

الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire

Ministère de l'Enseignement Supérieur
et de la Recherche Scientifique

Université Akli Mohand Oulhadj - Bouira -

Tasdawit Akli Muḥend Ulḥağ - Tubirett -



وزارة التعليم العالي والبحث العلمي
جامعة أكلي محمد أولحاج
- البويرة -

Faculté des Sciences et des Sciences Appliquées

Référence :/MM/2021

كلية العلوم والعلوم التطبيقية
المرجع :م / م / 2021

Mémoire de Master

Présenté au

Département : Génie Électrique

Domaine : Sciences et Technologies

Filière : Electronique

Spécialité : Electronique des systèmes embarqués

Réalisé par :

DEMOUCHE SARAH

Thème

Classification automatisée des radiographies thoraciques pour la pneumonie et les cas normaux

Soutenu le : **25/06/2025**

Devant la commission composée de :

Mr :	M . Nourine	M.C.A	Univ. Bouira	Président
Mr	Bilal Saoud	Prof.	Univ. Bouira	Rapporteur
Mr	S.chelbi	M.C.A	Univ. Bouira	Examineur

REMERCIEMENT

Remerciement

Avant toute chose, je rends grâce à Dieu Tout-Puissant, source de sagesse, de force et de patience. C'est grâce à Sa volonté que j'ai pu mener à bien ce travail, malgré les difficultés, les doutes et les moments de fatigue. Sa présence dans ma vie m'a donné le courage d'avancer à chaque étape.

Je tiens à exprimer toute ma gratitude envers ma famille, en particulier mes chers parents, qui ont toujours cru en moi, m'ont soutenue moralement et matériellement, et n'ont jamais cessé de m'encourager, même dans les périodes les plus éprouvantes. Leur amour, leurs prières et leurs sacrifices silencieux sont le fondement de tout ce que j'ai pu accomplir.

À mes frères et sœurs, je dis merci pour leur présence affectueuse et leurs encouragements sincères, qui ont été pour moi un véritable soutien.

Je souhaite adresser des remerciements tout particuliers à mon fiancé, pour sa patience, son écoute, son soutien indéfectible et sa présence apaisante à mes côtés tout au long de cette période exigeante. Sa confiance en moi m'a donné la force de continuer, même dans les moments de doute et de découragement.

Je remercie très sincèrement mon encadrant universitaire, Monsieur Saoud Bilal, pour ses conseils avisés, son accompagnement rigoureux et sa disponibilité tout au long de ce travail. Ses orientations précieuses ont grandement contribué à la progression et à la qualité de ce mémoire.

Je tiens également à remercier l'ensemble du corps enseignant du Master Électronique des Systèmes Embarqués, pour la qualité de l'enseignement dispensé, qui m'a permis d'acquérir les compétences nécessaires à la réalisation de ce projet.

Enfin, je remercie du fond du cœur mes amis, qui ont joué un rôle essentiel dans cette aventure. Leur aide précieuse, leur soutien constant, leur disponibilité et leur solidarité m'ont profondément touchée. Ils ont été présents dans les moments de doute, de fatigue, et m'ont toujours tendu la main. Ce mémoire porte aussi leur empreinte.

Dédicace

Dédicace

Je dédie ce mémoire :

À mes chers parents, pour leur amour inconditionnel, leurs sacrifices silencieux, leur patience infinie et leur soutien sans faille. Ce travail est le reflet de tout ce que vous m'avez transmis.

À ma famille, en particulier mes frères et sœurs, pour leur affection, leurs encouragements constants et leur présence rassurante à mes côtés.

À mon fiancé, pour sa patience, son soutien moral et sa confiance en moi. Merci d'avoir cru en moi même dans les moments de doute.

À mes amis fidèles, qui m'ont accompagnée, soutenue, et motivée tout au long de ce parcours. Vos paroles, votre aide et votre amitié m'ont été précieuses.

À toutes celles et ceux qui, de près ou de loin, ont contribué à la réussite de ce mémoire.

Sommaire

[Sommaire](#)

[Remerciement](#)

[Dédicace](#)

LISTE DES TABLEAUX EST DES FIGURE

INTRODUCTION GENERALE ----- 1

CHAPITRE 1 :RADIOGRAPHIE THORACIQUES

1.1. INTRODUCTION :-	2
1.2. RADIOGRAPHIE THORACIQUES	2
1.3. PRINCIPE DE FONCTIONNEMENT	2
1.4. RADIOGRAPHIE NUMERIQUE DU THORAX	3
1.5. TRAVERSEE DU THORAX	3
1.6. DETECTION NUMERIQUE	4
1.7. CONVERSION ET TRAITEMENT DU SIGNAL	4
1.8. ANATOMIE ET PATHOLOGIES THORACIQUES VISIBLES EN RADIOGRAPHIE	5
1.8.1. PATHOLOGIES VISIBLES EN RADIOGRAPHIE THORACIQUE	5
1.9. RADIOLOGIE ET DIAGNOSTIC DU THORAX PAR RADIOGRAPHIE	6
1.10. CONCLUSION	7

CHAPITRE 2 : METHODES DE CLASSIFICATION

2.1. INTRODUCTION	8
2.2. FONDEMENTS DE LA CLASSIFICATION D'IMAGES	8
2.3. METHODES CLASSIQUES DE CLASSIFICATION	9
2.3.1. METHODES BASEES SUR LES CARACTERISTIQUES MANUELLES	9
2.4. METHODES D'APPRENTISSAGE PROFOND	10
2.4.1 RESEAUX DE NEURONES CONSOLATIFS (CNN)	10
2.4.2 RESEAUX PRE-ENTRAINES ET TRANSFERT D'APPRENTISSAGE	11
2.4.3 ARCHITECTURES AVANCEES	11
2.4.4 COMPARAISON ENTRE CNN ET METHODES TRADITIONNELLES	12
2.5 PRETRAITEMENT ET AMELIORATION DES PERFORMANCES	12
2.6 ÉVALUATION DES PERFORMANCES	13
2.7 CONCLUSION	14

CHAPITER 3 :NOTRE MODELE DE CLASSIFICATION D'IMAGE

3.1 INTRODUCTION -----	15
3.2 CHOIX DE L'ARCHITECTURE -----	15
3.1 PRETRAITEMENT DES DONNEES -----	16
3.4. STRUCTURE DU MODELE PROPOSE -----	17
3 .5. CONCLUSION -----	20

CONCLUSION GENERALE -----	21
----------------------------------	-----------

REFERENCES BIBLIOGRAPHIQUES

Liste des tableaux est des figure

TABLEAU :

TABLEAU 1: EFFETS DE L'ATTENUATION DES RAYONS X SUR L'IMAGE RADIOLOGIQUE.....	3
---	---

FIGURE :

FIGURE 1.1 : CONVERSION DIRECTE DES RAYONS X VIA LE SELENIUM AMORPHE ET LECTURE PAR MEMOIRE STIMULEE : LIBERATION DES ELECTRONS PIEGES SOUS BALAYAGE LASER ET EMISSION PHOTONIQUE	4
FIGURE 2.1 : EXEMPLE DU SVM.....	10
FIGURE 2.2 : EXEMPLE D'UTILISATION DU VGG.....	11
FIGURE 3.1: EXEMPLE D'IMAGE DE LA BASE DE DONNEES QUE NOUS AVONS UTILISEE DANS NOTRE ETUDE	16
FIGURE 3.2 SCHEMA DU NOTRE MODELE.....	18
FIGURE 3.3 : ÉVOLUTION DE LA PRECISION (GAUCHE) ET DE LA PERTE (DROITE) PENDANT L'APPRENTISSAGE	19
FIGURE 3.4 MATRICE DE CONFUSION DU MODELE SUR L'ENSEMBLE DE TEST	19

Introduction générale

Introduction Générale

Pneumonie est une maladie Infectieuse aiguë des poumons qui constitue une cause primordiale de morbidité et de mortalité à l'échelle mondiale. Des millions de personnes sont infectées chaque année, en grande majorité des enfants et des personnes âgées. Le diagnostic rapide et complet de la pneumonie est indispensable à une gestion efficace et pour restreindre les risques de complications majeures [1].

