

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 : Systèmes Distribués et Intelligence Artificielle

Présenté par :

- **REZZAG MOHCEN Salem**

Thème

**Détection de Covid-19 basée
apprentissage par transfert,
apprentissage profond et
apprentissage automatique**

Soutenu le 22-09- 2021 Devant le jury:


M. Ben Ali Abdelkamel	MCA	Président
M. Bellila Khaoula	MAA	Rapporteur
M. Retima Farida	MCB	Encadreur
M. Hamoud Meriem	MCB	Co-encadreur

Année Universitaire: 2021/2022



Remerciements

Remerciements



A la fin de ce travail, tous mes remerciements s'adressent tout d'abord à tout puissant ALLAH, d'avoir guidé mes pas vers le chemin du savoir.

Nous tenons à exprimer notre plus grand remerciement à nos Très chers parents pour leur soutien moral et leurs encouragements, et tous les membres de ma famille.

Nous tenons tout particulièrement à remercier Dr. Melle HAMOUDE Meriem pour l'encadrement de ce mémoire et pour la confiance qu'elle nous accordée, sa disponibilité, son aide et ses bons conseils.

Sans oublier d'adresser nos vifs remerciements aux membres de Jury qui nous ont honoré de juger notre travail.

Enfin je remercie mon amis "Alaa, Cherif, Khaled, ...", Et toute personne ayant œuvré de près ou de loin à la réalisation de ce projet par une quelconque



Résumé

De nos jours, nous sommes confrontés à la lutte en cours contre le nouveau virus de Corona, où des millions de personnes sont infectées quotidiennement avec un taux de mortalité de 2%. En ce sens, nous visons à accomplir une méthode substantielle pour diagnostiquer les patients COVID-19 en distinguant les échographies thoraciques de COVID-19, de pneumonie et d'un patient en bonne santé. Les systèmes CAD d'apprentissage en profondeur semblent une bonne solution dans une situation aussi effrayante. En effet, les méthodes de segmentation manuelle sont chronophages, monotones et peuvent être affectées par la variabilité inter et intra-observateur.

Dans ce travail, nous utilisons l'apprentissage par transfert, la segmentation des poumons par le modèle U-net d'apprentissage profond ainsi qu'une classification via l'algorithme SVM pour détecter le COVID-19 basé les modèles de lois de puissance de Zipf et Zipf inverse et les filtres de Gabor pour la caractérisation de la texture.

Notre approche proposée a la capacité de classifier les échographies de COVID-19, la pneumonie et une personne en bonne santé avec une grande précision.

Mots clés : COVID-19, Echographie thoracique, Système CAD, Transfer learning, Segmentation, U-net, Classification, SVM, Les lois puissance : Zipf et Zipf inverse, Les filtres de Gabor.

Abstract

Nowadays we are in front of the ongoing fight with Novel Corona Virus where millions getting infected daily and a fatality rate of 2%. In this sense, we aim to accomplish a substantial method for diagnosing COVID-19 patients through distinguishing among X-rays of COVID-19, pneumonia and a healthy patient. Deep learning CAD systems seems a good solution amidst such a frightful situation. Indeed, manual segmentation methods are time-consuming, monotonous, and can be affected by inter and intra-observer variability.

In this work, we deal with transfer learning, lung segmentation through U-net deep learning model and classification framework based SVM algorithm to detect COVID-19 infection by power laws models of Zipf and inverse Zipf with Gabor filters for texture characterization.

Our proposed method has the ability to distinguish among X-rays of COVID-19, pneumonia and a healthy person with high accuracy.

Key words: COVID-19, X-rays, CAD systems, Transfer learning, Segmentation, U-net, Classification, SVM, Power law: Zipf and inverse Zipf, Gabor filters.

ملخص:

في يومنا هذا، نواجه معركة مستمرة ومستديمة ضد فيروس كورونا المستجد، حيث يصاب الملايين من الأشخاص يومياً بمعدل 2٪ من الوفيات. بمعنى، نهدف إلى إنجاز طريقة جوهرية لتشخيص مرضى فيروس كورونا 19 من خلال التمييز بين تصوير الموجات فوق الصوتية للصدر لفيروس كورونا 19، والالتهاب الرئوي والمريض السليم. تبدو أنظمة CAD للتعلم العميق في مثل هذا الموقف المخيف كحل جيد ومناسب. في الواقع، تستغرق طرق التجزئة يدوياً وقتاً طويلاً، وهي وتيرة يمكن أن تتأثر بالمتغيرات والمراقب الداخلي.

في هذا العمل، نستخدم التعلم بالتحول، تجزئة الرئة بواسطة نموذج التعلم العميق U-net والتصنيف عبر خوارزمية SVM للكشف عن COVID-19 استناداً إلى نماذج قانون الطاقة بـ Zipf و Zipf العكسي ومرشحات Gabor لوصف النسيج.

في نهجنا المقترح لديه القدرة على تصنيف فحوصات الموجات فوق الصوتية لـ COVID-19 والالتهاب الرئوي والشخص السليم بدقة عالية.

كلمات مفتاحية: COVID-19، الموجات فوق الصوتية للصدر، نظام CAD، التعلم بالتنقل، التقسيم، U-net، التصنيف، SVM، قوانين الطاقة: Zipf و Zipf العكسي، مرشحات Gabor.

Abréviations

IA	Intelligence Artificielle
Covid-19	Coronavirus 2019
ANN	Artificial neural network
1D	1 Dimension
2D	2 Dimension
3-D	3 Dimension
LBP	Local Binary Patterns
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
PHEIC	Public Health Emergency of International Concern
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
QaTa-COV19	Qatar Coronavirus 19
CLAHE	Contrast Limited Adaptive Histogram Equalization
GGO	Ground-Glass Opacification
HTML	HyperText Markup Language
CSS	Cascading Style Sheets
RBF	Radial Basis Function
W3C	World Wide Web Consortium
SQL	Structured Query Language
XML	eXtensible Markup Language
TP	True Positif
TN	True Négatif
FN	False Négatif
FP	False Positif

Table de matières

Table de matières	I
Liste des figures.....	VIII
Liste des tableaux.....	XV
Introduction générale	1
Chapitre I : Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond	
I.1 Introduction	4
I.2 La vision par ordinateur	5
I.3 L'analyse d'image	6
I.3.1 Les niveaux d'analyse d'image	7
I.3.2 Analyse de la texture d'image	8
I.4 Les nouvelles tendances de l'apprentissage automatique et l'apprentissage profond	9
I.4.1 L'apprentissage automatique	10
I.4.2 L'apprentissage profond	20
I.5 Les modèles des réseaux de neurone convolutifs	26
I.5.1 U-NET	26
I.5.2 VGG-16	27
I.5.3 ResNet	29
I.6 L'apprentissage par transfert	29
I.7 Conclusion	31
Chapitre II : Pronostic automatique de COVID-19	
II.1 Introduction	33
II.2 Aperçu sur la pandémie de Covid-19	34
II.3 Dépistage de covid-19	36

II.3.1	Dépistage par radiographie thoracique CXR (Chest X-Ray)	36
II.3.2	Dépistage par Tomodensitométrie (CT scan)	37
II.3.3	Bilan	38
II.4	Limites des images échographiques durant la détection de Covid-19	39
II.5	Diagnostic assisté par ordinateur (CAD) de Covid-19 ..	39
II.5.1	Détection des régions d'intérêt assistée par ordinateur (CAdE)	41
II.5.2	Diagnostic des régions d'intérêt assisté par ordinateur (CAdx)	42
II.6	Application de l'apprentissage automatique pour la détection de Covid-19	43
II.7	Application de l'apprentissage profond pour la détection de Covid-19	45
II.8	Conclusion	48
Chapitre III: Problématique extraite et approche suggérée		
III.1	Introduction	50
III.2	Problématique et plan d'action	51
III.3	Segmentation des régions d'intérêt dans les radiographies thoraciques basée Deep Learning	53
III.3.1	Base de données utilisée	53
III.3.2	Pipeline suivi basé U-Net pour la segmentation des régions d'intérêt	56
III.4	Classification des régions d'intérêt basée SVM	61
III.4.1	Régions d'intérêt obtenues	61
III.4.2	Pipeline de classification des régions d'intérêt basé l'algorithme des SVM	62
III.5	Aperçu schématique de l'approche proposée	72

