

N° d'ordre :
N° de série :

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



UNIVERSITE ECHAHID HAMMA LAKHDAR - EL OUED
FACULTÉ DES SCIENCES EXACTES
Département D'Informatique



Mémoire de Fin D'étude
Présenté pour l'obtention du Diplôme de

MASTER ACADEMIQUE

Domaine : **Mathématique et Informatique**
Filière : **Informatique**
Spécialité : **Systemes Distribués et Intelligence Artificielle**

Présenté par :

- **BELHADI Mehdi**
- **TOUMI Ali**

Thème

**Les paradigmes de l'intelligence
artificielle en vue de la détection de
Covid-19**

Soutenue le 16-06- 2022 Devant le jury:

M.	Dr BOUCHRIET AMMAR	MCA	Président
M.	BERDJOUH CHAFIK	MAA	Rapporteur
M.	Dr. HAMOUD MERIEM	MAA	Encadreur

Année Universitaire: 2021/2022

Remerciement

En fin de ce travail, nous remercions d'abord Dieu de nous avoir donné la volonté et la patience, qui nous a accordé le succès, pour terminer ce travail.

Nous tenons aussi à exprimer notre profonde gratitude au le **Dr HAMOUD MERIEM** que nous fournis des informations sous encadrer de notre recherches, et de m'avoir accepté, supporté et soutenu physiquement et moralement sans relâche pendant les bons et les mauvais moments pendant cette recherche .

Nous remercions également sincèrement tous les professeurs du Département d'informatique.

Mehdi Et Ali



DEDICACE

Je dédie ce mémoire à :

Mes chers parents à qui je dois tout ce que j'ai acquis dans la vie.

Mes frères et mes sœurs, à qui je souhaite beaucoup de réussites dans la vie

Toute ma famille.

Toute mes amis

Mehdi Et Ali



Abstract

In December 2019, the world was hit by COVID-19 pandemic consisting of an overwhelming challenge for the medical community around the globe. Indeed, it is critical to predict the COVID-19 pandemic due to the virus's tremendous transmission capacity and potential harm.

To tackle the effects of the outbreak; artificial intelligence, machine learning and deep learning based methods gained immense momentum in the early screening since they have introduced new breakthroughs in the healthcare field and becoming the cutting-edge medical image analysis tools with outstanding performance.

The main goal of the present work is to introduce the first representation-learning approach specifically built for obtaining an effective and reliable assessment of COVID-19 disease severity via automated CXR interpretation. Indeed, we deal firstly with lungs segmentation based U-net model which consists of an essential advance to remove the unnecessary background because, based on medical experience, the lesions caused by COVID-19 are not situated outside the lungs.

Secondly, the classification framework based SVM algorithm is implemented to detect COVID-19 infection by power laws models of Zipf and inverse Zipf with Gabor filters for texture characterization.

The suggested approach has the ability to distinguish among X-rays of COVID-19, viral pneumonia, bacterial pneumonia and a healthy person with high accuracy.

Key words: COVID-19, X-rays, Preprocessing, CAD systems, Lungs,

Résumé

En décembre 2019, le monde a été frappé par la pandémie de COVID-19 consistant en un défi écrasant pour la communauté médicale du monde entier. En effet, il est essentiel de prévoir la pandémie de COVID-19 en raison de l'énorme capacité de transmission du virus et de ses dommages potentiels.

Pour faire face aux effets de l'épidémie, les approches basées sur l'intelligence artificielle, l'apprentissage automatique et sur l'apprentissage profond ont pris un immense élan dans le dépistage précoce, du fait qu'elles ont introduit de nouvelles percées dans le domaine de la santé et sont devenues les outils d'analyse d'images médicales de pointe avec des performances exceptionnelles.

L'objectif principal de ce travail est de suggérer une approche dans le but d'obtenir une évaluation efficace et fiable de la gravité de la maladie de COVID-19 via une interprétation automatisée de la CXR. En effet, nous traitons d'abord la segmentation pulmonaire par le modèle U-net qui consiste en une avancée essentielle pour éliminer les parties inutiles car, d'après l'expérience médicale, les lésions causées par le COVID-19 ne sont pas situées à l'extérieur des poumons.

Deuxièmement, une classification basée l'algorithme SVM est mis en œuvre pour détecter l'infection au COVID-19 par des modèles de lois puissance de Zipf et de Zipf inverse avec des filtres de Gabor pour la caractérisation de la texture.

L'approche suggérée a la capacité de faire la distinction entre les images échographiques de COVID-19, de la pneumonie virale, de la pneumonie bactérienne ainsi qu'une personne en bonne santé avec une grande précision.

Mots clés : COVID-19, Rayons X, Prétraitement, Systèmes CAO, Poumons.

الملخص

في ديسمبر 2019، تعرض العالم لوباء COVID-19 الذي شكل تحدياً ساحقاً للمجتمع الطبي في جميع أنحاء العالم. في الواقع، يعد التنبؤ بجائحة COVID-19 ضرورياً نظراً لقدرة انتقال الفيروس الهائلة وأضراره المحتملة.

لتعامل مع آثار الوباء، اكتسبت الأساليب القائمة على الذكاء الاصطناعي والتعلم الآلي والتعلم العميق زخماً هائلاً في الكشف المبكر، حيث أدخلت اختراقات جديدة في مجال الصحة وأصبحت أدوات تحليل الصور الطبية المتطورة باستخدام أداء استثنائي.

الهدف الرئيسي من هذا العمل هو اقتراح نهج من أجل الحصول على تقييم فعال وموثوق لشدة مرض COVID-19 من خلال تفسير آلي لـ CXR. في الواقع، نعالج أولاً تجزئة الرئة من خلال نموذج U-net الذي يتكون من تقدم أساسي للتخلص من الأجزاء غير الضرورية، لأنه وفقاً للخبرة الطبية، لا توجد الآفات التي يسببها COVID-19 خارج الرئتين.

ثانياً، يتم تطبيق خوارزمية SVM تعتمد على التصنيف للكشف عن عدوى COVID-19 بواسطة Zipf ونماذج قانون الطاقة Zipf المعكوسة مع مرشحات Gabor لتوصيف النسيج.

النهج المقترح لديه القدرة على التمييز بين صور الموجات فوق الصوتية لـ COVID-19 والالتهاب الرئوي الفيروسي والالتهاب الرئوي الجرثومي وكذلك الشخص السليم بدقة عالية.

الكلمات الأساسية: COVID-19، الأشعة السينية، المعالجة المسبقة، أنظمة CAD، الرئتين.

Abréviations

IA	Intelligence Artificielle
Covid-19	Coronavirus 2019
ML	Machine Learning
DL	Deep Learning
SVM	Support Vector Machine
KNN	K Nearest Neighbor
CNN	Convolutional Neural Network
RGB	Red Green Blue
U-NET	U Network
ReLU	Rectified Linear Unit
VGG	Visual Geometry Group
ILSVRC	ImageNet Large Scale Visual Recognition Challenge
ResNet	Residual Neural Network
CXR	Chest X-Ray
CT	Computed Tomography
CAD	Computer Aided Diagnosis
SARSCoV- 2	Coronavirus-2 du Syndrome Respiratoire Aigu Sévère

WHO	World Health Organization
CoV	CoronaVirus
MERS-CoV	Middle East Respiratory Syndrome Coronavirus
SARS-CoV-2	Severe Acute Respiratory Syndrome Coronavirus -2
RT-PCR	Reverse Transcription Polymerase Chain Reaction
IRM	Imagerie par Résonance Magnétique
TDM	Tomodensitométrie
ROI	Region Of Interest
GLSZM	Grey-Level Size Zone Matrix
DNN	DotNetNuke
LSTM	Long Short-Term Memory
DeTraC	Decompose Transfer and Compose
CLAHE	Contrast Limited Adaptive Histogram Equalization
GGO	Ground-Glass Opacification
HTML	HyperText Markup Language
CSS	Cascading Style Sheets
W3C	World Wide Web Consortium
XML	eXtensible Markup Language

Sommaire

Titre	Page
Remerciement	-
Dédicace	-
Résumé	-
Sommaire	I
Liste de figure	III
Liste de tableaux	VI
Introduction Générale	02
Chapitre I: L'analyse d'image, la vision par ordinateur, l'apprentissage automatique et l'apprentissage profond : préambule	
I.1 Introduction	06
I.2 La vision par ordinateur	07
I.3 L'analyse d'image	07
I.4 Analyse de la texture d'image	08
I.5 Les nouvelles tendances de l'apprentissage automatique et l'apprentissage profond	09
I.6. Les modèles des réseaux de neurone convolutifs	16
I.7 Conclusion	20
Chapitre II: détection assistée par ordinateur du COVID-19	
II.1 Introduction	22
II.2 La pandémie de Covid-19	23
II.3 Les maladies pulmonaires	24
II.4 Détection de covid-19	25
II.5 Limites des images échographiques en vue de la détection de Covid-19	29
II.6 Diagnostic automatique (CAD) de Covid-19	30

II.7 Etat de l'art sur l'application de l'apprentissage automatique pour la détection de Covid-19	33
II.8 Etat de l'art sur l'application de l'apprentissage profond pour la détection de Covid-19	36
II.9 Conclusion	38
Chapitre III: Problématique extraite et approche suggérée	
III.1 Introduction	40
III.2 Problématique et plan d'action	41
III.3 Segmentation pulmonaire au sain des radiographies thoraciques basée Deep Learning	43
III.4 Classification des régions pulmonaires basée SVM	52
III.5 Aperçu schématique de l'approche proposée	64
III.6 Conclusion	65
Chapitre IV : Evaluation des résultats obtenus	
IV.1 Introduction	67
IV.2 Environnement de développement et outils utilisés	68
IV.3 Evaluation de l'approche proposée de détection de Covid-19	74
IV.4 Interface réalisée pour les approches proposées	81
IV.5 Conclusion	84
Conclusion générale	86
Références Bibliographiques	89

LISTE DE FIGURES

N	Figure	Page
CHAPITRE I		
Figure I.1	Exemple d'un réseau de neurones	11
Figure I.2	Hyperplan à marge maximale et marges par rapport à un SVM bâtie sur des échantillons de deux classes	12
Figure I.3	L'architecture d'un réseau de neurones convolutif.	14
Figure I.4	Processus de la convolution	15
Figure I.5	Exemples d'un max pooling ainsi qu'un average pooling	15
Figure I.6	6 Architecture du modèle U-NET	17
Figure I.7	Architecture de ResNet. Source	18
Figure I.8	Architecture de VGG-16	19
CHAPITRE II		
Figure II.1	Répartition des cas de Covid-19 dans le monde	23
Figure II.2	Radiographies thoraciques de patients infectés par COVID-19 : (a) opacités floues diffuses mal définies (flèches noires) ; (b) maladie pulmonaire diffuse et épanchement pleural droit (flèches noires); (c) opacités floues subtiles et mal définies du côté droit (flèches noires); (d) opacités pulmonaires périphériques gauches moyennes à inférieures (flèches noires)	26
Figure II.3	Les tomodensitogrammes au début de la phase rapide et progressive de Cas de COVID-19. a : GGO au quatrième jour. b : GGO plus consolidation au troisième jour. c : GGO le deuxième jour	27
Figure II.4	Fonctionnalités d'un système d'aide au diagnostic médical assisté par ordinateur (CAD)	30
Figure II.5	Impact de l'apprentissage profond sur le traitement d'images médicales pour lutter contre la pandémie de COVID-19	33
CHAPITRE III		
Figure III.1	Radiographies thoraciques avec leur msques pulmonaires de la	44

	base de donnée COVID-QU-Ex	
Figure III.2	Radiographies thoraciques relatives à : (a) cas sain, (b) Covid-19, (c) Pneumonie virale et (d) Pneumonie bactérienne	45
Figure III.3	Exemple de l'application d'un prétraitement par le filtre médian : à gauche les radiographies thoraciques originales et à droite le résultat du prétraitement	47
Figure III.4	Exemple de l'application d'un prétraitement par le CLAHE pour l'amélioration du contraste qui sera suivi par le filtre médian pour rehausser les contours : à gauche les radiographies thoraciques originales et à droite le résultat du prétraitement	48
Figure III.5	Architecture du modèle U-Net.	51
Figure III.6	Pipeline suivi pour la classification des régions d'intérêt	53
Figure III.7	Courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19	55
Figure III.8	Courbes de Zipf et de Zipf inverse d'un poumon sain	56
Figure III.9	Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie virale	57
Figure III.10	Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie bactérienne	58
Figure III.11	Les divers filtres de Gabor appliqués dans le domaine fréquentiel	62
Figure III.12	Parties réelles des filtres de Gabor utilisés	62
Figure III.13	Parties réelles des régions d'intérêt filtrées	63
Figure III.14	Magnitude de la réponse du filtre de Gabor suite à la convolution de la tumeur maligne avec une banque de filtres de Gabor	63
Figure III.15	Schématisation du pipeline de l'approche proposée de détection du Covid-19.	64
CHAPITRE IV		
Figure IV.1	logo Kaggle	68
Figure IV.2	logo python	69
Figure IV.3	Logo HTML5	71

Figure IV.4	Logo CSS3	72
Figure IV.5	Logo JavaScript	73
Figure IV.6	Entraînement et validation de l'accuracy	74
Figure IV.7	Entraînement et validation de loss	74
Figure IV.8	Courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19	75
Figure IV.9	Courbes de Zipf et de Zipf inverse d'un poumon sain	76
Figure IV.10	Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie virale	77
Figure IV.11	Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie bactérienne	78
Figure IV.12	Entraînement et validation de l'accuracy	79
Figure IV.13	Entraînement et validation de loss	79
Figure IV.14	Une comparaison entre la première et la deuxième expérience	80
Figure IV.15	Fenêtre principale (home) des approches proposées	81
Figure IV.16	Choix du modèle Covid-19/Pneulonia/normal lung	82
Figure IV.17	Choix de l'échographie thoracique de modèle Covid-19/Pneulonia/normal lung. L'échographie thoracique sera téléchargée dans l'interface	82
Figure IV.18	Téléchargement de l'échographie thoracique de modèle Covid-19/Pneulonia/normal lung	83
Figure IV.19	Segmentation de la lésion pulmonaire et réalisation de la classification où nous pouvons affirmer que l'approche a classifié correctement la lésion comme spécifique au Covid19	83

Liste de tableaux

N	Tableaux	Page
Chapitre II		
Tableau II.1	Approches CAD basées apprentissage automatique (Machine Learning) de détection du Covid-19	34
Tableau II.2	Approches CAD basées apprentissage profond (Deep learning) pour la détection du Covid-19.	36
Chapitre IV		
Tableau IV.1	Caractéristique de matériel de programmation	68
Tableau IV.2	Caractéristique de Kaggle	68
Tableau IV.3	Evaluation de l'approche proposée de détection de Covid-19	81

Introduction générale

Introduction générale

Depuis décembre 2019, le coronavirus (COVID-19) a causé de nombreux cas de décès et a touché tous les secteurs de la vie humaine. Avec une progression progressive du temps, COVID-19 a été déclaré par l'organisation mondiale de la santé comme une épidémie, qui a imposé un lourd fardeau à presque tous les pays [1]. Le Coronavirus est une maladie virale qui provoque une pneumonie grave et affecte les différentes parties du corps, de légère à sévère, selon le système immunitaire du patient.

Ce virus dangereux peut se transmettre facilement d'une personne à l'autre en contact étroit par des gouttelettes respiratoires. La présentation des symptômes commence du jour 2 à la période de 14 jours après un contact étroit avec une personne infectée. La plupart des gens exploreront des symptômes légers à modérés et pourront récupérer sans hospitalisation et pour les personnes âgées et les patients atteints d'une autre maladie peuvent nécessiter une hospitalisation. Les symptômes initiaux comprennent la toux, les frissons, les maux de tête, les douleurs corporelles, la fièvre, la faiblesse, la perte d'appétit et les symptômes graves comprennent des problèmes respiratoires tels que la lourdeur de la poitrine, la ségrégation des expectorations sèches entraîne des difficultés respiratoires et peut finalement entraîner la mort.

Les situations pandémiques COVID-19 posent plusieurs limites aux interventions humaines dans la gestion de la situation. Toutes les complications du risque de transmission de maladie aux professionnels de la santé pour retarder la détection et l'isolement des patients peut être mieux géré en utilisant une application appropriée de la technologie. Les études basées sur l'IA, l'apprentissage automatique et profond appliquées sur les maladies pulmonaires indiquent que le diagnostic de COVID-19 peut être plus rapide et cohérent avec ces techniques [2].

Covid-19 est détecté en effectuant un test RT-PCR (réaction en chaîne par polymérase de transcription inverse) en prélevant des échantillons de gorge et de nez des patients, ce qui prend 2,3 jours pour obtenir les résultats en raison du manque de disponibilité des ressources et les tests doivent être réalisés dans un milieu restreint et isolé qui est un enjeu majeur.

La solution consiste à découvrir des vaccins, de nombreuses sociétés pharmaceutiques ont mené des recherches sur la découverte et certaines sociétés ont déjà découvert les vaccins et les essais cliniques ont été commencé partout dans le monde, mais même si les résultats ne sont pas à la hauteur, de nombreux effets secondaires se manifestent. Cependant, ce problème est une

Introduction générale

pandémie en cours jusqu'à la découverte d'un vaccin sans faille [3] car bien que des vaccins aient été développés, les techniques d'apprentissage automatique et en profondeur se sont révélées être une méthode utile pour le diagnostic clinique et d'autres domaines [3]. En effet, même si l'utilisation de la radiographie thoracique pour le diagnostic ou le triage de la COVID-19 pour le patient est devenue un enjeu important pour préserver les ressources médicales limitées et empêcher la propagation du virus. Cependant, les performances de diagnostic actuelles avec CXR ne sont pas suffisantes pour une utilisation clinique de routine, donc le besoin de l'intelligence artificielle pour améliorer les performances diagnostiques des CXR augmente. Dans ce sens, le développement des systèmes CAD de diagnostic assisté par ordinateur a eu lieu.

Dans ce mémoire, nous suggérons une approche basée multi-cascade d'algorithmes de segmentation et de classification du Covid-19 où des algorithmes d'apprentissage en profondeur seront combinés à d'autres d'apprentissage automatique.

Durant la segmentation désignant une étape essentielle du traitement et d'analyse des images pour l'évaluation et la quantification de COVID-19, nous délimiterons les régions d'intérêt (ROI), consistants en les poumons. En effet, nous appliquerons le modèle U-net se constituant des couches de convolution et de sous-échantillonnage pour classifier les pixels bruts de l'image en leur attribuant un score de la classe à qui ils appartiennent. Les couches convolutives utilisent différents filtres de différentes tailles pour extraire les caractéristiques profondes de l'image de la tumeur cérébrale. Les tailles des cartes d'entités sont encore réduites à l'aide des couches de sous-échantillonnage. Cela minimisera également la résolution des caractéristiques spatiales de l'image cérébrale [3]. Les régions segmentées pourraient être davantage utilisées pour extraire des descripteurs pour le diagnostic se basant sur le processus de classification par les machines à vecteurs de support (SVM).

