retournés à la sonde, sont convertis en images en temps réel.

Contrairement aux rayons X, l'échographie n'utilise pas de rayonnement ionisant. Bien que l'air limite la pénétration des ultrasons dans le poumon sain (rendant l'intérieur du poumon peu visible), elle est très utile pour évaluer la plèvre, les épanchements pleuraux, les consolidations pulmonaires périphériques, les pneumothorax, les masses superficielles et pour guider des gestes comme les ponctions ainsi que les biopsies [27].



Figure 1.18 : Échographie thoracique [27]

1.6.6 Scintigraphie ventilation-perfusion

La scintigraphie ventilation-perfusion (ou scintigraphie V/Q) est un examen en médecine nucléaire, qui permet d'évaluer la circulation de l'air (ventilation) et la circulation sanguine (perfusion) dans les poumons. Elle est principalement utilisée pour rechercher une embolie pulmonaire, c'est-à-dire un caillot qui bloque la circulation sanguine dans une partie du poumon. Elle évalue alors, la fonction pulmonaire en mesurant le flux sanguin et la ventilation [28, 29].

1.6.7 Choix de l'examen

Le choix de l'examen d'imagerie [29] dépend de :

- + La symptomatologie du patient
- + L'âge et l'état de santé général
- + L'hypothèse diagnostique
- + Les contre-indications (par exemple, la grossesse pour la TDM).

1.7 Épidémiologie

Les maladies respiratoires constituent un problème de santé publique majeur à l'échelle mondiale, impactant des millions de personnes chaque année. Leur prévalence et leur gravité varient selon les régions, les âges et les facteurs socio-économiques [30-33].

1.7.1 Facteurs influençant l'épidémiologie pulmonaire

Plusieurs facteurs [31] peuvent influencer l'épidémiologie pulmonaire :

a. Facteurs environnementaux

- + **Pollution de l'air** : Les particules fines, le dioxyde de soufre et d'autres polluants exacerbent les maladies respiratoires existantes et augmentent le risque d'en développer de nouvelles.
- + **Changement climatique** : Les événements météorologiques extrêmes et les changements saisonniers peuvent influencer la fréquence et la sévérité des maladies respiratoires, en particulier les allergies.

b. Facteurs socio-économiques

- + **Pauvreté** : Les personnes vivant dans des conditions de vie précaires sont plus exposées aux polluants et ont moins accès aux soins de santé.
- + **Tabagisme** : Le tabagisme est un facteur de risque majeur pour de nombreuses maladies respiratoires, notamment la BPCO et le cancer du poumon.

c. Facteurs biologiques

- + **Âge** : Les nourrissons, les jeunes enfants et les personnes âgées sont plus vulnérables aux infections respiratoires.

- ✚ **Comorbidités** : Les personnes atteintes de maladies chroniques (diabète, maladies cardiovasculaires) sont plus susceptibles de développer des complications respiratoires.

d. Facteurs infectieux

- ✚ **Virus** : Le virus de la grippe, le VRS (virus respiratoire syncytial) et les coronavirus sont des agents infectieux majeurs responsables de nombreuses maladies respiratoires.
- ✚ **Bactéries** : Le pneumocoque et le 'Haemophilus influenzae' sont des bactéries responsables de pneumonies et d'autres infections respiratoires.

1.7.2 Tendances épidémiologiques

Les tendances épidémiologiques pulmonaires reflètent l'évolution des maladies respiratoires à l'échelle mondiale et locale, influencée par le tabagisme, la pollution, les infections, et les modes de vie [31]. Les principales tendances actuelles se résument suivant :

- ✚ **L'Augmentation des maladies chroniques** : On observe une augmentation de la prévalence de maladies respiratoires chroniques comme la BPCO et l'asthme, liée en partie au vieillissement de la population et à l'exposition à des facteurs de risque.
- ✚ **La Réémergence de certaines infections** : Des infections respiratoires autrefois contrôlées, comme la tuberculose, réémergent dans certaines régions du monde.
- ✚ **L'Émergence de nouvelles maladies** : L'émergence de nouveaux virus respiratoires, comme le SARS-CoV-2, souligne la nécessité d'une surveillance épidémiologique continue.
- ✚ **Le Changement climatique** : présente l'augmentation des allergies respiratoires, ainsi que l'allongement des saisons polliniques.
- ✚ **Le Vieillissement de la population** : présente une plus grande vulnérabilité aux maladies respiratoires chroniques et infectieuses.

1.7.3 Épidémiologie des maladies respiratoires chez les enfants en Algérie

Les infections respiratoires aiguës (IRA) représentent un problème majeur de santé publique en Algérie, particulièrement chez les enfants de moins de 5 ans.

Selon les directives techniques de l'Organisation mondiale de la Santé (OMS) publiées en 2002 [32], les IRA étaient responsables de 52 % des consultations pédiatriques et de 23,7 % des hospitalisations dans cette tranche d'âge en 2000. Parmi les enfants hospitalisés pour les IRA, 30 % avaient entre 24 et 59 mois, 21 % entre 12 et 23 mois, et 25 % entre 5 et 11 mois. La répartition topographique des IRA, montrait que 70 % étaient des infections des voies respiratoires supérieures et 30 % des voies inférieures.

De plus, les IRA constituaient 10,7 % des causes de décès chez les enfants de moins de 5 ans, en Algérie cette même année. En 2023, les IRA demeurent une cause majeure de morbidité chez les enfants, en particulier ceux de moins de 5 ans. Chaque enfant peut présenter en moyenne de 6 à 8 épisodes d'infection respiratoire par an. Les analyses cliniques indiquent, 30,30 % enfants de moins de 5 ans ainsi que, 70,30 % enfants de 5 à 16 ans atteints de rhinite. Dans le même cadre, 18,18 % enfants de moins de 5 ans et, 40,7 % enfants de 5 à 16 ans sont infectés par la bronchite [33].

Ces données soulignent l'importance de renforcer les stratégies de prévention, de diagnostic précoce et de prise en charge efficace des IRA pour réduire la morbidité et la mortalité infantiles dans le pays.

En décembre 2023, le ministère de la Santé algérien a lancé un guide destiné à améliorer la prise en charge thérapeutique des enfants souffrant d'IRA [33]. Ce guide vise à standardiser les pratiques médicales et à fournir un outil de référence aux professionnels de santé pour une prise en charge optimale des enfants infectés.

1.8 Conclusion

Le système respiratoire, de par sa complexité et son rôle vital, nécessite une attention médicale particulière. Les progrès en imagerie et la compréhension approfondie de la physiologie respiratoire par les cliniciens, ont permis d'améliorer significativement le diagnostic et le traitement des pathologies pulmonaires. Cependant, l'augmentation des maladies respiratoires chroniques et l'impact grandissant des facteurs environnementaux, soulignent l'importance d'une vigilance continue. La pneumologie reste ainsi un domaine en constante évolution, où la recherche et l'innovation sont essentielles pour répondre aux défis actuels et futurs de la santé respiratoire, à travers les nouvelles technologies.

Le prochain chapitre sera consacré à l'introduction de l'intelligence artificielle et aux réseaux de neurones.

Chapitre 2: Apprentissage automatique et profond

2.1 Introduction

Nous vivons aujourd'hui dans un royaume, où les algorithmes tissent des tapisseries complexes de pensée, apprenant des échos de l'ère numérique. C'est le monde de l'Intelligence Artificielle, un royaume où les frontières entre l'humain et la machine, commencent à s'estomper.

Plus confinée aux pages de la science-fiction, l'IA est désormais une force tangible, remodelant les industries, révolutionnant la santé et même inspirant l'expression artistique. Des voitures autonomes aux assistants virtuels, l'IA est le partenaire silencieux, la main invisible guidant notre évolution technologique. Mais ce qui distingue vraiment l'IA, c'est sa capacité à apprendre et à s'adapter. C'est comme un enfant curieux, absorbant constamment de l'information, questionnant le monde et devenant plus sage à chaque instant. Alors que l'IA continue d'évoluer, nous sommes au bord d'une nouvelle ère, où les limites du potentiel humain sont repoussées à des hauteurs inimaginables.

Ce chapitre aborde le concept du machine learning ainsi que celui du deep learning, pour décrire les réseaux de neurones et plus spécifiquement, les réseaux convolutifs, l'objectif de notre étude.

2.2 Introduction à l'intelligence artificielle (IA)

Dans le paysage technologique d'aujourd'hui en évolution rapide, l'IA est devenue un terme courant. Des 'chatbots' et assistants virtuels, aux voitures autonomes et aux algorithmes de recommandation, l'impact de l'IA est omniprésent [34-37]. Mais qu'est-ce que l'IA et comment fonctionne-t-elle exactement ?

2.2.1 Principe de l'intelligence artificielle

L'intelligence artificielle est un domaine scientifique qui vise à créer des ordinateurs et des machines capables de raisonner, d'apprendre et d'agir d'une manière qui nécessiterait normalement l'intelligence humaine ou qui implique des données, dont l'échelle dépasse ce que les humains peuvent analyser.

L'IA est un vaste domaine qui couvre un large éventail de spécialités, y compris l'informatique, l'analyse de données et les statistiques, l'ingénierie matérielle et logicielle, la linguistique, les neurosciences, ainsi que la philosophie et la psychologie [35, 37].

Au niveau opérationnel pour les entreprises, l'IA correspond à un ensemble de technologies basées principalement sur 'le machine learning et le deep learning', utilisées pour l'analyse de données, les prédictions et les prévisions, la catégorisation des objets, le traitement du langage naturel, les recommandations, ainsi que la récupération intelligente de données, etc...

2.2.2 Fonctionnement de l'IA

Le fonctionnement fondamental de l'IA s'articule autour des données, bien que les spécificités varient selon les techniques. Les systèmes d'IA apprennent et s'améliorent en étant exposés à de grandes quantités de données, en identifiant des tendances et des relations qui pourraient échapper aux humains. Ce processus d'apprentissage implique souvent des algorithmes, qui sont des ensembles de règles ou d'instructions guidant l'analyse et la prise de décision de l'IA. En machine learning (apprentissage automatique), un sous-domaine de l'IA, les algorithmes sont entraînés sur des données étiquetées ou non, afin de réaliser des prédictions ou classer des informations.

Le deep learning, une spécialisation plus approfondie, utilise des réseaux de neurones artificiels à plusieurs couches pour traiter les informations, imitant la structure et le fonctionnement du cerveau humain. En apprenant et en s'adaptant continuellement, les systèmes de l'IA deviennent de plus en plus aptes à effectuer des tâches spécifiques, de la reconnaissance d'images à la traduction de langues et, plus encore [37].

2.2.3 Types d'intelligence artificielle

L'intelligence artificielle peut être organisée de plusieurs manières, selon les étapes de développement ou les actions réalisées. Les types d'intelligence artificielle (IA) peuvent être classés selon **deux grandes perspectives : les fonctionnalités et le niveau de raisonnement**.

a. Classification de l'IA selon les fonctionnalités

Dans ce cadre, quatre types de développement de l'IA sont communément reconnues [37].

1. Machine réactive : Cette machine représente l'IA limitée, qui ne réagit qu'à différents types de stimuli en fonction de règles préprogrammées. Elle ne consomme pas de mémoire et ne peut donc pas, apprendre avec de nouvelles données. Le superordinateur Deep Blue d'IBM, qui a battu le champion d'échecs Garry Kasparov en 1997, a été un exemple de machine réactive.

2. Mémoire limitée : l'IA la plus moderne est considérée comme une mémoire limitée. Elle peut utiliser la mémoire pour s'améliorer au fil du temps, en s'entraînant avec de nouvelles données, généralement via un réseau de neurones artificiel, ou un autre modèle d'entraînement. Le deep learning, un sous-ensemble du machine learning, est considéré comme une intelligence artificielle limitée en mémoire.

3. Théorie des machines mentales : cette IA n'existe pas encore, mais les recherches se poursuivent dans cette éventualité. Il s'agit d'une IA capable d'émuler l'esprit humain. Elle est dotée de capacités décisionnelles égales à celles d'un être humain, y compris en reconnaissant et en mémorisant les émotions et en réagissant dans des situations sociales, comme le ferait un être humain.

4. Machines à prise de conscience de soi : cette IA se situe un cran, au-dessus de la théorie des machines mentales. Elle décrit une machine inventée qui a conscience de sa propre existence. Elle possède les capacités intellectuelles et émotionnelles d'un être humain. Comme pour la théorie des machines mentales, les machines à prise de conscience de soi n'existent pas encore.

b. Classification de l'IA selon le niveau de raisonnement

Il s'agit d'une classification **conceptuelle** de l'IA, selon son niveau d'autonomie et de raisonnement [35, 36].

- 1. IA étroite** : C'est une IA spécialisée dans **une seule tâche** (ex. : moteurs de recommandation, systèmes de diagnostic médical. Elle fonctionne dans un **cadre prédéfini** (ex. reconnaissance d'images, traitement du langage). Elle est dépendante de **données spécifiques à une tâche** et est incapable de s'auto-

améliorer ou de raisonner en dehors de son domaine. Elle ne peut pas généraliser ses connaissances à des domaines différents : C'est l'**IA actuelle**.

2. IA générale : Elle est capable d'apprendre et de comprendre comme un humain dans divers domaines. Polyvalente, elle peut résoudre des problèmes dans plusieurs domaines (maths, langues, art, logique...). Elle possède des capacités de raisonnement abstrait et, de compréhension du contexte. Elle pourrait s'auto-former, adapter ses stratégies, et même raisonner de façon créative. Elle est à ce stade, encore hypothétique.

3. Super intelligence : Elle dépasse l'intelligence humaine dans tous les domaines, scientifiques, artistiques, émotionnels, sociaux, etc. Elle est purement théorique à ce stade.

Cette IA pourrait avoir une capacité d'autonomie totale, de créativité supérieure, et de prise de décision ultra-rapide. Elle est aussi capable de manipuler des systèmes humains, anticiper les comportements, voire s'auto-améliorer exponentiellement (effet de « particularité » technologique).

Il est plus utile de catégoriser globalement les types d'intelligence artificielle, en fonction de ce que la machine peut faire. Tout ce qui est appelé actuellement intelligence artificielle, est considéré comme une intelligence artificielle étroite, car elle ne peut effectuer que des ensembles restreints d'actions, en fonction de sa programmation et de son entraînement. Par exemple, un algorithme d'IA utilisé pour la classification d'objets, ne pourra pas traiter le langage naturel. La recherche Google est une forme d'IA étroite, tout comme l'analyse prédictive ou les assistants virtuels [36].

2.3 Apprentissage automatique

L'apprentissage automatique (machine learning), consiste à créer des modèles, pour faire des prédictions ou prendre des décisions basées sur des données. Cet apprentissage englobe un large éventail de techniques, qui permettent aux ordinateurs d'apprendre et de faire des inférences à partir de données, sans être explicitement programmés pour des tâches spécifiques [38].

Il existe de nombreux types d'algorithmes d'apprentissage automatique, notamment la régression linéaire, la régression logistique, les arbres de décision, les forêts aléatoires¹, les machines à vecteur de support (SVM), les k- plus proches voisins (KNN), le clustering et bien d'autres [37]. Chacune de ces approches est adaptée à différents types de problèmes et de données. Mais l'un des types les plus populaires d'algorithme du machine learning, est le réseau de neurones artificiel. Ce type de réseau est modélisé selon la structure et la fonction du cerveau humain. Dans ce cas, un réseau de neurones est constitué de couches interconnectées de nœuds (analogues aux neurones), permettant de traiter et d'analyser des données complexes. Les réseaux de neurones sont bien adaptés aux tâches qui impliquent l'identification de modèles et de relations complexes, dans de grandes quantités de données. L'apprentissage automatique implique l'utilisation d'ensembles de données étiquetées ou non, pour former des algorithmes, à classifier les données ou à prédire les résultats avec précision.

Le but est que le modèle apprenne la cartographie entre les entrées et les sorties, dans les données de formation, afin qu'il puisse prédire les étiquettes des nouvelles données.

Dans ce cadre, l'apprentissage automatique [39] comprend quatre types : l'apprentissage supervisé, le non-supervisé, le semi-supervisé, l'auto-supervisé et l'apprentissage par renforcement.

1. Apprentissage supervisé : L'apprentissage supervisé est la technique d'apprentissage, dans laquelle le modèle apprend à faire des prédictions ou à classer les données, selon des bases de données étiquetées. Les algorithmes d'apprentissage profond comme les réseaux neuronaux convolutifs, les réseaux neuronaux récurrents sont utilisés pour de nombreuses tâches supervisées, telles que la classification et la reconnaissance des images, l'analyse des sentiments, les traductions linguistiques, etc.

2. Apprentissage non supervisé : Cet apprentissage, est l'approche dans laquelle le modèle apprend à regrouper l'ensemble de données, en fonction de leurs similarités à partir de bases de données non étiquetées. Il n'y a pas de variables cibles, alors que la machine doit déterminer elle-même les relations cachées, dans les ensembles de données. Les algorithmes d'apprentissage profond comme les encodeurs automatiques et les modèles génératifs, sont utilisés pour des tâches non supervisées telles que le clustering, la réduction de dimensionnalité et la détection d'anomalies.

3. Apprentissage semi-supervisé : Cet apprentissage est une méthode hybride utilisant un petit nombre d'exemples étiquetés et un grand nombre d'exemples non étiquetés. Elle vise à améliorer la performance, tout en réduisant le coût de l'étiquetage manuel, comme la reconnaissance d'images avec peu d'annotations.

4. Apprentissage auto-supervisé : C'est une méthode émergente où le modèle génère ses propres étiquettes, à partir des données non étiquetées, souvent en résolvant une tâche auxiliaire. C'est une approche très utilisée dans les modèles de traitement du langage (comme GPT) et la vision. Par exemple, elle permet de prédire les parties manquantes d'un texte ou d'une image.

5. Apprentissage par renforcement : L'apprentissage par renforcement est la technique d'apprentissage automatique, dans laquelle un agent apprend à prendre des décisions dans un environnement, pour maximiser un signal de récompense. L'agent interagit avec l'environnement en prenant des mesures et en observant les récompenses qui en découlent. L'apprentissage profond peut être utilisé pour apprendre des politiques, avec un ensemble d'actions, qui maximise la récompense cumulée au fil du temps. Les algorithmes d'apprentissage par renforcement profond comme les réseaux Deep Q et le gradient de politique déterministe profond (DDPG), sont utilisés pour renforcer des tâches telles que la robotique et le jeu, etc.

2. 4 Notions d'apprentissage profond

À l'ère de l'intelligence artificielle, en pleine évolution, l'apprentissage profond (Deep Learning) est une technologie clef, qui révolutionne la façon dont les machines comprennent, apprennent et interagissent avec des données complexes.

L'IA du Deep Learning imite les réseaux neuronaux complexes du cerveau humain, permettant aux ordinateurs de découvrir des modèles et de prendre des décisions à partir d'une grande quantité de données non structurées. Ce domaine transformateur a entraîné des percées dans divers domaines, de la vision par ordinateur et du traitement du langage naturel, au diagnostic médical et à la conduite autonome [40, 41].

2.4.1 Principe de l'apprentissage profond

Le deep learning est la branche du machine learning (figure 2.1), qui repose sur l'architecture des réseaux neuronaux artificiels. Un réseau de neurones artificiels (RNA) utilise des couches

de nœuds interconnectés, appelés neurones qui travaillent ensemble pour traiter et apprendre, à partir des données d'entrée.