III.6	Conclusion	74
	Chapitre IV: Evaluation des résultats obtenus par l'approche suggérée	
IV.1	Introduction	76
IV.2	Environnement de développement et outils utilisés	77
IV.2.1	Matériel	77
IV.2.2	Kaggle	77
IV.2.3	Python	78
IV.2.4	HTML5	79
IV.2.5	CSS3	80
IV.2.6	JavaScript	81
IV.3	Les mesures de performances utilisées	82
IV.3.1	Matrice de confusion	82
IV.3.2	Les formules des accuracy, sensitivity, specificity	83
IV.4	Evaluation des résultats de la segmentation des poumons	84
IV.4.1	Résultats obtenus pour le modèle 1.....	84
IV.4.2	Résultats obtenus pour le modèle 2	90
IV.5	Evaluation de l'approche proposée de détection de Covid-19	94
IV.6	Interface réalisée pour les approches proposées	95
IV.7	Conclusion	100
	Conclusion générale	101
	Bibliographie	104

Liste des figures

Chapitre I : Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

Figure I.1	Traitement de bas niveau des images	7
Figure I.2	Divers types de texture	9
Figure I.3	Exemple d'un réseau de neurones	11
Figure I.4	Le neurone avec une seule sortie	12
Figure I.5	Réseau de neurone à un seul niveau	13
Figure I.6	Réseau de neurones multi-niveaux	14
Figure I.7	Problème de classification à deux classes avec un séparateur linéaire	15
Figure I.8	Problème de classification à deux classes avec une séparatrice non linéaire	16
Figure I.9	Classification avec l'algorithme des K plus proches voisins	19
Figure I.10	Architecture générale d'un réseau de neurones convolutif	21
Figure I.11	Exemple de conv2d	22
Figure I.12	Convolution avec un noyau de taille 3*3 et un pas de 2..	23
Figure I.13	Exemple d'un Maxpooling	24
Figure I.14	Exemple de l'average pooling	25
Figure I.15	Allure de la fonction ReLU	25
Figure I.16	Architecture du modèle U-NET	27
Figure I.17	Architecture de VGG-16	28
Figure I.18	Bloc convolutif résiduel	29
Chapitre II : Pronostic automatique de COVID-19		
Figure II.1	Exemple du virus SARS-COV-2.....	35

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).....	37
Figure II.3	Tomodensitométrie après le symptôme de COVID-19, en a Jour 5, en b Jour 15 et en c Jour 20	38
Figure II.4	Fonctionnalités d'un système d'aide au diagnostic médical assisté par ordinateur (CAD)	40
Figure II.5	Processus d'extraction de la région des poumons. U-Net est appliqué comme méthode de segmentation et une image recadrée est obtenue.	42

Chapitre III: Problématique extraite et approche suggérée

Figure III.1	Quelques exemples des échographies thoraciques avec leur msques de lésions de COVID-19 de la base de donnée QaTa-COV19.....	54
Figure III.2	Quelques exemples des échographies thoraciques avec leur msques poumons.....	55
Figure III.3	Exemple de l'application d'un prétraitement par l'égalisation d'histogramme adaptative limitée en contraste (CLAHE) : à gauche les échographies originales et à droite après le prétraitement.....	57
Figure III.4	Architecture du modèle U-Net utilisé	59
Figure III.5	Pipeline suivi pour la classification des régions d'intérêt.....	62
Figure III.6	Courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19.....	64
Figure III.7	Courbes de Zipf et de Zipf inverse d'un poumon sein....	65
Figure III.8	Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie.....	66
Figure III.9	Les divers filtres de Gabor appliqués dans le domaine fréquentiel.....	70

Figure III.10	Parties réelles des filtres de Gabor utilisés.....	70
Figure III.11	Parties réelles des régions d'intérêt filtrées	71
Figure III.12	Magnitude de la réponse du filtre de Gabor suite à la convolution de la tumeur maligne avec une banque de filtres de Gabor.....	71
Figure III.13	Aperçu schématique du pipeline de l'approche proposée de détection du Covid-19.....	73

**Chapitre IV: Evaluation des résultats obtenus par
l'approche suggérée**

Figure IV.1	logo Kaggle.....	77
Figure IV.2	Bibliothèque Pytorch en Python	79
Figure IV.3	Logo HTML5	80
Figure IV.4	Logo CSS3	81
Figure IV.5	Logo JavaScript	82
Figure IV.6	Entraînement et validation de l'accuracy pour modèle 1 ..	85
Figure IV.7	Entraînement et validation de loss pour modèle 1	85
Figure IV.8	Résultat de courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19 de modèle 1.....	86
Figure IV.9	Résultat de courbes de Zipf et de Zipf inverse d'un poumon sein de modèle 1.....	87
Figure IV.10	Résultat de courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie de modèle 1.....	88
Figure IV.11	Exemple de X-ray d'échographie thoracique d'un poumon inpout de modèle 1.....	89
Figure IV.12	Exemple de masque X-ray d'échographie thoracique d'un poumon inpout de modèle 1.....	89
Figure IV.13	Résultat de segmentation X-ray d'échographie thoracique d'un poumon inpout de modèle 1.....	89
Figure IV.14	Entraînement et validation de l'accuracy pour modèle 2 ..	90
Figure IV.15	Entraînement et validation de loss pour modèle 2	90
Figure IV.16	Résultat de courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19 de modèle 2.....	91

Figure IV.17	Résultat de courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie de modèle 2.....	92
Figure IV.18	Exemple de X-ray d'échographie thoracique d'un poumon inpout de modèle 2.....	93
Figure IV.19	Exemple de masque X-ray d'échographie thoracique d'un poumon inpout de modèle 2.....	93
Figure IV.20	Résultat de segmentation X-ray d'échographie thoracique d'un poumon inpout de modèle 2.....	93
Figure IV.21	Fenêtre principale (home) des approches proposées	95
Figure IV.22	Choix du modèle Covid-19/Pneulonia/normal lung	96
Figure IV.23	Choix de l'échographie thoracique de modèle Covid-19/Pneulonia/normal lung	96
Figure IV.24	Téléchargement de l'échographie thoracique de modèle Covid-19/Pneulonia/normal lung	97
Figure IV.25	Choix du modèle Covid-19/Pneumonia lesions.....	97
Figure IV.26	Choix de l'échographie thoracique du modèle Covid-19/Pneumonia lesions.....	98
Figure IV.27	Téléchargement de l'échographie thoracique du modèle Covid-19/Pneumonia lesions.....	98
Figure IV.28	Segmentation de l'organe du poumon et réalisation de la classification où nous pouvons affirmer que l'approche a classifié correctement le poumon comme atteint du Covid-19.....	99
Figure IV.29	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 Covid-19.....	100

Liste des tableaux

Chapitre I : Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond


Tableau I.1	Les avantages et les inconvénients des SVM	16
Tableau I.2	Les avantages et les inconvénients de l'algorithme des KNN	19