La structuration de ce mémoire est comme suit :

Chapitre I : L'analyse d'image, la vision par ordinateur, l'apprentissage automatique et l'apprentissage profond : préambule

Durant ce chapitre, nous exposerons les concepts fondamentaux de l'intelligence artificielle, de l'analyse d'image ainsi que la vision par ordinateur.

Introduction générale

Chapitre II : Détection assistée par ordinateur du COVID-19

Au long du chapitre II, nous introduisons comment les paradigmes de l'apprentissage automatique et l'apprentissage profond ont été appliqués pour le diagnostic automatique de COVID-19.

Chapitre III : Problématique extraite et approche suggérée

Au-dedans du chapitre III, nous détaillons notre problématique pour la détection automatique de COVID-19 tout en indiquant l'approche suggérée.

Chapitre IV : Evaluation des résultats obtenus

Le chapitre IV sera consacré à l'évaluation des résultats aboutis par l'implémentation de l'approche proposée.

Nous achèverons ce mémoire par une conclusion générale et les perspectives soulignés.

Chapitre I:

**L'analyse d'image, la vision par
ordinateur, l'apprentissage
automatique et l'apprentissage
profond : préambule**

I.1 Introduction

L'ère actuelle où les technologies modernes sont très demandées dans divers secteurs. L'avancement des innovations et de ces technologies a joué un rôle vital dans les secteurs de la santé, essentiellement dans le diagnostic des maladies, le contrôle et l'influence des installations et des outils de santé intelligents. En particulier dans le diagnostic COVID-19, une technologie en évolution appelée intelligence artificielle a joué un rôle essentiel dans le diagnostic de la maladie. En effet, auparavant elle était utilisée dans l'analyse d'images médicales et où les résultats obtenus sont plus précis et ont aidé à réduire la consommation de temps et de main-d'œuvre

Nous présentons dans ce chapitre, les approches proposées pour l'analyse d'images et l'extraction de caractéristiques durant le processus du diagnostic médical assisté par ordinateur.

I.2 La vision par ordinateur

La vision par ordinateur s'appuie sur l'intelligence artificielle dans le but d'habiliter les systèmes à voir et à identifier des objets. En effet, l'apprentissage en profondeur est utilisé pour former les réseaux neuronaux guidant les systèmes durant le processus de traitement et d'analyse d'images. Une fois les réseaux de neurones furent entièrement formés, les modèles de la vision par ordinateur reconnaissent des objets, détectent et reconnaissent des personnes, voire plus, ils peuvent aussi suivre leurs mouvements. La détection, la reconnaissance et la classification d'objets présentent les fonctions principales des systèmes de vision par ordinateur.

Nous nous intéressons à l'application de la vision par ordinateur au domaine de la santé où les images prises par l'équipement médical seront utilisées pour la réalisation d'un diagnostic plus précis en vue de l'identification des maladies.

I.3 L'analyse d'image

Ce processus identifie l'information contenue dans l'image à travers un ensemble de traitements. Nous distinguons deux niveaux combinés d'analyse d'image comme suit :

I.3.1 Analyse de bas niveau d'image

Ceci consiste en la description du contenu bas niveau de l'image en termes de couleurs, textures ainsi que de formes. D'autres tâches interviennent dans la thérapie du bas niveau comme le filtrage pour l'annulation du bruit de l'image et l'amélioration du contraste pour améliorer la visibilité et la clarté de l'image [4] [5].

I.3.2 Analyse de haut niveau d'image

Ce niveau de traitement fait appel à un processus de reconnaissance des caractéristiques issues du bas-niveau en se basant sur la classification où chaque objet se fera associé une classe adéquate. En effet, l'intelligence artificielle avec ses différentes branches interviennent dans ce sens pour l'interprétation d'images.

I.4 Analyse de la texture d'image

L'analyse de la texture d'une image présente une problématique clé générant un descripteur incontournable dans le traitement d'image ainsi que la vision par ordinateur.

I.4.1 Définition de la texture

Il est difficile de trouver une définition universelle du concept de la texture. Ceci, malgré l'omniprésence des textures naturelles dans les différents types d'images.

Nous pouvons par exemple considérer la texture comme la reproduction spatiale d'un motif selon plusieurs directions.

La texture est considérée comme une propriété de la surface ou bien de la structure d'un objet. En effet, les caractéristiques de texture qu'on extrait furent fructueuses durant la reconnaissance et la distinction de diverses structures.

Selon [6], une texture désigne la répétition de motifs ou primitives avec une certaine fréquence et caractérisée par diverses statistiques (variance, moyenne ou histogramme...).

D'après [7], une texture consiste en une région de l'image caractérisée par une organisation spatiale homogène relative aux niveaux de luminance.

I.4.2 Caractérisation de la texture d'image

Les méthodes d'analyse et de caractérisation de la texture se divisent en trois catégories [7] [8] :

- **Méthodes statistiques**

Les méthodes statistiques s'appuient sur la distribution spatiale des niveaux de gris des pixels ainsi que sur la description statistique relative à leur arrangement. En effet, nous extrayons à l'aide des outils statistiques, des descripteurs texturaux. Nous affirmons que les matrices de cooccurrence proposées par Haralick [9] sont les plus connues et fréquemment utilisées.

- **Méthodes géométriques**

Ces méthodes s'intéressent à la fois à l'information structurelle et contextuelle de l'image. La quantification de la texture est réalisée suite à une extraction explicite de primitives, qui désignent un ensemble connexe composé de pixels partageant des propriétés similaires, ainsi que les règles d'agencement de ces primitives. Ceci, selon des attributs nommés les attributs géométriques. Il est important de mentionner que le fait que les attributs géométriques furent sensibles à la régularité des motifs texturés de l'image, ceci engendre le fait qu'ils présentent des limites durant la caractérisation des textures irrégulières. En effet, ces textures sont

omniprésentes dans les images naturelles.

- **Les méthodes fréquentielles**

Ces méthodes sont inspirées par le mécanisme du système visuel humain qui effectue des analyses fréquentielles au sein de l'image. En effet, les approches les majoritairement utilisées dans cette catégorie sont les filtres de Gabor, la transformée de Fourier ainsi que les transformées en ondelettes. Notons que les approches d'analyse par banc de filtre adoptent l'application d'une banque de filtres sur l'image où chacun extrait une texture ayant une fréquence ainsi qu'une orientation spécifique.

I.5 Les nouvelles tendances de l'apprentissage automatique et l'apprentissage profond

Historiquement, la construction d'un système d'apprentissage automatique exige l'expertise du domaine et l'ingénierie humaine pour concevoir des extracteurs de descripteurs qui transforment des données brutes en représentations appropriées à partir desquelles un algorithme d'apprentissage pourrait détecter des modèles [10]. En revanche, l'apprentissage en profondeur est une forme d'apprentissage dans laquelle une machine est nourrie de données brutes et développe ses propres représentations nécessaires à la reconnaissance de formes, qui est composée de plusieurs couches de représentations.

Ces couches sont généralement disposées séquentiellement et composées d'un grand nombre d'opérations primitives non linéaires, telle que la représentation d'une couche (en commençant par une entrée brute de données) est introduite dans la couche suivante et transformée en une représentation plus abstraite. Au fur et à mesure que les données circulent à travers les couches du système, l'espace d'entrée devient itérativement déformé jusqu'à ce que les points de données se distinguent. De cette manière, de très complexes descripteurs peuvent être appris.

Le domaine de l'apprentissage automatique (ML) recoupe plusieurs techniques basées sur les statistiques utiles pour les radiologues par exemple en cas de diagnostic de maladies qui complète le diagnostic profond, actuellement adopté.

I.5.1 L'apprentissage automatique

Le Machine Learning [11] est un sous-ensemble de l'intelligence artificielle utilisant des techniques permettant aux machines de tirer des renseignements à partir de leur expérience avec l'ultime but d'améliorer la façon dont elles exécutent leurs tâches. Nous affirmons que le *processus d'apprentissage* se base sur les étapes suivantes :

1. Alimenter un algorithme avec un flux de données tout en fournissant davantage d'informations au modèle, ceci peut consister en l'extraction de caractéristiques.
2. L'utilisation de ces données pour entraîner un éventuel modèle.
3. Le test ainsi que le déploiement du modèle.
4. La dernière étape consiste à appeler ainsi qu'utiliser le modèle déployé en vue de la prédiction automatisée retournée par ce modèle.

L'apprentissage automatique adopte divers algorithmes. Nous citons quelques algorithmes comme suit [2] :

- **Les réseaux de neurones**

Chaque nœud individuel dans un réseau de neurones peut être considéré comme étant son propre modèle de régression linéaire composé de données d'entrée, de poids, d'un biais (ou d'un seuil) et d'une sortie.

Lorsqu'une couche en entrée est déterminée, des poids sont affectés. Ces poids permettent de déterminer l'importance d'une variable donnée, les poids les plus importants contribuant de façon plus significative à la sortie par rapport aux autres entrées. Toutes les entrées sont ensuite multipliées par leurs poids respectifs, puis additionnées. Par la suite, la sortie est transmise via une fonction d'activation qui détermine la sortie. Si cette sortie dépasse un seuil donné, elle "déclenche" (ou active) le nœud, et transmet les données à la couche suivante du réseau. La sortie d'un nœud devient alors l'entrée du nœud suivant. Ce processus, qui consiste à transmettre les données d'une couche à la couche suivante, définit ce réseau neuronal comme un réseau à propagation. Nous présentons sur la figure I.1, un réseau de neurones.




Figure I.1 Exemple d'un réseau de neurones.

- **Les machines à vecteurs de support (SVM)**

Les machines à vecteurs de support ont été développées par Vapnik et sont bien connues comme classifieurs basés sur le principe de réduction du risque structurel catégorisé dans le théorème d'apprentissage statistique supervisé. L'idée principale du classifieur SVM est de déterminer un hyperplan optimal entre les échantillons positifs et négatifs [12]. En effet, cette notion de frontière suppose que les données soient linéairement séparables, malgré que ce soit rare à croiser. Pour y pallier, une astuce de noyau est utilisée pour transférer les données d'entrée vers un autre hyperplan où elles seront projetées dans un espace vectoriel de plus grande dimension.

Les machines à vecteurs de support présentent quelques avantages comme la grande précision de prédiction, la simplicité ainsi que la capacité de généralisation à partir d'un petit ensemble de données. D'autre part, des inconvénients se manifestent comme la diminution de l'efficacité sur les ensembles de données contenant du bruit et beaucoup.

Nous présentons sur la figure I.2 un hyperplan à marge maximale et marges par rapport à un SVM bâtie sur des échantillons de deux classes. Notons que les échantillons sur la marge sont appelés les vecteurs de support.




Figure I.2 Hyperplan à marge maximale et marges par rapport à un SVM bâtie sur des échantillons de deux classes.

- **Les K plus proches voisin (KNN)**

L'algorithme KNN fait partie des algorithmes les plus simples d'apprentissage artificiel. En effet, le principe consiste en que pour la classification d'une nouvelle observation x se trouvent dans un espace de caractéristiques, nous faisons voter les plus proches voisins relatifs à cette observation. A cet effet, la classe de x est connue en fonction de la classe majoritaire dans les K plus proches voisins de l'observation x [13]. Notons que cet algorithme se base sur deux paramètres : d'une part, une fonction de similarité pour comparer les individus dans l'espace de caractéristiques et le nombre K qui fixe le nombre des voisins générant la classification.

L'algorithme KNN présente quelques avantages comme la fait qu'il est simple et facile à mettre en œuvre, ne pas exiger d'hypothèse sur les données comme linéaires ou affines. Ceci dit, quelques inconvénients se présentent comme le fait que l'algorithme devient lent en fonction de l'augmentation du nombre d'exemples d'apprentissage, de plus le choix de la méthode de calcul ainsi que de la distance et le nombre des plus proches voisins K n'est pas évident.

I.5.2 L'apprentissage profond

L'apprentissage en profondeur est la tendance actuelle dans le traitement des images médicales [14]. Il est destiné à aider les radiologues à donner un diagnostic plus précis en donnant une analyse quantitative des lésions inquiétantes et en permettant un flux de travail clinique plus rapide. L'apprentissage en profondeur a déjà démontré des performances dans les tâches de reconnaissance et de vision par ordinateur qui peuvent dépasser les capacités humaines. L'architecture de l'algorithme d'apprentissage profond est plus complexe par rapport à l'algorithme traditionnel (apprentissage automatique). En effet, elle est composée de 3 étapes principales ; la première étape se fait par le pré-traitement et l'amélioration de chaque entrée. La deuxième étape est utilisée pour extraire les caractéristiques de cette entrée. La troisième étape est liée au processus de classification de chaque entrée en fonction de différents classifieurs. Le modèle d'apprentissage en profondeur minimise l'intervention humaine, traite des données complexes qui pourraient être difficiles dans l'apprentissage automatique et produit des résultats précis en peu de temps.

Nous constatons différents types d'architectures liés aux réseaux de neurones où nous pouvons citer :

- Réseau neuronal convolutif (CNN) largement utilisés dans des domaines tels que la reconnaissance vidéo, la reconnaissance d'images ou les systèmes de recommandation.
- Réseau de neurones récurrents (RNN) largement utilisés pour l'accomplissement de tâches complexes comme la prévision de séries chronologiques, l'apprentissage d'écriture manuscrite ou la reconnaissance linguistique.

Nous nous intéressons aux réseaux de neurones convolutifs. En effet, nous allons les détailler dans ce qui suit :

Le réseau neuronal convolutif, également connu sous le nom de CNN, est une technique d'apprentissage en profondeur composée de plusieurs couches empilées qui utilise des connexions locales appelées champ récepteur local et partage du poids pour de meilleures performances et une meilleure efficacité [14]. L'architecture profonde aide ces réseaux à apprendre de nombreuses caractéristiques différentes et complexes qu'un simple réseau de neurones ne peut pas apprendre. Les réseaux de neurones convolutifs alimentent le cœur de la vision par ordinateur qui a de nombreuses applications, notamment les voitures autonomes, la

robotique ...etc. Le concept principal de CNN est d'obtenir des caractéristiques locales à partir d'une entrée (généralement une image) au niveau des couches supérieures et de les combiner en caractéristiques plus complexes au niveau des couches inférieures. Une architecture typique de réseau neuronal convolutif est présentée sur la figure I.3 suivante :




Figure I.3 L'architecture d'un réseau de neurones convolutif. Source [15]

Nous allons détailler les couches d'un CNN comme suit [16] :

1- La couche convolutive

C'est la couche où le processus de convolution se produit et le modèle CNN apprend. Cette couche effectue la plupart des calculs pour un modèle CNN. C'est le composant le plus important d'un réseau convolutif. Il comporte certains paramètres et hyperparamètres, à savoir des filtres, des noyaux et des couches. La couche de convolution extrait des caractéristiques à l'aide de ces filtres, puis en tirent des informations. Pour cette raison, cette couche est également connue sous le nom de couche d'extraction de caractéristiques. Les images d'entrée sont comparées segment par segment pour distinguer les similitudes et les différences entre elles. Les segments sont appelés caractéristiques. La couche de convolution extrait une ou plusieurs caractéristiques des images d'entrée, puis à l'aide de la matrice d'image, elle crée un produit scalaire et produit une ou plusieurs matrices. Si nous avons une image de taille 5×5 et que les valeurs de pixel des images sont 0 ou 1, et que la taille de la matrice de filtre est 3×3 , alors la matrice de filtre 3×3 sera multipliée par 5×5 matrice de l'image, connue sous le nom de carte de caractéristiques. Le filtre se déplace de gauche à droite avec une valeur de foulée spécifique jusqu'à ce qu'il analyse toute la largeur comme mentionné sur la figure I.4. Ensuite, il descend vers le côté gauche de l'image avec la même foulée et répète le processus jusqu'à ce que l'image complète soit parcourue. L'objectif principal de cette couche de convolution est d'extraire des caractéristiques de haut niveau comme les bords. De plus,

diverses opérations sont effectuées dans cette couche, y compris le flou, la netteté, la détection des contours, en appliquant divers filtres.




Figure I.4 Processus de la convolution.

2- La couche de pooling

La couche de pooling est utilisée à plusieurs reprises dans le réseau de convolution pour réduire la taille du volume lorsque la taille de l'image est trop grande. Cette couche accélère le calcul, évite le surajustement et réduit la mémoire. Il existe différents types de couches de pooling comme mentionné sur la figure I.5, telles que le pooling maximal et le pooling moyen. Le pooling maximal prend la plus grande valeur de la carte des caractéristiques, le pooling moyen prend la moyenne en calculant pour chaque patch de la carte des caractéristiques.




Figure I.5 Exemples d'un max pooling ainsi qu'un average pooling.

3- La couche d'activation ReLU (Rectified Linear Units)

Cette couche vise à remplacer toutes les valeurs négatives reçues en entrées (la matrice des caractéristiques) par des valeurs de zéros. L'ultime but de ces couches d'activation est de rendre le modèle non linéaire.

4- La couche entièrement connectée

Elle calcule le score de la classe finale d'une entrée ; par conséquent, il en résulte un volume de taille $1 \times 1 \times N$, où N est le nombre de classes. Chaque neurone de cette couche connecte toutes les sorties du précédent volume. Les caractéristiques extraites des couches précédentes sont analysées globalement dans cette couche [2], et une combinaison non linéaire de ces caractéristiques est soumise à un classifieur.

En fonction de la force avec laquelle les caractéristiques correspondent à une classe particulière, un score est généré par la fonction d'activation.

I.6. Les modèles des réseaux de neurone convolutifs

I.6.1 U-net

C'est un modèle qui se compose d'un chemin de contraction avec quatre blocs d'encodage, suivis d'un chemin d'expansion avec quatre blocs de décodage [17]. Chaque bloc de codage se compose de deux blocs consécutifs de 3×3 couches convolutives suivies d'une couche de max-pooling avec une foulée de deux pour le sous-échantillonnage. En revanche, les blocs de décodage consistent en une couche de convolution transposée pour le suréchantillonnage, suivie d'une concaténation avec la carte des caractéristiques correspondante du chemin contractuel, et deux couches convolutives 3×3 consécutives. Le nombre de canaux de caractéristiques est doublé à chaque étape de sous-échantillonnage.

Toutes les couches convolutives sont suivies d'une activation de l'unité linéaire rectifiée (ReLU). A la dernière couche, la convolution 1×1 est utilisée pour cartographier la sortie du dernier bloc de décodage aux cartes de caractéristiques à deux canaux, où la fonction d'activation SoftMax est appliquée pour affecter chaque pixel dans une classe binaire d'arrière-plan ou de l'objet. Nous présentons sur la figure I.6, l'architecture de U-net.