Un réseau de neurones profond, comprend une couche d'entrée et une ou plusieurs couches cachées connectées les unes aux autres. Chaque neurone reçoit des informations de la couche précédente. La sortie d'un neurone devient l'entrée des autres neurones dans la couche suivante du réseau. Ce processus continue jusqu'à ce que la couche finale produise la sortie du réseau. Les couches du réseau neuronal transforment les données d'entrée par une série de transformations non linéaires, permettant au réseau d'apprendre des représentations complexes des données d'entrée [40, 41, 42].




Figure 2.1 : Interaction du deep learning avec l'intelligence artificielle [40]

Aujourd'hui, le deep learning est devenu l'un des domaines les plus populaires et visibles de l'apprentissage automatique (machine learning), en raison de son succès dans une variété d'applications, telles que la vision par ordinateur et le traitement du langage naturel.

2.4.2 Fonctionnement de l'apprentissage profond

Le *deep Learning* s'appuie sur un réseau de neurones artificiel, s'inspirant du cerveau humain. Ce réseau est composé de dizaines, voire de centaines de « couches » de neurones, chacune recevant et interprétant les informations de la couche précédente.

Le système apprend par exemple, à reconnaître les lettres avant de s'attaquer aux mots dans un texte, ou identifie un visage sur une photo, avant de découvrir de quelle personne il s'agit [40].

À travers un processus d'autoapprentissage (figure 2.2), le deep learning est capable d'identifier par exemple, un chat sur une photo. À chaque couche du réseau neuronal, correspond un aspect particulier de l'image. À chaque étape, les « mauvaises » réponses sont éliminées et renvoyées vers les niveaux en amont, pour ajuster le modèle mathématique. Au fur et à mesure, le programme réorganise les informations en blocs plus complexes. Lorsque ce modèle est par la suite appliqué à d'autres cas, il est capable de reconnaître un chat, sans que personne ne lui ait jamais indiqué qu'il n'ait jamais appris le concept du chat. Les données de départ sont essentielles : plus le système accumule d'expériences différentes, plus il sera performant [40 - 42].




Figure 2.2 : Autoapprentissage [42]

2.4.3 Différence entre l'apprentissage automatique et l'apprentissage profond

Le machine learning et le deep learning, sont des sous-ensembles de l'intelligence artificielle, présentant à la fois, de nombreuses similitudes ainsi que des différences (tableau 2.1).

Machine learning	Deep learning
Application des algorithmes statistiques pour l'apprentissage.	Utilisation des réseaux de neurones artificiels pour l'apprentissage.
Traitement d'un petit volume de jeu de données.	Traitement d'un plus grand volume de jeu de données par rapport à l'apprentissage automatique
Plus performant pour la tâche de faible label.	Plus performant pour les tâches complexes comme le traitement d'image, le traitement du langage naturel, etc.
Formation du modèle avec moins de temps que pour le deep learning.	Formation du modèle avec plus de temps que pour l'apprentissage automatique.
Création manuelle des caractéristiques pertinentes des données.	Création automatique des caractéristiques pertinentes à partir des données. C'est un processus d'apprentissage de bout en bout.
Moins complexe et facile à interpréter	Plus complexe, il fonctionne comme les boîtes noires.
Fonctionnement sur le processeur avec moins de puissance de calcul, que l'apprentissage profond.	Nécessité d'un ordinateur de haute performance avec GPU.

Tableau 2.1 : Différence entre l'apprentissage automatique et l'apprentissage profond [40]

2.5 Introduction aux réseaux de neurones

Les réseaux de neurones artificiels sont inspirés des réseaux de neurones biologiques, pour reproduire les fonctions du cerveau humain. Dans ce cadre, avant d'introduire ces réseaux, le principe des neurones biologiques est nécessaire.

2.5.1 Neurone Biologique

Le système nerveux est composé de milliards de cellules, réalisant un réseau de neurones biologique. En effet, les neurones ne sont pas indépendants les uns des autres, ils établissent entre eux des liaisons, pour former des réseaux plus ou moins complexes [43].

Le neurone biologique (figure 2.3) est constitué de trois parties principales :

- ✚ Le corps cellulaire composé du centre de contrôle traite les informations reçues par les dendrites.
- ✚ Les dendrites sont les principaux fils conducteurs par lesquels, transitent l'information venue de l'extérieur.
- ✚ L'axone conduit le signal de sortie du corps cellulaire vers d'autres neurones.




Figure 2.3 : Schéma d'un neurone biologique [43]

Les synapses (figure 2.4), font effet de liaison et de pondération entre les neurones, leur permettant, de communiquer entre eux [44].




Figure 2.4 : Synapses entre deux neurones [44]

2.5.2 Neurone artificiel

Le schéma de la figure 2.5, montre la composition d'un neurone artificiel. Chaque neurone faisant partie du réseau, est une machine élémentaire.

Il reçoit un certain nombre de variables d'entrées E , provenant des neurones en amont. À chacune de ces entrées, est associé un poids W , qui représente la force de la connexion entre les deux neurones. Chaque neurone est doté d'une unique sortie S , qui se ramifie ensuite pour représenter les entrées, qui alimenteront d'autres neurones en aval. En résumé, chaque neurone détermine une sortie unique, en se basant sur les informations qui lui sont données [45].




Figure 2.5 : Composition d'un neurone artificiel [45]

Le neurone en tant qu'unité élémentaire agit de la façon suivante :

- 🌈 **Première phase :** Le neurone évalue la somme pondérée des entrées ($E_1, \dots, E_n$) en fonction des poids ($w_1, \dots, w_n$). L'apprentissage ayant été réalisé, le poids des connexions est déterminé et fixé.
- 🌈 **Seconde phase :** À partir de la valeur obtenue, une fonction d'activation f , calcule la valeur de l'état du neurone. Le neurone compare la somme pondérée des entrées à une valeur de seuil et, fournit alors une réponse en sortie S [43, 45].

Dans ce cadre, la sortie S , envoyée biologiquement dans l'axone, se calcule comme une combinaison linéaire (équation 2.1) des poids et des entrées (plus un biais w_0).

$$S = f(w_0 + \sum_{i=1}^n w_i E_i) \quad 2.1$$

La relation entre le neurone biologique et l'artificiel établit donc, une connexion entre les différents paramètres conducteurs de l'information (tableau 2.2).

Neurone biologique	Neurone artificiel
Axones	Signal de sortie
Dendrites	Signal d'entrée
Synapses	Poids de la connexion
Somma	Fonction d'activation

Tableau 2.2 : Passage du neurone biologique vers le neurone formel [46]

2.5.3 Fonction d'activation

Une fonction d'activation est un élément fondamental des réseaux de neurones artificiels, utilisé pour introduire de la non-linéarité dans le modèle. En termes simples, elle transforme les signaux entrants d'un neurone, afin de déterminer s'il doit être activé ou non, c'est-à-dire s'il doit transmettre des informations aux neurones suivants.

Dans un réseau de neurones, les signaux bruts, ou données d'entrée, sont pondérés et accumulés dans chaque neurone. La fonction d'activation prend cette accumulation et la transforme en une sortie exploitable. Le terme "**potentiel d'activation**" provient de l'équivalent biologique, représentant le seuil de stimulation qui déclenche une réponse neuronale. Ce concept est essentiel dans les réseaux de neurones artificiels, car il permet de déterminer quand un neurone doit être activé en fonction de la somme pondérée des entrées. Sans fonction d'activation, le modèle ne serait qu'une simple combinaison linéaire des entrées, incapable de résoudre des problèmes complexes. En introduisant la non-linéarité, les fonctions d'activation permettent au réseau de neurones, de modéliser des relations complexes et d'apprendre des représentations abstraites des données [45, 47].

Pourquoi les fonctions d'activation sont-elles essentielles dans les réseaux de neurones ?

Les fonctions d'activation sont essentielles dans les réseaux de neurones pour plusieurs raisons fondamentales : elles ont un impact majeur sur la performance, la stabilité de l'apprentissage, la vitesse de convergence et la capacité des réseaux de neurones à capturer des schémas complexes, pour des prédictions précises. Elles transforment les données d'entrée en résultats exploitables, ce qui est nécessaire pour obtenir des prédictions fiables, conformes aux attentes du modèle [45, 46].

Par exemple, la fonction ReLU (rectified linear unit), a tendance à accélérer l'apprentissage des réseaux profonds en réduisant les problèmes de disparition du gradient [47].

Il existe plusieurs fonctions d'activations [47], dont le choix dépend de l'application. A cet effet, les fonctions d'activation les plus exploitées, sont les fonctions présentées ci-dessous :

a. Fonction identité/Rampe

C'est une fonction linéaire représentée par l'équation 2.2. La sortie S reste la même que l'entrée x . Elle est utilisée comme fonction d'activation pour la couche d'entrée.

$$S = f(x) = x, \forall x \quad 2.2$$

b. Fonction Echelon

La fonction échelon est exprimée par la relation 2.3. La sortie ne prend que deux valeurs : 0 pour un signal négatif et 1 pour un signal positif. Cette fonction n'est pas différentiable, ce qui peut poser des soucis lors de l'application du gradient.

$$f(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad 2.3$$

c. Fonction sigmoïde

Appelée aussi la fonction logistique, la sigmoïde est une fonction mathématique classique, la plus ancienne et la plus populaire (figure 2.6). C'est une fonction non-linéaire, dérivable, continue et symétrique par rapport à l'axe des y . Elle produit une courbe sigmoïde $f(x)$ définie par la formule 2.4.

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

2.4




Figure 2.6 : Fonction sigmoïde [47]

La fonction sigmoïde mappe l'entrée sur une plage comprise entre 0 et 1. Elle convient aux tâches de classification binaire. Il présente une courbe lisse en forme de S, facilitant une optimisation fluide basée sur le gradient.

d. Fonction Relu

Le fonctionnement de base de la fonction ReLU (figure 2.7) est simple : elle émet directement la valeur d'entrée si celle-ci est positive, transmet un zéro, si l'entrée est négative ou nulle. Ce simple mécanisme de seuillage (2.5), introduit une non-linéarité essentielle dans le réseau neuronal.

$$f(x) = \begin{cases} x & \text{si } x > 0 \\ 0 & \text{si } x \leq 0 \end{cases}$$

2.5




Figure 2.7 : Fonction Relu [47]

e. Fonction Tangente Hyperbolique

C'est une fonction trigonométrique dont la forme de sa courbe (figure 2.8), lui donne le privilège d'être choisie parmi les fonctions d'activations.

La seule différence entre cette fonction et la fonction sigmoïde est que Tan(h) est centrée sur le zéro. Elle produit des sorties qui sont comprises dans la plage $[-1,1]$, lui permettant de présenter une efficacité en plus, aux résultats.




Figure 2.8 : Fonction Tangente hyperbolique [47]

L'expression de cette fonction est donnée par la relation 2.6.

$$\tanh(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}}$$

2.6

f. Fonction Softmax

La fonction Softmax (2.7) permet de transformer un vecteur réel, en un vecteur de probabilités. On l'utilise souvent, dans la couche finale d'un modèle de classification, notamment pour les problèmes multiclassés.

$$f(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad 2.7$$

Où x_i est le vecteur d'entrée

2.5.4 Applications pratiques des différentes fonctions d'activation

Les différentes fonctions d'activation dans les réseaux de neurones ont une variété d'applications pratiques [45, 47], adaptées à différents types de problèmes et d'architectures de modèles. Quelques exemples d'applications pour chacune des principales fonctions d'activation sont cités ci-dessous :

1. Fonction Sigmoidale

Cette fonction est employée spécialement dans la :

- **Classification binaire** : Utilisée en couche de sortie pour produire des probabilités (entre 0 et 1) cette classification indique la classe prédictive.
- **Détection d'objets** : Peut être employée pour prédire la probabilité de présence d'un objet dans une région d'intérêt.
- **Reconnaissance de texte** : Sert à estimer la probabilité d'apparition d'un mot ou d'une entité spécifique.

2. Tanh (Tangente Hyperbolique)

Cette fonction est utilisée dans :

- **Les réseaux de neurones traditionnels** : Souvent utilisée dans les couches cachées pour introduire de la non-linéarité et normaliser les valeurs d'entrée entre -1 et 1.
- **La Reconnaissance vocale** : Utilisée pour classifier les phonèmes et les mots dans les systèmes de reconnaissance vocale.
- **Le Traitement du signal** : Appliquée à la segmentation et à la classification des signaux en médecine ou en télécommunications.

3. ReLU (Rectified Linear Unit)

Cette fonction est particulièrement abordée dans :

- **Les réseaux de neurones convolutifs (CNNs)** : Très populaire dans les couches cachées des CNNs pour l'extraction de caractéristiques visuelles en vision par ordinateur.
- **La détection d'objets** : Utilisée pour l'extraction robuste des caractéristiques et la réduction du temps de calcul dans les modèles de détection d'objets.
- **L'analyse du langage naturel** : Employée pour la classification de texte et la modélisation des sentiments grâce à sa simplicité et ses performances.

4. Softmax

Cette fonction est abordée dans :

- **La classification multi-classes** : Utilisée en couche de sortie pour normaliser les probabilités entre plusieurs classes, couramment employée dans les réseaux de classification.
- **Les systèmes de recommandation** : Permet d'évaluer et de classer les préférences des utilisateurs dans les moteurs de recommandation.
- **L'analyse des sentiments** : Utilisée pour prédire et classer les émotions à partir de textes en ligne, comme les avis clients ou les commentaires sur les réseaux sociaux.

2.5.4 Choix de la bonne fonction d'activation pour un modèle donné

Le choix de la fonction d'activation appropriée pour un modèle donné, est une décision cruciale qui peut influencer considérablement les performances et la capacité d'apprentissage du réseau de neurones [43, 47]. Plusieurs facteurs doivent être pris en compte lors de cette sélection :

Le premier critère à considérer est la nature du problème à résoudre. Chaque type de tâche (classification, régression, etc.) peut nécessiter une fonction d'activation spécifique, pour obtenir des résultats optimaux. Par exemple :

- ✚ **La fonction sigmoïde** permettant de produire des probabilités comprises entre 0 et 1, est souvent utilisée pour la **classification binaire ainsi que la régression bornée entre 0 et 1**.
- ✚ **Dans la classification multi-classes, c'est la fonction softmax** qui est privilégiée, car elle permet de normaliser les sorties sous forme de probabilités réparties sur plusieurs classes.

2.6. Architecture des réseaux de neurones

On distingue deux grandes familles des réseaux de neurones : les réseaux monocouches et les réseaux multicouches [43, 45].

2.6.1. Perceptron

Le **perceptron** représente l'architecture la plus simple des réseaux de neurones artificiels.

Il peut être comparé à une cellule unique dans un cerveau miniature, capable de prendre des décisions en se basant sur des entrées. Cet algorithme d'apprentissage automatique applique des opérations mathématiques aux données d'entrée afin de produire une sortie.

Plus précisément, le perceptron prend en entrée un vecteur de valeurs réelles, réalise une **combinaison linéaire** des entrées pondérées par des **poids attribués** à chaque attribut, puis additionne ces valeurs en un unique résultat. Ce dernier est ensuite transformé par une **fonction d'activation**, qui permet de moduler la réponse du neurone (figure 2.9).

Les perceptrons peuvent être combinés pour former des architectures plus complexes de **réseaux de neurones artificiels**, permettant ainsi de modéliser des relations non linéaires et d'améliorer les performances sur des tâches plus sophistiquées [48].




Figure 2.9 : Architecture d'un réseau neuronal monocouche [45]

2.6.2 Réseaux de neurones multicouches

Le **perceptron** représente le fonctionnement d'un neurone unique. Cependant, que se passe-t-il lorsque plusieurs perceptrons sont empilés en série et organisés en différentes couches ? Comment le modèle apprend-il dans ce cas ?

Il s'agit alors d'un **réseau de neurones multicouches feed-forward, appelé aussi, le perceptron multicouches (figure 2.10)**. Comme son nom l'indique, l'information circule dans une seule direction, de gauche à droite.

Lors de la **propagation avant** (*forward pass*), les données intègrent le modèle par la couche d'entrée, traversent une série de couches cachées, puis atteignent finalement la couche de sortie. Cette architecture du réseau de neurones est dite à **propagation avant**, car l'information ne boucle pas et ne revient pas en arrière, même avec plusieurs couches cachées.

Les couches profondes ne fournissent aucun retour (*feedback*) aux couches précédentes. Le processus d'apprentissage des **réseaux à propagation avant**, reste fondamentalement similaire, à celui du perceptron [45, 48].




Figure 2.10 : Architecture d'un réseau neuronal multicouche [48]

2.6.3 Réseaux de neurones récurrents

Les **réseaux de neurones récurrents (RNNs)** fonctionnent différemment des réseaux de neurones classiques. Dans un réseau de neurones classique, l'information circule dans une seule direction, de l'entrée vers la sortie. En revanche, dans un RNN, l'information est réinjectée dans le système après chaque étape.

Ce fonctionnement peut être comparé à la lecture d'une phrase : pour prédire le mot suivant, il ne suffit pas d'examiner uniquement le mot actuel, mais il est également nécessaire de se souvenir des mots précédents afin de formuler une prédiction plus précise.

Les **RNNs** (figure 2.11) permettent au réseau de "mémoriser" les informations passées en réutilisant la sortie d'une étape comme entrée pour l'étape suivante.

Cela permet au réseau de comprendre le **contexte** des informations déjà traitées et d'améliorer la pertinence des prédictions effectuées [41, 49].




Figure 2.11 : Réseaux de neurones récurrents [49]

2.6.4 Différence entre les RNNs et les réseaux de neurones Feed-Forward

Les **réseaux de neurones Feed-Forward (FNNs)** traitent les données dans une seule direction, de l'entrée vers la sortie, sans conserver d'information des entrées précédentes. Cette caractéristique les rend particulièrement adaptés aux tâches où les entrées sont indépendantes, comme la classification d'images. Cependant, les FNNs rencontrent des difficultés avec les **données séquentielles**, car ils ne disposent d'aucun mécanisme de mémoire.

Les **réseaux de neurones récurrents (RNNs)** surmontent cette limitation, en intégrant des **boucles de rétroaction**, permettant aux informations des étapes précédentes d'être réinjectées dans le réseau. Ce mécanisme de mémoire permet aux RNNs de conserver un **contexte**, ce qui les rend particulièrement efficaces pour les tâches nécessitant une prise en compte des séquences, comme le traitement du langage naturel ou la reconnaissance vocale [49]. La figure 2.12 représente les deux types de réseaux de neurones.




Figure 2.12 : RNNs VS FNNs [49]

2.6.4 Réseaux de neurones Convolutifs

Un réseau neuronal convolutif (CNN ou *ConvNet*) est un type de réseau neuronal artificiel, spécialement conçu pour traiter et analyser des données visuelles. Inspirés par l'organisation du cortex visuel chez les animaux, les CNNs sont particulièrement efficaces pour la reconnaissance d'images et les tâches d'analyse visuelle [50- 58].

2.6.4.1 Architecture des CNNs

Le réseau de neurones convolutif se compose de plusieurs couches ; comme la couche d'entrée (Input layer), les couches convolutives, la couche de mise en commun (pooling layer), la couche d'aplatissement (flatten layer) ainsi que les couches entièrement connectées (fully connected layers) [50, 51].




Figure 2.13 : Réseau de neurones convolutif [51]

2.6.4.2 Description des couches des CNNs

La couche convolutive applique des filtres à l'image d'entrée pour extraire les caractéristiques, la couche de 'pooling' effectue un échantillonnage en aval de l'image, pour réduire le calcul, la couche d'aplatissement transforme les données bidimensionnelles en un vecteur et la couche 'fully connected' effectue la prédiction finale. Le réseau apprend les filtres optimaux par la rétropropagation et la descente du gradient [51-58].

a. Couche de convolution

La **couche de convolution** est la composante clé des réseaux de neurones convolutifs, constituant toujours au moins, leur première couche.