Chapitre II : Pronostic automatique de COVID-19

Tableau II.1	Tableau II.1 Approches CAD basées apprentissage automatique de détection du Covid-19	43
Tableau II.2	Tableau II.2 Approches CAD basées apprentissage profond pour la détection du Covid-19.....	45

Chapitre IV: Evaluation des résultats obtenus par l'approche suggérée

Tableau IV.1	Caractéristique de matériel de programmation	77
Tableau IV.2	Caractéristique de Kaggle.....	77
Tableau IV.3	Termes utilisés pour définir accuracy, sensitivity, specificity	84
Tableau IV.4	Précision de la classification obtenue par les approches proposées.	94
Tableau IV.5	Comparaison de l'approche proposée vis-à-vis des approches de l'état de l'art pour le pronostic automatique de Covid 19.....	94



Introduction générale

Introduction générale

Le coronavirus 2 du syndrome respiratoire aigu sévère, appelé virus SARS-CoV-2, a émergé de la Chine vers la fin de l'année 2019 en provoquant une maladie nommée COVID-19, qui a actuellement évolué comme une pandémie [1]. En effet, le SRAS-CoV-2 a donné naissance au COVID-19, une maladie très répandue dans le monde et désignée comme une épidémie fin 2019 et a pour origine le syndrome respiratoire grave (SARS-COV-2).

L'augmentation de plusieurs infections chez les personnes, a entraîné un couvre-feu et des fermetures par les gouvernements partout dans le monde tout en restreignant la circulation des personnes. Les symptômes d'un patient atteint de coronavirus comprennent des difficultés respiratoires, des maux de gorge, une toux sèche et une fièvre élevée.

Nous pouvons noter que la détection d'une atteinte pulmonaire peut prédire une issue potentiellement mortelle chez les patients atteints de COVID-19. Ceci dit, le nombre de kits disponibles pour les tests corona est limité ; d'où le besoin de certaines techniques automatiques qui aident à la détection précoce. En effet, les images échographiques CXR s'avèrent potentiellement capables de détecter le COVID-19 et sont également moins nocifs pour le corps humain que la tomodensitométrie [2]. En effet, L'un des avantages de la CXR est la possibilité de les effectuer facilement à l'aide d'appareils de radiographie portables fournissant un diagnostic COVID-19 plus rapide et précis. Néanmoins, la pandémie de coronavirus 2019 (COVID-19) apporte un taux d'infection exponentiel générant la surcharge des systèmes de santé mondiaux. Dans ce sens, un système CAD de diagnostic assisté par ordinateur peut être implémenté pour interpréter correctement les cas COVID-19 à partir de l'image radiographique d'entrée [1]. Plusieurs études ont été menées avec cette motivation pour réduire la charge de travail des professionnels de la santé et contribuer au dépistage rapide du COVID-19 en utilisant l'intelligence artificielle et l'apprentissage automatique et profond.

Dans le présent travail, nous proposons une approche utilisant une multi-cascade d'algorithmes de détection et de classification des lésions du Covid-19 où des algorithmes d'apprentissage en profondeur seront combinés à des techniques d'apprentissage automatique.

Nous effectuerons deux techniques de segmentation : la première extrayant l'organe du poumon et la deuxième extrayant les lésions pulmonaires, ceci, par l'algorithme U-net d'apprentissage profond. En effet, la segmentation des régions d'intérêt désigne une phase décisive pour la classification car l'échec durant la segmentation engendra une réduction considérable des

Introduction générale

performances diagnostiques. D'où la suggestion de l'utilisation de la pertinence de l'apprentissage profond en fournissant ses sorties aux SVM durant la classification.

Nous allons évoquer la structuration de ce mémoire comme suit :

Chapitre I : Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

Au long du chapitre I, nous allons évoquer les concepts fondamentaux de l'intelligence artificielle, de l'analyse d'image ainsi que la vision par ordinateur.

Chapitre II : Pronostic automatique de COVID-19

Durant le chapitre II, nous introduisons les paradigmes de l'apprentissage automatique et l'apprentissage profond pour le pronostic automatique de COVID-19.

Chapitre III : Problématique extraite et approche suggérée

Quant au chapitre III, nous extrayons notre problématique pour la détection automatique de COVID-19 et évidemment l'approche suggérée.

Chapitre IV : Evaluation des résultats obtenus par l'approche suggérée

Nous consacrerons le chapitre IV à l'évaluation des résultats acquis suite à l'implémentation de l'approche proposée.

Nous achèverons ce mémoire par une conclusion générale décrivant les pivots de la contribution, sans doute, suivie par les perspectives tirées.



Chapitre I :

**Les appuis majeurs de l'analyse d'image et la
vision par ordinateur : préambule à
l'apprentissage automatique et
l'apprentissage profond**

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

I.1 Introduction

La vision par ordinateur est un ensemble de technologies d'intelligence artificielle (matériel et logiciel) qui permet aux ordinateurs de " voir " de la même façon que les êtres humains et d'extraire des données sémantiquement pertinentes à partir d'images ou et des vidéos. Donc un ensemble d'outils qui permet à un ordinateur la vision, et surtout de comprendre son environnement et d'en tirer des conclusions [3] [4].

L'intelligence artificielle (IA) correspond à un ensemble de technologies qui permet de simuler l'intelligence et accomplir automatiquement des tâches de perception, de compréhension et de prise de décision. Ces techniques font particulièrement appel à l'utilisation de l'informatique, de l'électronique, des mathématiques (notamment statistiques), des neurosciences et des sciences cognitives [5].

Nous distinguons usuellement au moins trois types d'apprentissage machine : l'apprentissage automatiquement (par renforcement), l'apprentissage supervisé et l'apprentissage non supervisé [6].

L'apprentissage automatique est une branche de l'intelligence artificielle (IA). Ce champ d'étude permet d'extraire de la connaissance exploitable et pertinente à partir des grands volumes de données. D'autre part, l'apprentissage profond ou Deep Learning est l'une des principales technologies de l'apprentissage automatique, consistant en un algorithme d'abstraction de haut niveau qui permet de modéliser les données à partir de grands ensembles de données apprises [5] [7].

Notons que l'apprentissage profond est une branche de l'apprentissage automatique basée sur les réseaux de neurones artificiels (ANN). Ces réseaux ont été exploités en apprentissage supervisé et non supervisé [5].

Commençons le présent chapitre où il détaille les différentes notions liées à l'analyse d'image et la vision par ordinateur, notamment, les nouvelles tendances de l'apprentissage automatique et l'apprentissage profond.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

I.2 La vision par ordinateur

La vision par ordinateur (vision artificielle, vision numérique) est une branche de l'intelligence artificielle (IA) dont le but de l'ordinateur est d'analyser, de traiter, et de comprendre les informations sur une ou plusieurs images prises par un système d'acquisition (photo ou vidéo captées par un équipement tel qu'une caméra). La vision par ordinateur est l'équivalent, en termes d'IA, des yeux humains et de la capacité de notre cerveau à traiter et analyser les images perçues. La reproduction de la vision humaine par des ordinateurs constitue d'ailleurs l'un des grands objectifs de la vision par ordinateur.

Avec le développement de l'internet et des réseaux sociaux, la quantité des images a rapidement augmenté. Par conséquent, le traitement de cette quantité d'information par les êtres humains devient impossible, car ils ne peuvent pas traiter efficacement autant de données. Ces informations sont donc traitées automatiquement à l'aide des systèmes de vision par ordinateur.

Le but de la vision par ordinateur est de développer des méthodes pour reproduire des systèmes qui ont une capacité équivalente à la vision humaine. Malgré les efforts faits, le domaine de vision par ordinateur a plusieurs défis liés à la compréhension limitée des systèmes de vision humaine et leurs complexités très élevées par rapport aux machines actuelles [5] [8] [9].