Historiquement, le diagnostic s'appuyait sur le feuilletage manuel des radiographies thoraciques par des radiologues expérimentés. Particulièrement, la lecture humaine est préjudiciable, fonction de la dextérité du praticien et longue dans certaines circonstances de surfilage hospitalier. Il démontre donc le besoin de développement de méthodes automatiques susceptibles de prétendre au rôle ou de prendre la place de la lecture humaine. Grâce aux avancées récentes en intelligence artificielle, en particulier dans le domaine de l'apprentissage profond (deep Learning), il est devenu possible de concevoir des modèles capables de classer automatiquement les radiographies thoraciques en détectant la présence ou l'absence de pneumonie avec une précision élevée [2, 3].

Cette étude a pour objectif de développer un modèle de classification automatique des radiographies thoraciques en deux classes : pneumonie et cas normaux. Nous avons proposé une architecture de réseau neuronal convolutif. Notre modèle a été testé et validé une base de données connue avec plus de 5000 images. Les résultats montrent l'efficacité de notre modèle.

Le manuscrit a été organisé en trois chapitres : Le premier chapitre présente les bases anatomiques et médicales des radiographies thoraciques, ainsi que leur importance dans le diagnostic de la pneumonie. Le deuxième chapitre est dédié à l'étude des modes variés de classification d'image, à savoir les méthodes classiques et récentes basées sur l'apprentissage automatique et l'apprentissage profond. En dernier lieu, le troisième chapitre montre notre contribution originale : un nouveau modèle de classification suggérée, sa conception, son évaluation, ainsi qu'une discussion sur les résultats obtenus.

Chapitre 1

Radiographie thoraciques

1.1. Introduction :

L'examen d'imagerie médicale le plus répandu au monde est la radiographie thoracique (CXR). Il est indispensable pour diagnostiquer diverses maladies pulmonaires et cardiaques. Cette méthode est rapide, économique et facilement accessible, toutefois son interprétation peut s'avérer complexe du fait de la superposition des structures anatomiques et de la variabilité entre différents observateurs. Les avancées récentes en matière d'intelligence artificielle, particulièrement grâce aux réseaux de neurones convolutif (CNN), proposent des perspectives encourageantes pour optimiser l'interprétation automatique des radiographies, en améliorant l'exactitude du diagnostic et en simplifiant l'accès aux soins [4].

1.2. Radiographique thoraciques

Les radiographies thoraciques, également appelées clichés thoraciques, sont des examens d'imagerie médicale qui utilisent les rayons X pour visualiser les structures internes du thorax, notamment les poumons, le cœur, les côtes, la trachée et le diaphragme. Elles représentent l'un des outils diagnostiques les plus couramment utilisés en médecine, permettant de détecter diverses pathologies pulmonaires (comme les infections, les tumeurs ou les affections chroniques), cardiaques et squelettiques. Rapide, peu coûteuse et non invasive, la radiographie thoracique constitue souvent une première étape essentielle dans l'évaluation de symptômes tels que la toux persistante, les douleurs thoraciques ou les difficultés respiratoires [4, 5].

1.3. Principe de fonctionnement

La radiographie thoracique repose sur l'utilisation des rayons X, émis sous forme d'un faisceau dirigé vers la région anatomique à examiner. Les rayons traversent les tissus du thorax, et en fonction de leur densité, ils sont absorbés en différentes proportions [6]. Dans la radiographie conventionnelle, les rayons X sont captés par un film ou une cassette après avoir traversé le corps. Dans la radiographie numérique, ils sont détectés par un capteur électronique, puis convertis en image numérique [7]. L'image obtenue est en niveaux de gris [8] :

- Les tissus très denses absorbent davantage les rayons X et apparaissent plus clairs (Blancs) sur l'image, comme les os (contenant du calcium) ou les métaux.
- Les tissus peu denses absorbent moins et apparaissent plus foncés, comme l'air dans les Poumons ou les graisses.
- L'eau et les tissus mous (muscles, moelle) apparaissent en gris moyen

Absorption des RX	Structure	Traduction radiographique
+	Air	Image noire
++	Graisse	Image gris foncé
+++	Tissu mou -eau	Image gris clair
++++	Calcification -os	Image blanche
+++++	Métal	Image blanche brillante

Tableau 1

Tableau 1: Effets de l'atténuation des rayons X sur l'image radiologique.

1.4. Radiographie numérique du thorax

La radiographie numérique thoracique est une technique d'imagerie médicale avancée qui utilise une faible dose de rayons X pour produire des images numériques détaillées des structures internes du thorax, telles que les poumons, le cœur, les os et les vaisseaux sanguins. Ce procédé combine l'émission de rayons X, leur traversée du corps, la détection électronique du signal, puis un traitement informatique sophistiqué permettant d'obtenir des images de haute qualité. Ces images, visualisées sur un écran, offrent aux professionnels de santé un outil précieux pour détecter, diagnostiquer et surveiller de nombreuses affections pulmonaires, cardiovasculaires et squelettiques, tout en réduisant l'exposition du patient aux radiations par rapport aux techniques analogiques traditionnelles [9, 10].

1.5. Traversée du thorax

Lors de l'examen radiographique, les rayons X émis traversent le thorax et interagissent différemment avec les divers tissus en fonction de leur densité. Les structures denses, comme les os, absorbent une grande partie des rayons X et apparaissent donc en blanc ou en clair sur l'image radiographique. À l'inverse, les zones remplies d'air, comme les poumons, laissent passer davantage de rayons, ce qui les rend plus sombres sur l'image finale. Cette variation d'atténuation permet de distinguer clairement les différentes structures anatomiques du thorax et de détecter d'éventuelles anomalies [12].

1.6. Détection numérique

Après avoir traversé le corps, le faisceau de rayons X atténué est capté par un détecteur numérique qui joue un rôle essentiel dans la transformation du signal en image exploitable. Ce détecteur convertit les rayons X en signal électrique selon deux principales technologies :

- **Conversion indirecte** : dans cette méthode, les rayons X sont d'abord transformés en lumière visible à l'aide d'un scintillateur (comme l'iodure de césium), puis cette lumière est convertie en signal électrique par des photodiodes. Ce procédé est couramment utilisé en raison de sa maturité technologique [13, 14].
- **Conversion directe** : ici, les rayons X sont directement convertis en charges électriques à l'aide d'un photoconducteur, typiquement du sélénium amorphe. Cette méthode permet d'obtenir une meilleure résolution spatiale, car elle évite la dispersion de la lumière intermédiaire, améliorant ainsi la netteté des images [13, 15].

Ces technologies de détection sont au cœur de la radiographie numérique moderne, offrant une qualité d'image élevée tout en optimisant la dose de rayonnement reçue par le patient.