Figure I.6 Architecture du modèle U-NET.

I.6.2 AlexNet

AlexNet est basé sur Deep CNN, AlexNet produit deux couches entièrement connectées, cinq couches convolutives et une seule couche de sortie Softmax. La couche d'entrée d'image nécessite $227 \times 227 \times 3$ images. Chaque couche convolutive est suivie de la fonction d'activation de l'Unité Linéaire Rectifiée (ReLU) [18]. Après chaque couche de convolution, AlexNet dispose d'une couche de pooling maximal pour réduire la taille du réseau. Après la dernière couche convolutive, il y a deux couches entièrement connectées avec 4096 sorties. Enfin, une couche est ajoutée après des couches entièrement connectées pour classifier les données à l'aide de la fonction Softmax.

I.6.3 Resnet-50

Resnet-50 est une sorte de réseau de neurones à convolution qui a été introduit par Kaiming He en 2015 et signifie Residual Neural Network qui a 50 couches profondes [3]. Dans ce modèle, il existe des blocs appelés blocs de convolution et blocs d'identité. Skip Connection est le concept utilisé dans Resnet-50. Sur les 50 couches, 48 sont les couches de convolution, 1 couche de pooling maximal et 1 couche de pooling moyen. La base de données ImageNet contenant plus d'un million de cas peut être chargée et préformée. Cette architecture ou cet algorithme sont principalement utilisés dans la classification d'images, la localisation d'objets

et la détection d'objets. Il se compose des éléments suivants. Un noyau de taille $7 * 7$ et 64 noyaux différents nous donnant 1 couche. Dans la deuxième convolution, $1 * 1$, 64 noyaux suivent $3 * 3$, 64 noyaux et enfin $1 * 1$, 256 noyaux donnant 9 couches. Dans la troisième convolution, $1 * 1$, 128 noyaux suivent $3 * 3$, 128 noyaux et enfin $1 * 1$, 512 noyaux donnant 12 couches. Dans la quatrième convolution, $1 * 1$, 256 noyaux suivent $3 * 3$, 256 noyaux et enfin $1 * 1$, 1024 noyaux donnant 18 couches. Les cinquième et sixième convolutions donnant 9 couches et 1 couche au total comprenant 50 couches.




Figure I.7 Architecture de ResNet. Source [3]

I.6.4 VGG-16

VGG-Visual Geometry Group a été développé à l'université d'Oxford par Karen Simonyan et Andrew Zisserman en 2014 [3]. Ce réseau se distingue par sa simplicité et son architecture uniforme. Ce modèle utilise 3×3 couches convolutives pondérées les unes sur les autres en profondeur croissante. Il apporte une amélioration par rapport à Alex-Net en remplaçant le filtre de grande taille. Ce réseau se compose de 16 couches convolutives empilées les unes après les autres avec une taille de noyau de $3 * 3$. Ce modèle augmente le nombre de cartes de caractéristiques ou de convolutions à mesure que la profondeur du réseau augmente, comme le montre la figure I.8. Ce réseau compte 138 millions de paramètres. La couche d'entrée est une image $224 * 224$ RVB (rouge, vert, bleu). VGG16 adopte plusieurs couches convolutives 3×3 en cascade parfois entrelacées avec un pooling maximal de 2×2 . Les dernières couches sont des couches denses complètement connectées pour obtenir la sortie.




Figure I.8 Architecture de VGG-16.

I.7 Conclusion

Durant ce chapitre, nous avons évoqué les principaux appuis majeurs du domaine de l'analyse d'image ainsi que la vision par ordinateur. En effet, où l'apprentissage automatique et l'apprentissage profond en figurent en force.

Le prochain chapitre sera consacré à la pandémie du COVID-19 où nous évoquerons tous les détails de la propagation de ce virus. Voir plus, nous analysons toutes les maladies pouvant toucher l'organe du poumon avec une tentative de proposer l'intelligence artificielle ainsi que ses paradigmes comme un remède dans ce sens.

Chapitre II

**détection assistée par ordinateur du
COVID-19**

II.1 Introduction

Suite à l'apparition brusque de la pandémie du Covid-19, un besoin accru d'un diagnostic automatique pour le dépistage des lésions du Covid-19 était en ordre. En effet, un diagnostic alternatif aidera à gérer le grand flux de données qui a submergé les hôpitaux et centres de diagnostic.

Notre axe de recherche s'intéresse aux images échographiques (CXR) au lieu des scanners CT, vu la flexibilité de cette modalité.

L'intelligence artificielle a pu donner son mot durant cette pandémie. En effet, ses paradigmes puissants d'apprentissage automatique et d'apprentissage profond ont permis le développement de systèmes d'aide au diagnostic médical assistés par ordinateur (CAD) qui détectent ce dangereux virus avec pertinence.

II.2 La pandémie de Covid-19

Le COVID-19 qui a pris naissance à Wuhan, en Chine, en décembre 2019, s'est propagé à travers le monde. Nous allons évoquer des statistiques concernant les atteintes par ce dangereux virus :

- Selon les données Covid-19 publiées par WHO le 23 avril 2021, le nombre total de cas confirmés a atteint 143 445 675 avec 3 051 736 décès dans le monde [19].
- Jusqu'en juillet 2021, 190 millions de cas de COVID-19 ont été signalés dans plus de 200 pays et territoires, entraînant environ 4 millions de décès [20].
- Jusqu'au 19 Mai 2022 environ 520 912 257 personnes infectées en engendrant 6 272 408 décès dans le monde. En date du 17 Mai 2022, 11 713 606 779 doses de vaccins a été attribuée [21].

Nous indiquons sur la figure II.1, la répartition des cas de Covid-19 dans le monde.




Figure II.1 Répartition des cas de Covid-19 dans le monde. Source [21]

Le nouveau coronavirus appartient à la famille des virus « Coronavirus » (CoV) qui s'appelait « Coronavirus du syndrome respiratoire aigu sévère 2 » (SRAS-CoV-2) avant d'être nommé COVID-19 par l'organisation mondiale de la santé (WHO) en février 2020 [14]. En effet, ce virus dangereux a englouti plus de 210 pays.

Une fois infecté, un patient COVID-19 peut développer divers symptômes et signes d'infection, notamment de la fièvre, de la toux et des maladies respiratoires (comme la grippe)., une disparition du goût, de la fatigue, des courbatures et une obstruction nasale peuvent également être observées chez certains patients. Dans les cas graves, l'infection peut provoquer une pneumonie, des difficultés respiratoires, une défaillance multiviscérale, voire plus, la mort...

L'infection de ce virus se transmet par les gouttelettes des patients tels que la toux et les éternuements [22].

En 2021, de nombreuses variantes de COVID-19 ont été détectées dans différents pays dont le Royaume-Uni, le Brésil et l'Inde. La propagation de ces variantes et les taux de mortalité sont plus importants que les précédents [23].

Le coronavirus a la propension à infecter les gens dans plusieurs vagues. Certains pays qui ont réussi à freiner la propagation de l'épidémie de covid-19, signalent maintenant une nouvelle recrudescence de cas.

Un autre problème découvert par les chercheurs est que le virus change de structure avec le temps, et il est donc difficile pour lui trouver une solution stable. En effet, les chercheurs ont confirmé que le virus changeait ses modèles, et donc un antidote développé pour un particulier pattern, n'est peut-être pas prêts à se battre avec leurs nouvelles variantes.

Malgré le déploiement des vaccins à travers le monde, il y a encore de nouveaux cas et de nouveaux décès enregistrés quotidiennement dans certains pays du monde [24].

II.3 Les maladies pulmonaires

La pneumonie [2] est le gonflement des sacs aériens dans les poumons pour diverses raisons, notamment virus, bactéries, champignons, etc., et peut entraîner des maladies mineures à graves chez les personnes de tous âges. Les symptômes courants de la pneumonie comprennent la toux, la fièvre, l'essoufflement, etc., et le diagnostic repose principalement sur la radiographie pulmonaire, l'hémoculture, l'expectoration, la tomodensitométrie

etc. Le traitement de la pneumonie est basé sur le type d'infection : bactérienne, virale, ou fongique. Diverses infections virales de la grippe commune aux plus mortelles y compris le SARS, le MERS, etc., peuvent entraîner une pneumonie, et la mort dans la plupart de ces cas est en raison d'une insuffisance respiratoire.

Les scanners CXR et CT sont les pratiques standard pour détecter une pneumonie, mais dans des situations de type pandémique, les services d'imagerie dans les hôpitaux peuvent être submergés par le grand nombre de cas, car l'analyse de des images de la radiographie nécessite l'expertise et le temps. Ainsi, il existe clairement un besoin de l'analyse de ces images, et les technologies basées sur l'IA/ML sont bien adaptées à de telles

Tâches. Les infections pulmonaires apparaissent généralement sous la forme de zones opaques sur les images, qui peuvent être peu clair et difficile à distinguer entre diverses anomalies pulmonaires, comme le pneumothorax, épanchement pleural, pneumonie, tuberculose pulmonaire, cicatrisation pulmonaire, etc., posant un défi même aux radiologues.

II.4 Détection de covid-19

Bien que des problèmes existent avec la détection rapide de COVID-19, les radiologues de première ligne trouvent des points en communs de caractéristiques telles que l'opacité en verre dépoli (GGO) à la périphérie des poumons, une opacité arrondie, des vaisseaux intra-infiltrés élargis avec des consolidations des poumons (tissu pulmonaire compressible rempli de liquide au lieu d'air) et d'autres consolidations qui sont des signes de développement d'une maladie grave [25].

II.4.1 Dépistage de Covid-19 par radiographie thoracique CXR (Chest X-Ray)

Wilhelm Conrad Rontgen a découvert la première radiographie en 1895 lors de l'expérimentation des tubes de Lenard et tubes de Crookes [23]. Les rayons X ont un rôle très important dans le domaine médical, ils peuvent aider à prévenir les infections, le diagnostic et le contrôle. Les scanners à rayons X sont utilisés dans le monde entier pour diagnostiquer la partie lésée et pour la détection d'autres maladies afin de traiter les patients.

Les images radiographiques peuvent être facilement acquises pour les patients même à leur domicile ou dans leur lieu de quarantaine. A cet effet, les images radiographiques ont été largement utilisées pour le diagnostic du COVID-19

Des études radiologiques montrent que des opacités en verre dépoli (GGO) désignant souvent le premier signe d'un diagnostic de pneumonie COVID-19, la distribution périphérique et

l'implication bilatérale sont largement observé sur les images CXR. En effet, les analyses des images CXR révèlent des occurrences fréquentes de GGO dans les zones périphérique, postérieure, médiale et basale, consolidation de l'espace aérien, bronchectasie de traction et épaissement septal [26]. Nous exposons sur la figure II.2, diverses manifestations radiographies thoraciques de patients portant le virus de covid-19.




Figure II.2 Radiographies thoraciques de patients infectés par COVID-19 : (a) opacités floues diffuses mal définies (flèches noires) ; (b) maladie pulmonaire diffuse et épanchement pleural droit (flèches noires); (c) opacités floues subtiles et mal définies du côté droit (flèches noires); (d) opacités pulmonaires périphériques gauches moyennes à inférieures (flèches noires). Source [27].

II.4.2 Dépistage de Covid-19 par tomодensitométrie (CT scan)

La tomодensitométrie CT est une méthode d'imagerie qui utilise un faisceau de rayons X spécial pour créer des scans détaillés de zones à l'intérieur du corps (par ex : poumons, cœur, vaisseaux sanguins, voies respiratoires et ganglions lymphatiques) [23]. Ces images sont prises sous différents angles pour générer les images tomographiques qui donnent la possibilité aux radiographes de voir directement à l'intérieur du corps à la place de la chirurgie. Les images CT sont considérées comme efficaces pour la prise des décisions cliniques. Elles ont montré une capacité élevée à diagnostiquer la COVID-19, en particulier les patients atteints mais ayant les résultats de RT-PCR faux négatifs.

Dans cette technique d'imagerie, plusieurs mesures radiographiques du poumon sont prises à différents angles, appelés tranches [2]. Un ordinateur combine ensuite ces tranches pour générer

un modèle 3D qui aide à montrer la taille, la forme et la position des poumons et des structures dans la cage thoracique comme illustré sur la figure II.3.




Figure II.3 Les tomodensitogrammes au début de la phase rapide et progressive de Cas de COVID-19. a : GGO au quatrième jour. b : GGO plus consolidation au troisième jour. c : GGO le deuxième jour. Source [23]

II.4.3 Avantages de la radiographie thoracique CXR (Chest X-Ray) par rapport à la Tomodensitométrie (CT scan)

Nous allons indiquer dans les points suivants, notre choix de l'utilisation des radiographies thoraciques pour la détection de Covid-19 :

- En particulier, la CXR est une pratique répandue pouvant être facilement amenée au lit du patient, même en les services d'urgence. Par conséquent, l'utilisation de CXR peut être préféré à CT non seulement dans des environnements à ressources limitées, mais là où cela devient fondamental pour éviter la prise en charge de patients plus fragilisés, ou pour prévenir la propagation de l'infection en raison des mouvements du patient.
- La CXR est recommandé comme outil de dépistage initial en raison des difficultés rencontrées dans la mise en place d'installations de tomodensitométrie spécialement dans le déplacement des patients vers les suites de tomodensitométrie. Avec l'infiltration de COVID-19, la consommation de temps en tomodensitométrie et la susceptibilité aux infections sur les sites de tomodensitométrie, a engendré un besoin croissant de détection de caractéristiques diagnostiques précieuses à partir des images CXR [26].

- Bien que le scanner thoracique offre une plus grande sensibilité aux maladies pulmonaires, il y a plusieurs défis à son utilisation. Il s'agit notamment de la non-portabilité, de l'obligation de désinfecter la chambre et le matériel entre les patients suivis par un retard d'au moins une heure, le risque d'exposer le personnel hospitalier et les autres patients, ainsi que les personnes sous investigation au virus. Bien que moins sensible, les CXR portables sont considérés comme une alternative acceptable étant donné que les personnes sous investigation peuvent être imagés dans des pièces plus isolées, limitant l'exposition du personnel et parce que l'assainissement est beaucoup moins complexe à obtenir qu'avec les CT [28].
- CT n'est pas très pratique en raison de la nature contagieuse de la maladie, et elle est moins disponibles dans les pays à faibles ressources. D'autre part, CXR est largement utilisée comme outil d'aide au diagnostic du COVID-19. L'imagerie par rayons X est un moyen moins cher, plus rapide et facilement accessible avec un risque réduit d'exposition aux rayonnements par rapport au scanner [17].
- Plusieurs travaux de la littérature ont réalisé la segmentation pulmonaire et la détection des nodules en tomodensitométrie. Ces examens, cependant, ont une disponibilité limitée dans la plupart des régions du monde, principalement en raison de leur coût élevé. Pour la raison mentionnée ci-dessus, la radiographie pulmonaire (CXR) est toujours parmi les tests d'imagerie les plus utilisés dans le monde, représentant au moins un tiers de tous les examens dans un service de radiologie typique [15]. Le principal avantage de CXR est la viabilité économique. Même dans les pays sous-développés, les appareils de radiographie numérique modernes sont abordables. Dans ce contexte, le CXR est certainement un outil de diagnostic très important qui aide à identifier une grande variété de maladies pulmonaires dans le monde.
- Le processus global d'imagerie thoracique pour obtenir les premiers résultats est beaucoup plus court que dans le cas de la RT-PCR. Le dépistage prend environ 15 s (pour la radiographie) à 21,5 minutes en moyenne (pour la TDM). De plus, les radiographies sont moins chers, plus disponibles dans le monde et moins nocifs que les scanners car la dose de rayonnement est plus faible [29].

II.5 Limites des images échographiques en vue de la détection de Covid-19

Des millions de CXR sont générés chaque année. Selon « the National Health Service (UK) », en 2017/18, plus de 22,9 millions d'images radiographiques ont été demandées au Royaume-Uni, ce qui représente 55,63 % de tous les tests d'imagerie, y compris la résonance magnétique (IRM) et la tomodensitométrie (TDM) [15]. Parmi ces examens X-Ray, 2,2 millions sont des CXR. Cela représente une charge de travail de diagnostic considérable compte tenu de la pénurie de radiologues dans le monde.

Un CXR fournit une grande quantité d'informations sur un patient. L'interprétation correcte de ces informations est un défi majeur pour les radiologues et nécessite un haut degré de compétence, d'expérience et de concentration. La distinction des structures anormales telles que les infiltrats des vaisseaux sanguins normaux, par exemple, est une tâche difficile même pour les radiologues expérimentés. Fréquemment, lorsque les radiologues évaluent la gravité des résultats anormaux, de grandes différences inter-observateurs et même intra-observateurs se produisent.

En raison de la nature projective de l'image CXR et du large éventail de manifestations possibles de la maladie, une évaluation visuelle de l'entité et de la gravité de la maladie pulmonaire est particulièrement difficile [30].

Les résultats cliniques des images CT et X-ray incluent des opacités bilatérales et périphériques en verre dépoli (GGO) ainsi qu'une consolidation. Cependant, la délimitation manuelle des zones touchées dans les poumons par les radiologues peut être un processus très mouvementé et chronophage, en particulier pour le nombre énorme de patients résultant de cette pandémie.

Il a été démontré que la distinction entre le COVID-19 et la pneumonie virale est une tâche difficile [29]. En effet, étant donné les difficultés et les pièges de l'interprétation visuelle des signes de la maladie sur les CXR (allant de découvertes subtiles à insuffisance pulmonaire lourde) ainsi que le manque d'informations détaillées de localisation [30], les architectures d'intelligence artificielle, d'apprentissage automatique et d'apprentissage profond peuvent extraire des caractéristiques de haut niveau à partir des deux modalités et peuvent être utilisées pour détecter et diagnostiquer le virus de COVID-19.

II.6 Diagnostic automatique (CAD) de Covid-19

Suite à l'avancée de l'imagerie électronique, un intérêt important exigeant le développement de systèmes de diagnostic assisté par ordinateur (CAD : Computer Aided Diagnosis) en vue de soulager la charge de travail au niveau des service de santé. En effet, actuellement le CAD est devenu un outil interdisciplinaire avancé relatif à la technologie dont les composants fondamentaux regroupent le traitement et l'analyse d'images ainsi que la reconnaissance des formes [31]. Nous exposons sur la figure II.4, les diverses fonctionnalités d'un système d'aide au diagnostic médical.




Figure II.4 Fonctionnalités d'un système d'aide au diagnostic médical assisté par ordinateur (CAD)

Il est nécessaire de mentionner que les systèmes CAD ne remplacent en aucun cas les médecins, en effet, ces systèmes sont utilisés comme « un deuxième avis » durant l'élaboration d'un diagnostic.