La vision par ordinateur est une fonctionnalité puissante qui peut être combinée à de nombreux types d'applications et d'appareils de détection pour prendre en charge un certain nombre de cas d'usage pratiques. Voici quelques-uns des différents types d'applications de la vision par ordinateur [8] [9] :

- **Organisation du contenu** : peut être utilisée pour identifier des personnes ou des objets dans des photos et les organiser en fonction de cette identification.
- **Extraction de texte** : la reconnaissance optique de caractères peut être utilisée pour booster la détectabilité du contenu pour les informations contenues dans de grandes quantités de texte et pour activer le traitement des documents pour les scénarios d'automatisation des processus robotisés.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

- **Réalité augmentée** : les objets physiques sont détectés et suivis en temps réel avec la vision par ordinateur. Ces informations sont ensuite utilisées pour placer des objets virtuels de manière réaliste dans un environnement physique.
- **Agriculture** : des images de cultures provenant de satellites, de drones ou d'avions peuvent être analysées pour surveiller les récoltes...etc.
- **Véhicules autonomes** : utilisent l'identification et le suivi des objets en temps réel pour recueillir des informations sur ce qui se passe autour d'elles et se diriger en conséquence.
- **Santé** : les images capturées par d'autres appareils médicaux peuvent être analysées pour permettre aux médecins d'identifier les problèmes et d'effectuer des diagnostics plus rapidement et avec plus de précision.
- **Sports** : la détection et le suivi des objets sont utilisés pour l'analyse des stratégies et du jeu.
- **Fabrication** : peut surveiller les machines de fabrication à des fins de maintenance, et être utilisée pour surveiller la qualité et l'emballage des produits sur une ligne de production.
- **Analyse spatiale** : le système identifie les personnes ou les objets, tels que les voitures dans un espace et suit leur mouvement au sein de cet espace.
- **Reconnaissance faciale** : peut être appliquée pour identifier les individus.

I.3 L'analyse d'image

L'analyse d'image est une branche du traitement de signal dédiée aux images et aux vidéos. Elle est constituée d'un ensemble de traitements que nous appellerons « Opérateurs » permettant d'extraire l'information d'une ou de plusieurs images. Afin d'améliorer la lisibilité et de faciliter l'interprétation, par exemple, le cas des opérations de rehaussement de contraste, l'élimination du bruit et la correction d'un flou. Cette information peut prendre les trois formes suivantes :

- Une image, par exemple pour l'amélioration de la visualisation : nous parlerons alors de traitement de bas niveau.
- De valeurs numériques, éventuellement associées à une image, par exemple l'extraction de segments de contours, les valeurs numériques étant les coordonnées des points extrémités. Nous parlerons de traitement de niveau intermédiaire.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

- De valeurs symboliques, ou de décisions : par exemple un cercle, une droite, ou un objet prédéfini ont été reconnus dans l'image. Ou bien une pièce manufacturée a été reconnue conforme comme le préhenseur du bras de robot, ou du robot delta va prendre la pièce sur le tapis roulant et la stocker. Nous parlerons de traitement de Haut Niveau [10] [11].

I.3.1 Les niveaux d'analyse d'image

En analyse d'images, nous distinguons les traitements de bas niveau et les traitements de haut niveau. Cette distinction est liée au contenu sémantique des entités traitées et extraites de l'image. L'analyse des images regroupe plusieurs disciplines que l'on classe en deux catégories :

- **Analyse de bas niveau**

Les traitements de bas niveau opèrent en général sur les grandeurs calculées à partir des valeurs attachées à chaque point de l'image sans faire nécessairement la liaison avec la réalité qu'elles représentent. Des analyses d'images ayant pour but d'extraire des caractéristiques des images et le rehaussement de contraste, le lissage, la détection de contour et enfin le seuillage dynamique avec l'ultime but d'analyser sans les interpréter. Par exemple, la détection des contours est un traitement de bas niveau qui est effectué « sans pour autant comprendre » l'image. Le contour détecté peut très bien ne pas correspondre à un bord d'objet dans la réalité et ne présente aucun intérêt, Ainsi les traitements de bas niveau opèrent plutôt sur des données de nature numérique [8] [11] [12] [13] [14]. Nous présentons sur la figure I.1, quelques traitements de bas niveau d'image.




Figure I.1 Traitement de bas niveau des images

ChapitreI Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

- **Analyse de haut niveau**

Le traitement haut-niveau intègre l'ensemble des méthodes permettant d'interpréter les caractéristiques issues du bas-niveau (prise de décision, classification, IA) se sont des entités de nature symbolique associées à une représentation de la réalité extraite de l'image et qui peuvent nécessiter des informations sur le contenu des images. Il s'agit de la reconnaissance de formes, de la reconstruction 3-D, les processus cognitifs de façon générale. Ils sont relatifs à l'interprétation et à la compréhension de l'image et sont exprimés avec des mots du vocabulaire de l'application. Par exemple, des zones d'une image aérienne peuvent être caractérisées par leur forme (rectangulaire, linéique,), être étiquetées avec les termes : bâtiment, route, bosquet, ombre, etc... Des relations entre ces zones sont exploitées pour comprendre la scène étudiée, par exemple : une route ne peut pas être incluse dans un bosquet [8] [11] [12] [13] [14].

I.3.2 Analyse de la texture d'image

Un des axes de recherche principal en analyse de textures par traitement d'image consiste à s'inspirer de ce mécanisme de perception visuelle des textures pour le simuler en proposant des représentations mathématiques utilisables dans des algorithmes de traitement automatisés.

Dans le traitement d'image, l'analyse de texture consiste à calculer une série de mesures dans le but de définir une texture perçue sur une image. L'analyse de texture renvoie des informations sur l'arrangement spatial des couleurs ou des intensités dans tout ou une partie de cette image.

Les données de texture d'une image peuvent être artificiellement créées (textures artificielles) ou résulter de l'analyse d'images filmées à partir de scènes ou d'objets réels (textures naturelles). L'analyse (ou caractérisation) de texture joue un rôle important dans la segmentation d'image ou dans sa classification. Les éléments apportant le plus de précisions dans la segmentation sont les fréquences spatiales et la moyenne du niveau de gris.

L'analyse de la texture d'image est la variation du niveau de gris ou des composantes couleurs dans le voisinage d'un pixel, pouvant refléter des propriétés de l'objet observé (rugosité, granularité, etc.) [15][16] [17] [18] [33].

Nous présentons sur la figure suivantes divers types de texture.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond




Figure I.2 Divers types de texture

Les recherches sur la perception visuelle des textures ont contribué à définir les principaux outils d'analyse texturale utilisés couramment en traitement d'image. Ces outils peuvent être classés en quatre grandes catégories :

- Les méthodes reposant sur l'analyse statistique de l'organisation spatiale des niveaux de gris ont été largement inspirées par les travaux de Julesz. Ces méthodes incluent les matrices de co-occurrence des niveaux de gris, les fonctions d'autocorrélation et les variogrammes.
- Les méthodes dites géométriques ou structurelles visent à caractériser la texture à travers l'analyse de la distribution de ses primitives et s'inspirent de la théorie des textons. On y retrouve entre autres les motifs binaires locaux (LBP – Local Binary Patterns).
- Les méthodes basées sur le filtrage fréquentiel se réfèrent à la perception multi-fréquentielle de la vision humaine et font appel à des outils de filtrage tels que la transformée de Fourier, les filtres de Gabor et les décompositions en ondelettes.
- Les méthodes basées sur des modèles cherchent à caractériser statistiquement l'image au moyen de modèles probabilistes en considérant la texture comme une réalisation d'un processus aléatoire. Les modèles Markoviens sont couramment utilisés pour la modélisation de la texture. Nous retrouvons parmi ceux-ci le modèle binomial utilisé pour la synthèse de textures ou le modèle de Gibbs pour la segmentation de textures [16].