1.7. Conversion et traitement du signal

Une fois capté par le détecteur, le signal analogique issu de l'interaction des rayons X avec les tissus est numérisé à l'aide d'un convertisseur analogique-numérique (CAN). Cette conversion permet de transformer le signal électrique en données numériques exploitables par des systèmes informatiques. Ces données sont ensuite traitées par des logiciels spécialisés qui optimisent la qualité de l'image en ajustant automatiquement le contraste, en réduisant le bruit électronique et en améliorant la netteté des contours anatomiques. De plus, des outils d'aide au diagnostic assisté par ordinateur (CAD - Computer-Aided Diagnosis) peuvent être intégrés pour assister les radiologues dans la détection et l'interprétation des anomalies, renforçant ainsi la précision et la rapidité du diagnostic médical [16]. La figure suivante montre ce processus.

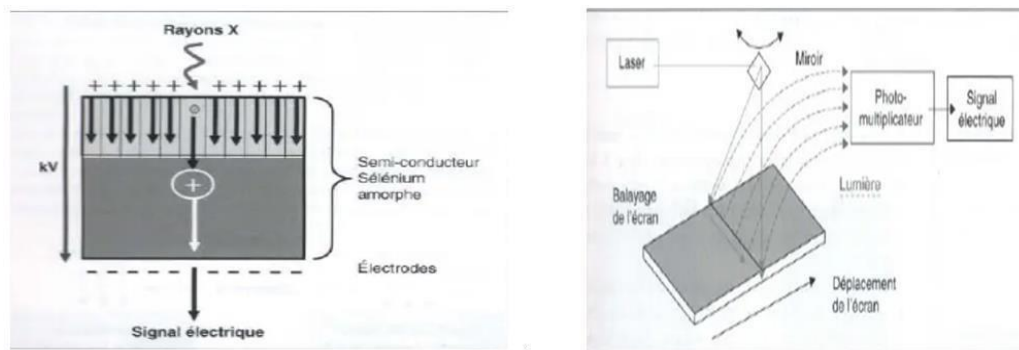


Figure 1.1 : Conversion directe des rayons X via le sélénium amorphe et lecture par mémoire stimulée : libération des électrons piégés sous balayage laser et émission photonique.

1.8. Anatomie et pathologies thoraciques visibles en radiographie

Le thorax est la partie du tronc située entre le cou et l'abdomen. Il forme une cavité osseuse et musculaire qui protège des organes vitaux comme le cœur, les poumons et les gros vaisseaux. Il est limité en haut par l'ouverture thoracique supérieure, en bas par le diaphragme, en avant par le sternum, en arrière par la colonne vertébrale thoracique, et sur les côtés par les côtes et les muscles intercostaux. Le squelette thoracique comprend le sternum, les douze paires de côtes (vraies, fausses et flottantes), ainsi que les vertèbres thoraciques. Les muscles principaux sont les intercostaux et le diaphragme, complétés par des muscles accessoires en cas de respiration forcée. Le thorax contient aussi les poumons, le cœur, la trachée, les bronches, l'œsophage et les gros vaisseaux [17, 18]. Le médiastin, situé entre les deux poumons, est divisé en parties supérieure et inférieure (antérieure, moyenne et postérieure).

Les fonctions du thorax incluent la protection des organes, la participation à la respiration et le passage de structures entre le cou et l'abdomen.

1.8.1. Pathologies visibles en radiographie thoracique

La radiographie thoracique permet de détecter de nombreuses pathologies pulmonaires, cardiaques, pleurales, osseuses et médiastinales.

Pathologies pulmonaires : La pneumonie se manifeste par des opacités alvéolaires localisées. La BPCO entraîne une hyperclarté, un thorax distendu et un aplatissement du diaphragme. La tuberculose produit des cavités, des adénopathies et des lésions fibreuses. Les tumeurs apparaissent comme des nodules ou masses. L'atélectasie provoque une rétraction pulmonaire visible par un déplacement des structures. Les lésions infiltrantes (fibrose, pneumopathies interstitielles) épaississent la trame pulmonaire.

Pathologies pleurales : L'épanchement pleural se traduit par une opacité basale homogène. Le pneumothorax se voit comme une hyperclarté sans trame vasculaire avec déplacement du poumon. La pleurésie entraîne une opacité unilatérale liée à l'accumulation de liquide.

Pathologies osseuses : Les fractures costales peuvent apparaître comme une discontinuité osseuse. Les déformations du rachis (scoliose, cyphose) modifient la symétrie thoracique. Les métastases osseuses créent des zones de lyse ou de condensation osseuse.

Pathologies cardiaques et vasculaires :

La cardiomégalie est définie par un indice cardiothoracique $> 50 \%$. L'insuffisance cardiaque se manifeste par un œdème pulmonaire et une redistribution vasculaire. L'anévrisme de l'aorte thoracique élargit le médiastin. Les calcifications vasculaires ou péricardiques apparaissent sous forme de dépôts visibles.

Pathologies médiastinales : Les adénopathies médiastinales élargissent les contours du médiastin. Les masses médiastinales (thymiques, kystiques, tumorales) se présentent comme des opacités bien limitées.

1.9. Radiologie et diagnostic du thorax par radiographie :

La radiographie thoracique est un examen d'imagerie médicale essentiel, largement utilisé en clinique pour son accessibilité, sa rapidité et son faible coût. Elle permet une visualisation globale du thorax, incluant les structures pulmonaires, cardiaques, médiastinales, pleurales et osseuses. Utilisée pour le dépistage, le diagnostic ou le suivi, elle s'avère particulièrement utile dans l'identification des pneumonies, des cardiomégalies, des épanchements pleuraux, des fractures costales ou encore des anomalies médiastinales. La qualité du diagnostic dépend notamment de l'incidence utilisée : postéro-antérieure (PA) chez les patients debout, antéro-postérieure (AP) pour les patients alités, ou latérale pour mieux localiser certaines anomalies. La radiographie numérique, quant à elle, améliore l'analyse grâce à des traitements d'image avancés, et peut être couplée à des algorithmes d'intelligence artificielle [19, 20].

L'interprétation suit généralement une méthode systématique (ABCDE), examinant successivement les voies aériennes, les structures osseuses, le cœur, le diaphragme et le reste du parenchyme pulmonaire et médiastinal. Malgré ses nombreux avantages, la radiographie thoracique présente des limites : superposition des structures anatomiques, sensibilité réduite pour certaines affections (ex. embolie pulmonaire), et nécessité fréquente de recours à des examens complémentaires comme le scanner. Néanmoins, en tant qu'outil de première ligne, elle reste incontournable dans l'évaluation thoracique en milieu clinique.

1.10. Conclusion

La radiographie thoracique demeure un outil fondamental de l'imagerie médicale pour l'exploration des affections pulmonaires, cardiovasculaires, pleurales, osseuses et médiastinales. Grâce à sa rapidité, son accessibilité et sa faible irradiation, elle constitue un examen de première intention incontournable dans la pratique clinique. Toutefois, malgré ses nombreux atouts, ses performances diagnostiques peuvent être limitées par la superposition des structures anatomiques, la subjectivité de l'interprétation humaine et la difficulté à détecter certaines anomalies subtiles. Ces contraintes justifient l'intérêt croissant pour l'intégration de technologies d'intelligence artificielle capables d'assister les radiologues, d'améliorer la précision des diagnostics et de réduire les erreurs liées à la fatigue ou aux biais cognitifs.

Chapitre 2 :

Méthodes de classification

2.1. Introduction

Au fil des dernières années, l'analyse automatisée des radiographies thoraciques est devenue un enjeu majeur dans le domaine médical, notamment pour détecter rapidement et avec précision des pathologies comme la pneumonie. Face à cet enjeu, l'intelligence artificielle s'est imposée comme un outil prometteur, en particulier grâce aux avancées du l'apprentissage automatique. Ces techniques permettent de traiter de grandes quantités d'images et d'en extraire des informations pertinentes de façon autonome. Dans ce chapitre, je vais présenter les principales méthodes de classification utilisées dans le cadre de l'analyse d'images médicales, en mettant l'accent sur celles qui ont contribué aux progrès récents dans la détection automatique de maladies pulmonaires. Ce survol théorique constitue une base essentielle pour comprendre le modèle développé dans la suite de ce mémoire.