Le CAD se constitue des deux composants suivants :

II.6.1 Détection des régions d'intérêt assistée par ordinateur (CADE)

L'analyse automatique des radiographies thoraciques à l'aide de systèmes de diagnostic assisté par ordinateur (CAD) est essentielle pour effectuer un dépistage de masse et détecter les signes précoces de diverses anomalies chez les patients. Dans un système CAD de radiographie thoracique, la segmentation des champs pulmonaires est une étape préalable pour définir précisément la région d'intérêt et est ensuite utilisée par d'autres étapes du système CAD. En effet, un élément essentiel de tout système assisté par ordinateur, que ce soit pour la détection ou le diagnostic en CXR numérique, est la segmentation automatique du champ pulmonaire [15]. L'un des principaux défis inhérents à cette tâche est d'inclure dans la segmentation les régions pulmonaires recouvertes d'anomalies denses, également appelées opacités, qui peuvent être causées par des maladies telles que la tuberculose et la pneumonie. Cette tâche spécifique est difficile car les opacités atteignent fréquemment des valeurs d'intensité élevées qui peuvent être interprétées de manière incorrecte par une méthode automatique comme le contour pulmonaire, et par conséquent, cela crée un défi dans le processus de segmentation, car les chances de segmentations incomplètes sont considérablement augmentées.

De plus, la segmentation fournit des informations structurelles sur les irrégularités de forme et les mesures de taille des poumons, qui peuvent être utilisées pour analyser des conditions cliniques sévères telles que l'épanchement pleural, l'emphysème et le pneumothorax. Puisqu'un masque de segmentation pulmonaire détermine spécifiquement la région pulmonaire, il détermine également la région non pulmonaire par exclusion, ce qui minimise les effets des artefacts d'imagerie dans le système CAD.

L'un des défis majeurs de la segmentation pulmonaire en CXR est d'inclure dans le masque de segmentation les régions du champ pulmonaire recouvertes par des structures anormales. Dans de bons scénarios, où les patients sont en bonne santé, ou dans les cas où ils n'ont qu'un petit nodule, par exemple, les méthodes CAD sont généralement capables de fournir des segmentations fiables, car le contraste entre les champs pulmonaires et leurs limites est

globalement maintenu. Cependant, dans des scénarios plus compliqués (et également fréquents), les patients peuvent avoir des maladies qui affectent leurs poumons avec des anomalies denses, telles que des opacités et des consolidations. En général, ces anomalies sont des structures mal définies qui chevauchent le champ pulmonaire avec des pixels de haute intensité, ce qui entraîne un contraste plus faible entre les poumons et leurs limites. Pour cette raison, la tâche de segmentation en CXR devient significativement plus complexe dans ces cas.

III.6.2 Diagnostic des régions d'intérêt assisté par ordinateur (CADx)

La classification est souvent appelée diagnostic assisté par ordinateur (CADx) [1]. Elle joue un rôle important dans le traitement des images médicales. Pendant la phase de la classification, une ou même plusieurs images sont prises comme échantillons d'entrée, et un seul facteur de diagnostic est généré comme sortie qui classe l'image. En effet, ceci, par l'extraction de descripteurs discriminants au sein des régions d'intérêt segmentées. Ensuite, ces derniers sont fournis comme des prédictions d'entrée à un classifieur. Un modèle prédictif est généré suite à l'ajustement des poids relatifs aux descripteurs en se basant sur les propriétés statistiques d'un ensemble d'apprentissage dans le but de l'estimation de la probabilité qu'une région d'intérêt appartienne à l'une des classes.

Il est important de mentionner le potentiel de l'apprentissage profond dans le traitement des images médicales afin de lutter contre la pandémie de COVID-19 en mettant en œuvre quatre stratégies. Les stratégies sont la prédiction des épidémies, le suivi de la propagation du virus, le diagnostic et le traitement de Covid-19, la vaccination et la découverte de médicaments, comme le montre la figure II.5.

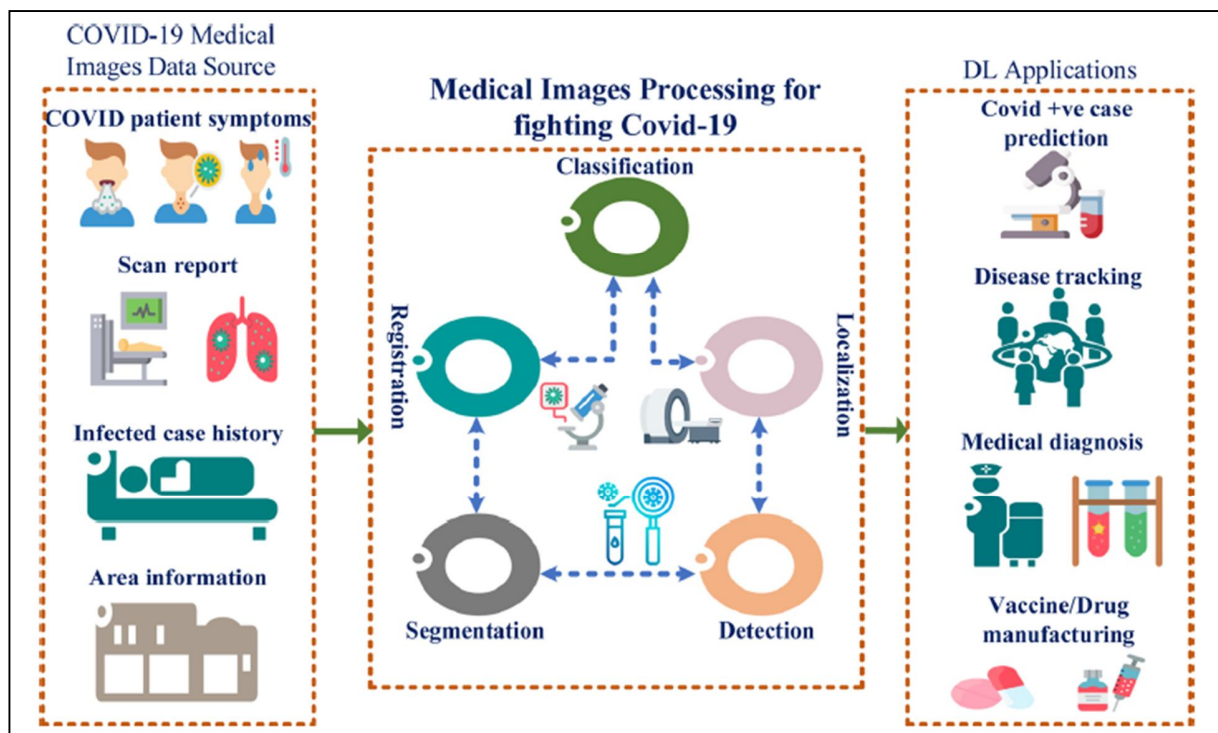


Figure II.5 Impact de l'apprentissage profond sur le traitement d'images médicales pour lutter contre la pandémie de COVID-19. Source [1]

II.7 Etat de l'art sur l'application de l'apprentissage automatique pour la détection de Covid-19

Le tableau II.1 exposera diverses approches CAD basées apprentissage automatique pour la détection de Covid-19. En effet, les classifieurs et méthodes d'extraction de descripteurs seront mentionnés, en outre, les mesures d'évaluation de performances les plus fréquemment appliquées seront soulignées.

Tableau II.1 Approches CAD basées apprentissage automatique (Machine Learning) de détection du Covid-19

Référence	Modalité utilisée	Contribution	Evaluation des performances
[32]	X-rays	Utilisation de CNN + SVM + Sobel	Acc = 99.02%
[33]	X-rays	Utilisation de ResNet152 et un classifieur d'apprentissage automatique (Random Forest) pour la classification de COVID-19 et pneumonie.	Acc = 97.3%
[34]	CT scans	Une approche basée les descripteurs de Grey-Level Size Zone Matrix (GLSZM) et le classifieur des SVM.	Acc = 99.68%
[35]	X-rays	Une approche basée classification binaire Covid-19/non Covid-19 où les descripteurs du modèle ResNet50 CNN ont utilisés à travers le classifieur des SVM.	Acc = 95.38%
[36]	X-rays	Une approche de classification en Covid-19, normal et pneumonie basée les descripteurs extraits par VGG19, AlexNet, ResNet et GoogleNet à travers le classifieur des SVM.	Acc = 99.38%
[37]	X-rays	Une technique de transfert learning basée ResNet-50 pour extraire les caractéristiques d'imagerie des patients infectés. Ensuite ces descripteurs ont été fournis aux SVM pour la classification.	Acc = 95.34%
[38]	X-rays	Une approche de détection de Covid-19 par les descripteurs de la transformée en Ondelette discrète et le CNN à travers le classifieur random forest.	Acc = 98.5%
[39]	X-rays	Une approche de détection de Covid-19 par les descripteurs Deep features à travers le classifieur des SVM.	Acc = 97.48%
		Des techniques d'apprentissage automatique ont été utilisé, à savoir SVM et Random Forest (RF) pour la détection précoce des symptômes de la COVID-19 chez les patients. Le modèle CNN a été appliqué pour l'extraction de caractéristiques.	Acc = 90.5% (SVM) Acc = 81% (RF)

[40]	X-rays		
[41]	X-rays	Une approche de détection de Covid-19 par les descripteurs Deep features : Resnet50 à travers le classifieur des SVM.	Acc = 95.33%
[42]	CT scans et X-rays	Une approche de détection de Covid-19 par les descripteurs de Ondelettes (DWT).	Acc = 98.2%
[43]	CT scans	Une approche de détection de Covid-19 par les caractéristiques quantitatives, comme le volume/rapport d'infection du poumon entier et le volume des régions d'opacité en verre dépoli (GGO) à travers le classifieur des Random Forest.	Acc = 87.5%
[44]	CT scans	Une approche de détection de Covid-19 qui utilise des descripteurs spécifiques à l'emplacement à travers le classifieur des Logistic Regression.	Acc = 86.2%
[45]	CT scans et X-rays	Une approche de détection de Covid-19 qui utilise des descripteurs deep features : DenseNet121 à travers le classifieur de Bagging tree.	Acc = 99%
[45]	X-rays	Une approche de détection de Covid-19 qui utilise des descripteurs deep features : CNN and HOG à travers le classifieur SVM.	Acc = 99.67%
[46]	X-rays	Un réseau de neurones convolutifs a été développé pour extraire des descripteurs profonds de haut niveau et durant le processus de classification une combinaison des classifieurs : random forest, support vector machine, decision tree, et AdaBoost a été appliqué pour la détection de Covid-19.	Acc = 98.91%

II.8 Etat de l'art sur l'application de l'apprentissage profond pour la détection de Covid-19

Tableau II.2 Approches CAD basées apprentissage profond (Deep learning) pour la détection du Covid-19.

Référence	Modalité utilisée	Contribution	Evaluation des performances
[47]	X-rays	Deep CNN (DeTraC)	Acc = 93.1%
[48]	X-rays	Un réseau de neurons profond (DNN) basé Faster Regions avec un réseau de neurone convolutif (Faster R-CNN) ont été suggéré pour la détection de Covid-19 parmi des cas normaux et d'autres de pneumonie.	Acc = 97.36%
[49]	X-rays	Un pré entraîné modèle de réseau de neurone convolutive a été ajusté pour la classification en Covid-19 ou pneumonie.	Acc = 89.2%
[50]	X-rays	La meilleure précision de classification est obtenue par ResNet-34 par rapport à ResNet-50, GoogleNet, VGG-16, AlexNet, MobileNet-V2, Inception-V3 et SqueezeNet.	Acc = 98.33%
[51]	X-rays	Le modèle de réseau de neurone convolutif basé sur « Xception architecture » qui a été pré entraîné sur la base ImageNet dataset pour la classification en Covid-19 ou pneumonie.	Acc = 89.6%
[52]	X-rays	Un nouvel modèle de réseau de neurone convolutif ayant 5 couches convolutives a été suggéré pour l'extraction de descripteurs via une classification basée les SVM selon Covid-19, normal ou pneumonie.	Acc = 98.97%
[53]	X-rays	Utilisation du modèle DarkNet.	Acc = 98.08% (Classification binaire) Acc = 87.02% (Classification multi-classes)
		Un modèle de réseau de neurone convolutif a été proposé qui apprend des modèles de filtres convolutifs uniques pour chaque type de pneumonie. Ceci est atteint en restreignant certains filtres dans une couche convolutive pour ne répondre au maximum qu'à	

[54]	X-rays	une classe particulière de pneumonie/COVID-19. Ceci avec l'ultime but d'extraire des descripteurs discriminants durant la classification.	Acc = 99.80%
[55]	X-rays	Un système de détection automatique du COVID-19 par l'utilisation de Inception V3 avec apprentissage par transfert pour détecter une infection. Le modèle a été testé sur 1341 images normales, 1345 pneumonies virales et 864 images COVID-19.	Acc = 96%
[56]	X-rays	Une approche d'extraction de descripteurs texturaux d'Haralick's pour la classification de divers types de pneumonie via un réseau de neurone artificiel.	Acc = 95%
[57]	X-rays	Le modèle DarkNet a été utilisé comme classifieur pour le modèle (YOLO) où 17 couches de convolutions ont été implémentées tout en introduisant différents filtres au niveau de chaque couche. Ceci pour une classification en Covid-19, non Covid-19 ou pneumonie.	Acc = 87.02%
[58]	X-rays	Une étude comparative de sept architectures d'apprentissage en profondeur pour détecter les symptômes du COVID-19. Ces modèles ont été formés sur 6087 images.	Acc = 92.18% (Inception-ResNetV2)
[59]	X-rays	Une approche combinant un réseau de neurone convolutionnel avec les (LSTM : short-term memory) pour la classification en Covid-19, non Covid-19 ou pneumonie. CNN est utilisé pour l'extraction des descripteurs.	Acc = 99.4%
[60]	X-rays	Utilisation du modèle VGG-16 pour la détection de Covid-19.	Acc = 87%
[61]	X-rays	Utilisation du modèle ResNet-18 pour la détection de Covid-19.	Acc = 88%
[62]	X-rays	Un modèle de réseau de neurone convolutionnel nommé (DeTraC : Decompose, Transfer, and Compose), pour la classification en Covid-19, non Covid-19 ou SARS.	Acc = 95.12%

II.9 Conclusion

Divers chercheurs utilisent les paradigmes de l'intelligence artificielle pour la détection du Covid-19. En effet, les approches d'apprentissage automatique effectuent un apprentissage sur les données d'entrée, ensuite, analysent statistiquement les données de sortie. Tandis que les approches de l'apprentissage profond se basent sur les réseaux de neurones multicouches où la précision sera meilleure.

Le chapitre prochain sera dédié à l'évocation de la problématique tirée dans cette crise sanitaire, entre autres, la méthodologie soulignée pour l'implémentation de l'approche proposée de détection automatique de Covid-19

Chapitre III:

**Problématique extraite et approche
suggérée**

III.1 Introduction

Nous allons détailler au long de ce chapitre la problématique soulignée consistant en l'application des paradigmes de l'intelligence artificielle pour la création d'un modèle prédictif de Covid-19, évidemment, les pipelines suivis seront exposés en détails.

III.2 Problématique et plan d'action

Actuellement, l'utilisant de la réaction de polymérisation en chaîne en temps réel (RT-PCR) est la technique standard utilisée pour diagnostiquer l'infection au COVID-19 [29]. Cependant, les résultats de la RT-PCR peuvent être affectés par des erreurs d'échantillonnage et une faible charge virale. En conséquence, ces tests souffrent de taux élevés de faux négatifs (avec une sensibilité de 71 % ou 69 %) et peuvent devoir être effectués deux fois ou plus avant que les résultats ne soient finalement confirmés. En effet, les résultats qui ont été rapportés à ce jour sont plus favorables pour la radiographie que pour la tomodensitométrie [63]. Il a été constaté que les classifications automatiques en utilisant les radiographies pulmonaires (CXR ou chest x-ray) obtiennent de meilleurs résultats que lors de l'utilisation de Tomodensitométrie (CT scan) : la précision moyenne (Acc) pour CT est de 90 % et pour CXR 96 % [63]. Cependant, durant la pandémie mondiale en évolution rapide de COVID-19, l'utilisation abusive de la radiographie thoracique pour le diagnostic ou le triage de la COVID-19 pour le patient a fait que la gestion de cet « énorme flux de données, devient un enjeu important pour préserver les ressources médicales limitées et empêcher la propagation du virus. En effet, les performances actuelles de diagnostic avec CXR ne sont pas suffisantes pour une utilisation clinique de routine, donc le besoin de l'incorporation de l'intelligence artificielle pour améliorer les performances diagnostiques des CXR augmente. Dans ce sens, l'interprétation assistée par ordinateur d'images radiologiques basées sur l'apprentissage automatique et l'apprentissage profond peut être un atout important pour une gestion plus efficace de la pandémie dans de nombreuses directions. En effet, en raison de l'importance clinique et de la nature compliquée de la radiographie thoracique, les chercheurs continuent d'explorer l'utilisation de techniques de traitement d'images et d'apprentissage automatique pour développer des méthodes informatiques aidant les radiologues à lire les images thoraciques [15].

De nombreux chercheurs ont étudié la détection du COVID et introduit différentes techniques pour ce problème. Cependant, la plupart d'entre eux n'ont pas fourni la haute précision requise, en particulier pour les cas de considérations de 4 classes [64]. Il est important de mentionner le dilemme des manifestations cliniques similaires. En effet, dans de nombreux cas, la pneumonie virale présente des symptômes similaires à ceux du COVID-19, ce qui rend difficile leur distinction [65]. A cet effet, un prétraitement est en ordre pour éliminer tout bruit survenu lors du

processus d'acquisition. Pour faire recours aux points problématiques cités, le plan d'action suivant sera adopté :

- 1- Proposer une technique hybridée pour le développement des systèmes de diagnostic assisté par ordinateur (CAD), qui assistent les radiologues dans la tâche difficile d'identification des anomalies sur les patients où deux des étapes clés nécessaires à la composition des systèmes CAD sont la segmentation et la classification.
- 2- Un prétraitement sera appliqué sur les radiographies thoraciques en utilisant le filtre médian vu sa puissance dans l'élimination du bruit surgissant lors du processus d'acquisition tout en préservant les contours, un deuxième prétraitement sera réalisé par l'application de l'égalisation adaptative d'histogramme (CLAHE) qui effectue une égalisation d'histogramme sur de petites régions dans l'image dans le but d'améliorer le contraste de chaque région individuellement pour ensuite appliquer le filtre médian qui aide à récupérer les contours perdu suite au prétraitement par le CLAHE [30].
- 3- L'amélioration de la précision de la détection du COVID-19 par l'utilisation de 4 classes (Covid-19 vs pneumonie bactérienne vs pneumonie virale vs cas normaux).
- 4- L'utilisation d'une technique hybride de CNN où l'algorithme u-net est utilisé pour la segmentation des poumons vu sa grande performance dans la segmentation des images médicales [14] et le classifieurs d'apprentissage automatique où les SVM sont utilisées pour la classification des poumons en 4 classes mentionnées en haut.
- 5- L'étude d'un biomarqueur d'images qui sont souvent utilisés dans l'analyse CXR, tels que la distribution d'intensité de la zone pulmonaire. En effet, notre analyse a révélé qu'il existe des différences dans la distribution d'intensité par classe, qui est bien corrélé avec les résultats radiologiques de la variation de la localisation d'intensité dans les CXR relatives aux Covid-19. Cependant, il faut faire attention, car non seulement les opacités multiples concentrées peuvent provoquer une distribution d'intensité inégale dans toute la région pulmonaire, mais aussi différentes autres distributions de la texture dans les CXR peuvent provoquer une intensité variante similaire. Par exemple, la consolidation multifocale distribuée de COVID-19 pourrait rendre la variance d'intensité facteur de différenciation avec d'autres classes, mais aussi la pneumonie bactérienne génère également de l'opacité, dont les caractéristiques peuvent conduire aux mêmes

distributions d'intensité en tant que résultats de différentes caractéristiques d'étalement de l'opacité.