La convolution fonctionne (figure 2.14) comme un filtre appliqué à une image. Dans ce cas, une petite fenêtre se déplace progressivement sur toute l'image, un peu comme si on la balayait case par case.

Au départ, cette fenêtre est placée en haut à gauche de la matrice, puis elle avance vers la droite, en sautant d'un certain nombre de cases (ce qu'on appelle le pas). Une fois qu'elle atteint le bord droit, elle descend d'un cran et recommence le même processus jusqu'à avoir couvert toute l'image [53, 54, 55].




Figure 2.14 : Schéma du parcours de la fenêtre de filtre sur l'image [55]

La couche de convolution considère les images d'entrée, en appliquant un processus de convolution à chacune d'elles, suivant différents filtres (figure 2.15). Ces filtres sont conçus pour détecter des **caractéristiques spécifiques** (*features*), que l'on souhaite identifier dans les images [54].




Figure 2.15 : Opération de convolution [54]

Pour chaque paire **image-filtre**, une **carte d'activation** (*feature map*) est générée (figure 2.16). Celle-ci met en évidence les zones de l'image, où les caractéristiques recherchées sont

présentes. Plus la valeur d'un point sur cette carte est élevée, plus cette région de l'image correspond à la caractéristique détectée [55, 56, 57].




Figure 2.16 : Carte d'activation (Feature Map) [57]

b. Couche de pooling

Les couches de pooling [50, 57], également appelées sous-échantillonnage ou sous-réseaux, sont utilisées pour réduire la dimensionnalité des cartes d'entités, tout en conservant les informations importantes. La couche de mise en commun réduit la dimensionnalité des données, en ne conservant que les caractéristiques les plus importantes, limitant ainsi le surapprentissage. Cela permet de réduire le nombre de paramètres et le risque de surapprentissage. Les couches de mise en commun les plus populaires sont notamment :

- 🌈 **Max-Pooling** : C'est la méthode de pooling la plus courante. Elle permet de diviser l'image, en sous-régions non superposées, en considérant la valeur maximale de chacune d'elle. Par exemple, dans une région 2x2, le max-pooling prendra la valeur la plus élevée des quatre pixels.
- 🌈 **Average-Pooling** qui est une autre méthode commune, où les valeurs dans chaque sous-région sont moyennées. Cette méthode est moins agressive que le max-pooling, mais conserve moins de détails.

Le pooling (figure 2.17) réduit la taille des cartes d'entités, ce qui minimise le nombre de paramètres et de calculs requis dans le réseau. Le modèle devient plus efficace (et, on ne peut pas dire assez souvent, moins susceptible de surajustement !) [57].




Figure 2.17 : Opération de pooling [57]

c. Couche ReLU

En intercalant entre les couches de convolution, une couche Relue via la fonction d'activation correspondante, le traitement des données est ainsi amélioré [57].

d. Couche de mise en commun

C'est la couche d'aplatissement qui sert à transformer une matrice de dimensions, $N \times N$ en un vecteur de $n \times 1$ [53].

e. couche fully connected

Le voyage des **pixels** dans un réseau de neurones convolutif, ne s'arrête pas à la couche de **sortie**. En effet, après avoir traversé les différentes étapes de convolution, de relu et de pooling, les données entament une autre partie importante de leur traitement : la transition vers les couches **Fully Connected** [54, 58]. Ces couches, comme leur nom l'indique, sont totalement connectées. Cela signifie que chaque **neurone** dans une couche Fully Connected (figure 2.18), est connecté à tous les neurones de la couche précédente. Le but de ces couches est de prendre en compte les caractéristiques de haut niveau apprises par les couches précédentes, pour effectuer la classification. Cette dernière permet donc, de classifier l'image en entrée du réseau, en renvoyant un vecteur de taille $N \times N$, où $N \times N$ est le nombre de classes

dans la classification d'images. Chaque élément du vecteur indique la probabilité d'appartenance à une classe, pour l'image en entrée.

La sortie de ces couches est traitée par une **fonction d'activation**. Cette fonction détermine si le neurone doit être activé ou non. Cette étape est cruciale pour la précision du réseau neuronal. Elle permet de faire la différence entre une prédiction juste et, une prédiction erronée [57].

Dans un réseau de neurones convolutifs, les couches fully connected agissent un peu comme le jury final d'un concours. Elles prennent en compte toutes les informations fournies par les précédents participants (les pixels et les caractéristiques extraites par les couches de convolution et de pooling), pour rendre leur verdict final.




Figure 2.18 : Couche fully connected [58]

2.7 Concours d'ImageNet

Le concours ImageNet est une compétition annuelle qui évalue les performances des algorithmes de vision par ordinateur, sur la tâche de classification d'images à grande échelle. Il a été créé en 2010 et est considéré comme l'un des défis, les plus prestigieux dans le domaine [59].

L'ensemble de données utilisé pour le concours est appelé ImageNet Large Scale Visual Recognition Challenge (ILSVRC). Il comprend des millions d'images, réparties en plusieurs milliers de catégories. Les participants doivent développer des modèles d'apprentissage

automatique, capables de classer correctement les images, en utilisant un ensemble d'entraînement donné.

Le concours se concentre généralement sur l'utilisation de réseaux de neurones convolutifs (CNN), en raison de leur succès, dans la tâche de classification d'images. Les participants doivent entraîner leurs modèles sur la base de données ImageNet appelé ImageNet-1K, qui contient environ 1,2 million d'images réparties en 1000 catégories [59].

Dans ce cadre, les performances des modèles sont évaluées en termes de précision de classification, c'est-à-dire la proportion d'images correctement classées.

Les modèles sont ensuite soumis au concours, pour être évalués sur un ensemble de données de test inconnu. Le gagnant du concours est généralement déterminé par la précision obtenue sur l'ensemble des données de test.

Le concours ImageNet a joué un rôle majeur dans l'avancement de la recherche en vision par ordinateur et, a permis de faire progresser considérablement les performances des algorithmes de classification d'images. De nombreux modèles et architectures de pointe, ont émergé et se sont développés grâce à ce concours. Le modèle Alexnet [60] a été le premier réseau du challenge ILSVRC, dont le principal but est la classification d'images. Il a obtenu des résultats en remportant la première place au concours ILSVRC 2012, conduisant à la renaissance de l'apprentissage profond dans le domaine de la reconnaissance d'images. AlexNet possède une structure de réseau relativement profonde, composée de 5 couches convolutives et de 3 couches entièrement connectées, avec 60 millions de paramètres et 650 000 neurones. Il utilise une série de technologies innovantes, telles que l'utilisation de la fonction d'activation ReLU pour résoudre le problème de la disparition du gradient qui peut survenir dans la fonction d'activation sigmoïde traditionnelle, ce qui permet au réseau de converger plus rapidement et d'améliorer les capacités d'expression non linéaire.

Les modèles auxquels la classification des pneumopathies infantiles, est réalisée, seront décrits dans le troisième chapitre.

2.8 Apprentissage par transfert

L'apprentissage par transfert (transfer learning) est une technique de l'apprentissage automatique, qui consiste à réutiliser un modèle pré-entraîné sur une tâche similaire, pour en résoudre une nouvelle, avec moins de données et de temps d'entraînement [58, 61].

Cette méthode consiste à entraîner le modèle sur les nouvelles données en gardant les poids des couches pré-entraînées fixés, puis à ajuster les poids de ces couches pour mieux s'adapter à la nouvelle tâche (figure 2.19).

L'apprentissage par transfert est particulièrement utile dans des scénarios où les données d'entraînement sont limitées, car il permet de tirer parti des connaissances acquises à partir de grandes quantités de données, pour améliorer les performances des modèles sur des tâches spécifiques.




Figure 2.19 : Exemple d'un modèle d'apprentissage par transfert [61]

2.9 Fine tuning dans l'apprentissage par transfert

Le fine-tuning dans l'apprentissage profond est un processus qui consiste à prendre un réseau neuronal profond pré-entraîné et, à l'adapter pour résoudre un nouveau problème, généralement lié au même domaine ou à la même tâche que l'original. Le fine-tuning est une forme d'apprentissage par transfert, qui implique la réutilisation des connaissances acquises, à partir d'une tâche ou d'un ensemble de données, pour améliorer les performances sur une autre tâche [62].

2.9.1 Fine tuning total

Lorsque la nouvelle base de données est importante, une stratégie courante consiste à remplacer la couche fully connected du modèle pré-entraîné, par un classificateur adapté au nouveau problème, initialisé de manière aléatoire. Ensuite, toutes les couches du modèle sont entraînées sur les nouvelles images.

2.9.2 Fine tuning partiel

Lorsque la nouvelle base de données est petite mais très différente de celle utilisée pour le pré-entraînement, une stratégie courante est de remplacer la dernière couche ‘fully connected’ par un nouveau classificateur initialisé de manière aléatoire, tout en fixant les paramètres de certaines couches du réseau pré-entraîné. En plus du classificateur, seules les couches non-fixées, seront entraînées sur les nouvelles données, généralement les plus hautes du réseau.

2.10 Conclusion

À travers ce chapitre, nous avons plongé dans l'univers fascinant de l'intelligence artificielle, du machine learning et du deep learning, en explorant leurs principes, leurs fonctionnements et leurs applications. Nous avons vu comment, inspirées par le cerveau humain, les machines apprennent aujourd'hui à percevoir, à raisonner et à agir avec une autonomie toujours plus impressionnante. Des concepts fondamentaux, comme le rôle crucial des fonctions d'activation ou encore la différence entre les réseaux Feed-Forward, RNNs et CNNs, montrent que derrière la complexité apparente de ces technologies, se cache une logique profondément ancrée dans l'imitation de la nature. À l'aube d'une ère où l'IA ne cesse de repousser les limites du possible, comprendre ces bases n'est plus un luxe, mais une nécessité pour mieux appréhender et façonner le monde de demain.

Ce voyage entre science et imagination, ne fait que commencer. Il continue à travers le troisième chapitre, où l'étude conceptuelle du système de classification des pneumopathies infantiles est présentée, en se focalisant sur les modèles des réseaux convolutifs sélectionnés.

Chapitre 3 Étude conceptuelle pour la catégorisation des données pneumologiques infantiles

3.1 Introduction

L'évolution fulgurante des technologies numériques, combinée à la disponibilité croissante des données médicales et à la puissance de calcul offerte par les GPU, a ouvert la voie à l'essor de l'apprentissage profond dans de nombreux domaines, notamment celui de la santé. Ce domaine, en perpétuelle quête de précision et de rapidité dans le diagnostic, bénéficie aujourd'hui grandement, de l'intégration des modèles intelligents issus du deep learning. Parmi ces modèles, les réseaux de neurones convolutifs (CNN) se sont imposés comme des outils incontournables dans le traitement et l'analyse des images médicales. Depuis l'avènement d'AlexNet en 2012 [60], ces architectures n'ont cessé d'évoluer, offrant des performances toujours plus prometteuses en matière de classification et de détection de pathologies. Le succès croissant de ces réseaux s'explique notamment par leur capacité à extraire automatiquement des caractéristiques visuelles complexes, souvent imperceptibles à l'œil humain.

Dans un contexte où l'humain est constamment exposé à des agents pathogènes et où certaines maladies peuvent évoluer rapidement, voire devenir mortelles, l'enjeu d'un diagnostic précoce devient crucial. C'est pourquoi de nombreuses recherches ont été menées, mettant à profit les techniques d'imagerie médicale, telles que : la radiographie, le scanner ou l'IRM, pour identifier différentes lésions, allant des tumeurs aux infections pulmonaires.

Ce chapitre se propose de retracer les différents modules de la quatrième version du système de catégorisation des pneumopathies infantiles, en présentant les architectures des réseaux convolutifs retenus, telles que VGG, ResNet, DenseNet, mobilenet et efficiennet, ainsi que les paramètres correspondants. Avant la présentation de l'étude conceptuelle, il est judicieux de s'intéresser à quelques travaux antérieurs, traitant de l'analyse des pathologies pulmonaires chez l'enfant, à partir d'images radiographiques.

3.2 Travaux réalisés

La classification des images radiographiques thoraciques pour la détection de la pneumonie chez les enfants, a été largement étudié dans la littérature. Plusieurs chercheurs ont proposé des approches basées sur le deep learning, en utilisant des réseaux de neurones convolutifs (CNN) pré-entraînés ou personnalisés. Cette section est consacrée à une synthèse de quelques travaux représentatifs.

Liz et al. [63], ont proposé un système intelligent de détection automatisée de la pneumonie chez l'enfant, basé sur des **modèles d'ensembles de réseaux de neurones convolutifs (CNN)**, combinés à des techniques d'**intelligence artificielle explicable (XAI)**. L'objectif est de détecter les signes radiologiques de pneumonie sur des radiographies thoraciques pédiatriques, tout en assurant l'interprétabilité des résultats.

La base de données utilisée comporte **950 radiographies** de patients âgés entre 1 mois et 16 ans, réparties en deux classes : consolidation (pneumonie alvéolaire) et non-consolidation (infiltrats non alvéolaires). Face à la petite taille de l'échantillon et à la faible qualité des images, les auteurs ont mis en œuvre une série d'étapes de **prétraitement**, notamment la normalisation, le redimensionnement (150 × 150 pixels), et une **augmentation de données** (rotation, translation, zoom, etc.) afin d'éviter le sur-apprentissage. Plusieurs architectures de CNN (avec 3 à 4 couches convolutives) ont été testées, avec des fonctions d'activation ReLU, et un dropout de 70 %. Les modèles ont été entraînés à l'aide de l'**optimiseur Adam** (taux d'apprentissage de 1e-4). La meilleure architecture (nommée Arch1) a été comparée au modèle de référence **CheXNet**, basé sur DenseNet121. Les performances ont été évaluées en termes de **AUC** (aire sous la courbe ROC) et de **TPR** (taux de vrais positifs). Les résultats selon le tableau 3.1, montrent que le **modèle d'ensemble (formé de 5 CNNs)** surpasse à la fois CheXNet et les modèles individuels.

Modèle	AUC	TPR
CheXNet	0.76	0.43
CNN (Arch1)	0.80	0.65
Ensemble CNN	0.89	0.72

Tableau 3.1 : Résultats obtenus par Helena Liz et al [63]

Pour renforcer l'explicabilité, les zones de l'image considérées comme les plus importantes par le modèle, ont été visualisées par les cartes thermiques (heatmap). Ces visualisations ont permis de repérer avec précision les régions suspectes dans les poumons, facilitant ainsi l'interprétation clinique.

Les auteurs ont également testé leur approche sur la base de données 'Chest X-ray' de **Kermany et al. [64]**, qui comprend 5856 radiographies pédiatriques. L'ensemble CNN a atteint un **AUC de 0.976 et un TPR de 1.0**, surpassant les résultats de l'étude de Kermany (AUC = 0.968, TPR = 0.932), démontrant ainsi la **robustesse et la généralisation** de la méthode.

Liang et al. [65], ont proposé une **méthode de diagnostic automatisé de la pneumonie infantile**, en combinant l'**apprentissage profond** avec les **réseaux de neurones résiduels profonds (ResNet)** et la **convolution dilatée**, dans une logique d'apprentissage par **transfert de connaissances**. L'approche s'appuie sur la capacité de ces réseaux à extraire efficacement les **caractéristiques texturales** pertinentes à partir d'images radiographiques thoraciques pédiatriques. Le modèle proposé est formé sur la **base de données pneumologiques annotées par Kermany et al.**, comprenant **5 856 radiographies** (1-5 ans), avec des classes équilibrées (normales et pneumonies). Le réseau convolutif résiduel comporte **49 couches convolutives**, une **convolution dilatée** pour préserver la résolution spatiale, une normalisation par batch, ainsi qu'un **dropout de 50 %** pour éviter le sur-apprentissage. L'architecture est optimisée à l'aide de l'**optimiseur Adam**, avec un taux d'apprentissage adaptatif. Les performances ont été mesurées sur un ensemble de test dédié à la détection de pneumonie pédiatrique (tableau 3.2).

Modèle	Justesse	Précision	Rappel	F1-score	AUC
VGG16	0.742	0.723	0.951	0.822	0.840
DenseNet121	0.819	0.792	0.964	0.869	0.769
InceptionV3	0.853	0.916	0.841	0.877	0.655
Xception	0.878	0.857	0.967	0.908	0.930
Méthode proposée par Liang et al	0.905	0.891	0.967	0.927	0.953

Tableau 3.2 : Résultats obtenus par Liang et al [65]

Jain et al. [66], ont développé une approche comparative pour la **détection automatique de la pneumonie** à partir de radiographies thoraciques, en utilisant plusieurs **modèles de réseaux de neurones convolutifs (CNN)**, y compris des **modèles pré-entraînés via le Transfer Learning**.

Six modèles ont été entraînés sur la base de données 'Chest X-Ray', qui comprend **5 216 images d'entraînement** et **624 images de test**. Les modèles 1 et 2 sont des architectures CNN personnalisées composées respectivement de deux et trois couches convolutives, tandis que les quatre autres sont des réseaux bien connus représentés par : **VGG16, VGG19, ResNet50 et Inception-v3**.

Les paramètres d'apprentissage comprennent : une fonction de coût **basée sur l'entropie**, l'optimiseur Adam avec un taux **d'apprentissage variable** (de 0.001 à 0.000001), et l'utilisation d'un **dropout** de 50 %, pour éviter le sur-apprentissage. Les résultats des performances obtenues dans cette étude, sont présentés par le tableau 3.3.

Modèle	Accuracy	Recall	F1-score
Modèle 1	0.8526	0.94	0.89
Modèle 2	0.9231	0.98	0.94
VGG16	0.8728	0.96	0.91
VGG19	0.8846	0.95	0.92
ResNet50	0.7756	0.97	0.86
Inception-v3	0.7099	0.84	0.77

Tableau 3.3 : Résultats obtenus par Jain et al [66]

Le **modèle 2** et **VGG19** ont généré les meilleurs résultats globaux, avec un bon équilibre entre le rappel et la précision. L'étude montre que des architectures CNN simples, peuvent rivaliser avec des modèles plus profonds, lorsqu'elles sont bien calibrées.

Raghaw et al [67], ont introduit un modèle hybride XCCNet (Explainable Contrastive-based CNN with Transformer) combinant : des convolutions dilatées pour capturer des patterns à différentes résolutions, des 'transformers' pour la capture de relations globales, un module d'explicabilité (par attention visuelle) et une augmentation de données, pour équilibrer les classes minoritaires.

L'étude a montré d'excellents résultats accordés par une précision globale (accuracy) de 96,8 % (supérieure à ResNet, EfficientNet et DenseNet sur le même jeu de données), une aire sous la courbe AUC de 98%, confirmant une excellente capacité de classification, un F1-score de 95%, une sensibilité de 96.2% et une spécificité de 97.2%.

Dans les travaux des laboratoires LATSI et LRDSI de l'université de Blida 1, trois types de systèmes d'aide au diagnostic de pneumopathologies infantiles, ont été réalisés et adaptés à la base 'chest-X ray', via divers réseaux de neurones pré-entraînés.

Dans le premier projet [68], le système PnuemoCNN1, a permis de classifier des pathologies oncologiques et des pneumopathies infantiles.