2.2. Fondements de la classification d'images

La classification d'images est une tâche fondamentale du traitement d'images et de la vision par ordinateur, qui consiste à attribuer à chaque image une ou plusieurs étiquettes correspondant à des catégories prédéfinies. Cette opération repose sur l'analyse automatique du contenu visuel d'une image afin d'en extraire les informations discriminantes permettant de la reconnaître parmi un ensemble de classes [21]. Elle est largement utilisée dans de nombreux domaines, tels que la médecine (détection de pathologies sur des radiographies), l'agriculture (identification de plantes ou de maladies), la sécurité (reconnaissance faciale), ou encore l'industrie (contrôle qualité automatisé).

Le processus de classification d'images suit généralement plusieurs étapes clés. La première est le prétraitement, qui vise à améliorer la qualité des images (redimensionnement, filtrage, normalisation) et à réduire le bruit ou les artefacts susceptibles d'affecter l'analyse. Vient ensuite l'extraction de caractéristiques, étape essentielle où l'image est transformée en un ensemble de descripteurs numériques (textures, formes, couleurs, gradients, etc.) qui résument son contenu visuel. Ces caractéristiques sont ensuite utilisées par un classifieur, qui peut être un algorithme classique (comme les k-plus proches voisins, SVM ou arbres de décision) ou un modèle d'apprentissage profond (comme les réseaux de neurones convolutifs), pour prédire la classe à laquelle appartient l'image. Enfin, l'évaluation des performances permet de mesurer la qualité de la classification à l'aide de métriques comme la précision, le rappel ou la F-mesure.

La réussite de la classification dépend fortement de la qualité des données, du choix des caractéristiques, de la robustesse du classifieur, ainsi que des techniques de validation utilisées.

Avec l'essor du deep learning, les approches modernes tendent à automatiser l'extraction de caractéristiques, en s'appuyant sur de grands volumes de données annotées et sur des architectures de plus en plus performantes [22, 23].

2.3. Méthodes classiques de classification :

2.3.1. Méthodes basées sur les caractéristiques manuelles

Avant l'émergence de l'apprentissage profond, la classification d'images reposait principalement sur l'extraction manuelle de caractéristiques visuelles pertinentes permettant de représenter le contenu de l'image. Ces caractéristiques incluent généralement la couleur, la forme, la texture ou encore les contours présents dans l'image. Les descripteurs les plus couramment utilisés sont l'histogramme de couleurs (pour analyser la distribution des teintes), le HOG (*Histogram of Oriented Gradients*) qui capture les orientations locales des gradients utiles pour la détection d'objets, le LBP (*Local Binary Patterns*) utilisé pour la description des textures, ainsi que le SIFT (*Scale-Invariant Feature Transform*), qui permet de détecter et décrire des points d'intérêt robustes aux changements d'échelle et de rotation. Une fois extraites, ces caractéristiques sont transformées en vecteurs numériques qui serviront d'entrée à un algorithme de classification. Bien que puissantes dans certaines applications, ces méthodes présentent des limites : elles nécessitent une expertise humaine pour sélectionner les bons descripteurs et sont souvent sensibles aux variations d'éclairage, de perspective ou de bruit dans les images [24].

Les classifieurs traditionnels constituent les premières approches utilisées pour la classification d'images, une fois les caractéristiques extraites manuellement. Parmi eux, l'algorithme k-NN (K-Nearest Neighbors) est l'un des plus simples : il classe une image en fonction des classes des k voisins les plus proches dans l'espace des caractéristiques. Le SVM (Support Vector Machine), quant à lui, est un classifieur performant qui cherche à maximiser la marge entre les différentes classes à l'aide d'un hyperplan optimal, et peut être combiné à des noyaux pour gérer les cas non linéaires (voir la figure 2.1). Le Naïve Bayes, basé sur le théorème de Bayes, suppose l'indépendance conditionnelle des caractéristiques et offre de bonnes performances pour des problèmes simples et bien structurés. Les réseaux de neurones simples, comme les perceptrons multicouches (MLP), permettent d'apprendre des fonctions de décision à partir de données d'entrée numériques, mais restent limités pour les images complexes sans extraction préalable de caractéristiques. Enfin, les forêts aléatoires (Random

2.3.2. Classifieurs traditionnels :

Forest), qui combinent plusieurs arbres de décision entraînés sur des sous-ensembles aléatoires des données, sont robustes aux sur-apprentissages et efficaces pour la classification multiclasse. Bien que ces classifieurs soient aujourd'hui souvent surpassés par les approches profondes, ils demeurent utiles dans les contextes de petite taille de données ou de systèmes à faible complexité [26, 27].

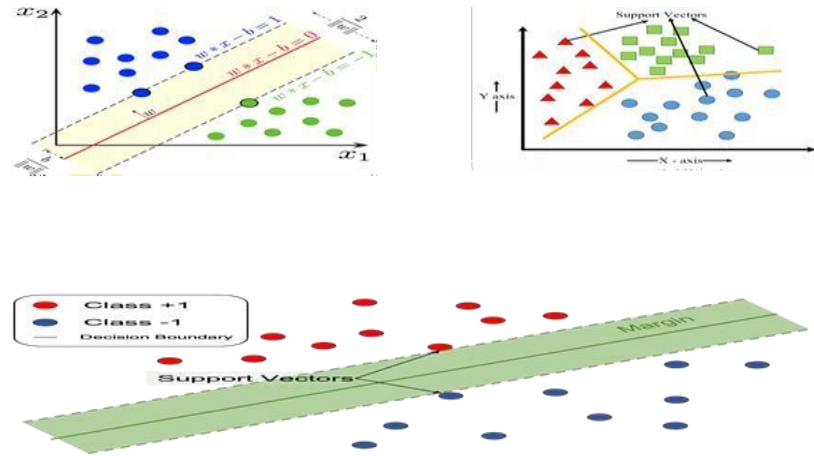


Figure 2.1 : Exemple du SVM

2.4. Méthodes d'apprentissage profond

L'émergence de l'apprentissage profond a révolutionné le domaine de la classification d'images en supprimant la nécessité d'une extraction manuelle des caractéristiques. Les modèles apprennent directement, à partir des pixels, des représentations complexes et hiérarchiques qui capturent automatiquement les informations discriminantes. Parmi ces modèles, les réseaux de neurones convolutifs (CNN) ont été les plus influents, avant l'essor récent des transformers visuels et des architectures hybrides.

2.4.1 Réseaux de neurones convolutifs (CNN)

Les CNN sont des architectures spécialement conçues pour traiter les données image en tenant compte de leur structure spatiale. Leur architecture générale comprend plusieurs couches: les couches de convolution qui détectent les motifs visuels (bords, textures, formes), les couches de pooling qui réduisent la taille des cartes de caractéristiques tout en conservant les informations importantes, et les couches fully connected (entièrement connectées) qui servent à la prise de décision finale. Grâce à leur capacité à apprendre des représentations hiérarchiques, les CNN ont montré d'excellentes performances dans de nombreuses tâches de classification d'images, y compris en médecine [27].