- 6- L'utilisation de caractéristiques discriminantes pour la classification basée SVM où l'analyse texturale distinguera entre les maladies pulmonaires notamment le virus de Covid-19). Ceci, par l'application des lois puissance : Zipf et Zipf inverse surgissant dans le domaine spatial pour l'analyse de la texture en modélisant la vision humaine. D'autre part, les filtres de Gabor seront hybridés avec ces lois puissance vu qu'ils se localisent au sein des deux domaines spatial et fréquentiel. En effet, cette hybridation permettra une analyse judicieuse de la texture des tumeurs. Il est important de mentionner que le choix de l'extraction des descripteurs par l'apprentissage automatique était bâti vu que cette approche était prédominante pendant plusieurs années. En effet, les approches actuelles proposées par l'apprentissage profond sont quelque peu traitées avec prudence en raison du manque de compréhension du fonctionnement de l'apprentissage profond désignant une boîte noire vu qu'il n'y a pas de formulation mathématique établie pour soutenir ses performances, ce qui le rend difficile à reproduire, et cela pourrait également être une autre source de préoccupation pour un large éventail d'acceptation [24][14].
- 7- Une étape d'évaluation des performances pour les processus de segmentation et de classification (loss, accuracy, ...) aura lieu.

III.3 Segmentation pulmonaire au sein des radiographies thoraciques basée Deep Learning

III.3.1 Base de données utilisée

Nous avons utilisé deux segments de radiographies thoraciques comme suit :

1- Premier segment de radiographies thoraciques

Les chercheurs de l'Université du Qatar ont compilé la base de données COVID-QU-Ex [72-81], qui se compose de 33 920 images radiographiques thoraciques (CXR), dont :

- 11 956 COVID-19
- 11 263 infections non COVID (pneumonie virale ou bactérienne)
- 10 701 normales

Des masques de segmentation pulmonaire « Ground-truth » sont fournis par cette base de données qui contient le plus grand nombre de masques pulmonaires créés. Ce flux énorme de donnée a été collecté à partir de [1-D/10-D].

Nous avons utilisé 6000 radiographies thoraciques durant l'apprentissage du modèle de segmentation pulmonaire basé U-net. Nous exposons sur la figure III.1 quelques radiographies thoraciques avec leurs masques respectifs.




Figure III.1 Radiographies thoraciques avec leur masques pulmonaires de la base de donnée COVID-QU-Ex.

2- Deuxième ensemble de radiographies thoraciques

Nous avons collecté un deuxième ensemble de données de radiographies thoracique des poumons [82] [83]. En effet, nous visons à effectuer une classification basée 4 classes : Covid-19, cas sains, pneumonie virale et pneumonie bactérienne. Nous exposons sur la figure III.2 des exemples sur les 4 classes.




Figure III.2 Radiographies thoraciques relatives à : (a) cas sain, (b) Covid-19, (c) Pneumonie virale et (d) Pneumonie bactérienne.

III.3.2 Pipeline de la segmentation pulmonaire basé U-Net

- **Prétraitement**

Le but du prétraitement est de rendre les images provenant de différentes ressources de données homogènes et cohérentes [29]. Ce processus réduit la possibilité de biais en éliminant certains artefacts des images, tels que les légendes, les annotations, qui peuvent tromper le modèle. Le modèle doit apprendre à différencier les étiquettes de classes en se concentrant sur les caractéristiques de l'image, et non en reconnaissant de quelle base de données provient l'image. Pendant le prétraitement, les caractéristiques d'image non pertinentes qui sont plus faciles à apprendre sont supprimées. En effet, dans certaines bases de données, il n'y a aucun cas de personnes souffrant de COVID-19, tandis que dans d'autres, il n'y a, par exemple, que des cas graves. Ces différences, insignifiantes d'un point de vue humain, doivent être éliminées. Pour les machines, même l'information selon laquelle les images d'une ressource de données sont relativement plus sombres peut être pertinente. En résumé, le prétraitement est une étape importante précédant l'apprentissage du modèle. Cela devrait réduire la possibilité de biais et garantir des images plus homogènes sans éliminer aucune caractéristique médicalement significative.

Nous allons appliquer un prétraitement pour améliorer la résolution et le contraste tout en réduisant le bruit dans les radiographies thoraciques. Nous distinguons diverses approches de prétraitement comme les Ondelettes, les filtres médians ainsi que les filtres de Wiener. En effet, les filtres médians sont le plus souvent utilisés durant la phase de prétraitement dans le but de préserver les contours de l'image [28]. Dans ce sens, nous avons appliqué le filtre médian sur l'intégralité des radiographies thoraciques comme exposé sur la figure III.3. En outre, un second prétraitement a été réalisé basé l'égalisation adaptative d'histogramme (CLAHE) ensuite le filtre médian pour récupérer les contours flous générés par le CLAHE comme indiqué sur la figure III.4.




Figure III.3 Exemple de l'application d'un prétraitement par le filtre médian : à gauche les radiographies thoraciques originales et à droite le résultat du prétraitement.




Figure III.4 Exemple de l'application d'un prétraitement par le CLAHE pour l'amélioration du contraste qui sera suivi par le filtre médian pour rehausser les contours : à gauche les radiographies thoraciques originales et à droite le résultat du prétraitement.

- **Segmentation basée U-Net**

En termes de régions d'intérêt, les méthodes de segmentation dans COVID- 19 peuvent être principalement regroupées en deux catégories [66], à savoir, les méthodes axées sur la région pulmonaire et les méthodes axées sur la lésion pulmonaire. Les méthodes axées sur la région

pulmonaire visent à séparer les poumons entiers et lobes pulmonaires. En effet, c'est une étape considérée comme une étape préalable dans les applications COVID-19.

Nous nous sommes retrouvés face à plusieurs défis...

- Celui que de nombreuses études en cours dans l'IA pour la segmentation et diagnostic sont basés sur de petits échantillons, ce qui peut conduire à l'overfitting des résultats, c'est-à-dire lorsque les paramètres q produisent une fonction f qui est très précise pour les données d'apprentissage mais qui ne se généralise pas bien aux données de test. Dans ce sens, pour rendre les résultats cliniquement utiles, la qualité et le nombre de données doivent encore être améliorés d'où nous avons utilisé 10 000 radiographies thoraciques avec leurs masques respectives durant la phase d'apprentissage.
- La segmentation des images Xray est plus difficile que les images CT. Ceci est dû au fait que dans les images radiographiques 2D, les côtes sont projetées sur les tissus mous confondant le contraste d'image.
- Le diagnostic assisté par ordinateur des images radiographiques pulmonaire (CXR) dépend de manière critique de la segmentation automatisée des poumons, qui est un problème difficile en raison de la présence de bords solides au niveau de la cage thoracique et de la clavicule, de l'absence d'une forme cohérente des poumons chez différents individus, et l'apparition de l'apex du poumon.
- Les études des radiologues ont révélé que les caractéristiques d'imagerie des patients atteints de COVID-19 sont : un verre dépoli bilatéral, périphérique et multifocal, opacité et consolidation, principalement situées au niveau sous-pleural et péri-bronchovasculaires, étaient les caractéristiques typiques. Cependant, d'autres types de pneumonie virale peuvent imiter également la pneumonie COVID-19, ce qui rend difficile la différenciation [24].

Les réseaux de neurones convolutifs sont des méthodes d'apprentissage en profondeur qui prennent une image en entrée et ont une architecture destinée à prendre en charge la dimension des images [2]. Les neurones des différentes couches d'un CNN sont disposés sur les trois dimensions, hauteur, largeur et profondeur, similaires à la connectivité des neurones dans le cerveau. Les neurones de chaque couche sont connectés à une petite région de la couche

précédente. En règle générale, un CNN se compose de trois couches, à savoir, couche convolutive, couche de pooling et une couche dense (entièrement connectée).

Nous visons à délimiter la région pulmonaire d'intérêt, désignant une zone critique pour la localisation des structures pathologiques causées par le COVID-19, indépendamment de la subjectivité du clinicien (sujet particulièrement sensible dans les situations de stress élevé et d'usure psychologique) et sous des conditions défavorables de capture.

Le modèle U-Net [66] a été considéré vu le fait qu'il soit doté de skip connexions comme indiqué sur la figure II.5, transmettant les informations contextuelles et spatiales à partir de l'encodeur vers le décodeur et permettant ainsi au réseau de restituer les informations spatiales perdues. Dans ce sens, l'avantage de U-Net est que la partie décodeur reçoive les informations spatiales perdues durant le pooling à l'aide de ces skip connexion ce qui facilite le processus d'apprentissage.




Figure III.5 Architecture du modèle U-Net.

Nous distinguons les parties suivantes :

1- Contracting path (Downsampling)

Il consiste en l'application répétée de :

- Deux 3x3 convolutions (unpadded convolutions).
- Suivi d'une ReLU et d'une normalisation par lots.
- Une opération de 2x2 max pooling.

2- Expansive path (Upsampling)

Consistant en séquence de convolutions ascendantes et de concaténation :

- 2 x 2 convolution (convolution ascendante) qui réduit de moitié le nombre de canaux de caractéristiques.
- Une concaténation avec la carte des caractéristiques rognée en conséquence à partir du chemin contractuel.
- Deux convolutions 3x3

- Suivi d'un ReLU avec normalisation des lots.

3- Final Bottleneck Layer

Au niveau de la couche finale, une convolution 1x1 est utilisée pour mapper chaque vecteur d'entités à 64 composants au nombre de classes souhaité.

Un autre défi à surmonter est la fonction de perte (loss function) en imagerie médicale, en effet, l'anatomie d'intérêt n'occupe qu'une très petite région de l'analyse, ce qui fait que le processus d'apprentissage est piégé dans des minima locaux de la loss function produisant un réseau dont les prédictions sont fortement biaisées vers l'arrière-plan.

En conséquence, la région de premier plan est souvent manquante ou seulement partiellement détectée.

La fonction de perte utilisée par notre modèle U-Net est : **Dice loss** du fait qu'elle prend en compte les informations de perte à la fois localement et globalement, ce qui est essentiel pour une grande précision. En effet, sa formule est la suivante :

$$D = \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2}$$

Où p et q représentent des paires de valeurs de pixels correspondantes de prédiction et de ground truth, respectivement. Sa quantité varie entre 0 et 1 que nous visons à maximiser.

Nous avons appliqué deux types de segmentation comme suit :

III.4 Classification des régions pulmonaires basée SVM

III.4.1 Régions d'intérêt obtenues

Nous avons effectué la segmentation de l'intégralité du poumon. En effet, le processus de classification sera consacré à une classification en 4 classes : Covid-19, pneumonie bactérienne, pneumonie virale ou poumon sain sans la présence d'aucune pathologie.

III.4.2 Pipeline de classification des poumon basé SVM

Nous présentons sur la figure III.6, le pipeline pris en considération pour la classification des régions d'intérêt. Notons que l'étape du prétraitement a déjà été réalisé durant le pipeline de la segmentation des régions d'intérêt.

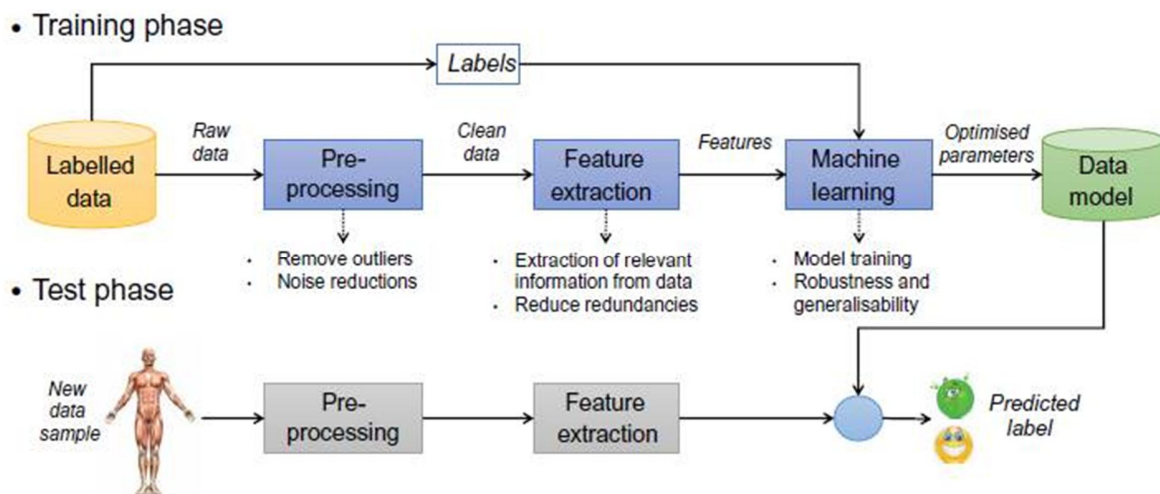


Figure III.6 Pipeline suivi pour la classification des régions d'intérêt. Source [67].

• Extraction des descripteurs

L'extraction automatique des caractéristiques saillantes des images pulmonaires segmentées, permettent la détection efficace des cas de COVID-19 et de pneumonie virale ou bactérienne ainsi que le cas où le poumon est sain sans pathologies. En effet, l'extraction des caractéristiques est considérée comme l'une des étapes essentielles du processus de classification des images. Les caractéristiques traditionnelles de l'apprentissage automatique se sont révélées utiles dans la littérature pour les tâches de classification d'images.

D'une part, les anomalies en verre dépoli sur les radiographies thoraciques sont considérées comme des régions homogènes translucides diffuses plus claires que le fond sombre normal des poumons (bien qu'avec un ton sombre, néanmoins) généralement causées par une inflammation

des tissus dus à l'infection virale. D'autre part, les consolidations inégales se présentent sous la forme d'un motif brillant irrégulier qui pourrait atteindre une texture changeante si la maladie est assez avancée. Ces structures apparaissent lorsque des régions des poumons sont remplies de fluides étrangers au lieu d'air normal qui modifient la densité. En effet, l'analyse texturale peut distinguer entre les différentes pathologies pulmonaires [68].

1- Analyse et caractérisation de la texture des poumons par les lois de Zipf et de Zipf inverse

Les lois de Zipf et de Zipf inverse sont des approches perceptuelles qui analysent le contenu structurel des images durant la caractérisation de la texture.

Nous allons utiliser ces lois puissance pour l'analyse de la texture en modélisant la vision humaine pour la détection de Covid-19.

Les lois de Zipf et de Zipf inverse analysent statistiquement la complexité structurelle de la texture d'une image en caractérisant la structure sous-jacente des lésions mammaires. En effet, nous allons encoder les régions d'intérêt par le codage des rangs généraux jugé le plus adéquat pour l'étude de la texturation fine de l'image.

Nous obtenons les courbes de Zipf et de Zipf inverse des poumons atteints de Covid-19, poumons sains ainsi que poumons affectés de pneumonie virale et bactérienne comme mentionné sur les figures III.7, III.8, III.9 et III.10 respectivement. Par la suite, une extraction des descripteurs texturaux à partir des courbes de Zipf et Zipf inverse est effectuée pour les fournir comme entrée aux SVM durant la phase de classification.

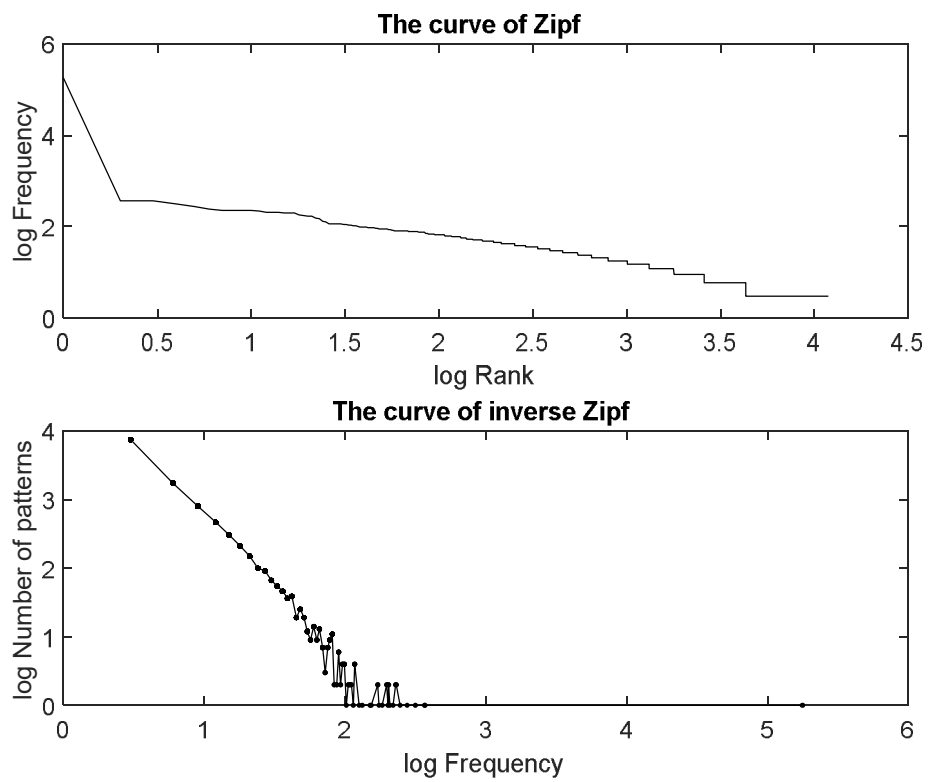


Figure III.7 Courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19.