La première est implémentée pour classer les images tomodensitométriques en deux catégories, maligne et bénigne alors que la deuxième, sert à catégoriser les radiographiques thoraciques, en classe normale et en pneumopathie, selon les modèles VGG16, VGG19 et un réseau convolutif personnalisé. L'approche adoptée pour l'analyse des pneumopathies, montre son efficacité avec une précision de 98.5%, l'aire sous la courbe ROC, de 98%, une sensibilité de 92% et un taux de perte de 5% après 25 itérations.

Dans la seconde étude [69], le système développé pour la classification des pneumopathies infantiles, est basé également sur trois modèles des réseaux convolutifs pré-entraînés, le VGG16, le VGG19 et le Resnet50, différant de l'approche précédente, au niveau du fine tuning. Cette réalisation a montré des résultats, dépassent les 97% en termes de précision, sur les différents modèles de CNN explorés.

La troisième étude [70] expose également la classification des radiographies pneumologiques infantiles, en deux classes : normale et pathologique. L'approche proposée est mise en œuvre par des CNNs pré-entraînés : le ResNet50, le DenseNet121 et le DenseNet201, afin d'effectuer une classification binaire (pneumonie et normale), pour une aide à l'interprétation.

Les résultats expérimentaux montrent une précision de 98%, un rappel de 96 %, et une AUC de 98 %. Comparativement à l'état de l'art, ces résultats confirment que le système implanté, est fiable dans la tâche de classification des pneumopathies infantiles.

3.3 Conception de système "PneumoCNN 4"

Dans le cadre de ce mémoire, nous proposons une solution basée sur l'apprentissage profond, une quatrième variante PneumoCNN4, pour la catégorisation automatique des données pneumologiques infantiles. Ce système (figure 3.1) repose sur le développement de 8 modèles convolutifs (CNN) accordés par un fine tuning sur : Resnet50, Resnet101, VGG16, VGG19, Densenet121, Densenet201, EfficiennetB0, ainsi que mobilenetV2. Ces modèles ont prouvé leur efficacité, dans la reconnaissance d'images médicales [71-74].




Figure 3.1 : Schéma synoptique du système "PneumoCNN 4"

Les architectures choisies sont modifiées, en remplaçant leurs dernières couches par un nouveau classifieur adapté, aux classes de la base de données étudiée. Ces modèles sont affinés suivant le fine tuning.

3.3.1 Base de données

Le système repose sur une base de données constituée d'**images radio-thoraciques** d'enfants âgés de **moins de cinq ans**. Cette base contient des images radiographiques pulmonaires (figure 4.2), en format JPEG, suivant la vue antéropostérieure des patients infantiles, issues du centre médical 'Guangzhou' pour femmes et enfants en Chine [64].

Cet ensemble de données se compose de 5856 images radiographiques, thoraciques séparées en deux classes : pneumonie et normale. Au total, la base comprend 1583 images pour la classe « Normale » et 4273 images pour la classe « Pneumonie ». Cette population cible (enfants < 5 ans) est particulièrement vulnérable aux affections pulmonaires, ce qui rend la classification précoce à l'aide de l'IA, à la fois pertinente et bénéfique sur le plan médical.

3.3.2 Préparation des données

La qualité et la pertinence des données jouent un rôle central, dans la réussite d'un système d'aide au diagnostic. Dans le cadre de la détection de la pneumonie à partir d'images médicales (radiographies thoraciques), la préparation des données constitue une étape déterminante qui permet d'améliorer la performance, la robustesse et la capacité de généralisation du modèle. Cette étape comporte plusieurs sous-processus essentiels dont, la distribution du jeu de données, la normalisation des images ainsi que leur redimensionnement, l'augmentation des données et l'équilibre des classes.

3.3.2.1 Organisation du jeu de données

Le jeu d'images est généralement structuré en deux dossiers correspondant aux deux classes : normale et pneumonie. Chaque image doit être soigneusement étiquetée en fonction de sa classe, afin de permettre au modèle d'apprendre à distinguer les caractéristiques propres à chaque catégorie.

Le jeu de données est alors réparti en trois sous-ensembles distincts :

- 🌈 **Un Jeu d'entraînement** (training set) pour entraîner le modèle.

✚ **Un Jeu de validation** (validation set) pour ajuster les hyperparamètres et, évaluer la performance pendant l'entraînement.

✚ **Jeu de test** (test set) : utilisé uniquement pour évaluer la performance finale du modèle.

Dans le cadre de l'étude réalisée, une répartition typique est donc de 70% pour l'entraînement, 15% pour la validation et 15% pour le test.

3.3.2.2 Augmentation des données (Data Augmentation)

Les données médicales et en particulier, les radiographies thoraciques, sont souvent disponibles en quantité limitée.

L'augmentation des données [71, 74, 75] permet d'enrichir artificiellement le jeu d'entraînement, en générant de nouvelles images, à partir de transformations appliquées aux images existantes. Cela aide à réduire le risque de surapprentissage (overfitting), tout en rendant le modèle plus robuste face aux variations naturelles des images.

Il est crucial de choisir des transformations biologiquement plausibles, afin de ne pas dénaturer le contenu médical de l'image. Dans le cas de cette étude, la sélection s'est faite suivant, une rotation légère, un renversement horizontal, une translation légère et un ajustement du contraste.

- a. **Une rotation légère** de 5 à 10° est appliquée sur l'image, afin de ne pas affecter le contenu de l'image. Elle permet de jouer sur les angles de prise de vue.
- b. **Un renversement horizontal** : permet de généraliser l'apparence des poumons gauche et droit.
- c. **Un zoom ou une translation légère** autour de (1.0 à 1.2×), simule un léger changement de cadrage, pour ne pas déformer les structures anatomiques.
- d. **Une translation** de l'image d'un léger décalage de position du thorax, permet de déplacer l'image horizontalement ou verticalement, sans affecter l'anatomie.
- e. **Un ajustement du contraste ou de la luminosité** permet de simuler des conditions d'éclairage différentes.

3.3.2.3 Normalisation

Les images médicales sont souvent encodées avec des valeurs de pixels, variant entre 0 et 255. La normalisation consiste à ramener ces valeurs dans une plage plus restreinte, typiquement entre 0 et 1 ou entre -1 et 1, ce qui facilite le traitement par les réseaux de neurones. Cette étape a pour but de garantir que toutes les images soient traitées sur la même échelle, évitant ainsi que certaines caractéristiques dominent l'apprentissage, uniquement en raison de leur amplitude numérique [71, 74].

3.3.2.4 Redimensionnement des images

Les réseaux de neurones convolutifs exigent des images d'une taille fixe [71, 74]. Il est donc nécessaire de redimensionner toutes les images à une dimension standard (par exemple 224×224 pixels), tout en conservant autant que possible les proportions anatomiques. Ce redimensionnement permet de traiter les images par lot (batch) et de garantir une entrée cohérente au réseau.

3.3.2.5 Équilibre des classes

Dans le cas où le nombre d'images est déséquilibré entre les deux classes (par exemple, beaucoup plus d'images de pneumonie que d'images normales), il est important de prendre des mesures pour équilibrer les données. Cela peut se faire par :

- Sur-échantillonnage de la classe minoritaire (réplication ou augmentation)
- Sous-échantillonnage de la classe majoritaire
- Utilisation de techniques de pondération pendant l'entraînement

Un bon équilibre permet au modèle de ne pas devenir biaisé envers la classe majoritaire [71, 76]. C'est le sur-échantillonnage de la classe minoritaire qui est prise en considération, dans le cas de notre étude.

3.3.3 Architectures des réseaux de neurones explorés

L'étape d'entraînement repose sur l'utilisation de plusieurs **architectures CNN pré-entraînées** sur ImageNet (présentation vue dans le second chapitre), adaptées ensuite à notre tâche par transfert d'apprentissage suivant un fine-tuning partiel [74]. Ces modèles ont été choisis pour

leur complémentarité en termes de profondeur, de taille et de capacité de généralisation. Les différentes modifications sur les couches fully-connected, seront exposées dans le dernier chapitre, qui est dédié à la mise en œuvre du système.

3.3.3.1 VGG16

VGG16 est un type des réseaux CNN, considéré comme l'un des meilleurs modèles de la vision par ordinateur à ce jour. Les créateurs de ce modèle [77], ont évalué les réseaux et augmenté la profondeur en utilisant une architecture avec des filtres à convolution de taille (3 x 3), ce qui a montré une amélioration significative par rapport aux configurations de l'état de la technique. Ils ont poussé la profondeur à 16–19 couches, ce qui en fait environ 138 millions de paramètres d'apprentissage.

VGG16 est un algorithme de détection et de classification d'objets capable de classer 1000 catégories différentes issues de la base Imagenet, avec une précision de 92,7 %. C'est l'un des algorithmes les plus utilisés pour la classification d'images, facile à utiliser avec l'apprentissage par transfert [78].

Le réseau VGG16 (figure 3.2) fait référence aux 16 couches, comprenant treize couches convolutives avec des filtres de 3x3 et, trois couches denses.

L'architecture détaillée de VGG16 (figure 3.3) comprend cinq blocs de couches de convolution, suivis de trois couches entièrement connectées.

Chaque bloc convolutif est suivi d'un regroupement maximal avec une fenêtre de 2x2, alors que chaque convolution est suivie d'une fonction 'Relu'. Trois couches entièrement connectées (FC) se succèdent aux blocs précédents (qui ont une profondeur différente dans différentes architectures). Chacune des deux premières couches comprenant 4096 neurones, est suivie par une couche 'Relu'. La couche finale est la couche soft-max, qui catégorise les 1000 classes.




Figure 3.2 : Architecture du VGG 16 [78]



Figure 3.3 : VGG 16 [78]

3.3.3.2 VGG 19

Le modèle VGG19 est basé sur le modèle VGG16, à l'exception qu'il supporte 19 couches. Les nombres « 16 » et « 19 » font référence aux couches convolutionnelles. Par rapport à VGG16, VGG19 contient trois couches convolutives supplémentaires [77, 79].

Le modèle VGG-19 se compose de 16 couches convolutives et 3 couches entièrement connectées (figure 3.4). L'architecture suit un schéma simple et répétitif, ce qui facilite sa compréhension et son application [80].




Figure 3.4 : Architecture du VGG 19 [80]

3.3.3.3 ResNet

Le modèle Residual Network a été lancé par les experts de Microsoft Research en 2015 avec la proposition de ResNet [81].

L'idée des blocs résiduels (figure 3.5) a été créée par cette conception pour traiter le problème du gradient de disparition. Une méthode connue sous le nom de connexions sautées dans ce réseau, y est appliquée. La connexion de saut contourne certains niveaux entre les activations des couches de liaison aux couches suivantes. Cela crée un bloc restant. Ces blocs restants sont empilés pour générer des 'resnets'.

La stratégie derrière ce réseau, est de laisser le réseau s'adapter à la cartographie résiduelle, plutôt que d'avoir des couches, apprendre la cartographie sous-jacente [82].

Ce réseau facilite l'apprentissage en ajoutant les connexions résiduelles. Dans ce cadre la sortie résiduelle y est déterminée suivant l'équation 3.1.

$$y = F(x) + x \quad 3.1$$

Où : $F(x)$ est la transformation (résiduelle) et x l'entrée initiale (skip connection).




Figure 3.5 : Bloc résiduel [81]

a. Architecture de Resnet50

Le modèle Resnet50 présente la structure du tableau 3.4.

Étape	Couches	Nombre de blocs
Entrée	Image 224×224×3	
Conv1	7×7, 64, stride 2 + MaxPool 3×3, stride 2	1
Conv2_x	1×1, 64 → 3×3, 64 → 1×1, 256 (×3 blocs)	3
Conv3_x	1×1, 128 → 3×3, 128 → 1×1, 512 (×4 blocs)	4
Conv4_x	1×1, 256 → 3×3, 256 → 1×1, 1024 (×6 blocs)	6
Conv5_x	1×1, 512 → 3×3, 512 → 1×1, 2048 (×3 blocs)	3
Sortie	Average Pool + FC (Dense 1000 classes pour imagenet)	-

Tableau 3.4 : Structure du réseau resnet50 [82]

b. Architecture de Resnet101

Le réseau resnet101 (tableau 3.5) présente la même structure, avec plus de blocs dans Conv4_x.

Étape	Couches	Nombre de blocs
Entrée	Image $224 \times 224 \times 3$	
Conv1	7×7 , 64, stride 2 + MaxPool 3×3 , stride 2	
Conv2_x	1×1 , 64 $\rightarrow$ 3×3 , 64 $\rightarrow$ 1×1 , 256 ($\times 3$ blocs)	3
Conv3_x	1×1 , 128 $\rightarrow$ 3×3 , 128 $\rightarrow$ 1×1 , 512 ($\times 4$ blocs)	4
Conv4_x	1×1 , 256 $\rightarrow$ 3×3 , 256 $\rightarrow$ 1×1 , 1024 ($\times 23$ blocs)	23
Conv5_x	1×1 , 512 $\rightarrow$ 3×3 , 512 $\rightarrow$ 1×1 , 2048 ($\times 3$ blocs)	3

Tableau 3.5 : Structure du réseau resnet101 [82]

Où Conv_x désigne un groupe de blocs résiduels.

Les **ResNet-50** et **ResNet-101** utilisent des **blocs bottleneck** (3 couches par bloc). Chacun de ces blocs présente une convolution de 1×1 , une convolution de 3×3 et une convolution de 1×1 .

3.3.3.4 MobileNet

MobileNet est une architecture (figure 3.6) du réseau neuronal convolutif (CNN), conçue pour des modèles d'apprentissage profond efficaces et légers. Le principal objectif de MobileNet est de fournir une solution pour l'exécution des réseaux neuronaux profonds sur les appareils à ressources limitées, tels que, les téléphones mobiles, les systèmes embarqués et d'autres appareils à faible puissance [73, 83].




Figure 3.6 : Architecture du MobileNet [83]

L'idée clé de MobileNet est d'utiliser des convolutions séparables au sens inverse (depthwise), plutôt que les convolutions traditionnelles, afin de réduire la complexité du calcul et la taille du modèle.

Les convolutions séparables en sens inverse divisent l'opération de convolution standard, en deux opérations distinctes : une convolution en sens inverse et une convolution ponctuelle (pointwise) [83].

Le tableau 3.6 expose les différents paramètres de mobilenetV2.

Type / Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5×	Conv dw / s1	$3 \times 3 \times 512$ dw
	Conv / s1	$1 \times 1 \times 512 \times 512$
Conv dw / s2	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw / s2	$3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool 7×7	$7 \times 7 \times 1024$
FC / s1	1024×1000	$1 \times 1 \times 1024$
Softmax / s1	Classifier	$1 \times 1 \times 1000$

Tableau 3.6 : Modèle de mobilenetV2 [83]

3.3.3.5 DenseNet

DenseNet (Dense Convolutional Network) est une architecture qui vise à rendre les réseaux d'apprentissage profond encore plus profonds, mais en même temps à les rendre plus

efficaces pour s'entraîner, en utilisant des connexions plus courtes entre les couches. DenseNet est un réseau neuronal convolutif, où chaque couche est reliée à toutes les autres couches qui sont plus profondes dans le réseau, c'est-à-dire que la première couche est reliée à la deuxième, troisième, quatrième et ainsi de suite, la seconde couche est reliée à la troisième, quatrième, cinquième et ainsi de suite. Ceci est fait pour permettre le maximum de flux d'informations entre les couches du réseau.

DenseNet se compose de deux blocs importants autres que les couches convolutives et de regroupement de base, à savoir les blocs denses et les couches de transition [73, 84].




Figure 3.7 : Architecture du modèle DenseNet [84]

Dans l'approche étudiée, deux réseaux Densenet sont considérés : le Densenet121 (figure 3.8) et le Densenet201 (figure 3.9).

a. Structure de Densenet121

La structure du modèle Densenet121 est dressée par le tableau 3.7.

Couches	Description
Couche d'entrée	Conv7×7 (stride=2) + MaxPool3×3 (stride=2)
Bloc dense 1	6 couches convolutives
Couche de transition 1	1×1 conv + AvgPool (stride=2)
Bloc Dense 2	12 couches convolutives

Couche de transition 2	1×1 conv + AvgPool
Bloc Dense 3	24 couches convolutives
Couche de transition 3	1×1 conv + AvgPool
Bloc Dense 4	16 couches convolutives
Couche finale	Global Average Pooling + Fully Connected Layer (classification)

Tableau 3.7: Structure de densenet121 [84]

Chaque "couche" dans un bloc dense est en réalité un bloc de 2 convolutions : une convolution de 1×1 (bottleneck) et une convolution de 3×3 .

b. Structure de Densenet201

DenseNet-201 suit la même architecture que DenseNet-121, mais avec plus de couches dans chaque bloc dense (tableau 3.9).

Étape	Détail technique	Nombre de couches
Conv initiale	Conv 7×7, stride=2 + MaxPool 3×3, s=2	1
Bloc Dense 1	Blocs densément connectés	6
Couche de transition 1	1×1 Conv + AvgPool	1
Bloc Dense 2	Blocs densément connectés	12
Couche de transition 2	1×1 conv + AvgPool	1
Bloc Dense 3	Blocs densément connectés	48
Couche de transition 3	1×1 conv + AvgPool	1
Bloc Dense 4	Blocs densément connectés	32
Global Avg Pooling + FC	Global Average Pooling + Fully Connected Layer (classification)	1

Tableau 3.9 : Structure du réseau Densenet201 [84]

Les modèles DenseNets présentent plusieurs avantages convaincants :

- Ils atténuent le problème du gradient de fuite.
- Ils renforcent la propagation des caractéristiques.
- Ils réduisent considérablement le nombre de paramètres.

3.3.3.6 EfficientNet

EfficientNet est un réseau neuronal convolutif basé sur un concept appelé « échelle composée ». Ce concept aborde le compromis de longue date entre la taille du modèle, la précision et l'efficacité du calcul. L'idée derrière la mise à l'échelle des composés, est d'évaluer trois dimensions essentielles d'un réseau de neurones : la largeur, la profondeur et la résolution.

EfficientNet utilise des couches 'Mobile Inverted Bottleneck (MBConv)', qui sont une combinaison de convolutions séparables en profondeur et de blocs résiduels inversés.

De plus, l'architecture du modèle utilise l'optimisation Squeeze-and-Excitation (SE) pour améliorer encore les performances du modèle.

La couche MBConv est un élément fondamental de l'architecture EfficientNetB0 (figure 3.8). Cet élément s'inspire des blocs résiduels inversés de MobileNetV2, mais avec quelques modifications [73, 85].




Figure 3.8 : Architecture du réseau EfficientNetB0 [85]

3.3.4 Classification

Une fois le modèle entraîné, il est capable de prédire automatiquement la catégorie clinique d'une image en entrée. La sortie du réseau prend la forme d'un vecteur de probabilités à travers la fonction d'activation softmax, représentant la confiance du modèle pour chaque classe. La classe avec la probabilité maximale, est choisie comme prédiction finale.

3.4 Optimisation & Paramètres d'entraînement du système

L'optimisation est une étape essentielle dans la conception et l'entraînement d'un modèle d'apprentissage profond. Elle vise à minimiser une fonction de perte, en ajustant les paramètres internes (poids et biais) du réseau neuronal à l'aide d'un algorithme d'optimisation [74, 76]. Dans ce travail, plusieurs techniques sont combinées pour améliorer la performance, la stabilité et la généralisation du système **PneumoCNN4**.