2.4.2 Réseaux pré-entraînés et transfert d'apprentissage

L'entraînement de CNN profonds nécessite de grandes quantités de données, ce qui n'est pas toujours disponible. Pour pallier ce problème, on utilise des modèles pré-entraînés sur de vastes bases de données comme ImageNet. Des architectures populaires telles que VGG, ResNet, Inception ou EfficientNet ont été largement adoptées. Le transfert d'apprentissage consiste alors à réutiliser ces modèles, soit en les utilisant comme extracteurs de caractéristiques (feature extraction), soit en ajustant partiellement ou totalement leurs poids sur de nouvelles données spécifiques (fine-tuning) [28]. Cette approche permet de bénéficier de la puissance des CNN tout en s'adaptant à des jeux de données plus restreints. La figure suivante montre un exemple d'utilisation du VGG.

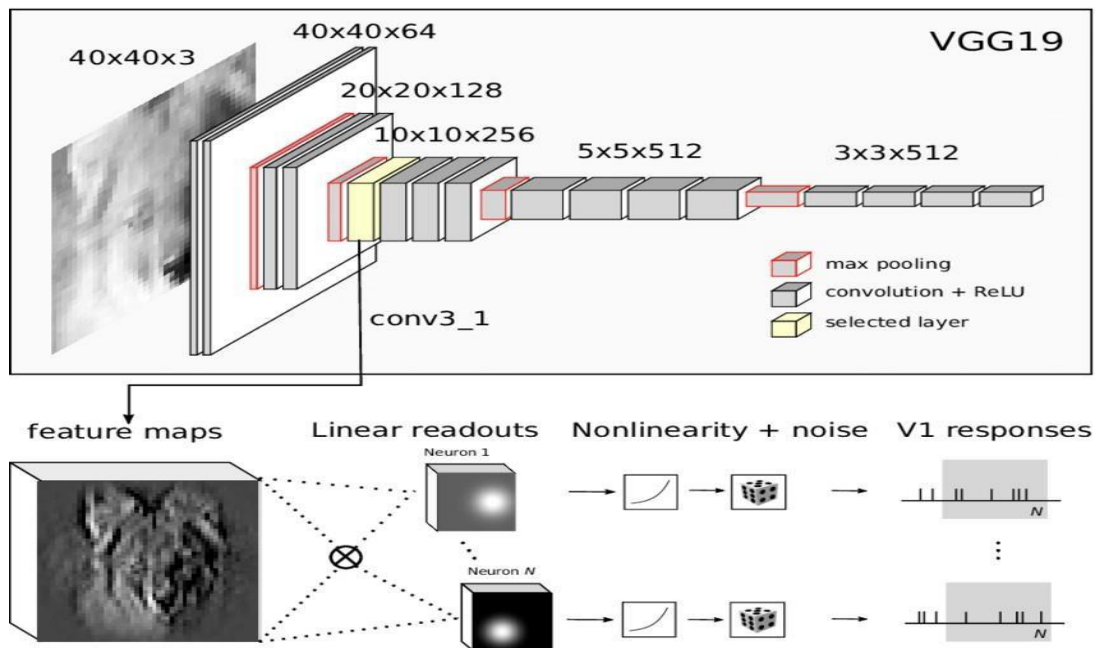


Figure 2.2 : Exemple d'utilisation du VGG.

2.4.3 Architectures avancées

Plus récemment, de nouvelles architectures ont émergé pour dépasser certaines limites des CNN. Les Vision Transformers (ViT) utilisent des mécanismes d'attention issus du traitement du langage pour analyser des patches d'images, sans convolutions, permettant une meilleure capture des relations globales dans l'image. D'autres modèles proposent une combinaison des deux approches, donnant naissance à des architectures hybrides CNN-Transformer qui exploitent à la fois l'efficacité locale des convolutions et la puissance de l'attention globale. Ces modèles montrent de très bonnes performances, notamment sur des images complexes ou contextuelles [29].

2.4.4 Comparaison entre CNN et méthodes traditionnelles

Comparées aux méthodes classiques basées sur des caractéristiques manuelles, les approches par CNN et deep learning offrent une meilleure précision, une généralisation plus robuste, et une capacité à traiter des images non structurées ou bruitées. Là où les méthodes traditionnelles exigent une expertise humaine pour concevoir les bons descripteurs, les CNN apprennent directement à extraire et combiner les caractéristiques optimales. Cependant, elles nécessitent davantage de ressources computationnelles et des jeux de données volumineux, ce qui peut représenter un frein dans certains contextes spécifiques.

2.5 Prétraitement et amélioration des performances

Avant d'entraîner un modèle de classification d'images, il est essentiel de préparer les données de manière adéquate afin d'en optimiser l'exploitation. Le prétraitement des images comprend généralement le redimensionnement, qui vise à uniformiser les dimensions des images d'entrée ; la normalisation, qui consiste à ramener les valeurs des pixels dans une plage standardisée (souvent entre 0 et 1) pour stabiliser l'apprentissage ; et l'augmentation de données, qui permet de générer artificiellement de nouvelles images par rotations, zooms, retournements ou modifications de luminosité. Ces techniques permettent d'augmenter la diversité du jeu d'entraînement, de réduire le sur-apprentissage et d'améliorer la généralisation du modèle [28, 29].

En complément, certaines techniques de régularisation sont intégrées aux architectures de réseaux de neurones pour éviter le surapprentissage. Le Dropout, par exemple, consiste à désactiver aléatoirement certains neurones pendant l'entraînement afin de forcer le réseau à ne pas dépendre uniquement de certaines connexions. La Batch Normalization, quant à elle, permet de normaliser les activations entre les couches du réseau, ce qui accélère la convergence et améliore la stabilité de l'apprentissage. Enfin, l'optimisation des performances passe par un choix judicieux des hyperparamètres (taux d'apprentissage, nombre de couches, taille du batch, etc.) et par des méthodes de validation telles que la validation croisée, qui permettent d'évaluer la robustesse du modèle sur différentes partitions des données. Ensemble, ces techniques jouent un rôle crucial dans l'obtention de modèles performants et généralisables.

2.6 Évaluation des performances

L'évaluation des performances d'un modèle de classification d'images est une étape essentielle pour juger de sa fiabilité, de sa capacité de généralisation et de sa pertinence en

contexte réel [27]. Plusieurs métriques de classification sont utilisées à cet effet. La précision (accuracy) mesure la proportion de prédictions correctes parmi l'ensemble des prédictions.

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

TP = Vrais positifs (*True Positives*) ; TN = Vrais négatifs (*True Negatives*) ; FP = Faux positifs (*False Positives*) ; FN = Faux négatifs (*False Negatives*).

Le rappel (recall) indique la capacité du modèle à identifier correctement les instances positives, tandis que la F1-score, qui est la moyenne harmonique de la précision et du rappel, offre un bon compromis entre les deux, surtout en cas de classes déséquilibrées.

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

$$F1 - score = 2 \times \frac{\text{Précision} \times \text{rappel}}{\text{Précision} + \text{rappel}}$$

La courbe ROC (Receiver Operating Characteristic) et la surface sous la courbe (AUC) sont également utilisées pour évaluer la performance globale d'un classifieur binaire en mesurant le compromis entre le taux de vrais positifs et de faux positifs.

Pour assurer une évaluation objective, différentes méthodes de validation sont appliquées. La méthode hold-out consiste à diviser le jeu de données en un ensemble d'entraînement et un ensemble de test. La validation croisée k-fold, plus robuste, divise les données en k sous-ensembles : à chaque itération, l'un est utilisé pour le test et les autres pour l'entraînement, garantissant une meilleure estimation des performances moyennes. La méthode leave-one-out est un cas particulier où chaque échantillon est tour à tour utilisé comme test, ce qui offre une évaluation très précise mais coûteuse en temps de calcul. En parallèle, une analyse des erreurs est souvent menée pour identifier les types de fautes les plus fréquentes, détecter d'éventuelles confusions entre classes et ajuster le modèle ou les données en conséquence. Ce processus est crucial pour améliorer la robustesse et la fiabilité du système de classification.