I.4 Les nouvelles tendances de l'apprentissage automatique et l'apprentissage profond

Durant la dernière décennie, l'intelligence artificielle fut en plein développement. Comprendre les dernières avancées dans ce domaine revient à étudier

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

deux concepts très populaires tels que l'apprentissage automatique ou Machine Learning (ML) et l'apprentissage profond ou Deep Learning (DL).

Les réseaux Deep Learning (DL) ont été largement exploités dans différents domaines grâce à leur capacité dans la résolution des problèmes complexes. Ces réseaux ont prouvé leur efficacité par rapport aux méthodes d'apprentissage classique dans plusieurs applications récentes. Malgré leurs avantages, ils ont plusieurs défis liés aux problèmes de sur-apprentissage, de dégradation de gradient, et de la complexité temporelle élevée. Afin de réduire ces problèmes, pour apprendre un algorithme doit se baser sur un très grand nombre de données préexistantes (apprentissage supervisé) ou acquises à travers son entraînement (apprentissage non supervisé). Le résultat de l'algorithme dépend donc inéluctablement de la qualité des données sur lesquelles se fonde l'apprentissage.

Dans cette partie, nous allons présenter l'apprentissage automatique et ses algorithmes ainsi que l'apprentissage profond et ses algorithmes [5], [19].

I.4.1 L'apprentissage automatique

L'apprentissage automatique est un vaste domaine à l'intersection de la statistique, des probabilités et de l'informatique qui regroupe l'apprentissage supervisé et non-supervisé [20]. En effet, il fait référence au développement, l'analyse et l'implémentation de méthodes qui permettent à une machine (au sens large) d'évoluer et de remplir des tâches associées à une intelligence artificielle grâce à un processus d'apprentissage. Cet apprentissage permet d'avoir un système qui s'optimise en fonction de l'environnement, les expériences et les résultats observés [21]. Ce domaine a pris de l'ampleur où Peter Dayan et Larry Abbott l'ont appliqué aux neurosciences [22].

Toutes les approches d'apprentissage automatique comportent deux phases :

- 1- La première est celle de l'apprentissage à proprement parler et consiste à choisir un modèle (ex : arbre de décision ou réseau de neurones) puis ajuster ses paramètres à partir de données en entrée, par exemple des photos de chat et de chien, pour un modèle de reconnaissance visuelle.
- 2- La deuxième phase est celle de l'inférence. À partir des paramètres qui ont été appris, l'algorithme effectue la tâche qui lui a été fixée, par exemple distinguer

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

les photos de chat des photos de chien. Parmi les approches de l'apprentissage automatique, on peut distinguer différentes techniques qui peuvent correspondre aux différents problèmes [19].

Nous distinguons plusieurs algorithmes d'apprentissage automatique :

- **Les réseaux de neurones**

Un réseau neuronal [21] est l'association en un graphe plus ou moins complexe d'objets élémentaires, les neurones formels. Les principaux réseaux se distinguent par l'organisation du graphe (en couches), c'est-à-dire leur architecture, son niveau de complexité (le nombre de neurones) et par le type de neurones (leurs fonctions de transition).

Les réseaux de neurones ont été développés comme un modèle mathématique générique afin de modéliser les neurones biologiques. Ils comportent un certain nombre d'éléments de traitement d'information appelés neurones.

Chaque neurone a son propre état interne interprété par la fonction d'activation. Il envoie son activation aux autres neurones sous forme de signaux. La connexion entre les neurones est réalisée via des liens orientés et pondérés [24].

Les neurones sont organisés en couche successive comme mentionné sur la figure I.3 : une couche d'entrée qui représente les données, des couches cachées qui représentent des résultats d'analyse intermédiaires et une couche de sortie qui représente le résultat [8].

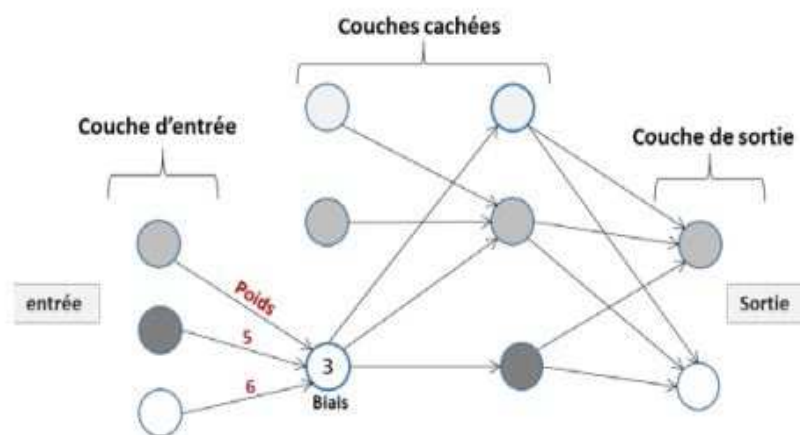


Figure I.3 Exemple d'un réseau de neurones.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

Chaque neurone a son propre état interne interprété par la fonction d'activation comme mentionné sur la figure I.4. Il envoie son activation aux autres neurones sous forme de signaux. La connexion entre les neurones est réalisée via des liens orientés et pondérés [24].

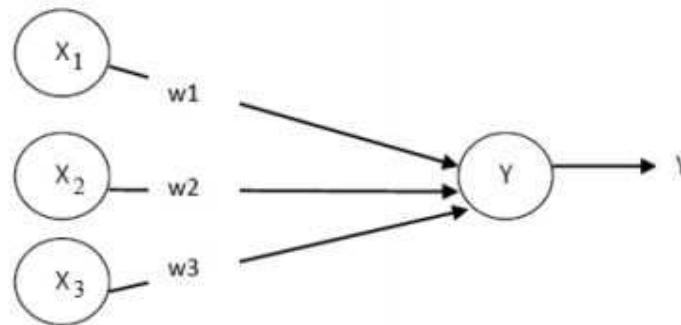


Figure I.4 Le neurone avec une seule sortie

Le neurone Y reçoit les entrées de X_1 , X_2 et X_3 qui ont comme valeurs de sortie x_1 , x_2 et x_3 . Les poids des liens de connexion de X_1 , X_2 et X_3 sont w_1 , w_2 et w_3 . La valeur d'entrée de neurone Y est : $y = w_1x_1 + w_2x_2 + w_3x_3$. Le signal de sortie y est déterminée par la fonction d'activation (y).

Les réseaux de neurones sont caractérisés par l'architecture (l'organisation des neurones), l'apprentissage (méthode de détermination des poids de connexions), et par leur fonction d'activation [23] [24].

Un neurone artificiel reçoit des entrées de certains autres neurones ou d'une source externe ayant des valeurs numériques x_1 , x_2 , ... x_n auxquels il est connecté par des synapses et calcule une sortie y . Chaque entrée x_i a un poids associé w_i , qui est attribué en fonction de son importance relative par rapport aux autres entrées. La valeur d'entrée x du neurone correspond à la somme pondérée de ses entrées en ajoutant une autre entrée ayant un poids b appelé biais. Ensuite, le neurone applique une fonction f sur cette somme [16].

Les réseaux de neurones sont souvent classifiés en deux architectures : les réseaux de neurone avec un seul niveau et multi-niveaux. Le nombre de niveaux est calculé sans prendre en considération les unités [16], [24].

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

1- Perceptron monocouche : Il s'agit d'un réseau de neurones à propagation avant le plus simple qui contient une couche cachée [16].