3.4.1 Fonction coût

L'**entropie croisée catégorique** est une fonction de perte (loss function) largement utilisée en **classification multi-classes** dans le deep learning. Elle mesure la différence entre la distribution de probabilités prédite par un modèle et la distribution réelle des classes (3.2). Son objectif est de maximiser la probabilité attribuée à la classe correcte, tout en pénalisant les mauvaises prédictions.

$$L(y, \hat{y}) = - \sum_{i=1}^C y_i \log(\hat{y}_i) \quad (3.2)$$

Où : y_i représente la vraie classe, $\hat{y}$ est la probabilité prédite pour la classe (i) et (C) est le nombre total de classes. Cette fonction est souvent utilisée avec **Softmax**, qui normalise les probabilités des sorties du modèle. Plus une prédiction est éloignée de la vérité, plus la pénalité est forte, ce qui permet au modèle d'apprendre efficacement à distinguer les différentes classes [73, 86, 87].

3.4.2 Optimiseur Adam

L'optimisateur **Adam** (Adaptive Moment Estimation) est une méthode d'optimisation utilisée en apprentissage automatique, notamment pour l'entraînement des réseaux de neurones. Il combine les avantages de deux autres techniques : **Momentum** et **RMSprop** (Root Mean Square Propagation), ce qui lui permet d'ajuster dynamiquement le taux d'apprentissage pour chaque paramètre [71, 74, 88].

Adam ajuste les poids à chaque itération en utilisant **deux estimations** :

- ✚ **1er moment (m)** : la moyenne des gradients (comme un effet de *momentum*) pour accélérer la descente de gradient et réduire les oscillations.
- ✚ **2e moment (v)** : la moyenne des **carrés** des gradients (variance) pour éviter ainsi des mises à jour trop brusques ou trop lentes.
- ✚ **Correction du biais** : Comme les estimations initiales des moments sont biaisées vers zéro, Adam applique une correction pour améliorer la stabilité de l'optimisation.

Grâce à ces caractéristiques, Adam est particulièrement efficace pour les modèles complexes et les grands ensembles de données, car il est **mémoire-efficace** et **s'adapte automatiquement** aux variations des gradients [88].

3.4.3 Couche Dropout

La couche **Dropout** permet de **réduire le surapprentissage (l'overfitting)** lors de l'entraînement du modèle. Le terme « Dropout » fait référence à la **suppression de neurones**, dans les couches d'un modèle du **Deep Learning** [74].

En fait, on **désactive temporairement** certains neurones dans le réseau, ainsi que **toutes ses connexions** entrantes et sortantes (figure 3.10).




Figure 3.9 : Réseau de Neurones Standard [88]




Figure 3.10 : Après avec Dropout

Le choix des neurones à désactiver est **aléatoire**. On attribue **une probabilité p** à tous les neurones qui **détermine leur activation**. Lorsque $p = 0.1$, **chaque neurone a une chance sur 10 d'être désactivé**.

À **chaque itération**, on applique cette désactivation aléatoire. C'est-à-dire qu'à chaque propagation avant (forward propagation), le modèle apprendra avec **une configuration de neurones différentes**, les neurones s'activant et se désactivant **aléatoirement** [73, 88].

3.4.4 Paramètres d'entraînement

Les paramètres d'entraînement des données utilisés dans la réalisation d'un modèle de réseau de neurones [72, 74], sont accordés par :

- ✚ **Batch (lot)** : Le lot représente un seul échantillon de la base des données.
- ✚ **Batch-Size** : La taille du lot est le nombre d'échantillons avec lesquels, les entrées du réseau de neurones sont alimentées en un seul pas.
- ✚ **Learning rate** : Le taux d'apprentissage est un paramètre très important utilisé dans l'optimiseur, pour indiquer la taille du pas. Ce taux d'apprentissage est généralement réglé entre 0,01 et 0,0001.
- ✚ **Epoch** : Epoch représente le cycle de passage de tous les échantillons de la base de données, à travers le réseau de neurones dans le processus de d'entraînement.

✚ **Pas par 'epoch'** : il correspond au nombre de la taille du lot pendant une époque. Il est calculé en divisant la longueur de l'ensemble de données, par la taille du lot utilisée.

3.5 Métriques d'évaluation

Plusieurs métriques issues de la théorie de la classification supervisée, permettent d'évaluer la performance des différents modèles de la classification d'images pneumologiques. Ces métriques estiment la capacité du modèle à prédire correctement les classes pathologiques à partir des données d'entrée [72, 86].

3.5.1 Exactitude

L'exactitude (Accuracy) est une mesure fondamentale qui évalue les performances d'un modèle de classification, montrant la façon dont le modèle fonctionne en termes de prévisions correctes. Ce paramètre est calculé par le rapport entre les prédictions correctes et le nombre total d'échantillons d'entrée (3.2).

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$$

(3.2)

Où : TP = vrai positif ; FP = faux positif ; TN = vrai négatif ; FN = faux négatif.

- ✚ **Vrais positifs (TP)** : cas bien classés comme positifs,
- ✚ **Faux positifs (FP)** : cas faussement classés comme positifs,
- ✚ **Faux négatifs (FN)** : cas faussement classés comme négatifs,
- ✚ **Vrais négatifs (TN)** : cas bien classés comme négatifs.

3.5.2 Aire sous la courbe (AUC)

La courbe AUC (Area Under the Curve) fait référence à l'aire sous la courbe ROC (Receiver Operating Characteristic), un outil clé pour évaluer les performances d'un modèle de classification binaire.

La courbe ROC indique le taux des vrais positifs (fraction des positifs qui sont effectivement détectés) en fonction du taux des faux positifs (fraction des négatifs qui sont incorrectement détectés), pour plusieurs seuils de classification.

L'AUC est la surface sous la courbe ROC. Elle donne une valeur unique qui résume la performance du modèle sur tous les seuils possibles [86]. Plus la valeur de l'AUC est élevée, meilleure est la performance du modèle.

1. Taux de vrais positifs (TPR)

Appelé aussi sensibilité, le taux de vrais positifs (3.3) correspond aux vrais positifs correctement classés. C'est le rapport entre les instances positives correctement prédites et le total des instances positives réelles [63]. Ce paramètre est déterminé par l'équation 3.3.

$$\text{TPR} = \text{TP} / (\text{TP} + \text{FN}) \quad (3.3)$$

2. Taux de vrais négatifs (TNR)

Appelé spécificité, le taux de vrais négatifs, correspond aux vrais négatifs correctement classés. Ce paramètre est déterminé par l'équation 3.4.

$$\text{TNR} = \text{TN} / (\text{TN} + \text{FP}) \quad (3.4)$$

3. Taux de faux positifs (FPR)

Le taux de faux négatifs correspond à la proportion de positifs réels qui sont mal identifiés comme négatifs.

$$\text{FPR} = \text{FP} / (\text{FP} + \text{TN}) \quad (3.5)$$

3.5.3 Précision

La précision (3.6) est une mesure de la performance d'un modèle, qui indique le taux des prédictions positives correctement classées [86].

$$\text{Précision} = \text{TP} / (\text{TP} + \text{FP}) \quad (3.6)$$

3.5.4 F1 Score

F1-Score est une moyenne harmonique entre le rappel et la précision. Sa plage est de [0,1]. Cette métrique indique à quel point le classificateur est précis (classe correctement le nombre d'instances) et robuste (ne manque aucun nombre important d'instances).

Un rappel plus faible et une précision plus élevée, présentent une grande exactitude, mais alors il manque un grand nombre d'instances. Plus le score F1 est élevé, meilleure sera la performance. Il peut être exprimé mathématiquement de la façon suivante :

$$F1 = 2 * [1 / (\text{precision} + \text{recall})] \quad (3.7)$$

3.5.5 Matrice de confusion

La matrice de confusion crée une matrice $N \times N$, où N est le nombre de classes ou de catégories qui doivent être prévues. C'est une matrice (tableau 3.9) présentant les classes désirées (lignes) et les classes obtenues (colonnes), pour l'échantillon. La matrice de confusion est un tableau à double entrée qui compare les prédictions du modèle aux valeurs réelles. Elle constitue la base pour le calcul de nombreuses autres métriques [71, 86].

Sur la diagonale principale, se trouve donc les valeurs bien classées, hors diagonale les éléments mal classés.

		<i>Reality</i>	
Confusion matrix		Negative : 0	Positive : 1
<i>Prediction</i>	Negative : 0	True Negative : TN	False Negative : FN
	Positive : 1	False Positive : FP	True Positive : TP

Tableau 3.9 : Matrice de confusion [71]

3.6 Conclusion

Ce chapitre a exploré les différentes facettes théoriques de la conception du système "PneumoCNN 4", dédié à la classification automatique des pneumopathies infantiles à partir d'images radiographiques.

Nous avons mis en lumière l'importance des réseaux de neurones convolutifs (CNNs) à travers leurs différents paramètres de fonctionnement, qui, grâce à leurs performances exceptionnelles en classification d'images, se révèlent être des outils précieux dans le domaine médical, notamment dans la détection précoce de maladies pulmonaires chez les enfants. Ce système, structuré de manière modulaire, intègre des processus de préparation et de transformation des données, garantissant une préparation optimale pour l'apprentissage des modèles.

Le chapitre suivant explore la mise en œuvre du système proposé, suivant les résultats obtenus pour chacun des modèles étudiés ainsi que leur interprétation.

Chapitre 4 Mise en œuvre du système PneumoCNN4

4.1 Introduction

Ce chapitre présente l'implémentation du système PneumoCNN4, développé pour la classification des pathologies pulmonaires infantiles à partir de la base de données chinoise 'chest-X ray. Il s'appuie sur l'utilisation de réseaux convolutifs pré-entraînés, dans le cadre de l'apprentissage par transfert. L'environnement de travail, les outils mobilisés ainsi que les résultats obtenus et leurs performances, suivis de leur interprétation y sont exposés.

4.2 Environnement de travail

Le système PneumoCNN4 a été réalisé sous environnement anaconda 3, où les codes ont été développés dans le langage python.

4.2.1 Matériel utilisé

Ce travail a été réalisé à l'aide d'un ordinateur de bureau DESKTOP-EURODF, fonctionnant sous Windows 11 Professionnel 64 bits (10.0, build 26100). L'unité centrale de traitement est un AMD Ryzen 5 5600G with Radeon Graphics (12 CPUs), ~3.9GHz. Le système dispose d'une capacité de mémoire vive de 16GB RAM. Le rendu graphique a été assuré par une carte graphique 'AMD Radeon (TM) Graphics', avec environ 8328 MB de mémoire graphique totale.

4.2.2 Langage de programmation

Le langage de programmation le plus utilisé dans le deep learning, est sans conteste Python. Sa popularité s'explique par sa simplicité, la richesse de son écosystème de bibliothèques et l'immense communauté qui le soutient. Python [90] est devenu la norme pour la recherche, le développement et le déploiement de modèles d'intelligence artificielle.

a. Anaconda

Anaconda est une distribution qui héberge des paquets Python essentiels, des outils comme Jupyter et RStudio et un gestionnaire de paquets appelé Conda. Cela simplifie la

gestion et le déploiement de paquets, pour les sciences des données, l'apprentissage automatique et l'informatique [91].

b. Jupyter

JupyterLab est le tout dernier environnement de développement interactif en ligne, pour les blocs-notes, le code et les données. Son interface flexible permet aux utilisateurs de configurer et d'organiser des flux de travail, dans les domaines de la science des données, de l'informatique, des sciences computationnelles et de l'apprentissage automatique [92].

4.2.3 Bibliothèques utilisées

Dans le cadre de la réalisation de ce projet, plusieurs bibliothèques ont été prises en compte, pour déployer les architectures neuronales, évaluer les performances des résultats et visualiser les courbes obtenues.

a. TensorFlow

TensorFlow est une bibliothèque open-source développée par Google, spécialement conçue pour 'le machine et le deep learning'. Elle permet de construire, d'entraîner et de déployer des modèles de réseaux de neurones de manière efficace. TensorFlow offre une grande flexibilité pour la manipulation de données, la modélisation, l'entraînement sur GPU/TPU et le déploiement en production [93].

b. Keras

Keras est une interface de haut niveau pour la construction et l'entraînement de réseaux de neurones profonds. Elle permet de construire des modèles en empilant simplement les couches les unes sur les autres, ou en créant des architectures plus complexes avec l'API fonctionnelle. La bibliothèque Keras est utilisée pour importer des modèles pré-entraînés comme VGG16, MobileNetV2 ou EfficientNetB0. Elle facilite aussi l'ajout de couches personnalisées (couches denses, dropout, global pooling, etc.), l'entraînement avec des callbacks, comme 'Early Stopping' et la sauvegarde des modèles pour une utilisation ultérieure [94].

c. NumPy

NumPy (Numerical Python) est la bibliothèque de base pour le calcul scientifique en Python. Elle permet de manipuler efficacement des tableaux multidimensionnels (ndarray),

de réaliser des opérations mathématiques avancées et d'interagir avec d'autres bibliothèques comme TensorFlow [95].

d. Matplotlib

Matplotlib est une bibliothèque de visualisation qui permet de créer une grande variété de graphiques, allant des simples courbes aux visualisations plus complexes. Elle est largement utilisée pour afficher les courbes de progression de l'apprentissage (loss, accuracy) pendant et après l'entraînement. Dans ce projet, Matplotlib visualise la performance du modèle au cours du temps, ce qui permet de détecter un surapprentissage ou une stagnation [96].

e. Seaborn

Seaborn est une bibliothèque de visualisation statistique, construite au-dessus de Matplotlib. Elle offre des fonctions de haut niveau, pour dessiner des graphiques plus esthétiques et plus informatifs. Seaborn est particulièrement utile pour afficher les matrices de confusion sous forme de "heatmaps" (cartes thermiques), qui permettent de visualiser clairement les performances du modèle par classe [97].

f. Scikit-learn (sklearn)

Scikit-learn est une bibliothèque puissante pour l'apprentissage automatique, offrant des outils pour la classification, la régression, le clustering, la réduction de dimensionnalité et l'évaluation de modèles. Dans l'application considérée, cette bibliothèque est principalement utilisée pour l'évaluation suivant le calcul notamment de la précision, le rappel, l'exactitude, ainsi que le tracé des courbes ROC, pour mesurer la performance par classe [98].

g. Pandas

Pandas est une bibliothèque de manipulation et d'analyse de données, construite autour de deux structures principales : les séries (1D) et les DataFrames (2D, comme des tableaux Excel). Elle est extrêmement utile pour lire et organiser des fichiers de données comme les fichiers CSV, ou encore afficher les résultats sous forme de tableaux [99].

h. Os et glob

Le module os de Python permet d'interagir avec le système de fichiers de l'ordinateur. Il peut ainsi : parcourir les répertoires, créer des dossiers, manipuler les chemins d'accès, etc. Le module glob, quant à lui, est utilisé pour récupérer les chemins des fichiers

correspondant à un motif donné (par exemple, toutes les images avec l'extension .jpg). Ensemble, ces bibliothèques permettent d'automatiser la recherche d'images, dans les dossiers, de créer des ensembles de données organisés et de parcourir automatiquement les structures du dataset pour le prétraitement [100].

i. Open CV (cv2)

OpenCV (Open Source Computer Vision Library) est une bibliothèque de traitement d'images et de vidéos. Elle propose un large éventail de fonctions pour manipuler, transformer, filtrer et analyser des images [101].

4.3 Système développé

Le système PneumoCNN4 est réalisé pour classifier des images radiographiques thoraciques infantiles, suivant huit modèles des réseaux de neurones convolutifs : VGG16, VGG19, Resnet50, resnet101, densenet121, densenet201 et efficientnetB0.

4.3.1 Présentation de la base utilisée

La base de données [64] d'images radiographiques de pneumopathies infantiles chest x-ray (figure 4.1), est structurée en trois sous-ensembles principaux : entraînement, validation et test. Les images sont classées selon deux catégories : pneumonie et normale. Au total, 5 856 radiographies thoraciques ont été sélectionnées à partir de dossiers pédiatriques rétrospectifs de patients âgés de 1 à 5 ans.




Figure 4.1 : Exemples d'images radiographiques thoraciques des deux classes
(a) Normal, (b) Pneumonie

L'application développée est effectuée autour de trois distributions différentes (tableaux 4.1, 4.2 et 4.3).

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

Tableau 4.1 : Première distribution de la base chest X-ray

Classe	Entrainement	Validation	Test
Normale	1341	120	122
Pneumonie	3875	120	278

Tableau 4.2 : Seconde distribution de la base chest X-ray

Classe	Entrainement	Validation	Test
Normale	3875	372	182
Pneumonie	3875	372	182

Tableau 4.3 : Troisième distribution de la base chest X-ray

4.3.2 Préparation des données

Dans le cadre de la préparation des données du dataset Data-Chest-ray, plusieurs étapes de prétraitement ont été effectuées afin d'adapter les images aux exigences des modèles du deep learning utilisés, tout en améliorant leur robustesse face à la variabilité des données médicales.

a. Redimensionnement des images

Toutes les images radiographiques ont été redimensionnées à une taille uniforme de 224×224 pixels. Ce format standard est requis par la plupart des architectures pré-entraînées sur ImageNet. Il permet de garantir une cohérence dimensionnelle entre les images d'entrée du réseau.

b. Normalisation des pixels

Les valeurs des pixels des images, initialement comprises entre 0 et 255, ont été normalisées entre 0 et 1 en les divisant par 255. Cette opération permet de réduire l'écart de la dynamique entre les valeurs d'entrée, d'accélérer la convergence lors de l'apprentissage et de stabiliser les gradients lors de la rétropropagation.

c. Augmentation des données

Pour enrichir le jeu de données d'entraînement et améliorer la capacité de généralisation du modèle, une stratégie d'augmentation de données a été mise en place. Les transformations suivantes ont été appliquées de manière aléatoire pendant l'entraînement :

- Rotation à 15 degrés.
- Zoom compris entre 90 % et 110 % de l'échelle originale.
- Translations horizontales et verticales.
- Renversement horizontal (horizontal flip).

Ces transformations simulent différentes positions ou variations des images médicales (figure 4.4) tout en préservant leur signification diagnostique. L'augmentation permet ainsi de réduire le risque de surapprentissage, notamment dans les cas où le dataset est de taille modérée.




Figure 4.2 : Exemples d'augmentation des données

4.3.3 Modèles utilisés

Dans le cadre de ce travail, plusieurs architectures de réseaux de neurones convolutifs (CNNs) pré-entraînées ont été sélectionnées pour la tâche de classification d'images pulmonaires, notamment : ResNet50, ResNet101, VGG16, VGG19, EfficientNetB0, MobileNetV2, DenseNet121 et DenseNet201. Ces modèles ont été choisis pour leurs performances prouvées dans diverses tâches de la vision par ordinateur, en particulier dans le domaine biomédical, où ils ont montré une grande efficacité en termes de précision [63-70].

L'architecture de base de chaque modèle, se compose de deux parties principales : un extracteur de caractéristiques, issu du modèle pré-entraîné sur ImageNet et un classifieur, constitué de couches entièrement connectées en remplacement de la dernière du réseau. Une approche du fine-tuning a été adoptée : les poids des couches convolutives ont été gelés, tandis que la couche entièrement connectée a été remplacée par 3 à 4 couches denses activées par la fonction ReLU, suivies d'une couche finale avec une activation softmax adaptée au nombre de classes cibles. Afin d'améliorer la capacité de généralisation des modèles et de limiter le sur-apprentissage, des couches de normalisation par lot (batch

normalization) ainsi que des couches de dropout, ont été intégrées dans les modèles. Plusieurs valeurs du taux de dropout (20%, 30%, 50%, 70 %) ont été testées pour chaque architecture, afin d'identifier la configuration la plus performante. Cette expérimentation a permis de déterminer la meilleure structure du classifieur pour chaque modèle retenu. Les figures 4.5, 4.6, 4.7, 4.8, 4.9, 4.10, 4.11 et 4.12, présentent les architectures adoptées pour les différents modèles utilisés dans cette étude.