2.7 Conclusion

La classification d'images représente un domaine clé du traitement d'images et de l'intelligence artificielle, avec des applications variées et critiques, notamment en médecine, sécurité, et industrie. Ce chapitre a présenté les fondements du processus de classification, en détaillant les méthodes classiques basées sur l'extraction manuelle de caractéristiques et les

classifieurs traditionnels, ainsi que les approches modernes d'apprentissage profond, dominées par les réseaux convolutifs et les architectures avancées comme les Vision Transformers. L'importance du prétraitement, de l'optimisation des performances et de l'évaluation rigoureuse par des métriques adaptées a également été soulignée. Malgré les avancées technologiques, le choix de la méthode dépend fortement du contexte applicatif, de la qualité des données et des ressources disponibles. Ces éléments posent les bases pour la suite du mémoire, notamment en ce qui concerne l'automatisation du diagnostic médical à partir d'images radiographiques.

CHAPTER 3

Notre modèle de classification d'images

3.1 Introduction

Ce chapitre présente le modèle de classification d'images que nous avons conçu et implémenté dans le cadre de ce travail. Après avoir étudié les différentes approches théoriques de la classification, tant traditionnelles qu'à base d'apprentissage profond, nous proposons ici une solution adaptée à notre problématique spécifique. L'objectif principal est de développer un modèle performant, capable de classer efficacement des images selon les catégories définies, tout en assurant une bonne généralisation sur des données nouvelles. Nous décrirons dans les sections suivantes le choix de l'architecture du modèle, les méthodes de prétraitement appliquées aux données, les détails de l'implémentation, ainsi que les paramètres d'entraînement adoptés. L'évaluation du modèle sera également présentée à travers des métriques pertinentes et une analyse critique des résultats. Ce chapitre constitue ainsi la concrétisation pratique des fondements théoriques abordés précédemment.

3.2 Choix de l'architecture

Le modèle de classification proposé repose sur une architecture classique de réseau de neurones convolutif (CNN), largement utilisée dans les tâches de vision par ordinateur pour sa capacité à extraire automatiquement des caractéristiques discriminantes à partir d'images. Pour sa mise en œuvre, nous avons opté pour les bibliothèques TensorFlow et Keras, reconnues pour leur flexibilité, leur simplicité d'utilisation et leur compatibilité avec les architectures modernes.

Le réseau est conçu pour traiter des radiographies thoraciques, préalablement redimensionnées à 256×256 pixels et normalisées à l'aide d'un rescaling par un facteur de $1/255$. L'architecture comprend trois blocs convolution-pooling successifs. Le premier applique une couche Conv2D avec 32 filtres, suivie d'un MaxPooling2D. Le second bloc utilise 64 filtres, et le troisième, 128 filtres, chacun suivi d'un pooling pour réduire la dimensionnalité tout en conservant les caractéristiques essentielles. Les cartes de caractéristiques sont ensuite aplaties par une couche Flatten, puis transmises à une couche Dense de 128 neurones avec une activation ReLU, suivie d'un Dropout de 0,5 pour limiter le surapprentissage. Enfin, une couche de sortie Dense avec une activation sigmoid permet de distinguer deux classes : Normal et Pneumonia.

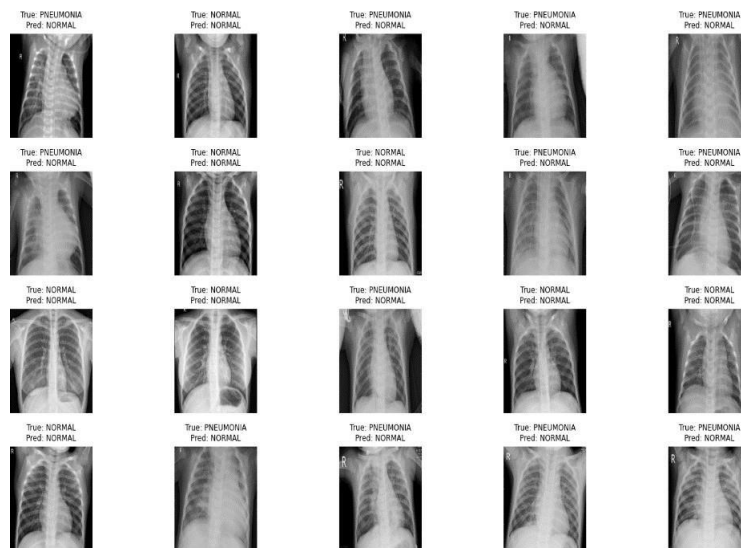
L'entraînement du modèle a été réalisé sur 10 époques, avec une taille de lot de 32, en utilisant l'optimiseur Adam et la fonction de perte `binary_crossentropy`, bien adaptée à la classification binaire. Ce choix d'architecture assure un bon équilibre entre complexité, précision et efficacité, tout en étant compatible avec les ressources matérielles disponibles.

3.1 Prétraitement des données

Le jeu de données utilisé pour l'entraînement du modèle provient de la plateforme Kaggle, sous le nom Chest X-Ray Images (Pneumonia) [30]. Il s'agit d'un jeu d'images radiographiques thoraciques classées en deux catégories : Normal et Pneumonia, ce qui en fait une base adaptée pour une tâche de classification binaire. Pour assurer une évaluation rigoureuse des performances, le jeu de données a été réparti en trois sous-ensembles : un ensemble d'entraînement (~5 216 images), un ensemble de validation (~578 images) extrait automatiquement depuis l'entraînement à l'aide d'un `validation_split` de 10 %, et un ensemble de test indépendant.

Les images ont été chargées et préparées à l'aide de la fonction `image_dataset_from_directory()` de TensorFlow, qui facilite le chargement structuré des images à partir d'un répertoire, tout en effectuant un redimensionnement automatique et une normalisation des pixels (valeurs comprises entre 0 et 1 grâce à la mise à l'échelle par `Rescaling(1./255)`). Ce traitement garantit l'uniformité des entrées pour le réseau de neurones et permet d'accélérer la convergence pendant l'apprentissage. Ce prétraitement joue un rôle fondamental pour optimiser la qualité des données d'entrée et, par conséquent, améliorer la robustesse et la précision du modèle final. La figure suivante donne un exemple d'image de notre base de données que nous avons sélectionnée.

Figure 3.1: Exemple d'image de la base de données que nous avons utilisée dans notre étude



3.4. Structure du modèle proposé

Le modèle de classification repose sur une architecture convolutive séquentielle, conçue pour extraire progressivement des caractéristiques discriminantes à partir des radiographies thoraciques. Il est composé de plusieurs couches empilées de manière hiérarchique, allant des couches de convolution aux couches entièrement connectées, adaptées à une classification binaire.

La première partie du réseau comprend trois blocs Conv2D–MaxPooling2D successifs. Le premier bloc applique une couche de convolution (Conv2D) avec 32 filtres, un noyau de taille 3×3 , et une fonction d'activation ReLU, suivie d'un MaxPooling2D pour réduire les dimensions spatiales. Le second bloc utilise 64 filtres, avec les mêmes paramètres de noyau et de pooling. Le troisième bloc, plus profond, contient 128 filtres, ce qui permet de capturer des motifs plus complexes. Ces couches extraient les caractéristiques visuelles à différents niveaux d'abstraction tout en conservant l'essentiel des informations.