Figure III.8 Courbes de Zipf et de Zipf inverse d'un poumon sain.





Figure III.9 Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie virale.





Figure III.10 Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie bactérienne.

Les descripteurs dérivés des courbes de Zipf et de Zipf inverses sont les suivants [69] :

1- Les pentes des courbes de Zipf et de Zipf inverse

La pente moyenne d'une courbe est le coefficient directeur de la droite des moindres carrés. Elle est donnée par la formule III.1 :

$$p = \frac{n \sum_{i=1}^n y_i x_i - \sum_{i=1}^n y_i \sum_{i=1}^n x_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \quad (\text{III.1})$$

2- L'aire délimitée par la courbe de Zipf

Nous calculons l'aire délimitée par la courbe de Zipf à partir des courbes de Zipf obtenues suite au codage de l'image par le codage des rangs généraux. Soit n le nombre de motifs de la courbe, f_i la fréquence et r_i le rang du motif i , l'aire de la courbe est donnée par la formule III.2 :

$$A = \sum_{i=1}^{n-1} \frac{(f_i + f_{i+1})(r_{i+1} - r_i)}{2} \quad (\text{III.2})$$

3- Entropie1 de la courbe de Zipf

L'entropie relative aux motifs des images mammographies est définie par la formule III.3:

$$H_w = - \sum_{r=1}^R \frac{f(r)}{T} \log_R \frac{f(r)}{T} \quad (\text{III.3})$$

Dans cette formule, $f(r)$ représente la fréquence du motif pour la ligne r , T représente le nombre total de motifs différents, et nous utilisons un logarithme avec la base R .

4- Entropie2 de la courbe de Zipf

L'entropie relative à la fréquence d'apparition des motifs est définie par la formule suivante :

$$H_f = - \sum_{f=1}^F \frac{I(f)}{R} \log_F \frac{I(f)}{R} \quad (\text{III.4})$$

Dans cette formule, $I(f)$ représente le nombre de motifs distincts ayant une fréquence d'apparition égale à f et F représente le nombre entier d'occurrences des motifs dans l'image.

5- Les ordonnées à l'origine des courbes de Zipf et Zipf inverse

6- La constante alpha de la courbe de Zipf

La loi de Zipf est fortement exprimée de la façon suivante : Quel que soit un motif appartenant à une image, la fréquence d'apparition de ce motif * son rang dans une liste ordonnée décroissante des fréquences d'apparition des motifs = constante.

2- Analyse et caractérisation de la texture des poumons par les filtres de Gabor

Mentionnons que les filtres de Gabor se localisent au sein des deux domaines spatial et fréquentiel. En effet, ils effectuent une décomposition multi-résolution.

Dans le cas des images 2D, le filtre de Gabor est généré suite à une gaussienne bidimensionnelle modulée par une fonction sinusoïdale complexe [70]. La formule du filtre de Gabor 2D est donnée par [70] :

$$h(x, y) = \frac{1}{\sigma_x \sigma_y 2\pi} \exp\left(-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}\right) \exp(j2\pi u_0(x \cos\theta + y \sin\theta)) \quad (\text{III.5})$$

L'enveloppe Gaussienne :

$$g(x, y) = \frac{1}{\sigma_x \sigma_y 2\pi} \exp\left(-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}\right) \quad (\text{III.6})$$

Avec : $X = x \cos \theta + y \sin \theta$

$Y = -x \sin \theta + y \cos \theta$

Où σ_x et σ_y sont les écarts-types respectivement le long des axes x et y (ou les constants spatiales du filtre), elles déterminent la largeur du filtre.

U_0 : la fréquence centrale.

θ : l'angle de rotation de $[x, y]$ par rapport à (x, y) , il donne l'orientation de l'enveloppe Gaussienne $g(x, y)$.

La puissance des filtres de Gabor pour la caractérisation de la texture revient au fait qu'ils isolent dans une image ; des constituantes très variées allant d'objets nettement définis jusqu'à de fins

détails d'orientation particulière. Ceci, suite au changement de deux paramètres : la fréquence ainsi que l'orientation.

Les filtres de Gabor sont un type de filtrage passe-bande et conservent l'information prise sur le spectre d'une image via la bande de fréquence sélectionnée. En effet, ces filtres analysent des propriétés locales au sein d'une région d'intérêt extraite à partir de l'image. Par conséquent, la configuration fréquemment utilisée d'extraction de données spatio-fréquentielles à partir des textures est générée suite à la convolution de la région d'intérêt avec une banque de filtres [70] où chacun se retrouvera centré sur une fréquence et une orientation avec l'ultime but de couvrir parfaitement l'intégralité du domaine fréquentiel. En effet, tout pixel de l'image générera une réponse pour chaque filtre.

En ce qui concerne le processus de la classification, nous cherchons la relation existante entre les réponses données par les filtres de Gabor relatives à chacune des régions d'intérêt.

Nous exposons sur la figure l'application des filtres de Gabor sur une tumeur où les sorties seront utilisées pour l'extraction des descripteurs.

Les paramètres pertinents du filtre de Gabor sont la fréquence radiale ainsi que l'orientation. Ils définissent la localisation du canal dans le plan fréquentiel. En effet, chaque image de taille $N \times N$ aura des fréquences significatives dans l'intervalle $[0..N/4]$ et à la puissance 2.

Nous avons appliqué une banque des filtres de Gabor avec une taille de 39×39 selon 5 fréquences et 8 orientations comme mentionné sur la figure III.11 :




Figure III.11 Les divers filtres de Gabor appliqués dans le domaine fréquentiel.

Suite à l'utilisation d'un ensemble riche en variation de filtres de Gabor, ceci permettra une couverture plus étendue de l'espace fréquentiel en détectant davantage d'orientations, et aboutir donc à l'extraction de tous les contours des régions d'intérêt.

La figure III.12, démontre la partie réelle de ces filtres.




Figure III.12 Parties réelles des filtres de Gabor utilisés.

Nous allons démontrer sur la figure III.13, la partie réelle des régions d'intérêt filtrées :




Figure III.13 Parties réelles des régions d'intérêt filtrées

A ce stade, nous allons exposer sur la figure III.14, la magnitude de la réponse des régions d'intérêt filtrées.




Figure III.14 Magnitude de la réponse du filtre de Gabor suite à la convolution de la tumeur maligne avec une banque de filtres de Gabor.

Pour toutes les sorties du filtre, un calcul de statistiques locales est effectué et le vecteur de descripteurs texturaux est obtenu par combinaison de ces statistiques comme mentionné dans [71].

- **Processus d'apprentissage automatique basé SVM**

Les machines à vecteurs de support sont généralement considérées comme une méthode de classification puissante. En effet, SVM construit un hyperplan dans un espace multidimensionnel pour séparer différentes classes. SVM produit itérativement le meilleur hyperplan, qui est ensuite utilisé pour minimiser les erreurs de classification. Les caractéristiques obtenues après la concaténation des caractéristiques sont utilisées pour réaliser l'apprentissage de l'SVM linéaire, la fonction de noyau sigmoïde, la fonction de noyau polynomial, le RBF. Nous allons classifier chaque région pulmonaire par les SVM [64].

Une fois le SVM finalise son optimisation, le modèle prédéfini d'apprentissage automatique est orienté au test. En effet, la généralisabilité du modèle sera validée via des instances non utilisées durant la phase d'apprentissage. La puissance prédictive du modèle est calculée par rapport à la puissance de généralisation obtenue.

III.5 Aperçu schématique de l'approche proposée

Nous exposons sur la figure III.13 un aperçu schématique du pipeline de détection du Covid-19.




Figure III.15 Schématisation du pipeline de l'approche proposée de détection du Covid-19.

III.6 Conclusion

Durant ce chapitre, nous avons détaillé l'approche proposée de détection automatique de COVID-19 où la validation des résultats obtenus sera traitée au-dedans du chapitre à venir. En outre, une comparaison avec l'état de l'art sera évoquée également malgré les difficultés rencontrées du fait que les chercheurs utilisent diverses segments ou bases de données qui est justifié par le fait que le virus dangereux de Covid-19 a apparu récemment.

Chapitre IV

Evaluation des résultats obtenus

IV.1 Introduction

Dans ce chapitre, nous allons présenter les expérimentations effectuées sur notre modèle afin de démontrer son efficacité à détecter Covid19 ou Pneumonia ou non à partir d'échographie thoracique. Nous détaillerons d'abord environnement de développement et outils utilisés (Python, HTML5, CSS, JavaScript), ainsi que la description des mesures de performances utilisées (la matrice de confusion et les formules), puis nous allons présenter évaluation des résultats de la segmentation des poumons, et puis évaluation de l'approche proposée de détection de Covid-19 (SVM, RBF kernel- accuracy). Ensuite nous présentons des captures d'écran de l'exécution de notre application.

IV.2 Environnement de développement et outils utilisés

IV.2 .1 Matériel

Tableau IV.1 Caractéristique de matériel de programmation.

Nom de pc	Processeur	Système d'exploitation	Mémoire (RAM)
Dell	intel (R) Core (TM) i3-3320M CPU 2.60GHz	windows 10 64 bits	IV GB

IV.2 .2 Kaggle

Kaggle est une collection de données scientifiques. Kaggle permet aux utilisateurs de rechercher et de publier des ensembles de données et des explorateurs, de créer des modèles dans un environnement de science des données basé sur le Web, de travailler avec d'autres données scientifiques et des moteurs de correspondance automatique, et de participer à des concours pour résoudre les failles de données

Tableau IV.2 Caractéristique de Kaggle.

Nom d'éditeur	RAM	GPU Memoiry	Disk
Kaggle Editeur	13 G MAX	15 G MAX	73 G MAX

Figure IV.1 logo Kaggle.



The image shows the Kaggle logo, which consists of the word "kaggle" in a lowercase, blue, sans-serif font. The letter 'k' is notably larger and more stylized than the other letters.

IV.2 .3 Python

Python3 est un langage de programmation de haut niveau interprété (il n'y a pas d'étape de compilation) et orienté objet avec une sémantique dynamique. Il est très sollicité par une large communauté de développeurs et de programmeurs. Python est un langage simple, facile à apprendre et permet une bonne réduction du coût de la maintenance des codes. Les bibliothèques (packages) python encouragent la modularité et la réutilisabilité des codes.

Nous avons opté pour la version Python 3.9. Nous avons utilisé l'ensemble de packages fournis par Anaconda, une distribution de Python : ceux-ci comprennent Python. 3.9, toute la bibliothèque: numpy , torch, torchvision, tqdm, argparse, os, matplotlib, sklearn, pandas, PIL, cv2, scipy, pickle, csv.

Elle comprend notamment des fonctions pour estimer des forêts aléatoires, des régressions logistiques, des algorithmes de classification, et les machines à vecteurs de support. Elle est conçue pour s'harmoniser avec des autres bibliothèques libre Python, notamment NumPy et SciPy



Figure IV.2 logo python

Anaconda: Anaconda est une plate-forme informatique gratuite. Il est possible de l'installer en fonction du système d'exploitation Windows, Linux, MacOS. Il se compose des distributions Python et R et du gestionnaire de paquets appelé conda. Anaconda fournit un ensemble de bibliothèques et de packages pré-installés. Certains d'entre eux sont NumPy, SciPy, Pandas, Scikit Learn, Nltk et Jupiter. Anaconda Enterprise est le produit commercial d'Anaconda. Il permet aux entreprises de développer des applications sécurisées, évolutives et de niveau entreprise.

Toutefois, pour effectuer des tâches Data Science, il est possible d'installer python, puis d'installer les packages à l'aide de pip, selon les besoins. Anaconda est une alternative et fournit tous les paquets nécessaires en même temps. Donc, c'est plus pratique pour les utilisateurs. Les deux méthodes exécutent la même tâche. Les développeurs peuvent choisir l'un ou l'autre en fonction de leurs préférences. Habituellement, la communauté de la science des données préfère Anaconda car il résout beaucoup de problèmes communs au stade initial ainsi que tout au long du processus de développement. Globalement, Anaconda facilite la science des données et les tâches d'apprentissage automatique..

IV.2 .4 HTML5

HTML5 (HyperText Markup Language 5) est la dernière révision du principal langage du web, HTML. HTML5 spécifie deux syntaxes d'un modèle abstrait défini en termes de DOM : HTML5 et XHTML5. Le langage comprend également une couche application avec de nombreuses API, ainsi qu'un algorithme afin de pouvoir traiter les documents à la syntaxe non conforme. Le travail a été repris par le W3C en mars 2007 après avoir été initié par le WHATWG. Les deux organisations travaillent en parallèle sur le même document afin de maintenir une version unique de la technologie

HTML5 propose une interface commune qui facilite le chargement des éléments et rend inutile l'installation d'un plug-in Flash, par exemple, car ces éléments s'exécutent tout seuls.

Les nouvelles fonctionnalités de HTML5 incluent :

De nouvelles règles d'analyse qui ne sont pas basées sur SGML mais qui sont orientées vers une analyse flexible et une compatibilité.

Prise en charge de l'utilisation de graphiques vectoriels scalaires en ligne (SVG) et du langage de balisage mathématique (MathML) en texte/html.

Les nouveaux éléments disponibles incluent article, aparté, audio, bdi, canvas, command, datalist, details, embed, figcaption, figure, footer, header, hgroup, keygen, mark, meter, nav, output, progress, rp, rt, ruby, section, source, résumé, heure, vidéo et wbr.

Les nouveaux types de contrôles de formulaire disponibles incluent les dates et heures, l'e-mail, l'URL, la recherche, le nombre, la plage, le téléphone et la couleur.

Nouveaux attributs disponibles de charset sur meta et async sur script.



Figure IV.3 Logo HTML5

IV.2 .5 CSS3

Le terme CSS est l'acronyme anglais de Cascading Style Sheets qui peut se traduire par "feuilles de style en cascade". Le CSS est un langage informatique utilisé sur l'internet pour mettre en forme les fichiers HTML ou XML. Ainsi, les feuilles de style, aussi appelé les fichiers CSS, comprennent du code qui permet de gérer le design d'une page en HTML.

Bien que l'HTML puisse être mis en forme à l'aide de balises prévus à cet effet, de nos jours il est plus judicieux d'utiliser le CSS et de n'utiliser le XHTML que pour le contenu.

L'avantage de l'utilisation d'un fichier CSS pour la mise en forme d'un site réside dans la possibilité de modifier tous les titres du site en une seule fois en modifiant une seule partie du fichier CSS. Sans ce fichier CSS, il serait nécessaire de modifier chaque titre de chaque page du site (difficilement envisageable pour les énormes sites de plusieurs milliers de pages).

D'autres points fort sont perceptible. Il est par exemple possible de créer une feuille de style spécifique pour l'impression des documents, ce qui permet de retirer tous les effets de style et toutes les parties inutile lors de l'impression. De même, une feuille de style peut être utilisée pour les utilisateurs d'un téléphone portable, ce qui permet de mieux gérer la mise en forme particulièrement pour les petits écrans de ces appareils.



Figure IV.4 Logo CSS3

IV.2 .6 JavaScript

JavaScript désigne un langage de développement informatique, et plus précisément un langage de script orienté objet. On le retrouve principalement dans les pages Internet. Il permet, entre autres, d'introduire sur une page web ou HTML des petites animations ou des effets.

Créé en 1995 par Brendan Eich, en même temps que la technologie Java, le langage JavaScript se distingue des langages serveurs par le fait que l'exécution des tâches est opérée par le navigateur lui-même, sur l'ordinateur de l'utilisateur, et non sur le serveur web. Il s'active donc généralement sur le poste client plutôt que côté serveur

les principaux frameworks JavaScript ?

Il existe de nombreux frameworks JavaScript orientés vers les interfaces web (ou "orientés client"). Les trois plus connus sont JQuery, AngularJS (qui a été initialement développé par Google) et React (qui, lui, est né chez Facebook). Il existe néanmoins quelques infrastructures JavaScript open source orientées serveur, même si ce langage n'avait pas été conçu dans cette optique au départ. La plus célèbre d'entre elles n'est autre que NodeJS.

les principaux usages de JavaScript ?

Le langage JavaScript est principalement employé pour améliorer l'ergonomie d'un site Internet et/ou d'une interface applicative utilisateur. Il sert également à intégrer des effets esthétiques, toutefois rarement indispensables. Son principal intérêt réside dans son mode de fonctionnement : le langage

JavaScript offre en effet la possibilité d'exécuter un code sans être contraint de recharger une page web. En cela, il joue un rôle dans l'amélioration de la rapidité de chargement des pages, un critère d'ergonomie et de référencement de plus en plus important.



Figure IV.5 Logo JavaScript

IV.3 Evaluation de l'approche proposée de détection de Covid-19

- **Résultats obtenus pour le modèle 1**

SVM (Support Vector Machine) avec le noyau RBF (Radial Basis Function) est une méthode de classification fréquemment utilisée car elle fournit généralement des résultats précis.

La plupart des recherches d'optimisation SVM se concentrent sur l'optimisation des données d'entrée, tandis que le paramètre de la fonction noyau (RBF), le sigma, qui est utilisé dans SVM a également le potentiel d'améliorer les performances de SVM lorsqu'il est optimisé

Nous exposons les résultats de la classification basée SVM obtenus. En effet, pour le premier modèle distinguant les poumons portant une pneumonie, les poumons portant le virus de Covid-19 et ceux normales sans lésion ; nous avons obtenue une précision de classification de l'ordre de 92%. Tandis que pour le deuxième modèle distinguant les régions d'intérêt des lésions de Covid-19 ainsi que les régions d'intérêt de lésions de la pneumonie ; nous avons obtenu 96%.