Figure 4.3 : Architecture de mobilenetV2 affinée




Figure 4.4 : Architecture d'EfficientNetB0




Figure 4.5 : Architecture de VGG16 affinée




Figure 4.6 : Architecture de VGG19 affinée




Figure 4.7 : Architecture de Resnet50 affinée




Figure 4.8 : Architecture de resnet101 affinée





Figure 4.9 : Architecture de densenet121 affinée **Figure 4.10 :** Architecture de densenet201 affinée

4.4 Application PneumoCNN4 et Résultats

Dans le cadre de cette étude, une comparaison approfondie de huit architectures CNN pré-entraînées a été menée dans le but de classer automatiquement des radiographies thoraciques pédiatriques en deux classes : *normale* et *pneumonie*. Les modèles testés incluent VGG16, VGG19, ResNet50, ResNet101, MobileNetV2, EfficientNetB0, DenseNet121 et DenseNet201. Chaque modèle a été entraîné sur trois répartitions différentes de la base de données *Data-Chest X-ray*. La première répartition suit la structure d'origine, dans laquelle l'ensemble de validation est très faiblement représenté (seulement 16 images). Pour pallier à ce déséquilibre, une seconde répartition a été définie en transférant un nombre d'images de l'ensemble test vers la validation, ce qui permet une meilleure stabilité lors de l'évaluation pendant l'entraînement. Une troisième répartition a été également employée, pour pallier au déséquilibre des classes. Dans les trois cas, une stratégie d'augmentation des données a été appliquée à l'ensemble d'entraînement. Le modèle a été construit en utilisant les bases pré-entraînées sur ImageNet, en désactivant l'apprentissage des couches convolutionnelles et en ajoutant un classifieur dense personnalisé. Ce classifieur se compose de deux couches entièrement connectées de 256 et 128 neurones, activées par Relu, séparées par deux couches de Dropout pour limiter le sur-apprentissage. La couche finale utilise une activation softmax adaptée à la classification binaire. L'entraînement a été réalisé avec l'optimiseur Adam, avec un taux d'apprentissage fixé à 0.0001 et une fonction de perte catégorique croisée, bien adaptée à la classification multi-classe. La taille de lot (batch size) a été fixée à 32 pour l'entraînement et la validation, tandis que l'évaluation sur l'ensemble de test, a été effectuée avec une taille de lot de 1 pour un traitement image par image. Enfin, un mécanisme de Early Stopping a été intégré, surveillant la perte de la validation et arrêtant l'entraînement, en cas de stagnation durant cinq époques consécutives. Le nombre total a été ajusté selon les cas.

4.4.1 Résultats suivant la première répartition

Cette section présente les résultats obtenus suivant la première répartition de la base de données.

4.4.1.1 VGG16

Afin de mettre en évidence les performances du modèle VGG16 au cours de l'apprentissage, une série de résultats est présentée.

Elle inclut les courbes de perte et d'exactitude (figure 4.13, tableau 4.4), la courbe ROC (figure 4.14), la matrice de confusion sur l'ensemble de test (figure 4.15), ainsi que les principales métriques relatives à la classification (tableau 4.5). Ces éléments permettent d'évaluer la capacité du modèle à différencier les deux classes, tout en analysant sa stabilité durant l'entraînement.




Figure 4.11 : Courbe de Accuracy et perte du modèle VGG16 pour différentes valeurs du dropout

Exactitude et Perte Dropout1 & Dropout2	Exactitude d'entraînemen t	Perte d'entraînement	Exactitude de la Validation	Perte de la Validation
20 %, 20 %	0.9879	0.0297	1.0000	0.0230
20 %, 50 %	0.9889	0.0314	1.0000	0.0252
50 %, 50 %	0.9867	0.0487	0.9375	0.1301
70 %, 70 %	0.9841	0.0552	0.9375	0.0776

Tableau 4.4 : Résultats de l'entraînement du modèle VGG16




Figure 4.12 : Courbe ROC du modèle VGG16 avec différentes valeurs du Dropout

Dropout	Precision		Recall		F1-Score		F1-Score(macro)	AUC
Classe	Normal	Pneumonie	Normal	Pneumonie	Normal	Pneumonie	0.89	0.98
20%	0.98	0.87	0.76	0.99	0.86	0.93		
20%,50%	0.96	0.89	0.80	0.98	0.87	0.93		
50%	0.97	0.91	0.83	0.98	0.89	0.94		
70%	0.98	0.92	0.85	0.99	0.91	0.95		

Tableau 4.5: Performances du modèle VGG16




Figure 4.13 : Matrice de confusion du modèle VGG16 avec différentes Valeurs du Dropout

Discussion des résultats obtenus avec VGG16

Le modèle VGG16 a été évalué à travers différentes configurations du dropout (0.2, 0.2-0.5, 0.5 et 0.7), et un fine-tuning sur les dernières couches du réseau de base. Les performances générales montrent que VGG16, parvient à bien capturer les caractéristiques discriminantes entre les deux classes (normale et pneumonie), avec des résultats globalement satisfaisants. Les meilleurs scores sont obtenus pour un dropout de 0.5 et 0.7, indiquant qu'un certain degré de régularisation est bénéfique pour ce modèle. Nous observons aussi, que le fine-tuning améliore généralement la stabilité du modèle, permettant d'atteindre de meilleures performances sur les classes minoritaires.

Une bonne convergence est notée sur les courbes d'apprentissage, avec un gap modéré entre l'exactitude de l'entraînement et la validation, ce qui témoigne d'un contrôle de l'overfitting correct grâce au dropout et à l'early stopping.

La matrice de confusion montre cependant une tendance à légèrement sous-classifier les cas normaux, avec un rappel entre 76 % et 85 %, tandis que la classe pneumonie est bien capturée avec un rappel proche de 99 %. Cela pourrait indiquer un léger déséquilibre dans la sensibilité du modèle. Les courbes ROC confirment cette bonne capacité discriminante, avec des AUC > 90% pour les deux classes.

4.4.1.2 VGG19

L'évolution de l'apprentissage est observée via les courbes de l'exactitude et de la perte (figure 4.16) et les résultats notés dans le tableau 4.6. Tandis que la matrice de confusion (figure 4.18) et la courbe ROC (figure 4.17) permettent une analyse plus précise de la qualité de prédiction en phase de test. Les performances du modèle VGG19 sont représentés par le tableau 4.7.

Exactitude et Perte & Dropout1 Dropout2	Exactitude d'entraînement	Perte d'entraînement	Exactitude De Validation	Perte De Validation
20 %, 50 %	0.9826	0.0464	0.9375	0.1037
30 %, 50 %	0.9810	0.0539	0.8125	0.3851
50 %, 50 %	0.9820	0.0644	0.8125	0.3315
70 %, 70 %	0.9717	0.1165	0.9375	0.2640

Tableau 4.6: Résultats de l'entraînement du modèle VGG19




Figure 4.14 : Courbe de l'exactitude et de la perte du modèle VGG19 pour

différentes valeurs dropout




Figure 4.15 : Courbe ROC du modèle VGG19 avec différentes valeurs du dropout

Dropout	Precision		Recall		F1-Score		F1-Score(macro)	AUC
	Normal	Pneumonie	Normal	Pneumonie	Normal	Pneumonie		
20%,50%	0.98	0.88	0.77	0.99	0.86	0.93	0.89	0.97
30%,50%	0.94	0.90	0.81	0.97	0.87	0.93		0.96
50%	0.96	0.87	0.76	0.98	0.85	0.92	0.88	0.97
70%	0.95	0.89	0.81	0.98	0.88	0.93	0.90	0.96

Tableau 4.7: Performances du modèle VGG19




Figure 4.16 : Matrice de confusion du modèle VGG19 avec différentes Valeurs Dropout

Discussion des résultats avec VGG19

Le modèle VGG19 a démontré une capacité intéressante à classifier les images radiographiques infantiles, malgré une profondeur plus importante que VGG16, ce qui le rend plus sensible à l'overfitting. Les résultats expérimentaux montrent que les meilleures performances ont été obtenues avec un dropout de 20%-50%, atteignant un AUC de 97% et un F1-score macro de 89%. Les courbes d'apprentissage indiquent une bonne stabilité, bien que l'exactitude de la validation, varie davantage pour les configurations de dropout plus élevés (30%-50% et 50%-50%), ce qui reflète un compromis entre la régularisation et la capacité d'apprentissage. La matrice de confusion révèle une légère tendance à sous-classifier

la classe "normale", avec un rappel oscillant entre 76 % et 81 %, tandis que la classe "Pneumonia" est correctement identifiée (rappel jusqu'à 99 %).

Cela montre que VGG19, grâce à sa richesse de représentation, parvient à extraire des caractéristiques fines.

4.4.1.3 ResNet50

Les performances du modèle ResNet50 sont examinées à travers différents indicateurs visuels et quantitatifs (tableau 4.8). Les courbes d'apprentissage (figure 4.19) mettent en lumière la dynamique de la convergence du modèle. Tandis que la matrice de confusion (figure 4.21) et l'AUC (figure 4.20) offrent un aperçu global de sa précision, dans la classification binaire sur les données médicales testées.

Exactitude et Perte Dropout1 & Dropout2	Exactitude d'entraînement	Perte d'entraînement	Exactitude De Validation	Perte De Validation
20 %, 50 %	0.9928	0.0233	1.0000	0.0040
30 %, 50 %	0.9946	0.0169	1.0000	0.0072

Tableau 4.8: Résultats de l'entraînement du modèle ResNet50




Figure 4.17 : Accuracy et perte du modèle ResNet50 pour différentes valeurs du dropout




Figure 4.18 : Courbe ROC du modèle Resnet50 avec différentes valeurs du dropout

Dropout	Precision		Recall		F1-Score		F1-Score(macro)	AUC
Classe	Normal	Pneumonie	Normal	Pneumonie	Normal	Pneumonie		
20%,50%	0.91	0.91	0.85	0.95	0.88	0.93	0.90	0.97
30%,50%	0.93	0.89	0.80	0.96	0.86	0.92	0.89	0.96

Tableau 4.9: Performances du modèle ResNet50




Figure 4.19 : Matrice de confusion du modèle ResNet50 pour différentes valeurs du dropout

Discussion des résultats avec ResNet50

Le modèle ResNet50 s'est illustré comme l'une des architectures les plus performantes de cette étude. Son mécanisme de résidus (skip connections) facilite l'apprentissage de réseaux profonds en réduisant le risque de dégradation. Les courbes d'apprentissage montrent une convergence rapide et stable avec des accuracy de validation atteignant 100 % pour les configurations de dropout 20%-50% et 30%-50%. Le modèle obtient un F1-score macro de (0.89-0.90) et un AUC de (0.96-0.97), confirmant son excellente capacité discriminante. Contrairement à VGG19, ResNet50 maintient un bon équilibre entre la détection des classes "Normal" et "Pneumonia", avec des recalls respectivement de 85 % à 91 % et de 95 % à 96 %, ce qui témoigne d'une généralisation robuste sur les deux catégories. La matrice de confusion met en évidence une très faible proportion d'erreurs, suggérant que l'architecture profonde et optimisée de ResNet50, est particulièrement bien adaptée à la classification des images radiographiques thoraciques pédiatriques.

4.4.1.4 ResNet101

Dans cette section, les résultats obtenus avec ResNet101, sont illustrés par les graphes de la perte/accuracy (figure 4.22), ainsi que les courbes ROC (figure 4.23). La matrice de confusion (figure 4.24) ainsi que les performances globales du modèle sur les ensembles de validation et de test (tableaux 4.10 et 4.11) sont utilisées pour évaluer le modèle.

Accuracy et Perte Dropout1 & Dropout2	Accuracy d'entraînement	Perte d'entraînement	Accuracy De Validation	Perte De Validation
20 %, 50 %	0.9911	0.0328	0.8750	0.2071
30 %, 50 %	0.9920	0.0190	1.0000	0.0578
70%, 70%	0.9808	0.0481	1.0000	0.1097

Tableau 4.10: Résultats de l'entraînement du modèle ResNet101




Figure 4.20 : Accuracy et perte du modèle ResNet50 pour différentes valeurs du dropout




Figure 4.21: Courbe ROC du modèle ResNet101 avec différentes valeurs du dropout

Dropout	Precision		Recall		F1-Score		F1-Score(macro)	AUC
	Normal	Pneumonie	Normal	Pneumonie	Normal	Pneumonie		
20%,50%	0.94	0.87	0.76	0.97	0.84	0.92	0.87	0.97
30%,50%	0.93	0.90	0.82	0.96	0.87	0.93	0.90	0.97
70%,70%	0.95	0.87	0.75	0.98	0.84	0.92	0.87	0.97

Tableau 4.11: Performances du modèle ResNet101




Figure 4.22 : Matrice de confusion du modèle ResNet101 avec différentes valeurs du dropout

Discussion des résultats avec ResNet101

Le modèle ResNet101, est capable d'apprendre des représentations complexes, tout en maintenant une bonne stabilité. Avec un dropout de 30%-50%, ResNet101 a atteint des performances optimales : une exactitude de la validation de 100 %, une AUC de 97% et un F1-score macro de 90%. Les courbes d'apprentissage montrent une convergence stable. La matrice de confusion souligne une capacité équilibrée à classer les deux catégories, avec un rappel de 82 % pour "Normale" et 96 % pour "Pneumonia".

Cette robustesse s'explique par la profondeur du réseau (101 couches), qui facilite l'apprentissage des caractéristiques fines tout en évitant la dégradation des gradients.

4.4.1.5 MobileNetV2

Le modèle MobileNetV2, connu pour sa légèreté, est analysé à travers des indicateurs classiques d'évaluation en classification binaire. Les performances sont illustrées par le tableau 4.12, les courbes d'entraînement/validation (figure 4.25), la matrice de confusion (figure 4.27), la courbe ROC (figure 4.26) ainsi qu'un tableau récapitulatif des scores F1, de la précision et du rappel (tableau 4.13).

Dropout1 & Dropout2	Exactitude d'entraînement	Perte d'entraînement	Exactitude De Validation	Perte De Validation
20 %, 20 %	0.9843	0.0412	1.0000	0.0327
20 %, 50 %	0.9649	0.0936	0.7500	0.9004
50 %, 50 %	0.9559	0.1068	0.7500	0.4548
70 %, 70 %	0.9808	0.0543	0.5625	4.7205

Tableau 4.12: Résultats de l'entraînement du modèle MobileNetV2

Dropout	Precision		Recall		F1-Score		F1-Score(macro)	AUC
	Normal	Pneumonie	Normal	Pneumonie	Normal	Pneumonie		
Classe								
20%,20%	0.95	0.91	0.84	0.97	0.89	0.94	0.91	98
20%,50%	0.97	0.86	0.72	0.98	0.83	0.92	0.87	0.97
50%,50%	0.95	0.85	0.71	0.98	0.81	0.91	0.86	0.97
70%,70%	1.00	0.71	0.33	1.00	0.50	0.83	0.66	0.96

Tableau 4.13 : Performances du modèle MobileNetV2




Figure 4.23 : Courbe de l'exactitude et de la perte du modèle MobileNetV2 pour différentes valeurs du dropout




Figure 4.24 : Courbe ROC du modèle MobileNetV2 avec différentes valeurs Dropout




Figure 4.25 : Matrice de confusion du modèle MobileNetV2 avec différentes valeurs du dropout

Discussion des résultats avec MobileNetV2

Le modèle MobileNetV2 a montré un comportement contrasté au cours des expériences, illustrant bien son compromis entre légèreté computationnelle et capacité discriminative. Avec une configuration de dropout modérée (20%-20%), il atteint des performances remarquables avec une accuracy de validation de 100 %, un AUC de 0.98 et un F1-score macro de 0.91, démontrant ainsi qu'un modèle léger peut efficacement classer les images de pneumonie pédiatrique. Cependant, dès que le taux de dropout augmente (notamment 50%-50% et 70%-70%), une forte dégradation des performances est observée : la accuracy de validation chute respectivement à 75 % et 56.25 %, et l'AUC diminue également.

Cette sensibilité accrue au dropout élevé souligne que MobileNetV2, a une capacité d'apprentissage plus fragile face à une régularisation trop forte.

La matrice de confusion révèle aussi un déséquilibre plus marqué pour les classes « Normal », avec un rappel tombant à 33 % pour le cas le plus extrême.

4.4.1.6 EfficientNetB0

Les résultats du modèle EfficientNetB0 sont synthétisés suivant leurs performances (tableaux 4.14 et 4.15). Les courbes d'évolution de la perte et de l'exactitude (figure 4.28), la matrice de confusion (figure 4.30) et la courbe ROC (figure 4.29), permettent de juger la pertinence de ce modèle, dans un contexte médical exigeant.

Accuracy et Perte & Dropout1 & Dropout2	Accuracy d'entraînement	Perte d'entraînement	Accuracy De Validation	Perte De Validation
20 %, 20 %	0.9744	0.0662	0.9250	0.1921
20 %, 50 %	0.9542	0.1245	0.9375	0.2258

Tableau 4.14: Résultats de l'entraînement du modèle EfficientNetB0




Figure 4.26 : Courbe de l'exactitude et la perte du modèle EfficientNetB0




Figure 4.27 : Courbe ROC du modèle EfficientNetB0 avec différentes valeurs du dropout

Dropout	Precision		Recall		F1-Score		F1-Score(macro)	AUC
Classe	Normal	Pneumonie	Normal	Pneumonie	Normal	Pneumonie		
20%,20%	0.94	0.88	0.70	0.98	0.80	0.93	0.86	97
20%,50%	0.95	0.84	0.70	0.98	0.80	0.91	0.85	0.96

Tableau 4.15 : Performances du modèle EfficientNetB0




Figure 4.28 : Matrice de confusion du modèle EfficientNetB0 avec différents Dropout

Discussion des résultats avec EfficientNetB0

Le modèle EfficientNetB0 a démontré une capacité de généralisation intéressante, malgré une architecture compacte. Avec un dropout modéré (20%-20% et 20%-50%), il a atteint une exactitude pour la validation de 92,5 % à 93,75 %, un F1-score macro de 85-86% et un AUC élevé (96-97%). Les courbes ROC et la matrice de confusion, montrent une bonne discrimination entre les deux classes, bien que la sensibilité pour la classe *Normale* reste légèrement inférieure à celle de *Pneumonia* (rappel de 70 % contre 98 %). Ce comportement reflète l'efficacité d'EfficientNetB0, pour extraire des caractéristiques pertinentes sur des données médicales complexes.

4.4.1.7 DenseNet121

L'analyse du modèle DenseNet121 est présentée à l'aide d'outils visuels et métriques classiques en deep learning. L'ensemble des résultats obtenus suivant les métriques d'évaluation (tableaux 4.16 et 4.17), les courbes d'apprentissage (figure 4.31), la matrice de confusion (figure 4.33), les scores de la classification, ainsi que la courbe ROC (figure 4.32), fournit une évaluation complète de ses performances, sur les radiographies thoraciques pédiatriques.