Après la phase de convolution, les cartes de caractéristiques sont aplaties à l'aide d'une couche Flatten, puis transmises à une couche Dense de 128 neurones, également activée par ReLU, qui permet l'apprentissage de représentations non linéaires. Pour limiter le risque de surapprentissage, une couche Dropout avec un taux de 0.5 est insérée, désactivant aléatoirement une partie des neurones à chaque itération. La couche de sortie est une Dense avec une seule unité, utilisant une fonction d'activation sigmoid, ce qui convient parfaitement à une tâche de classification binaire (Normal vs Pneumonia).

Le modèle est entraîné avec la fonction de perte `binary_crossentropy`, adaptée aux tâches binaires, et optimisé à l'aide de l'algorithme Adam, réputé pour sa rapidité et sa capacité à ajuster dynamiquement le taux d'apprentissage. L'architecture ainsi conçue permet d'assurer un bon équilibre entre profondeur, précision et généralisation, tout en restant relativement légère et rapide à entraîner. Le schéma du notre modèle est représenté par la figure 3.2.

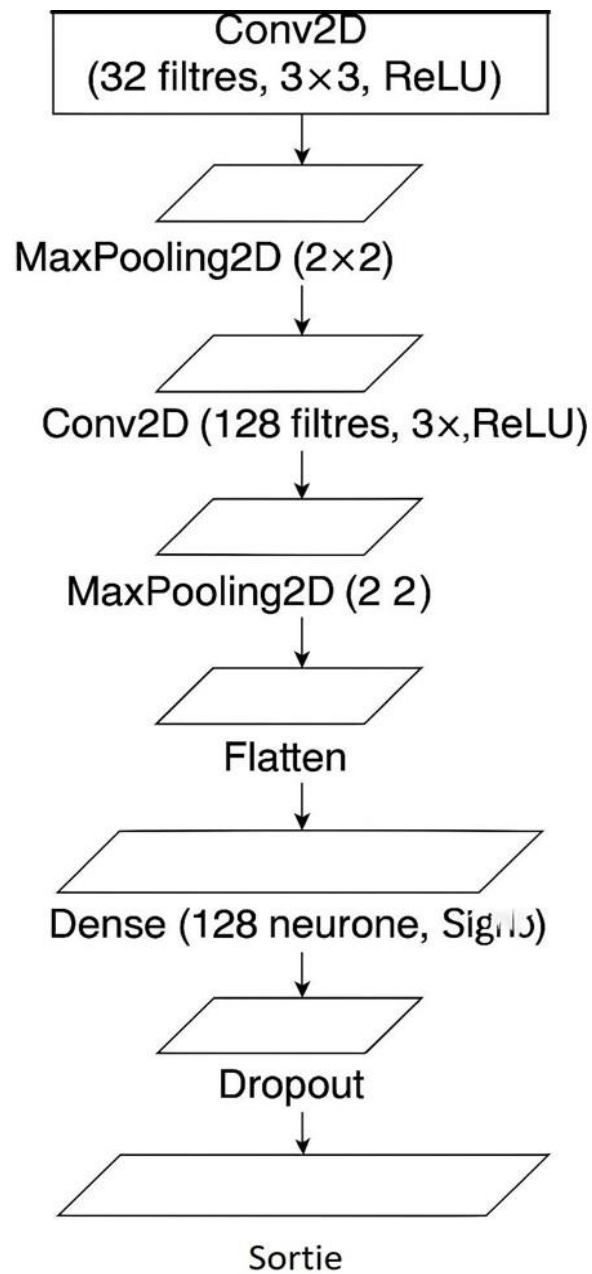


Figure 3 .2 schéma du notre modèle.

qui traduit une bonne capacité de généralisation. De même, la courbe de perte montre une diminution progressive sur les deux ensembles, sans signe apparent de surapprentissage.





Figure 3.3 : Évolution de la précision (gauche) et de la perte (droite) pendant l'apprentissage

La matrice de confusion révèle cependant une limitation importante du modèle : toutes les images de l'ensemble de test, qu'elles soient normales ou atteintes de pneumonie, sont systématiquement classées comme "PNEUMONIA". Cela se traduit par une sensibilité maximale (100 %) pour la classe "PNEUMONIA", mais une spécificité nulle pour la classe "NORMAL". Cette situation implique une incapacité du modèle à détecter les cas normaux, ce qui est problématique dans un contexte médical. Ces résultats mettent en évidence un déséquilibre de la performance par classe et soulignent la nécessité d'ajuster le modèle, notamment en retravaillant l'équilibre du jeu de données ou en ajustant les seuils de classification pour corriger ce biais.

Figure 3.4 :Matrice de confusion du modèle sur l'ensemble de test.



3.5. Conclusion

Dans ce chapitre, nous avons présenté en détail le développement de notre modèle de classification d'images basé sur un réseau de neurones convolutif (CNN) pour la détection de la pneumonie à partir de radiographies thoraciques. Nous avons justifié le choix de l'architecture, décrit le processus de prétraitement des données, la structure du modèle, les paramètres d'entraînement ainsi que les résultats obtenus. Bien que le modèle ait montré une excellente précision globale pendant l'entraînement et la validation, l'analyse fine des résultats, notamment à travers la matrice de confusion, a révélé un déséquilibre dans la classification des classes, indiquant une nécessité d'amélioration. Cette évaluation souligne l'importance de la robustesse des données, de la sensibilité aux classes minoritaires et d'une stratégie d'optimisation plus fine pour obtenir des performances fiables et généralisables. Ces observations constituent une base solide pour des ajustements futurs et l'intégration éventuelle d'approches plus avancées comme l'apprentissage par transfert ou des architectures hybrides.

Conclusion générale

La pneumonie demeure l'une des affections respiratoires les plus fréquentes et les plus redoutables, en particulier chez les populations vulnérables telles que les enfants et les personnes âgées. La radiographie thoracique s'impose comme un outil de référence pour le dépistage et le suivi de cette pathologie. Cependant, l'interprétation manuelle de ces examens présente des limites, notamment en termes de subjectivité, de lenteur et de charge de travail, surtout dans des contextes cliniques sous-dotés.

Ce mémoire a exploré l'apport de l'intelligence artificielle, et plus particulièrement des réseaux de neurones convolutifs (CNN), dans l'automatisation du diagnostic de la pneumonie. Après avoir exposé les principes de la radiologie thoracique et les différentes approches de classification d'images, nous avons proposé un modèle CNN simple mais efficace, entraîné sur un jeu de données issu de radiographies pulmonaires. Les résultats obtenus montrent une bonne capacité de détection des cas pathologiques.

Plusieurs pistes d'amélioration s'ouvrent : recours à des modèles préentraînés via le transfert d'apprentissage, enrichissement des données par augmentation et segmentation, ou encore expansion de la base de données. Ces perspectives permettraient de renforcer la robustesse et la précision du modèle.

Ce travail met en lumière le potentiel considérable de l'IA pour assister les professionnels de santé, en contribuant à un diagnostic plus rapide, plus fiable et moins dépendant de l'expertise humaine. Toutefois, une validation clinique rigoureuse reste indispensable avant toute application à grande échelle.