Figure IV.6 Entraînement et validation de l'accuracy




Figure IV.7 Entraînement et validation de loss

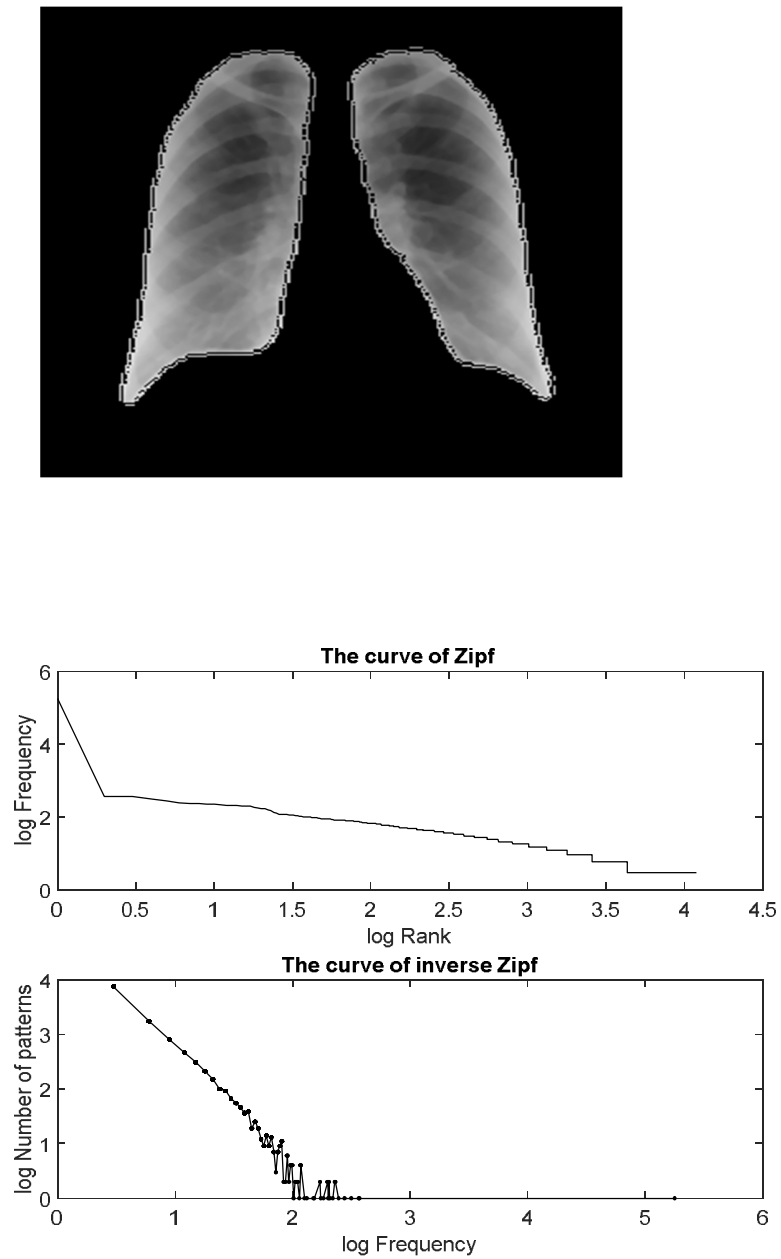


Figure IV.8 Courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19

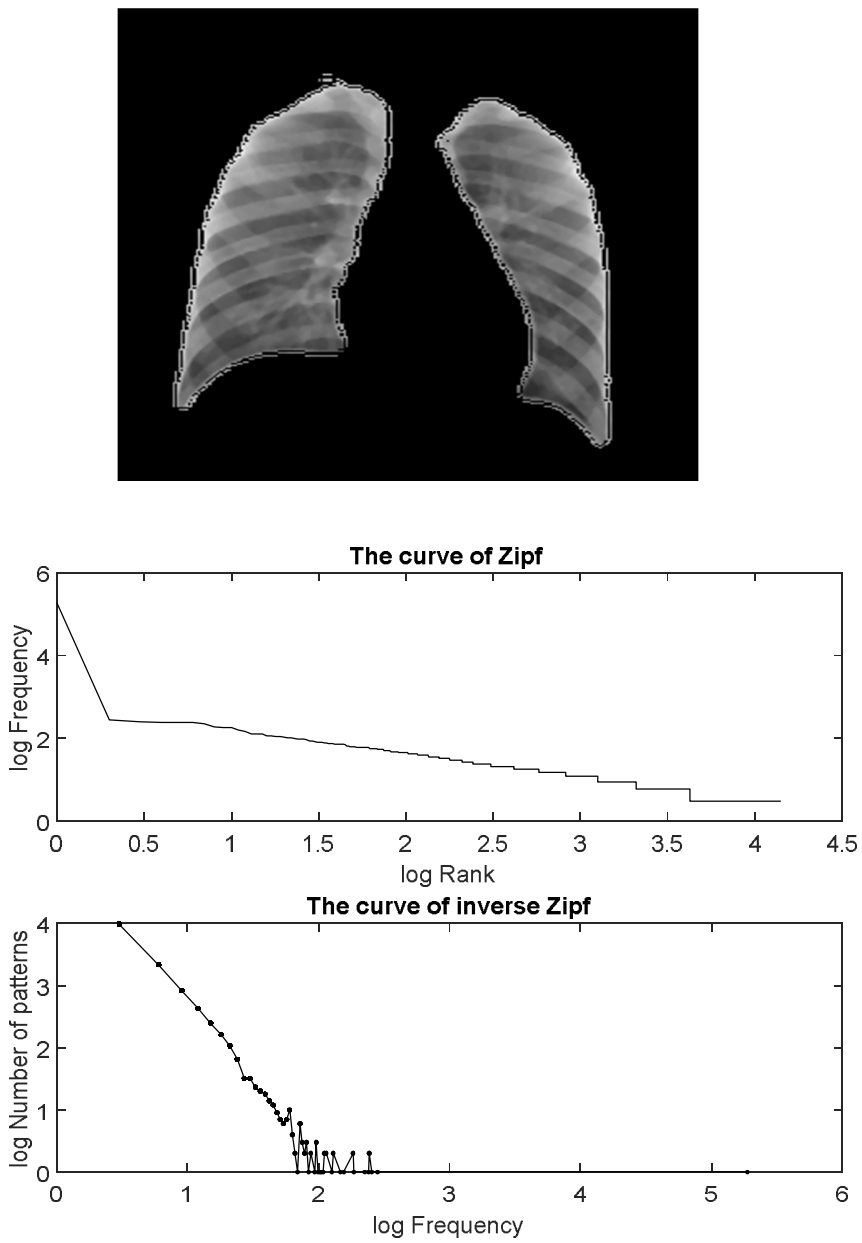


Figure IV.9 Courbes de Zipf et de Zipf inverse d'un poumon sain





Figure IV.10 Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie virale.





Figure IV.11 Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie bactérienne

- **Résultats obtenus pour le modèle 2**




Figure IV.12 Entraînement et validation de l'accracy




Figure IV.13 Entraînement et validation de loss

Au cours des premières étapes de l'expérience ... nous avons décidé de mener une deuxième expérience où nous avons appliqué le filtre CLAHE puis suivi du filtre médian sur les données et l'avons testé pour voir leur effet sur les données. Comme l'une des caractéristiques du filtre est la surbrillance CLAHE, mais les images sont perdues les contours.

C'est pourquoi nous avons appliqué après celui-ci un filtre médian pour essayer de récupérer les contours que nous avons précédemment perdu et nous terminons le reste du processus comme la première étape.

- **Comparaison**

Une comparaison entre la première et la deuxième expérience, la première image (à gauche) montre l'expérience du filtre médian, et la deuxième image montre l'expérience du filtre CLAHE, suivie du filtre médian.




Figure IV.14 Une comparaison entre la première et la deuxième expérience

Tableau IV.3 Evaluation de l'approche proposée de détection de Covid-19.

Nom modèle de classification (SVM)	kernel	C	Numb de Xray	Accuracy
Modèle1	RBF	1.0	3000	0.93
Modèle2	RBF	1.0	7345	0.98

IV.4 Interface réalisée pour les approches proposées

Nous allons maintenant présenter les résultats obtenus grâce à des expériences réalisées par l'application de notre approche de segmentation et classification des échographies thoraciques.

Les fonctionnalités de notre interface sont les suivantes :

1. Disponibilité des modèles pour d'éventuelles segmentations ainsi que classifications de nouvelles échographies thoraciques.
2. Sélectionner l'échographie thoracique à segmenter et classifier.
3. Obtention de la segmentation de l'échographie thoracique par le modèle de segmentation.
4. Obtention de la classification de l'échographie thoracique par le modèle de classification basé l'algorithme des SVM.

Nous présentons sur la figure IV.21, la fenêtre principale de l'interface de nos approches.




Figure IV.15 Fenêtre principale (home) des approches proposées.

Ensuite, nous devons choisir le modèle désiré à savoir celui de la distinction entre un poumon atteint de Covid-19, un poumon atteint de pneumonie ou un poumon normal ou bien celui distinguant entre les lésions de Covid-19 et celles de la pneumonie.




Figure IV.16 Choix du modèle Covid-19/Pneulonia/normal lung.

Ensuite nous choisissons l'échographie thoracique comme mentionné sur la figure IV.23.

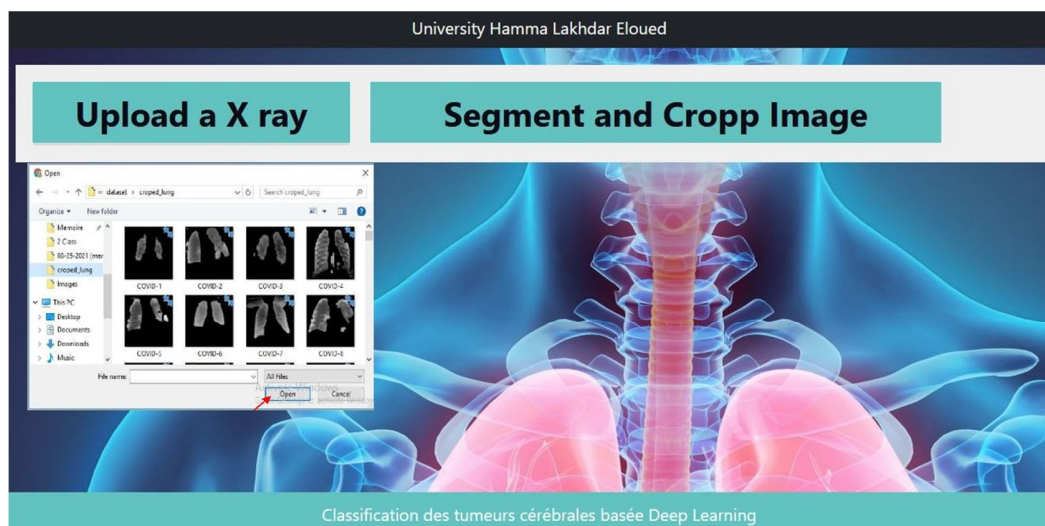


Figure IV.17 Choix de l'échographie thoracique de modèle Covid-19/Pneulonia/normal lung.

L'échographie thoracique sera téléchargée dans l'interface.




Figure IV.18 Téléchargement de l'échographie thoracique de modèle Covid-19/Pneulonia/normal lung.

D'autre part, si nous désirons faire appel au deuxième modèle segmentant la lésion présente dans le poumon et réalisant sa classification, ceci sera comme indiqué sur la figure IV.29 où il s'est avéré que les lésions segmentées à partir du poumon sont bien celles relatives au Covid-19.

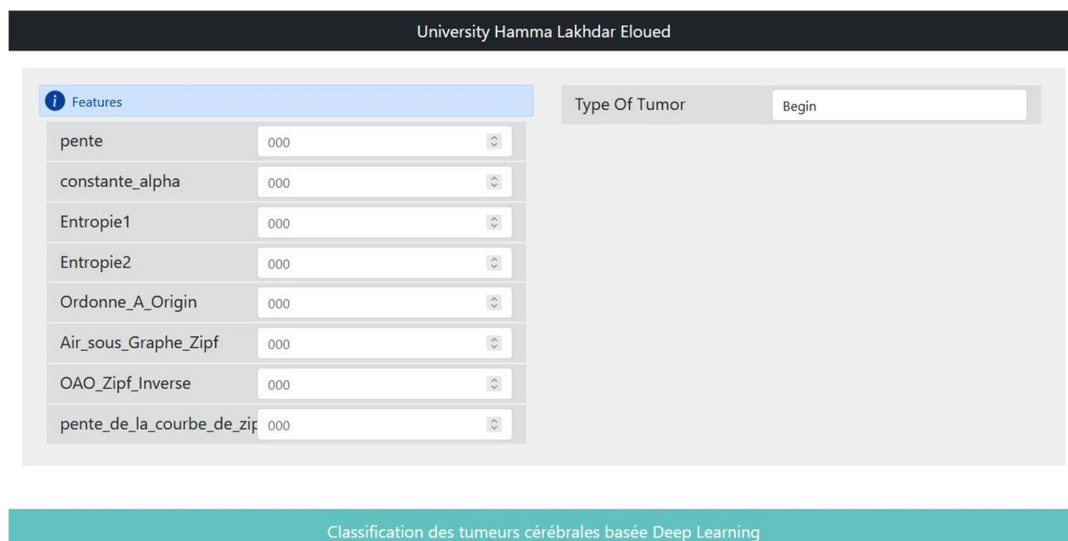


Figure IV.19 Segmentation de la lésion pulmonaire et réalisation de la classification où nous pouvons affirmer que l'approche a classifié correctement la lésion comme spécifique au Covid19.

IV.5 Conclusion

Dans ce chapitre, nous avons expliqué la mise en œuvre de notre application ainsi que la configuration matérielle et logicielle utilisée. et les mesures de performances utilisées (la matrice de confusion et les formules: accuracy, sensitivity, specificity), et ensuite présenter l'évaluation des résultats de la segmentation des poumons (le accuracy de la segmentation, les courbes de l'accuracy, le résultat de segmentation), A la fin nous avons présenté notre application en donnant quelques captures d'écran qui expliquent l'évaluation de l'approche proposée de détection de Covid-19.

Conclusion générale

Conclusion générale

Conclusion générale

Depuis le début de la pandémie de COVID-19, le monde a connu des perturbations d'une ampleur sans précédent affectant notre vie quotidienne, y compris, mais sans s'y limiter, la santé, les affaires, l'éducation et les transports.

Le manque de succès de diagnostic et les mesures préventives ont entraîné une augmentation du nombre de cas, une augmentation du coût des hospitalisations et les soins palliatifs. Par conséquent, les scientifiques et les industries médicales du monde entier ont incité pour aboutir à une détection rapide et précise de COVID-19 pour la prévention précoce, le dépistage, la prévision, le développement de médicaments, et le suivi des contacts pour gagner plus de temps par rapport à la communauté scientifique et les experts de la santé.

Sachons que le RT-PCR a une faible sensibilité de 60 % à 70 % [16] et qu'il s'agit également d'une méthode qui prend du temps, la détection des effets pathologiques du COVID-19 en examinant les images des poumons des patients peut garantir un traitement précoce. En effet, au fur et à mesure que l'épidémie se propageait, l'augmentation des données de CXR des patients diagnostiqués avec COVID-19 a polarisé presque tous les efforts de recherche sur les études d'interprétation d'images. Dans ce sens, la lutte contre la pandémie de Covid-19 peut être entreprise à l'aide de l'intelligence artificielle, en particulier les modèles basés sur l'apprentissage automatique et profond qui seront la base de développement de systèmes CAD de détection automatique de Covid-19.

Les méthodes d'apprentissage en profondeur ont été spécialement largement appliquées dans de nombreux domaines de l'imagerie médicale. En conséquence, le dépistage de Covid-19 par des algorithmes d'apprentissage en profondeur s'est considérablement épanoui au cours de cette épidémie.

Les réseaux de neurones convolutifs ont obtenu des résultats extraordinaires. En effet, un réseau de neurones est une série d'algorithmes qui reconnaissent les relations dans un ensemble de données grâce à un processus très similaire au fonctionnement du cerveau humain [16]. Cet algorithme est très efficace pour la reconnaissance de formes et le traitement d'images. Il prend des images en entrée et construit un modèle qui traite les images pour extraire les caractéristiques de ces images et reconnaît un objet par exemple. En utilisant le modèle, CNN identifie les similitudes des nouvelles entrées aussi précisément que possible. Cet algorithme est très

Conclusion générale

populaire en raison de sa structure simple, de son adaptabilité, de ses paramètres d'apprentissage réduits et de la faible complexité du modèle de réseau.

Malgré le succès des paradigmes de l'intelligence artificielle dans la lutte contre le Covid-19, ceci dit, quelques perspectives s'imposent :

- La communauté scientifique et les développeurs doivent normaliser un protocole dans le but de minimiser l'énorme volume d'études sur le Covid-19 qui peut prêter à confusion pour les chercheurs intéressés et fournir des études solides en suivant les critères suivants [14] : Recueillir un ensemble de données approprié auprès de différents centres médicaux, y compris de nombreux images pour chaque patient, la phase de prétraitement de l'ensemble de données doit être améliorée en termes de modèle utilisé, comme l'utilisation de FC-DenseNet103 pour la segmentation au lieu de UNet, également dans les études examinées, l'augmentation des données est soit complètement exclue, soit non significative en taille, dans le cas de la pandémie de COVID-19, les chercheurs doivent fournir des modèles légers à utiliser par les développeurs et les chercheurs dans les pays qui ont des ressources limitées, les chercheurs devraient se concentrer sur les images ULS plutôt que sur les rayons X et la tomodensitométrie, toutes les mesures d'évaluation doivent être utilisées dans le but de détecter le COVID-19 afin de proposer un prototype solide capable de détecter différents types de maladies sur la base d'images.
- Bien que les méthodes ML et DL aient grand potentiel dans la gestion du Covid-19, l'efficacité des méthodes dépend des bases de données où certaines bases de données contiennent des étiquettes incomplètes et erronées, ce qui crée un défi durant la prédiction de la maladie.
- Il convient de noter que l'imagerie ne fournit que des informations partielles sur les patients atteints de COVID-19. Ainsi, il est important de combiner les données d'imagerie avec les manifestations cliniques et les résultats des examens de laboratoire pour aider à une meilleure détection et diagnostic de Covid-19.

Les Références

Références

- [1] S Bhattacharya, P Kumar, R. Maddikunta, Q. Pham, T R. Gadekallu, S R Krishnan, C Lal Chowdhary, Mamoun Alazab, Md. Jalil Piran. Deep learning and medical image processing for coronavirus (COVID-19) pandemic: A survey. *Sustainable Cities and Society* 65 (2021).
- [2] S Suba and N. Parekh. Machine Learning Approaches in Detection and Diagnosis of COVID-19. *Artificial Intelligence and Machine Learning in Healthcare*. (2021).
- [3] S Kumari, Ediga Ranjith , Abhishek Gujjar , Siranjeevi Narasimman , H S Aadil Sha Zeelani Comparative analysis of deep learning models for COVID-19 detection. *Global Transitions Proceedings* 2 (2021).
- [4] M Khamadja et S Benierbah, Traitement d'images, Université des frères Mentouri Constantine 1, 10/03/2020.
- [5] A LE NEGRATE, A BEGHADADI, K BOUSSAÏDBELKACEM, Quelques traitements bas niveau basés sur une analyse du contraste local, Université Paris.
- [6] H S CHAHINEZ, B KHADIDJA. FILTRE DE GABOR. Université Abou Bekr Belkaid – Tlemcen (2014).
- [7] T Chabha, ZOBIRI Assia. Segmentation d'images texturées par filtrage de Gabor : application aux images médicales. Université Mouloud Mammeri Tizi Ouezou. (2011).
- [8] M Mehri, Mohamed Mhiri, Petra Gomez-Krämer, Pierre Héroux, Mohamed Ali Mahjoub, et al. Étude comparative de trois ensembles de descripteurs de texture pour la segmentation de documents anciens. *CIFED 2014 - Actes du treizième Colloque International Francophone sur l'Écrit et le Document*, Mar 2014, Nancy, France. pp.41-56, 2014.
- [9] R M Haralick, K Shanmugam., I Dinstein, « Textural features for image classification », *SMC*, vol. 3, no 6, p. 610-621, 1973.
- [10] A Esteva, A Robicquet, B Ramsundar, V Kuleshov, M DePristo, K Chou, C Cui, Greg Corrado, Sebastian Thrun and Jeff Dean. A guide to deep learning in healthcare. *Nature Medicine*. VOL 25 **24**. (2019).
- [11] C Janiesch, P. Zschech, & K. Heinrich, Machine learning and deep learning. *Electron Markets* **31**, 685–695 (2021). <https://doi.org/10.1007/s12525-021-00475-2>
- [12] M Aras. Ismael, Abdulkadir S,engür. Deep learning approaches for COVID-19 detection based on chest X-ray images. *Expert Systems With Applications* 164 (2021).