Exactitude et Perte Dropout1 & Dropout2	Accuracy d'entraînement	Perte d'entraînement	Accuracy De Validation	Perte De Validation
20 %, 50 %	0.9567	0.1089	0.9375	0.1530
50 %, 50 %	0.9574	0.1143	0.9375	0.2150
70%,70%	0.8043	0.4110	0.6875	0.6304

Tableau 4.16: Résultats de l'entraînement du modèle EfficientNetB0

Dropout	Precision		Recall		F1-Score		F1-Score(macro)	AUC
	Normal	Pneumonie	Normal	Pneumonie	Normal	Pneumonie		
Classe								
20%,50%	0.93	0.89	0.79	0.97	0.86	0.93	0.89	0.96
50%,50%	0.95	0.87	0.76	0.97	0.84	0.92	0.88	0.96
70%,70%	0.89	0.71	0.33	0.97	0.48	0.82	0.64	0.91

Tableau 4.17 : Performances du modèle DenseNet121




Figure 4.29 : Courbe de l'exactitude et la perte du modèle DenseNet121 pour différentes valeurs Dropout




Figure 4.30 : Courbe ROC du modèle DenseNet121 avec différentes valeurs Dropout




Figure 4.31 : Matrice de confusion du modèle DenseNet121

Discussion des résultats avec DenseNet121

DenseNet121 s'est révélé robuste et équilibré dans cette tâche de classification. Les meilleures performances sont obtenues avec un dropout de 20%-50 %, atteignant un F1-score macro de 89% et une AUC de 96%. Les courbes d'apprentissage confirment une convergence stable et une généralisation satisfaisante. Le modèle parvient à maintenir un bon rappel sur les deux classes (79 % pour Normale et 97 % pour Pneumonia) en limitant le surapprentissage. Cependant, un dropout trop élevé (70%-70%) dégrade nettement les performances, illustrant la sensibilité du modèle à une régularisation excessive. Dans l'ensemble, DenseNet121 s'est montré adapté à cette application médicale, grâce à sa capacité à capter des détails fins dans les images.

4.4.1.8 DenseNet201

Les résultats pour le modèle DenseNet201 sont décrits, afin de juger sa capacité à classer les images étudiées. Dans ce cas, les courbes de la perte et de l'exactitude (figure 4.34), la matrice de confusion (figure 4.36), la courbe ROC (figure 4.35) ainsi que l'estimation de ses performances (tableaux 4.18 et 4.19), permettent d'évaluer son aptitude à distinguer efficacement les deux classes cibles.




Figure 4.32 : Courbe de l'exactitude et la perte du modèle DenseNet201




Figure 4.33 : Courbe ROC du modèle Densenet201




Figure 4.34 : Matrice de confusion du modèle Densenet201

Accuracy et Perte Dropout1 & Dropout2	Accuracy d'entraînement	Perte d'entraînement	Accuracy De Validation	Perte De Validation
70%,70%	0.9428	0.1453	0.8750	0.2979

Tableau 4.18: Résultats de l'entraînement du modèle DenseNet201

Dropout	Precision		Recall		F1-Score		F1-Score(macro)	AUC
	Normal	Pneumonie	Normal	Pneumonie	Normal	Pneumonie		
70%,70%	0.92	0.84	0.70	0.96	0.79	0.90	0.84	0.96

Tableau 4.19 : Performances du modèle DenseNet201

Discussion des résultats avec DenseNet201

DenseNet201, malgré sa profondeur plus importante, a présenté des résultats plus contrastés. Avec un dropout de 70%-70 %, l'accuracy de validation est de 87,5 %, le F1-score macro atteint 0.84 et l'AUC 0.96.

Toutefois, une dégradation du rappel sur la classe Normale (70 %) est observée, traduisant une difficulté relative à équilibrer les prédictions entre les deux classes. La courbe ROC reste néanmoins satisfaisante, montrant que DenseNet201 conserve une capacité discriminante importante. Ces résultats suggèrent que bien que DenseNet201 possède une forte expressivité, son entraînement nécessite un réglage fin des hyperparamètres pour éviter le déséquilibre en classification binaire.

Discussion générale

Les résultats obtenus sur la première répartition, ont permis de démontrer la capacité des différentes architectures à classer efficacement les images thoraciques pédiatriques. Toutefois, la faible taille de l'ensemble de validation a pu limiter la stabilité des évaluations intermédiaires et, la capacité à détecter un éventuel sur-apprentissage. Afin de renforcer la fiabilité des analyses et d'assurer une meilleure représentativité des performances en phase de validation, une seconde répartition plus équilibrée des données a été définie. Celle-ci pourrait évaluer plus précisément la robustesse et la généralisation des modèles, dans un contexte plus réaliste.

4.4.2 Résultats de la deuxième répartition

Afin de pallier le déséquilibre observé dans la première répartition, en particulier le faible nombre d'images dans l'ensemble de validation, une seconde répartition a été mise en place. Celle-ci consiste à transférer un nombre d'images depuis l'ensemble de test vers la validation, permettant ainsi une évaluation plus stable et plus représentative durant l'apprentissage.

Dans ce cas, les modèles implémentés ont été évalués, en conservant la configuration dropout offrant les meilleures performances. Le tableau 4.20, permet d'apprécier la capacité discriminante des modèles développés dans cette répartition.

Modèle	Dropout1 Dropout 2	Exactitude	Précision	F1- Score	Rappel	AUC	F1- Score macro	Perte
VGG16	70%, 70%	97%	96%/N 91%/PN	86%/N 95%8PN	78%/N 99%/PN	96%	96%	5%
VGG19	20%, 50%	98%	94%/N 91%/PN	85%/N 94%/PN	78%/N 98%/PN	95%	89%	0.05
Resnet50	20%, 50%	98.7%	93%/N 91%/PN	84%/N 94%/PN	77%/N 97%/PN	96%	89%	0.0038
Resnet101	30% 50%	99.32%	90%/N 91%/PN	84%/N 94%/PN	78%/N 96%/PN	97%	88%	0.0197
MobilenetV2	20% 20%	98.97%	88%/N 90%/PN	82%/N 95%/PN	77%/N 95%/PN	94%	87%	0.0283
EfficientnetB0	20% 20%	96.79%	93%/N 88%/PN	80%/N 93%/PN	70%/N 98%/PN	97%	86%	0.0845
Densenet121	20% 50%	96.10%	87%/N 88%/PN	77%/N 94%/PN	70%/N 95%/PN	94%	84%	0.0989
Densenet201	70% 70%	97.62%	89%/N 86%/PN	74%/N 91%/PN	63%/N 96%/PN	95%	82%	0.0675

Tableau 4.20 : Performances de PneumoCNN4 pour la seconde répartition

Discussion générale sur la seconde répartition

Les résultats obtenus pour la seconde répartition, ont démontré une nette amélioration de la stabilité et de la représentativité des évaluations, grâce à un ensemble de validation renforcé. Les performances globales des modèles, montrent une capacité robuste à classifier les images thoraciques pédiatriques, avec un bon équilibre entre la précision et la généralisation, malgré une récurrence de la sous-classification de la classe normale. Toutefois, un léger déséquilibre persiste dans la base de données, influençant le rappel sur cette classe. Afin de remédier à cette limitation et de garantir une évaluation encore plus fiable et équilibrée, une troisième répartition a été mise en place. Celle-ci repose sur un rééquilibrage explicite de la base de

données, avec un nombre de cas identiques par classe pour les ensembles d'entraînement, de validation et de test. Les résultats correspondants sont présentés dans la section suivante.

4.4.3 Troisième répartition

Suite aux observations réalisées sur la seconde répartition, il est apparu que le déséquilibre résiduel entre les classes continuait d'impacter les performances des modèles, notamment en ce qui concerne le rappel de la classe Normale.

Afin de pallier cette limitation et de garantir une évaluation plus juste et représentative, une troisième répartition des données a été mise en place.

Celle-ci repose sur un rééquilibrage explicite de la base, en veillant à ce que les ensembles d'entraînement, de validation et de test contiennent un nombre identique d'images pour chaque classe. Cette nouvelle configuration permet de mieux apprécier la capacité réelle des modèles à discriminer de manière équilibrée entre les deux catégories, en minimisant l'influence du déséquilibre initial. Les résultats des performances de cette dernière répartition équilibrée sont présentés dans les tableaux 4.36-4.50. Chacun des modèles a été réentraîné en conservant la configuration de dropout, qui avait donné les meilleures performances lors des précédentes expérimentations. Le tableau 4.21 regroupe les résultats obtenus pour chacun des modèles implémentés.

Modèle	Dropout1 Dropout 2	Exactitude	Précision	F1- Score	Rappel	AUC	F1- Score macro	Perte
VGG16	70%, 70%	98.06%	95%/N 83%/PN	88%/N 89%/PN	81%/N 96%/PN	96%	88%	0.0586
VGG19	20%, 50%	98.98%	95%/N 84%/PN	88%/N 90%/PN	82%/N 96%/PN	96%	88%	0.0380
Resnet50	20%, 50%	99.41%	95%/N 92%/PN	93%/N 93%/PN	92%/N 95%/PN	98%	93%	0.0215
Resnet101	30% 50%	99.13%	93%/N 89%/PN	90%/N 91%/PN	88%/N 93%/PN	96%	90%	0.0238
MobilenetV2	20% 20%	98.68%	93%/N 91%/PN	92%/N 93%/PN	90%/N 93%/PN	98%	91%	0.0349
EfficientnetB0	20% 20%	98.68%	93%/N 91%/PN	92%/N 92%/PN	90%/N 93%/PN	98%	91%	0.0349
Densenet121	20% 50%	96.76%	95%/N 82%/PN	86%/N 88%/PN	79%/N 96%/PN	96%	84%	0.0875
Densenet201	70% 70%	96.10%	94%/N 83%/PN	87%/N 89%/PN	81%/N 94%/PN	95%	87%	0.1152

Tableau 4.21 : Performances de PneumoCNN4 pour la troisième répartition

4.4.3 Comparaison entre les modèles et identification du meilleur

En comparant les performances des modèles, ResNet50 se distingue comme le meilleur modèle dans cette étude. Il a atteint une exactitude parfaite de 100 % et un F1-score macro de 93%, tout en maintenant un excellent équilibre entre les deux classes. ResNet50 a surpassé les autres modèles grâce à son mécanisme de résidus, qui facilite l'apprentissage en profondeur tout en évitant la dégradation des gradients. Bien que VGG19 et ResNet101 aient également montré de très bonnes performances, ils n'ont pas atteint le niveau de précision et de stabilité de ResNet50. MobileNetV2 et EfficientNetB0, bien qu'efficaces en termes de calcul, n'ont pas pu rivaliser avec les modèles plus profonds en termes de précision. DenseNet121 et DenseNet201 ont montré de bonnes performances, mais leur tendance à sous-classifier la classe "Normale" les place derrière ResNet50.

4.5 Conclusion

Ce chapitre a présenté l'implémentation et l'évaluation du système PneumoCNN4 pour la classification des pathologies pulmonaires infantiles à partir d'images radiographiques. Plusieurs architectures de réseaux convolutifs pré-entraînées ont été testées, notamment VGG16, VGG19, ResNet50, ResNet101, MobileNetV2, EfficientNetB0, DenseNet121 et DenseNet201. Les résultats obtenus sur trois répartitions différentes des données, ont permis d'évaluer la robustesse et la capacité de généralisation de chaque modèle. Parmi eux, ResNet50 s'est distingué comme le modèle le plus performant, atteignant une exactitude (accuracy) parfaite et, un excellent équilibre entre les classes. Ces résultats mettent en évidence l'importance de choisir une architecture adaptée et de bien équilibrer les données, pour garantir des performances optimales dans des applications médicales critiques.

Le système PneumoCNN4, basé sur ResNet50, offre ainsi une solution prometteuse pour la détection automatique des pathologies pulmonaires infantiles, avec des perspectives intéressantes pour une intégration clinique future.

Conclusion générale

L'initiation à la recherche réalisée dans le cadre de ce mémoire, s'inscrit dans les objectifs de l'équipe, "IMAD", du laboratoire LATSI du département d'électronique de l'université de Blida 1, pour la conception de systèmes d'aide au diagnostic en imagerie médicale.

Ce projet de fin d'études s'est inscrit dans le cadre de l'exploration et de l'optimisation des approches d'apprentissage profond, pour la classification automatique d'images radiographiques pulmonaires pédiatriques.

Face aux enjeux critiques du diagnostic précoce des pathologies pulmonaires chez l'enfant, nous avons cherché à développer des modèles performants et robustes, capables d'assister efficacement les professionnels de santé.

Dans ce contexte, la première phase du projet, a été une préparation rigoureuse des données accomplies suivant le redimensionnement des images, leur normalisation, et l'enrichissement de la base, par des techniques d'augmentation de données, pour pallier au déséquilibre ainsi qu'à la variabilité du dataset. Ce prétraitement a constitué une étape essentielle, pour garantir une meilleure généralisation des modèles.

Sur le plan méthodologique, le système PneumoCNN4 a exploré plusieurs architectures des réseaux de neurones convolutionnels (CNN) pré-entraînés : VGG16, VGG19, EfficientNetB0, MobileNetV2, Densenet121, Densenet201, ResNet50 et ResNet101. Un processus de fine-tuning ciblé a permis d'ajuster les poids des couches profondes, pour une meilleure spécialisation au domaine médical traité. L'entraînement a été optimisé via l'intégration de techniques avancées, telles que Early Stopping.

Le système PneumoCNN4 a été évalué par plusieurs métriques, telles que : la courbe ROC, la précision, le rappel et le F1-score, pour estimer sa robustesse, face aux données traitées.

Sur le plan des performances comparatives, l'analyse approfondie des résultats a permis de mettre en évidence des différences significatives entre les modèles testés. **ResNet50** s'est clairement distingué comme **le meilleur modèle** de cette étude. Il a atteint une **exactitude parfaite de 100 %** et un **F1-score macro de 93%**, démontrant un excellent équilibre entre les différentes classes. Son architecture basée sur le **mécanisme de résidus** facilite l'apprentissage en profondeur, tout en évitant la dégradation des gradients, ce qui lui a permis

de surpasser les autres modèles testés. Bien que **VGG19** et **ResNet101** aient également présenté de très bonnes performances, ils n'ont pas atteint le même niveau de précision, ni la même stabilité que ResNet50.

Par ailleurs, les modèles plus légers comme **MobileNetV2** et **EfficientNetB0**, ont confirmé leur intérêt en termes de **compromis entre légèreté, rapidité d'exécution et consommation de ressources**, les rendant parfaitement adaptés pour une **intégration sur des dispositifs médicaux mobiles, ou dans des environnements à ressources limitées**. Cependant, ils n'ont pas pu rivaliser avec la précision offerte par ResNet50. Enfin, bien que les architectures **DenseNet121** et **DenseNet201** aient obtenu de bonnes performances globales, leur tendance à sous-classifier la classe "Normale" limite leur pertinence par rapport à ResNet50 dans le cadre de cette tâche.

Ce travail ouvre plusieurs perspectives intéressantes pour des recherches futures :

1. Élargissement du dataset

Le dataset utilisé (Chest-X-ray) présente certaines limitations en termes de diversité et de volume. Il serait pertinent d'intégrer des images radiographiques différentes provenant de plusieurs hôpitaux, pour renforcer la **généralisation** du modèle et éviter le surapprentissage sur des caractéristiques spécifiques au dataset actuel.

2. Déploiement en environnement réel

Ce travail pourrait être déployé vers un prototype fonctionnel intégrable sur un système hospitalier ou une application mobile, avec des contraintes de **temps de prédiction** et de **consommation mémoire**. Cela impliquerait aussi un travail sur la compression de modèle.

3. Extension à une classification multi-pathologies

Dans cette étude, la classification s'est concentrée sur des classes binaires. Un prolongement naturel serait d'entraîner et d'évaluer les modèles, sur un ensemble plus large et plus complexe de pathologies pulmonaires pédiatriques, voire sur des cas combinés (co-morbidités).

Ce travail ouvre la voie à des applications pratiques, pour la prise en charge des pneumopathies infantile.

Bibliographie

- [1] World Health Organization (WHO). Pneumonia accounts for 14 % of all deaths of children under 5 years old, killing 740 180 children in 2019, <https://www.who.int/news-room/fact-sheets/detail/pneumonia>, novembre 2022, date de consultation, novembre 2024.
- [2] Encyclopédie Larousse. Appareil respiratoire, https://www.larousse.fr/encyclopedie/medical/appareil_respiratoire/15843, Larousse, date de consultation, novembre 2024.
- [3] R. Dezube. Présentation du système respiratoire. Manuel MSD, <https://www.msdmanuals.com/fr/accueil/troubles-pulmonaires-et-des-voies-a%C3%A9riennes/biologie-des-poumons-et-des-voies-respiratoires/pr%C3%A9sentation-du-syst%C3%A8me-respiratoire>, janvier 2023, date de consultation, novembre 2024.
- [4] Visible Body. Inspirer et traiter l'air : comment fonctionnent les structures du système respiratoire inférieur ? <https://www.visiblebody.com/fr/learn/respiratory/lower-respiratory-system>, 2025, date de consultation, mars 2025.
- [5] Assistance scolaire personnalisée. Les échanges gazeux dans une alvéole pulmonaire - Ressources pour les enseignants, <https://www.assistancescolaire.com/enseignant/college/ressources/base-documentaire-en-sciences/les-echanges-gazeux-dans-une-alveole-pulmonaire-5sre0204>, date de consultation, janvier 2025.
- [6] Yves Castier. Explorations thoraciques principales, <https://www.chirvtt.fr/chirurgie-thorax/explorations-thoraciques-principales/>, ChirVtt, service de chirurgie vasculaire, thoracique et transplantation pulmonaire, Hôpital Bichat, septembre 2017, date de consultation, janvier 2025.
- [7] R. Dezube. Contrôle de la respiration. Manuel MSD, <https://www.msdmanuals.com/fr/accueil/troubles-pulmonaires-et-des-voies-a%C3%A9riennes/biologie-des-poumons-et-des-voies-respiratoires/contr%C3%B4le-de-la-respiration>, janvier 2023, date de consultation, janvier 2025.
- [8] Children's Health Queensland Hospital and Health Service. *Anatomical and physiological differences*, https://www.childrens.health.qld.gov.au/__data/assets/pdf_file/0031/179725/how-children-are-different-anatomical-and-physiological-differences.pdf, janvier 2024, date de consultation, Novembre 2024.
- [9] V. Guellec, G. Orliaguet. *Gestion des voies aériennes de l'enfant*, https://sofia.medicalistes.fr/spip/IMG/pdf/gestion_des_voies_aeriennes_de_l_enfant.pdf, 2023, date de consultation, janvier 2025.

[10] B. Dallens. Particularités physiologiques de *l'enfant*, Polycopié de cours en physiologie pédiatrique, université de Laval, https://www.fmed.ulaval.ca/fileadmin/doc/faculte/departements/anesthesiologie/membres/presentations/2009/17-20091008physiologie_enfant.pdf, 2009, date de consultation, janvier 2025.

[11] Elsan. Pneumologie, <https://www.elsan.care/fr/chpb-grand-large/patients/pneumologie>, date de consultation, février 2025.

[12] J. Lee. Présentation des maladies pulmonaires interstitielles. Manuel MSD, <https://www.msdmanuals.com/fr/accueil/troubles-pulmonaires-et-des-voies-a%C3%A9riennes/maladies-pulmonaires-interstitielles/pr%C3%A9sentation-des-maladies-pulmonaires-interstitielles>, July 2023, date de consultation janvier 2025.

[13] Ramsay Santé. Broncho-pneumopathie chronique obstructive – BPCO, <https://www.ramsaysante.fr/vous-etes-patient-en-savoir-plus-sur-ma-pathologie/broncho-pneumopathie-chronique-obstructive>, date de consultation janvier 2025.

[14] Association pulmonaire du Québec. Asthme : diagnostic, traitements et gestion. <https://poumonquebec.ca/maladie/asthme/qu-est-ce-que-asthme.php>, date de consultation, janvier 2025.