Références bibliographiques

Références bibliographiques

- [1] Y. Lahmouz, "Les caractéristiques immuno-virologiques et thérapeutiques de l'infection à VIH-1 chez une cohorte de patients suivis au Centre de Virologie et de Maladies Infectieuses et Tropicales à l'Hôpital Militaire Mohamed V de Rabat," Thèse de doctorat, Université non précisée, 2021.
- [2] P. Fener and C. Criton, "Manifestations cliniques et biologiques de l'infection à VIH/sida chez la femme," Thèse de doctorat, INIST-CNRS, 2007.
- [3] P. Fener and C. Criton, "Manifestations cliniques et biologiques de l'infection à VIH/sida chez la femme," Thèse de doctorat, INIST-CNRS, 2007.
- [4] D. P. Balla, "Le diagnostic anténatal chromosomique," Thèse de doctorat, 2014.
- [5] F. Liehr, "Open Archive Toulouse Archive Ouverte," OATAO. [En ligne]. Disponible sur: <https://oatao.univ-toulouse.fr>. [Consulté le: jj/mm/aaaa].
- [6] D. Abdenneb, "L'effet de maintenance préventive des capteurs sur la rentabilité de divers dispositifs médicaux," Thèse de doctorat, Université de Ghardaïa, 2020.
- [7] M. F. Devaux, A. Sire, and P. Papineau, "Macrovision et analyse granulométrique en niveaux de gris pour l'analyse histologique de tissus végétaux," *NOV'AE - Ingénierie et savoir-faire innovants*, Cahier des techniques, pp. 93-100, 2009.
- [8] T. Lymohamed and O. A. Sow, "Les nouveaux métiers liés à l'usage des technologies d'information et de la communication dans le domaine de la santé en Algérie : Cas de l'Hôpital Chahids Mahmoudi (HCM) de Tizi-Ouzou," Thèse de doctorat, Université Mouloud Mammeri, 2022.
- [9] T. Lymohamed and O. A. Sow, "Les nouveaux métiers liés à l'usage des technologies d'information et de la communication dans le domaine de la santé en Algérie : Cas de l'Hôpital Chahids Mahmoudi (HCM) de Tizi-Ouzou," Thèse de doctorat, Université Mouloud Mammeri, 2022
- M
- [10] . E. H. I. D. I. Abdallah, "Imagerie médicale," Document non publié.
- [11] S. Drif, "Calculs dosimétriques des faisceaux de rayons X dans une radiothérapie externe," Mémoire de master, 2019.
- [12] A. H. Chehade, "Détection et classification multi-label de maladies pulmonaires par apprentissage automatique à partir d'images de radiographie thoracique," Thèse de doctorat, Université d'Angers, 2024.
- [13] J. B. Perraud, "Reconstructions rapides d'images en régime térahertz 3D," Thèse de doctorat, Université de Bordeaux, 2018.
- [14] C. Grignon, "Étude et développement d'un télescope Compton au xénon liquide dédié à l'imagerie médicale fonctionnelle," Thèse de doctorat, Université de Nantes, 2007.
- [15] M. Coulomb, G. Ferretti, R. Guillemaud, and F. Thony, "Technologie – Radiographie numérique," *Feuilles de Radiologie*, vol. 40, no. 2, pp. 83-105, 2000.
- [16] D. Ménard, "Méthodologies de conversion automatique en virgule fixe pour les applications de traitement du signal," École Thématique ARCHI03, p. 68, 2003.
- [17] B. Samia, "Segmentation d'images par seuillage non paramétrique d'histogrammes couleur," Thèse de doctorat, Université Mouloud Mammeri, 2015.
- [18] A. Waugh and A. Grant, *Ross et Wilson – Anatomie et physiologie normales et pathologiques*, 14e éd., Elsevier Health Sciences, 2023.),
- [19] "Troubles ORL – Les présentations cliniques," [En ligne]. Disponible sur: (URL à compléter). [Consulté le: jj/mm/aaaa].
- [20] O. El Masfioui, "Aspects cliniques et chirurgicaux des goitres plongeants : Expérience du service de chirurgie thoracique de l'hôpital militaire Moulay Ismail-Meknès (environ 40 cas)," Thèse de doctorat, 2020.
- [21] Kokal, O., Saoud, B., Shayea, I., & Batkuldin, A. (2024, July). Chest X-ray Classification Based on Deep Neural Network. In 2024 IEEE 3rd World Conference on Applied Intelligence and Computing (AIC) (pp. 71-75).

Références bibliographiques

- [22] Buluş, F., Saoud, B., Shayea, I., & Syzdykova, Z. (2024, July). Machine Learning Algorithms for Predicti Chronic Diseases. In 2024 IEEE 3rd World Conference on Applied Intelligence and Computing (AIC) (pp. 1007-1012). IEEE.
- [23] Saroğlu, H. E., Shayea, I., Saoud, B., Azmi, M. H., El-Saleh, A. A., Saad, S. A., & Alnakhli, M. (2024).Machine learning, IoT and 5G technologies for breast cancer studies: A review. Alexandria engineering journal, 89, 210- 223.
- [24] Routray, S., Ray, A. K., & Mishra, C. (2017, February). Analysis of various image feature extraction methods against noisy image: SIFT, SURF and HOG. In 2017 Second International Conference on Electrical, Computer and Communication Technologies (ICECCT) (pp. 1-5). IEEE.
- [25] Dinesh, P., Vickram, A. S., & Kalyanasundaram, P. (2024, May). Medical image prediction for diagnosis of breast cancer disease comparing the machine learning algorithms: SVM, KNN, logistic regression, random forest and decision tree to measure accuracy. In AIP Conference Proceedings (Vol. 2853, No. 1). AIP Publishing.
- [26] Sajitha, P., Andrushia, A. D., Anand, N., & Naser, M. Z. (2024). A review on machine learning and deep learning image-based plant disease classification for industrial farming systems. Journal of Industrial Information Integration, 38, 100572.
- [27] Archana, R., & Jeevaraj, P. E. (2024). Deep learning models for digital image processing: a review. Artificial Intelligence Review, 57(1), 11.
- [28] Wang, J., Wang, S., & Zhang, Y. (2025). Deep learning on medical image analysis. CAAI Transactions on Intelligence Technology, 10(1), 1-35.
- [29] Xu, Y., Quan, R., Xu, W., Huang, Y., Chen, X., & Liu, F. (2024). Advances in medical image segmentation: a comprehensive review of traditional, deep learning and hybrid approaches. Bioengineering, 11(10), 1034.
- [30] <https://www.kaggle.com/>

Résumé

La pneumonie représente l'une des principales causes de morbidité et de mortalité dans le monde, en particulier chez les populations vulnérables. La radiographie thoracique constitue un outil de diagnostic clé pour la détection de cette pathologie, mais son interprétation manuelle reste sujette à la subjectivité et à des erreurs potentielles, notamment en cas de surcharge des professionnels de santé. Ce mémoire présente le développement d'un modèle de classification automatique des images radiographiques pulmonaires en deux catégories : cas normaux et pneumonie. Nous avons conçu un réseau de neurones convolutif (CNN) simple à l'aide de TensorFlow et Keras, comprenant des couches de convolution, de pooling et des couches entièrement connectées, avec un entraînement sur un jeu de données public (Chest X-Ray Images de Kaggle). Les résultats obtenus montrent une accuracy de 0,76. Ce travail confirme le potentiel de l'intelligence artificielle pour assister le diagnostic radiologique et appelle à des validations cliniques plus poussées avant un déploiement en pratique.

Abstract

Pneumonia remains one of the leading causes of morbidity and mortality worldwide, especially among vulnerable populations. Chest X-ray imaging is a key diagnostic tool for detecting this condition, but manual interpretation is often subjective and prone to errors, particularly in overloaded healthcare settings. This thesis presents the development of an automatic classification model for chest radiographs into two categories: normal and pneumonia cases. We designed a simple convolutional neural network (CNN) using TensorFlow and Keras, integrating convolutional, pooling, and fully connected layers, and trained it on a public dataset (Chest X-Ray Images from Kaggle). The results show an accuracy of 0.76. This work confirms the potential of artificial intelligence to support radiological diagnosis and underscores the need for further clinical validation before widespread deployment.