Les neurones de la couche d'entrée doivent uniquement passer et distribuer les entrées et ne pas effectuer de calcul comme mentionné sur la figure I.5. Ainsi, la seule vraie couche de neurones est celle de droite. Chacune des entrées $X_1, X_2 \dots X_n$ est connectée à chaque neurone de la couche de sortie à travers le poids de lien. Comme chaque valeur des sorties $Y_1, Y_2 \dots Y_n$ est calculée à partir du même ensemble de valeurs d'entrée, chaque sortie est modifiée en fonction des poids de liens [24].

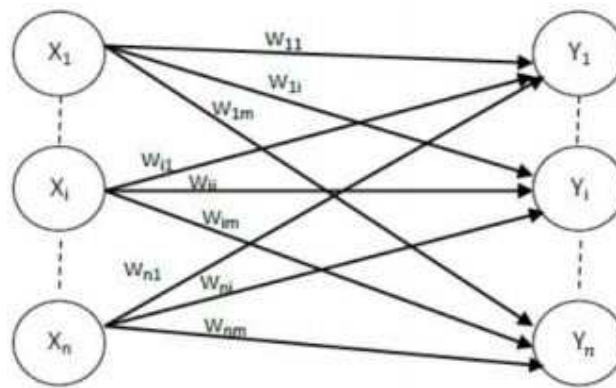


Figure I.5 Réseau de neurone à un seul niveau

2- Perceptrons multicouches : Il comporte une ou plusieurs couches cachées. En effet, ce type à perceptrons multicouches est le plus appliqué en littérature car ils sont plus utiles que les perceptrons monocouches dans les travaux actuels [16].

Nous exposons sur la figure I.6 un réseau de neurones multi-niveaux. Dans cette structure, les nœuds d'entrée transmettent les informations aux unités dans la première couche masquée, puis les sorties de la première couche masquée sont passées à la couche suivante, et ainsi de suite.

Le réseau multi-niveau peut également être considéré comme une cascade de groupes de réseaux d'un seul niveau. Le niveau de complexité se traduit par le nombre de réseaux monocouche qui sont combinés dans ce type de réseau. Le concepteur d'un réseau de neurones devrait considérer combien de couches cachées sont requises, selon la complexité du calcul [24].

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond




Figure I.6 Réseau de neurones multi-niveaux.

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

Les machines à vecteurs de support ou séparateurs à vaste marge sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de classification ou de régression. Les SVM sont une généralisation des classifieurs linéaires. Ce modèle est similaire à la régression logistique dans le sens où il est piloté par une fonction linéaire $w^T x + b$. Les SVM ont rapidement été adoptés pour leur capacité à travailler avec des données de grandes dimensions, le faible nombre d'hyperparamètres, leurs garanties théoriques, et leurs bons résultats en pratique.

Les SVM ont été appliqués à de très nombreux domaines (bio-informatique, recherche d'information, vision par ordinateur). Selon les données, la performance des machines à vecteurs de support est de même ordre, ou même supérieure, à celle d'un réseau de neurones [25].

L'ultime but des SVM est de trouver un séparateur entre deux classes qui soient au maximum éloignés de n'importe quel point de données d'entraînement. Si nous arrivons à trouver un séparateur linéaire c'est-à-dire qu'il existe un hyperplan séparateur alors le problème est dit linéairement séparable comme mentionné sur la figure I.7 sinon non linéairement [24].

La classification se fait en séparant le jeu de données en deux classes à travers une droite appelée hyperplan séparateur selon la formule suivante [16] :

$$h(x) = \sum_{i=1}^n w_i a_i + b = w^T \cdot x + b \quad \text{I.1}$$

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

Où $w = (w_1, w_2, \dots, w_n)$ le vecteur de poids, $x = (a_1, a_2, \dots, a_n)$ l'entrée à classifier et b le biais. Soit x_k un point à classifier, selon le signe de $h(x_k)$, le SVM décide si x_k appartient à telle ou telle classe [16].

$$\begin{cases} h(x_k) \geq 0 \Rightarrow x_k \in \text{classe1} \\ h(x_k) < 0 \Rightarrow x_k \in \text{classe2} \end{cases}$$




Figure I.7 Problème de classification à deux classes avec un séparateur linéaire.

Dans le cas où le problème n'est pas linéairement séparable, nous introduisons une fonction noyau dans le produit scalaire, donc, les données subissent une transformation non linéaire vers un espace de caractéristiques de plus grande dimension. Ceci génèrera une surface de séparation non linéaire comme mentionné sur la figure I.8.

Sur le plan théorique, la fonction noyau définit un espace de Hilbert, dit auto-répliquant et équidistant par transformation non linéaire de l'espace initial, et résout le problème linéaire dans celui-ci.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

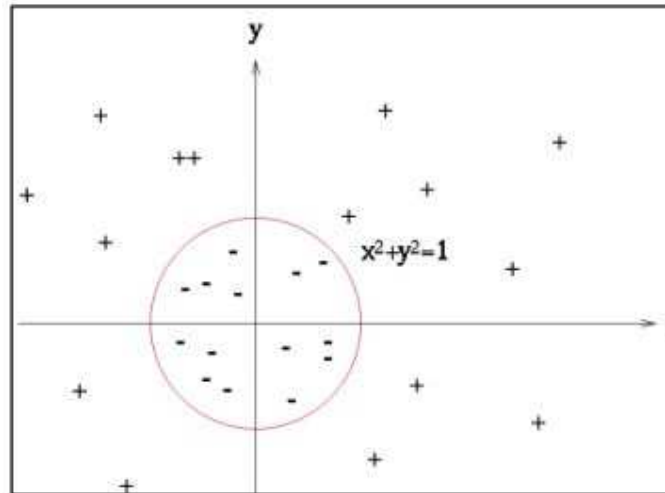


Figure I.8 Problème de classification à deux classes avec une séparatrice non linéaire.

Les SVM présentent plusieurs avantages et inconvénients, comme mentionné sur le tableau I.1 [24] :

Tableau I.1: Les avantages et les inconvénients des SVM

Les avantages des SVM	Les inconvénients des SVM
<ul style="list-style-type: none">- Elles ont une base théorique solide.- Les SVM sont efficaces dans les espaces de grande dimension.- Différentes fonctions noyau peuvent être spécifiées.	<ul style="list-style-type: none">- Elles utilisent des fonctions mathématiques complexes pour la classification.- Les machines à support de vecteurs demandent un temps énorme durant les phases de test.

• **Les arbres de décision**

Les arbres de décision sont les plus populaires des méthodes d'apprentissage. Comme toute méthode d'apprentissage supervisée, les arbres de décision utilisent des exemples [21]. En effet, un arbre de décision est un graphe qui utilise une méthode de branchement pour illustrer tous les résultats possibles d'une décision.

Les arbres de décision peuvent être dessinés à la main ou créés avec un programme graphique ou un logiciel spécialisé. De manière informelle, les arbres de

ChapitreI Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

décision sont utiles pour focaliser la discussion lorsqu'un groupe doit prendre une décision. Ils peuvent être utilisés pour attribuer des valeurs aux résultats possibles, afin que les décisions puissent être automatisées. L'algorithme de l'arbre de décision est utilisé dans l'exploration de données pour simplifier les défis stratégiques complexes et évaluer la rentabilité des décisions de recherche et de gestion. Les variables dans un arbre de décision sont généralement représentées par des cercles [16].

Si nous devons classer des exemples dans des catégories, il faut construire un arbre de décision par catégorie. Pour déterminer à quelle catégorie appartient un nouvel exemple, on utilise l'arbre de décision de chaque catégorie auquel on soumet le nouvel exemple à classer [21].