[15] Ramsay Santé. Fibrose pulmonaire, <https://www.ramsaysante.fr/vous-etes-patient-en-savoir-plus-sur-ma-pathologie/fibrose-pulmonaire>, date de consultation, janvier 2025.

[16] R. Finger, R. Rodriguez, R. Schönegg, T. Kluckert, M. Brutsche. Sarkoïdose : aperçu clinique, Forum Med Suisse, vol. 13, pages 265-270, https://www.sarkoidose.ch/images/sarkoidose_brutsche_FR.pdf, 2013, date de consultation, novembre 2024.

[17] Ramsay Santé. Cancer du poumon, <https://www.ramsaysante.fr/vous-etes-patient-en-savoir-plus-sur-ma-pathologie/cancer-du-poumon>, date de consultation, novembre 2024.

[18] Centre Hospitalier de Luxembourg, CHL. La pneumonie, <https://www.chl.lu/fr/dossier/la-pneumonie>, date de consultation, novembre 2024.

[19] Association pulmonaire du Québec. L'embolie pulmonaire, <https://poumonquebec.ca/maladies/lembolie-pulmonaire/>, date de consultation, mars 2025.

[20] Health New Zealand. Bronchiolitis, <https://www.tewhatuora.govt.nz/assets/For-health-providers/Education-sector/Early-learning-services/Fact-sheets/bronchiolitis-els-factsheet.pdf>, mai 2022, date de consultation, novembre 2024.

[21] R. Bhatia. Asthme chez l'enfant. Manuel MSD, <https://www.msdmanuals.com/fr/accueil/probl%C3%A8mes-de-sant%C3%A9-infantiles/affections-respiratoires-chez-le-nourrisson-et-l-enfant/asthme-chez-l-enfant>, mars 2024, date de consultation, novembre 2024.

- [22] ACIBADEM hospitals, health point. Pneumonie Radio : Guide de Diagnostic en Imagerie, <https://www.acibademhealthpoint.com/pneumonie-radio-guide-de-diagnostic-en-imagerie/>, août 2024, date de consultation, novembre 2024.
- [23] Institut de Cardiologie de L'Université D'Ottawa. Radiographie thoracique, <https://www.ottawaheart.ca/fr/examen-intervention/radiographie-thoracique>, mai 2024 date de consultation, novembre 2024.
- [24] F. X. Slosman. Tomodensitométrie du thorax, <https://info-radiologie.ch/but-scanner-thorax.php>, date de consultation, décembre 2024.
- [25] Institut de Cardiologie de L'Université D'Ottawa. Imagerie par résonance magnétique (IRM) cardiaque. <https://www.ottawaheart.ca/fr/examen-intervention/imagerie-par-resonance-magnetique-irm-cardiaque>, mai 2024, date de consultation, décembre 2024.
- [26] D. Vodovar · J. Aboab · S. Silva · N. Tournier. Comprendre la tomographie par émission de positons (TEP) — une modalité d'imagerie pour la réanimation ? Méd. Intensive Réa, pages 1-6, Note technique, Lavoisier 2019.
- [27] L. Demi, F. Wolfram, C. Klersy, A. De Silvestri et al. New International Guidelines and Consensus on the Use of Lung Ultrasound, journal of ultrasound in medicine, vol. 42, pages 309-344, 2023.
- [28] Kids Health. Scintigraphies pulmonaires de perfusion et de ventilation. <https://www.aboutkidshealth.ca/fr/scintigraphies-pulmonaires-de-perfusion-et-de-ventilation>, février 2013, date de consultation novembre 2024.
- [29] Institut de cardiologie de Montréal. Scintigraphie pulmonaire, <https://icm-mhi.org/soins-et-services/scintigraphie-pulmonaire/>, date de consultation, janvier 2025.
- [30] I. Annesi-Maesano, M. Bentayeb, C. Billionnet, M. Hulin. *Épidémiologie Des Maladies Respiratoires*, Revue des maladie respiratoires, vol.2 pages 21-29, 2010.
- [31] Organisation mondiale de la Santé (OMS) : Région méditerranée orientale. Maladies des voies respiratoires, <https://www.emro.who.int/fr/health-topics/respiratory-tract-diseases/Page-1.html>, date de consultation, novembre 2024.
- [32] Organisation mondiale de la Santé (OMS). *Directives techniques pour la prise en charge des infections respiratoires aiguës chez l'enfant en Algérie*, Ministère de la Santé, de la Population et de la Réforme hospitalière – Algérie, <https://fr.scribd.com/document/459722371/ira>, 2002, date de consultation, janvier 2025.
- [33] Ministère algérien de la santé. Guide de prise en charge des infections respiratoires aiguës de l'enfant, https://www.dsp-tissemsilt.dz/wp-content/uploads/2024/02/Guide_IRA_web17-12.pdf, décembre 2023, date de consultation, novembre 2024.
- [34] Express Computer. (How AI and Technology is Blurring the Lines Between Humans and Machines. Express Computer. <https://www.expresscomputer.in/guest-blogs/how-ai-and->

technology-is-blurring-the-lines-between-humans-and-machines/105150/#:~:text=As%20technology%20becomes%20ever%20more,man%20and%20machine%2C%20it's%20important, octobre 2023, date de consultation, janvier 2025.

[35] Jorie AI | The Hidden Workforce : Machine Learning « Silent Partner » in Healthcare Administration, <https://www.jorie.ai/post/the-hidden-workforce-machine-learning-as-a-silent-partner-in-healthcare-administration#:~:text=Acting%20as%20a%20'silent%20partner,human%20error%2C%20and%20offering%20predictive>, date de consultation, janvier 2025.

[36] Geeks for Geeks. What is Artificial Intelligence ? Geeks for Geeks. <https://www.geeksforgeeks.org/What-is-ai-artificial-intelligence/?ref=shm>, 21 août 2024, date de consultation, janvier 2025.

[37] Google Cloud. What is artificial intelligence (AI) ? <https://cloud.google.com/learn/what-is-artificial-intelligence>, date de consultation, janvier 2025.

[38] IA School. Machine learning, qu'est-ce que c'est ? IA School. <https://www.intelligence-artificielle-school.com/ecole/technologies/machine-learning-quest-ce-que-cest/>, septembre 2023 date de consultation, novembre 2024.

[39] Thales. Qu'est-ce que l'intelligence artificielle et le machine learning ? <https://justaskthales.com/fr/quest-ce-que-lintelligence-artificielle-et-le-machine-learning/>, date de consultation, décembre 2025.

[40] Geeks for Geeks. Introduction to Deep Learning. Geeks for Geeks. <https://www.geeksforgeeks.org/introduction-deep-learning/?ref=shm>, mai 2024, date de consultation, janvier 2025.

[41] J. Robert. Deep Learning ou Apprentissage Profond : qu'est-ce que c'est ? Data Scientist. <https://datascientest.com/deep-learning-definition#:~:text=Le%20Deep%20Learning%20ou%20apprentissage,%C3%A0%20l'%C3%A9tablisement%20des%20r%C3%A8gles>, avril 2025, date de consultation, mai 2025.

[42] C. Deluzarche, Deep Learning : qu'est-ce que c'est ? Futura. <https://www.futura-sciences.com/tech/definitions/intelligence-artificielle-deep-learning-17262/>, décembre 2024 date de consultation, janvier 2025.

[43] Visible Body. L'histoire des neurones : L'histoire des neurones : aperçu de ces cellules chargées en électricité, <https://www.visiblebody.com/fr/learn/nervous/neurons>, date de consultation, janvier 2025.

- [44] Eric H. Chudler. Neuroscience For Kids, the synapse, <https://faculty.washington.edu/chudler/synapse.html>, juin 2025, date de consultation, juin 2025.
- [45] C. TOUZET, les réseaux de neurones artificiels introduction au connexionnisme, cours, exercices et travaux pratiques. EC2, Collection de l'EERIE, N. Giambiasi, juillet 1992.
- [46] Astronoo. Neurone formel : Comprendre notre univers, <https://astronoo.com/fr/articles/neurone-formel.html>, date de consultation, janvier 2025.
- [47] Innovatiana. Activation functions and neural networks, <https://en.innovatiana.com/post/activation-function-in-ai>, date de consultation, Janvier 2025.
- [48] A. Nasr. Perceptron multicouche, cours de master en sciences cognitives, université d'Aix en Provence, https://pageperso.lis-lab.fr/~alexis.nasr/Ens/MASCO_AA/mlp.pdf, date de consultation, janvier 2025.
- [49] Geeks for Geeks. (2025, 11 février). Introduction to Recurrent Neural Networks. Geeks for Geeks. <https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/>, date de consultation, janvier 2025.
- [50] Innovatiana. Understanding convolutional neural networks (CNN). <https://en.innovatiana.com/post/convolutional-neural-network>, date de consultation, janvier 2025.
- [51] A. Kothiya. Understanding “convolution” operations in CNN - Analytics Vidhya - Medium. Medium. <https://medium.com/analytics-vidhya/convolution-operations-in-cnn-deep-learning-computer-vision-128906ece7d3>, juin 2021, date de consultation janvier 2025.
- [52] Geeks for Geeks. Introduction to Convolution Neural Network. Geeks for Geeks. <https://www.geeksforgeeks.org/introduction-convolution-neural-network/>, octobre 2024, date de consultation, janvier 2025.
- [53] J. Dejasmin. Les réseaux de neurones convolutifs : Le Meilleur de la Technologie Au Service de la Biodiversité, <https://www.natural-solutions.eu/blog/la-reconnaissance-dimage-avec-les-reseaux-de-neurones-convolutifs#:~:text=Qu'est%2Dce%20que%20la,%C3%A0%20la%20reconnaissance%20d'ima ge.>, juillet 2019, date de consultation, janvier 2025.
- [54] P. Monasse, K. Nadjahi. Vision par ordinateur, partie 3 : Classifier les images à l'aide de réseaux de neurones convolutifs, <https://openclassrooms.com/fr/courses/4470531-classez->

[et-segmentez-des-donnees-visuelles/5083336-decouvrez-les-differentes-couches-dun-cnn](https://www.datacamp.com/fr/tutorial/segmentation-de-images), date de consultation, décembre 2024.

[55] B. El Habib. Les réseaux de neurones convolutifs. <https://datasciencetoday.net/index.php/en-us/deep-learning/173-les-reseaux-de-neurones-convolutifs>, date de consultation, janvier 2025.

[56] Super Data Science. Convolutional Neural Networks (CNN): Step 1- Convolution Operation, <https://www.superdatascience.com/blogs/convolutional-neural-networks-cnn-step-1-convolution-operation>, date de consultation, janvier 2025.

[57] IA Insights. Guide ultime des réseaux de neurones convolutifs : Votre clé pour maîtriser le Deep Learning, <https://www.ia-insights.fr/comprendre-les-reseaux-de-neurones-convolutifs-cnn-le-guide-ultime-pour-une-croissance-rapide-dans-le-deep-learning/>, juin 2023, date de consultation, décembre 2024.

[58] A. Amidi, S. Amidi. Pense-bête de réseaux de neurones convolutionnels. <https://stanford.edu/~shervine/l/fr/teaching/cs-230/pense-bete-reseaux-neurones-convolutionnels>, date de consultation, janvier 2025.

[59] ImageNet Large Scale Visual Recognition Challenge (ILSVRC), <https://www.image-net.org/challenges/LSVRC/>, date de consultation, janvier 2025.

[60] A. Krizhevsky, I. Sutskever, G. E. Hinton. ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems vol. 25, pages 1106-1114, 2012.

[61] P. Marcelino. Transfer learning from pre-trained models, <https://towardsdatascience.com/transfer-learning-from-pre-trained-models-f2393f124751>, date de consultation, janvier 2025.

[62] A. Zhang, Z. Lipton, M. Li, A. Smola. Dive into deep learning, fine tuning, http://d2l.ai/chapter_computer-vision/fine-tuning.html, date de consultation, janvier 2025.

[63] Liz, H., M. Sánchez-Montañés, A. Tagarro, S. Domínguez-Rodríguez, R. Dagan, D. Camacho. Ensembles of convolutional neural network models for pediatric pneumonia diagnosis. Future Generation Computer Systems, vol. 122, pages 220–233, 2021.

[64] D. Kermany, K. Zhang, M. Goldbaum. Chest X-ray images for classification, <https://data.mendeley.com/datasets/rscbjbr9sj/2>, date de consultation, janvier 2025.

- [65] G. Liang, L. Zheng. A transfer learning method with deep residual network for pediatric pneumonia diagnosis. *Computer Methods and Programs in Biomedicine*, vol. 187, pages 1-9, 2020.
- [66] R. Jain, P. Nagrath, G.Kataria, V. S. Kaushik, D. J. Hemanth. Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. *Measurement*, vol. 165, pages 1-23, 2020.
- [67] C. S. Raghaw, P. S. Bhore, M. Z. Ur Rehman, N. Kumar. An Explainable Contrastive-based Dilated Convolutional Network with Transformer for Pediatric Pneumonia Detection (XCCNet), *Applied Soft Computing*, vol. 167, pages 1-36, 2024.
- [68] Y. Meradi, S. Khemis. Analyse automatique d'images pulmonaires pour la détection de pathologies oncologiques et de pneumopathies, mémoire de master en Electronique, université de Blida 1, Algérie, 2020.
- [69] A. Azine, L. Talbi. Analyse de radiographies pulmonaires par deep learning pour la détection de pneumopathies, mémoire de master en automatique et informatique industrielle, Université de Blida 1, 2021.
- [70] Z. Laïeb, O. Immessaoudene. Détection de pneumopathies infantiles par apprentissage profond à partir de radiographies du thorax Pour l'aide à l'interprétation, mémoire de master en électronique, Université de Blida 1, 2021.
- [71] I. Ben M'hamed, H. Nekkach. Analyse de carcinomes mammaires par les techniques du deep learning pour l'aide à l'interprétation, mémoire de master en automatique, université de Blida 1, Algérie, 2022.
- [72] W. Salmi, A. Bouguetof. Conception et implémentation d'un système de classification d'images mammaires par les réseaux de neurones convolutifs pour l'aide au diagnostic, mémoire de master en électronique, université de Blida 1, Algérie, 2022.
- [73] O. Aïssat, F. Chambet Hezardja. Détection de tumeurs mammaires histologiques par les réseaux de neurones convolutifs pour l'aide à la décision, mémoire de master en électronique, université de Blida 1, Algérie, 2023.
- [74] M. Chane. Deep learning en imagerie médicale : stratégies d'apprentissage pour les modèles, Page Web IMAios, <https://www.imaios.com/fr/Societe/blog/IA-pour-limagerie-medicale-strategies-d-apprentissage>, 2021, date de consultation, janvier 2025.
- [75] J. Brownlee. How to Configure Image Data Augmentation in keras, <https://machinelearningmastery.com/how-to-configure-image-data-augmentation-when-training-deep-learning-neural-networks/>, 2019, date de consultation, janvier 2025.
- [76] S. Samana. *Data Préparation for Machine Learning : The Ultimate Guide to Doing It Right*. Pecan AI. <https://www.pecan.ai/blog/data-preparation-for-machine-learning/>, juin 2024, date de consultation, janvier 2025.

- [77] K. Simonyan et A. Zisserman, « Very Deep Convolutional Networks for Large-Scale Image Recognition », arXiv :1409.1556, 2015, date de consultation, février 2025.
- [78] G. Rohini. Everything you need to know about VGG16, <https://medium.com/@mygreatlearning/everything-you-need-to-know-about-vgg16-7315defb5918>, septembre 2021, date de consultation, janvier 2025.
- [79] Geeks for Geeks. VGGNet Architecture explained. GeeksforGeeks. <https://www.geeksforgeeks.org/vgg-net-architecture-explained/>, juin 2024, date de consultation, janvier 2025.
- [80] S. Arvinth. VGG16 vs. VGG19 vs. EfficientNetB5: Which Model is Best for Your Project? <https://medium.com/@sanjaiarvinth.drive/vgg16-vs-vgg19-vs-efficientnetb5-which-model-is-best-for-your-project-ce09d0f46f6b>, novembre 2024, date de consultation, janvier 2025.
- [81] S. Bangar. Resnet Architecture Explained Medium. *Medium*. <https://medium.com/@siddheshb008/resnet-architecture-explained-47309ea9283d>, juillet 2022, date de consultation, janvier 2025.
- [82] I. Azeem. Understanding ResNet Architecture: A Deep Dive into Residual Neural Network, <https://medium.com/@ibtedaazeem/understanding-resnet-architecture-a-deep-dive-into-residual-neural-network-2c792e6537a9>, novembre 2023, date de consultation, Janvier 2025.
- [83] D. Singh. MobileNet CNN and Implementation, <https://medium.com/@singhdewansh99/dlao-part-20-mobilenet-cnn-and-implementation-7b03bb41ffbe>, mai 2023, date de consultation, janvier 2025.
- [84] A. Sarkar. Creating DenseNet 121 with TensorFlow, <https://medium.com/data-science/creating-densenet-121-with-tensorflow-edbc08a956d8>, mai 2023, date de consultation, Janvier 2025.
- [85] P. Potrimba. What is EfficientNet ? The Ultimate Guide. Roboflow Blog. <https://blog.roboflow.com/what-is-efficientnet/>, avril 2024, date de consultation, janvier 2025.
- [86] Geeks for Geeks. Evaluation Metrics in Machine Learning, <https://www.geeksforgeeks.org/metrics-for-machine-learning-model/>, avril 2025, date de consultation, mai 2025.
- [87] Geeks for Geeks. Categorical Cross Entropy in MultiClass Classification, <https://www.geeksforgeeks.org/categorical-cross-entropy-in-multi-class-classification/>, septembre 2024, date de consultation, janvier 2025.
- [88] Geeks for Geeks. What is Adam Optimizer? Geeks for Geeks. <https://www.geeksforgeeks.org/adam-optimizer/>, mars 2025, date de consultation, avril 2025.

- [89] T. Keldenich. Le Dropout c'est quoi ? <https://inside-machinelearning.com/le-dropout-cest-quoi-deep-learning-explication-rapide/>, janvier 2023, date de consultation, janvier 2025.
- [90] Python. <https://docs.python.org/3/>, date de consultation, novembre 2024.
- [91] Anaconda. Anaconda vs. Python : What's the Difference ? <https://www.anaconda.com/topics/choosing-between-anaconda-vs-python>, date de consultation, janvier 2025.
- [92] Jupyter. <https://jupyter.org/>, date de consultation, Janvier 2025.
- [93] TensorFlow. <https://www.tensorflow.org/>, date de consultation, janvier 2025.
- [94] Keras. *Deep Learning for humans*, <https://keras.io/>, date de consultation, Janvier 2025.
- [95] NumPy. <https://numpy.org/>, date de consultation, janvier 2025.
- [96] Matplotlib. Visualization with Python,, <https://matplotlib.org/>, date de consultation, Janvier 2025.
- [97] Seaborn. Statistical data visualization documentation, <https://seaborn.pydata.org/>, date de consultation, Janvier 2025.
- [98] Scikit-learn. Machine learning in Python — scikit-learn 1.6.1 documentation, <https://scikit-learn.org/stable/>, date de consultation, Janvier 2025.
- [99] Pandas. Python Data Analysis Library, <https://pandas.pydata.org/>, date de consultation, Janvier 2025.
- [100] Glob. Unix style path name pattern expansion Python documentation, <https://docs.python.org/fr/3/library/glob.html>
- [101] OpenCV. (Get started - OpenCV. <https://opencv.org/get-started/>, date de consultation, mars 2025.