Les Références

- [13] Frédéric SUR, Introduction à l'apprentissage automatique, École des Mines de Nancy, 2020-2021.
- [14] A I Khan, J Latief Shah , Mohammad Mudasir Bhat. CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images. *Computer Methods and Programs in Biomedicine* 196 (2020).
- [15] J Carvalho Souza, JoãoOtávio Bandeira Diniz, Jonnison Lima Ferreira, Giovanni Lucca França da Silva, Aristófanés CorrêaSilva, AnselmoCardoso dePaiva. An automatic method for lung segmentation and reconstruction in chest X-ray using deep neural networks. *Computer Methods and Programs in Biomedicine* 177 (2019)
- [16] E Hussain , M Hasan , Md Anisur Rahman, Ickjai Lee, Tasmi Tamanna , Mohammad Zavid Parvez. CoroDet: A deep learning based classification for COVID-19 detection using chest X-ray images. *Chaos, Solitons and Fractals* 142 (2021).
- [17] M Anas. Tahir, Yazan Qiblawey, Amith Khandakar, Tawsifur Rahman, Uzair Khurshid, Farayi Musharavati, M. T. Islam, Serkan Kiranyaz, Somaya Al-Maadeed, Muhammad E. H. Chowdhury. Deep Learning for Reliable Classification of COVID-19, MERS, and SARS from Chest X-ray Images. *Cognitive Computation* (2021).
- [18] M Fatih Aslan, M Fahri Unlarsen, Kadir Sabanci, Akif Durdu. CNN-based transfer learning–BiLSTM network: A novel approach for COVID-19 infection detection. *Applied Soft Computing Journal* 98 (2021)
- [19] A Ambati, S R Dubey. AC-CovidNet: Attention Guided Contrastive CNN for Recognition of Covid-19 in Chest X-Ray Images. *arXiv:2105.10239v1*(2021).
- [20] A Bhattacharyya, D Bhaik, S Kumar, P Thakur, Rahul Sharma, Ram Bilas Pachori. A deep learning based approach for automatic detection of COVID-19 cases using chest X-ray images. *Biomedical Signal Processing and Control* 71 (2022).
- [21] W. U. O. COVID-19, 2022. [https:// covid 19. who. int/.com](https://covid19.who.int/)
- [22] N NarayanDas, N.Kumarb, M.Kaur, V.Kumard, D.Singh. Automated Deep Transfer Learning-Based Approach for Detection of COVID-19 Infection in Chest X-rays. *IRBM* (2020).
- [23] W Hariri, A Narin. Deep Neural Networks for COVID-19 Detection and Diagnosis using Images and Acoustic-based Techniques: A Recent Review. *arXiv:2012.07655v4*. (2021).
- [24] T E Komolafe, Yuzhu Cao, MS, Benedictor Alexander Nguchu, Patrice Monkam, Ebenezer Obaloluwa Olaniyi, Haotian Sun, Jian Zheng, Xiaodong Yang. Diagnostic Test Accuracy of

Les Références

- Deep Learning Detection of COVID-19: A Systematic Review and Meta-Analysis. *Academic Radiology* (2021).
- [25] Q Ye, J Xia, G Yang. EXPLAINABLE AI FOR COVID-19 CT CLASSIFIERS: AN INITIAL COMPARISON STUDY. arXiv:2104.14506v1. (2021).
- [26] N B Prakash, M. Murugappan, G.R. Hemalakshmi, M. Jayalakshmi, Mufti Mahmud. Deep transfer learning for COVID-19 detection and infection localization with superpixel based segmentation. *Sustainable Cities and Society* 75 (2021).
- [27] R Chandra Joshi, Saumya Yadav, Vinay Kumar Pathak, Hardeep Singh Malhotra, Harsh Vardhan Singh Khokhar, Anit Parihar, Neera Kohli, D. Himanshu, Ravindra K. Garg, Madan Lal Brahma Bhatt, Raj Kumar, Naresh Pal Singh, Vijay Sardana, Radim Burget, Cesare Alippi, Carlos M. Travieso-Gonzalez, Malay Kishore Dutta. A deep learning-based COVID-19 automatic diagnostic framework using chest X-ray images. *bio cybernetics and biomedical engineering* 41 (2021) 239–254.
- [28] S RAJARAMAN, J SIEGELMAN, O PHILIP. ALDERSON, LUCAS S. FOLIO, LES R. FOLIO, AND SAMEER K. ANTANI. Iteratively Pruned Deep Learning Ensembles for COVID-19 Detection in Chest X-Rays. *Digital Object Identifier 10.1109/ACCESS.2020.3003810* (2020)
- [29] W Hryniewska , P Bombi ´nski, P Szatkowski , P Tomaszewska , Artur Przelaskowski , Przemysław Biecek. Checklist for responsible deep learning modeling of medical images based on COVID-19 detection studies. *Pattern Recognition* 118 (2021)
- [30] A Signoroni, M Savardi, S Benini, N Adami, Riccardo Leonardi, Paolo Gibellini, Filippo Vaccher, Marco Ravanelli, Andrea Borghesi, Roberto Maroldi, Davide Farina. End-to-end learning for semiquantitative rating of COVID-19 severity on Chest X-rays. arXiv:2006.04603v2. (2020).
- [31] P Kumar, S Ambekar, S Roy, and P Kunchur. Computer-Aided Diagnosis of Life-Threatening Diseases. *Application of Biomedical Engineering in Neuroscience* 2019.
- [32] D Sharifrazi, , Alizadehsani, R., Roshanzamir, M., Joloudari, J. H., Shoeibi, A., Jafari, M., et al. (2021). Fusion of convolution neural network, support vector machine and sobel filter for accurate detection of covid-19 patients using X-ray images. *Biomedical Signal Processing and Control*, 68, Article 102622.

Les Références

- [33] R Kumar, R Arora, V Bansal, Sahayasheela VJ (2020) Accurate prediction of COVID-19 using chest X-ray images through deep feature learning model with SMOTE and machine learning classifiers. medRxiv Prepr. <https://doi.org/10.1101/2020.04.13.20063461>.
- [34] M Barstugan, Ozkaya U, Ozturk S. Coronavirus (covid-19) classification using ct images by machine learning methods. arXiv:200309424. 2020.
- [35] P K Sethy, S.K. Behera, P.K. Ratha, P. Biswas, Detection of coronavirus disease (COVID-19) based on deep features, Int. J. Math. Eng. Manag. Sci. 5 (2020) 643–651, <http://dx.doi.org/10.20944/preprints202003.0300.v1>.
- [36] M Canayaz, MH-COVIDNet: Diagnosis of COVID-19 using deep neural networks and meta-heuristic-based feature selection on X-ray images, Biomed. Signal Process. Control 64 (2021).
- [37] P K Sethy, SK Behera. Detection of coronavirus disease (COVID-19) based on deep features. Preprints 2020:2020030300.
- [38] R Mostafiz, M.S. Uddin, N.-A.- Alam, Md.M. Reza, M.M. Rahman, Covid-19 detection in chest X-ray through random forest classifier using a hybridization of deep CNN and DWT optimized features, J. King Saud Univ. Comput. Inf. Sci. (2020).
- [39] A Hassanien, E., Mahdy, L. N., Ezzat, K. A., Elmousalami, H., & Aboul Ella, H. (2020). Automatic X-ray COVID-19 Lung Image Classification System based on Multi-Level Thresholding and Support Vector Machine.
- [40] A M Alqudah, S Qazan, H Alquran, A QasmiehI, A Alqudah. COVID-2019 detection using X-ray images and artificial intelligence hybrid systems. <https://doi.org/10.5455/jjee.204-1585312246>, 2020.
- [41] P SethyK., S. Behera, K., Ratha, P. K., & Biswas, P. (2020). Detection of coronavirus disease (COVID-19) based on deep features and support vector machine. International Journal of Mathematical, Engineering and Management Sciences, 5(4), 643–651. <https://doi.org/10.33889/IJMEMS.2020.5.4.052>.
- [42] A O Salau, Detection of Coronavirus Disease Using a Novel Machine Learning Approach. 2021 International Conference on Decision Aid Sciences and Application (DASA), Sakheer Bahrain, 2021, pp. 587–590, <https://doi.org/10.1109/DASA53625.2021.9682267>.

Les Références

- [43] Z Tang, Zhao, W, Xie, X, Zhong, Z, Shi, F, Liu, J, & Shen, D. (2020). Severity assessment of coronavirus disease 2019 (COVID-19) Using quantitative features from chest CT images. *ArXiv*, 2019, 1–18.
- [44] F Shi, Xia, L, Shan, F, Wu, D, Wei, Y, Yuan, H, & et al. (2020). Large-scale screening of COVID-19 from community acquired pneumonia using infection size-aware classification. *ArXiv*.
- [45] S H Kassani, P H Kassani, Michal J. Wesolowski, Kevin A. Schneider, Ralph Deters. Automatic detection of coronavirus disease (COVID-19) in X-ray and CT images: A machine learning based approach. *biocybernetics and biomedicalengineering* 41 (2021) 867– 879
- [46] P Saha, M Sheikh Sadi, Md. M Islam. EMCNet: Automated COVID-19 diagnosis from X-ray images using convolutional neural network and ensemble of machine learning classifiers. *Informatics in Medicine Unlocked* 22 (2021) 100505.
- [47] A Abbas, M Abdelsamea, M, & Gaber, M. M. (2021). Classification of covid-19 in chest X-ray images using detrac deep convolutional neural network. *Applied Intelligence: The International Journal of Artificial Intelligence, Neural Networks, and Complex Problem-Solving Technologies*, 51(2), 854–864.
- [48] K Shibly, H. Dey, S. K., Islam, M. T. U., & Rahman, M. M. (2020). COVID faster R–CNN: A novel framework to Diagnose Novel Coronavirus Disease (COVID-19) in X-Ray images. *Informatics in Medicine Unlocked*, 20, 100405. <https://doi.org/10.1016/j.imu.2020.100405>.
- [49] L Hall, O. Paul, R., Goldgof, D. B., & Goldgof, G. M. (2020). Finding COVID-19 from Chest X-rays using Deep Learning on a Small Dataset. *ArXiv*, 1–8.
- [50] S Nayak. R Nayak, D. R., Sinha, U., Arora, V., & Pachori, R. B. (2021). Application of deep learning techniques for detection of covid-19 cases using chest X-ray images: A comprehensive study. *Biomedical Signal Processing and Control*, 64, Article 102365.
- [51] A Khan, I. Shah, J. L., & Bhat, M. M. (2020). CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images. *Computer Methods and Programs in Biomedicine*, 196, 105581. <https://doi.org/10.1016/j.cmpb.2020.105581>.

Les Références

- [52] M Nour , Z. Cömert, & Polat, K. (2020). A Novel Medical Diagnosis model for COVID-19 infection detection based on Deep Features and Bayesian Optimization. *Applied Soft Computing Journal*, xxxx, 97, 106580. <https://doi.org/10.1016/j.asoc.2020.106580>.
- [53] T Ozturk, M Talo, EA Yildirim, UB Baloglu, O Yildirim, UR Acharya. Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Comput Biol Med* 2020:103792.
- [54] R Karthik, R Menaka, & M. Hariharan, (2020). Learning distinctive filters for COVID- 19 detection from chest X-ray using shuffled residual CNN. *Applied Soft Computing Journal*, xxxx, 106744. <https://doi.org/10.1016/j.asoc.2020.106744>.
- [55] S Asif, Y Wenhui. Automatic detection of COVID-19 using X-ray images with deep convolutional neural networks and machine learning. *medRxiv*, 2020.
- [56] S Varela-Santos, P Melin, Classification of x-ray images for pneumonia detection using texture features and neural networks, in: *Intuitionistic and Type-2 Fuzzy Logic Enhancements in Neural and Optimization Algorithms: Theory and Applications*, Springer International Publishing, 2020, pp. 237–253.
- [57] T Ozturk, M.Talo, E Yildirim, U. B Baloglu, O Yildirim, & R Acharya, U. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*, 121(April), Article 103792. <https://doi.org/10.1016/j.combiomed.2020.103792>.
- [58] K E Asnaoui, Y Chawki, A Idri. Automated methods for detection and classification pneumonia based on X-ray images using deep learning. *arXiv preprint. arXiv:2003 .14363*, 2020
- [59] M Z Islam, M. M Islam, & A. Asraf, (2020). A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images. *Informatics in Medicine Unlocked*, 20, 100412. <https://doi.org/10.1016/j.imu.2020.100412>.
- [60] M Qjidaa, A. Ben-Fares, Y. Mechbal, H. Amakdouf, M. Maaroufi, B. Alami, et al., Development of a clinical decision support system for the early detection of COVID- 19 using deep learning based on chest radiographic images, in: *2020 Int. Conf. Intell. Syst. Comput. Vision ISCV*, 2020, p. 2020, <https://doi.org/10.1109/ ISCV49265.2020.9204282>.

Les Références

- [61] Y Oh, S Park, J C Ye, Deep learning COVID-19 features on CXR using limited training data sets, *IEEE Trans. Med. Imaging* 39 (2020) 2688–2700, <https://doi.org/10.1109/TMI.2020.2993291>.
- [62] A Abbas, M. M Abdelsamea, & M. M. Gaber, (2020). Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network. *Applied Intelligence*. <https://doi.org/10.1007/s10489-020-01829-7>.
- [63] J D Lopez-Cabrera, R Orozco-Morales, J A Portal-Diaz, O Enriquez, M Perez-Diaz. Current limitations to identify COVID-19 using artificial intelligence with chest X-ray imaging. *Health and Technology* (2021) 11:411–424.
- [64] S Ahmed, Elkorany, F Zeinab. Elsharkawy. COVIDetection-Net: A tailored COVID-19 detection from chest radiography images using deep learning. *Optik - International Journal for Light and Electron Optics* 231 (2021)
- [65] S Rahman, S Sarker, Md Abdullah AlMiraj, R A Nihal, A. K. M. Nadimul Haque, A Al Noman. Deep Learning–Driven Automated Detection of COVID-19 from Radiography Images: a Comparative Analysis. *Cognitive Computation* (2021).
- [66] F Shi, J Wang, J Shi , Wu Ziyang, Q Wang, Z Tang, He Kelei, Y Shi , and Dinggang Shen. Review of Artificial Intelligence Techniques in Imaging Data Acquisition, Segmentation, and Diagnosis for COVID-19. *IEEE REVIEWS IN BIOMEDICAL ENGINEERING*, VOL. 14, 2021
- [67] N Cummins, Z Ren, A M Ragolta, B Schuller. Machine learning in digital health, recent trends, and ongoing challenges. CHAPTER. *Artificial Intelligence in Precision Health*. <https://doi.org/10.1016/B978-0-12-817133-2.00005-7.2020>.
- [68] P L Vidal, J Moura, Jorge Novo, Marcos Ortega. Multi-stage transfer learning for lung segmentation using portable X-ray devices for patients with COVID-19. *Expert Systems With Applications* 173 (2021)
- [69] M HAMOUD, Indexation et segmentation d'images basées loi de Zipf et Zipf inverse, mémoire de doctorat UNIVERSITY BADJI MOKHTAR-ANNABA 2015.
- [70] B ALLEL, L MIHOUBI. Analyse de texture par les filtres de Gabor et Laws. Mémoire de Master en Electronique. 2014.

Les Références

- [71] M Haghghat, S Zonouz, M Abdel-Mottaleb, "CloudID: Trustworthy cloud-based and cross-enterprise biometric identification". *Expert Systems with Applications*, vol. 42, no. 21, pp. 7905-7916, 2015.
- [72] QaTa-COV19 Database. <https://www.kaggle.com/aysendegerli/qatacov19-dataset>. Accessed 14 March 2021.
- [73] Covid-19-image-repository. Available: <https://github.com/ml-workgroup/covid-19-image-repository/tree/master/png>. Accessed 14 March 2021.
- [74] Eurorad. Available: <https://www.eurorad.org/>. Accessed 14 March 2021.
- [75] Covid-chestxray-dataset. Available: <https://github.com/ieee8023/covid-chestxray-dataset>. Accessed 14 March 2021.
- [76] COVID-19 DATABASE. Available: <https://www.sirm.org/category/senza-categoria/covid-19/>. Accessed 14 March 2021.
- [77] Kaggle. (2020). COVID-19 Radiography Database. Available: <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>. Accessed 14 March 2021.
- [78] GitHub. (2020). COVID-CXNet. Available: <https://github.com/armiro/COVID-CXNet>. Accessed 14 March 2021.
- [79] RSNA Pneumonia Detection Challenge. Available: <https://www.kaggle.com/c/rsna-pneumonia-detection-challenge/data>. Accessed 14 March 2021.
- [80] Chest X-Ray Images (Pneumonia). Available: <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>. Accessed 14 March 2021.
- [81] Medical Imaging Databank of the Valencia Region. PadChest: A large chest x-ray image dataset with multi-label annotated reports. Available: <https://bimcv.cipf.es/bimcv-projects/padchest/>. Accessed 14 March 2021.
- [82] M E H Chowdhury, T Rahman, A Khandakar, R Mazhar, M A Kadir, Z B Mahbub, K R Islam, M S Khan, A Iqbal, N Al-Emadi, M B I Reaz, M T Islam, "Can AI help in screening Viral and COVID-19 pneumonia?" *IEEE Access*, Vol. 8, 2020, pp. 132665 - 132676. Paper link
- [83] T Rahman, A Khandakar, Y Qiblawey, A Tahir, S Kiranyaz, Kashem, S B A, Islam, M T, Maadeed, S A, Zughaier, S M, Khan, M S and Chowdhury, M E, 2020. Exploring the Effect of Image Enhancement Techniques on COVID-19 Detection using Chest X-ray Images.