Chaque arbre répond par Oui ou Non (il prend une décision). Concrètement, chaque nœud d'un arbre de décision contient un test (un IF...THEN) et les feuilles ont les valeurs Oui ou Non. Chaque test regarde la valeur d'un attribut de chaque exemple. En effet, nous supposons qu'un exemple est un ensemble d'attributs/valeurs.

Pour construire l'arbre de décision, il faut trouver lequel des attributs à tester à chaque nœud. En effet, ceci consiste en un processus récursif. Pour déterminer quel attribut à tester à chaque étape, nous utilisons un calcul statistique qui détermine dans quelle mesure cet attribut sépare bien les exemples Oui/Non. Nous créons alors un nœud contenant ce test, et nous créons autant de descendants que de valeurs possibles pour ce test.

L'arbre de décision a montré une bonne classification des attributs, ceci dit il montre ses limites pour généraliser, c'est-à-dire qu'il prédit mal la classification (Oui /Non) de nouvelles instances.

- **KNN**

La méthode des K plus proches voisins (k-nearest neighbor, KNN) est une méthode supervisée et est une famille de techniques pouvant être utilisées pour la classification ou la régression. Elle a été utilisée dans l'estimation statistique et la reconnaissance des modèles comme une technique non paramétrique, cela signifie qu'elle ne fait aucune hypothèse sur la distribution des données [16] [24].

L'algorithme KNN figure parmi les plus simples algorithmes d'apprentissage artificiel. Dans un contexte de classification d'une nouvelle observation x , l'idée

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

fondatrice simple est de faire voter les plus proches voisins de cette observation. La classe de x est déterminée en fonction de la classe majoritaire parmi les K plus proches voisins de l'observation x [25].

L'algorithme KNN est un type d'apprentissage basé sur l'apprentissage paresseux (lazy learning). En d'autres termes, il n'y a pas de phase d'entraînement explicite ou très minime. Cela signifie que la phase d'entraînement est assez rapide.

La méthode KNN suppose que les données se trouvent dans un espace de caractéristiques. Cela signifie que les points de données sont dans un espace métrique.

Les données peuvent être des scalaires ou même des vecteurs multidimensionnels. La méthode des k plus proches voisins est utilisée pour la classification et la régression. Dans les deux cas, l'entrée se compose des K données d'entraînement les plus proches dans l'espace de caractéristiques [24].

Pour trouver la classe d'un nouveau cas, cet algorithme se base sur le principe suivant : il cherche les K plus proches voisins de ce nouveau cas, ensuite, il choisit parmi les candidats trouvés le résultat le plus proche et le plus fréquent. En effet, pour affecter un nouvel individu à une classe, l'algorithme cherche les K plus proches voisins parmi les individus déjà classés. Ainsi, l'individu est affecté à la classe qui contient le plus d'individus parmi les candidats trouvés.

Cette méthode utilise principalement deux paramètres : une fonction de similarité pour comparer les individus dans l'espace de caractéristiques et le nombre K qui décide combien de voisins influencent la classification.

Pour tester la similarité entre deux vecteurs, un calcul de distance est appliqué. Elle permet de mesurer le degré de différence entre deux vecteurs. Il existe plusieurs types de distance parmi lesquels nous travaillons généralement avec la distance Euclidienne dont la formule est la suivante [24] :

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

Où : x, y sont des vecteurs.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

Nous présentons sur la figure I.9, un exemple du principe de la classification par les K plus proches voisins.




Figure I.9 Classification avec l'algorithme des K plus proches voisins.

Les KNN représentent plusieurs avantages et inconvénients, comme exposé sur le tableau I.2 [24] :

Tableau I.2 : Les avantages et les inconvénients de l'algorithme des KNN

Les avantages des KNN	Les inconvénients des KNN
<ul style="list-style-type: none">- L'algorithme KNN est robuste envers des données bruitées.- La méthode des k plus proches voisins est efficace si les données sont larges et incomplètes.- Cette méthode est l'une des plus simples de tous les algorithmes d'apprentissage automatique.	<ul style="list-style-type: none">- Le besoin de déterminer la valeur du nombre des plus proches voisins (le paramètre k).- Le temps de prédiction est très long puisqu'on doit calculer la distance de tous les exemples.- Cette méthode est gourmande en espace mémoire car elle utilise une grande capacité de stockage pour le traitement des corpus.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

I.4.2 L'apprentissage profond

Au cours des dernières années, l'apprentissage profond est apparu comme une nouvelle zone de recherche de l'apprentissage automatique où la machine est capable d'apprendre par elle-même, contrairement à la programmation où elle se contente d'exécuter à la lettre des règles prédéterminées [19]. Les techniques développées dans l'apprentissage profond ont déjà eu un impact sur les travaux de traitement des signaux et de l'information, y compris les aspects de l'apprentissage automatique et l'intelligence artificielle.

L'apprentissage profond (Deep Learning) est une classe de techniques d'apprentissage automatique qui modélisent avec un haut niveau d'abstraction des données grâce à des architectures à multiples niveaux. Les caractéristiques et les concepts de niveau supérieur sont donc définis en termes de niveaux inférieurs, et une telle hiérarchie est appelée architecture profonde [24].

L'apprentissage profond est basé sur ce qui a été appelé, par analogie, des "réseaux de neurones artificiels", composés de milliers d'unités "les neurones" qui effectuent chacune des petites opérations simples. Les résultats d'une première couche de "neurones" servent d'entrée aux calculs d'une deuxième couche et ainsi de suite.

Par exemple, pour la reconnaissance visuelle, des premières couches d'unités identifient des lignes, des courbes, des angles... des couches supérieures identifient des formes, des combinaisons de formes, des objets, des contextes...

Les progrès de l'apprentissage profond ont fait une révolution notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données ou le "Big Data" [25].

- **Réseaux de neurone à convolution (CNN)**

Un réseau de neurones convolutif (CNN) est un algorithme d'apprentissage profond. Ce réseau a été largement exploité en vision par ordinateur pour la classification et ont été utilisés dans les systèmes de recommandation et la détection des objets grâce à ses fonctionnalités inspirées du cortex visuel. Contrairement aux réseaux classiques d'apprentissage profond, les CNN sont caractérisés par des couches

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

de convolution et de pooling. Ces couches introduisent des liens partiels pour réduire le nombre des paramètres et renforcer le partage des caractéristiques communes.

Les CNN sont adaptés pour les problèmes d'apprentissage sur des données structurées, organisées sous forme de grille 1D, 2D, et 3D (signal audio, les images ou encore la vidéo). Ce type de réseau de neurones se différencie par l'utilisation d'une opération de convolution, appliquée successivement sur des zones restreintes de l'image, avec un partage des paramètres [5].

Un réseau de neurone convolutif est habituellement constitué de trois couches principales, la convolution suivie par une fonction d'activation non-linéaire de type ReLU, puis un sous-échantillonnage des images de descripteurs [20].

Malgré les avantages des CNN, ils ont plusieurs défis liés aux problèmes de sur-apprentissage sur les volumes limités de données et une complexité de calcul élevée. Pour résoudre ces problèmes, des architectures connues de type CNN ont été proposées. Ces architectures sont basées sur des blocs convolutionnels optimisés qui permettent de générer des structures plus profondes et moins exigeantes en termes de capacité de calcul et de stockage [5].

Créer un nouveau réseau de neurones convolution est coûteux en termes d'expertise, de matériel et de quantité de données annotées nécessaires [25]. En effet, les couches suivantes doivent être présentes : couche de convolution, couche de pooling et couche entièrement connectée comme mentionné sur la figure I.10 [5].

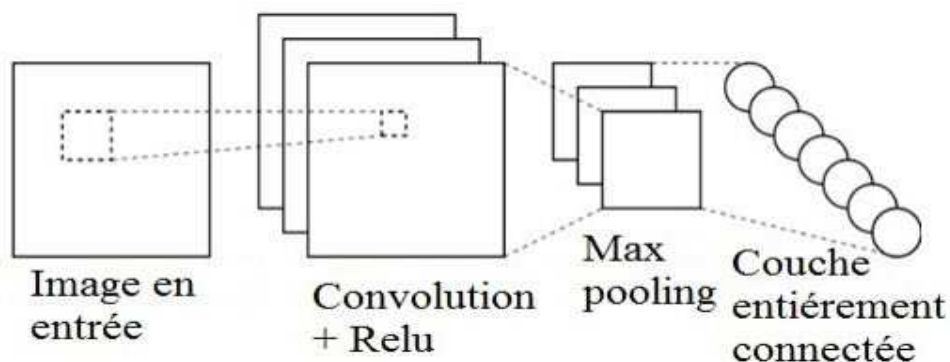


Figure I.10 Architecture générale d'un réseau de neurones convolutif.

1- Couche de convolution

La couche de convolution est le bloc de construction de base du réseau convolutif. Elle consiste en le fait d'appliquer un filtre mathématique à une image. D'un

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

point de vue plus technique, ces couches se composent d'une grille rectangulaire de neurones qui ont un petit champ réceptif, mais s'étend à travers toute la profondeur du volume d'entrée. Ainsi, la couche de convolution est juste une convolution d'image de la couche précédente, où les poids spécifient le filtre de convolution. La Figure I.11 montre un exemple de conv2d [29].

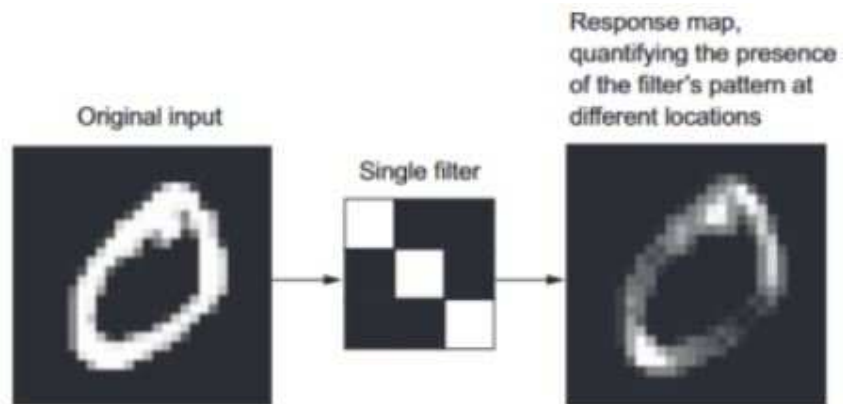


Figure I.11 Exemple de conv2d

La couche de convolution va opérer sur une image en 3 dimensions, qui a donc une longueur, largeur et profondeur, la profondeur peut être égale 0 dans le cas où l'image est en noir et blanc, sinon égale à 3 si elle est en couleur (RGB), en d'autres termes notre image est soit une matrice 2 dimensions si elle est en noir et blanc, soit un bloc a 3 dimensions si elle est en couleurs [30]. Nous présentons sur la figure I.12, une convolution avec un pas de 2.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

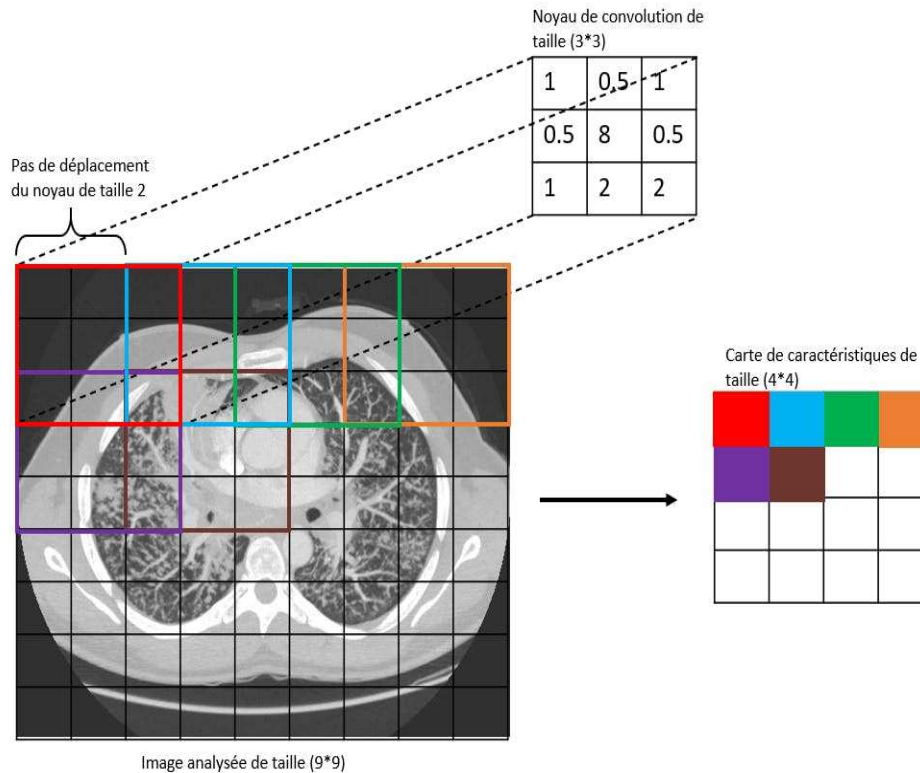


Figure I.12 Convolution avec un noyau de taille 3*3 et un pas de 2.

La couche de convolution est le bloc de construction de Trois paramètres permettent de dimensionner le volume de la couche de convolution :

Profondeur : de la couche est le nombre de neurones associés à un même champ récepteur.

Le pas : contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.

La marge (à 0) ou zero padding : la dimension spatiale du volume de sortie. En particulier, il est parfois souhaitable de conserver la même surface que celle du volume d'entrée [31].

Il s'agit de faire glisser une matrice par-dessus une image, et pour chaque pixel, utiliser la somme de la multiplication de ce pixel par la valeur de la matrice. Cette technique nous permet de trouver des parties de l'image qui pourraient nous être intéressante [32].

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

2- Couche de pooling

Le pooling est une forme de sous-échantillonnage de l'image [25]. Après chaque couche de convolution, il peut y avoir une couche de pooling. En effet, le pooling est une spécificité des réseaux de neurones convolutifs. Les deux méthodes les plus utilisées pour appliquer cette opération sont les suivantes, soit on fait la moyenne des valeurs de la zone (pooling average), soit on extrait uniquement la valeur la plus élevée (pooling max). L'ultime but est de réduire progressivement la taille spatiale de la représentation pour réduire le nombre de paramètres et de calculs dans le réseau sans perdre les informations les plus importantes, et donc de contrôler également l'overfitting. Le principal avantage du pooling average est qu'il est efficace lorsque l'on souhaite détecter des signaux faibles comme pour le cas de la stéganalyse [30].

Le pooling max est quant à lui efficace lorsque l'on veut détecter des signaux forts, comme des objets par exemple, de plus il permet au modèle d'être invariant aux translations. Après cette étape de sous-échantillonnage nous obtenons une featuremap qui est définie comme démontré sur la figure I.13 [30] :




Figure I.13 Exemple d'un Maxpooling

L'average pooling où la sortie est la moyenne des valeurs du patch d'entrée. En effet, même si initialement l'average pooling était souvent utilisé il s'est avéré que le max-pooling était plus efficace car celui-ci augmente plus significativement l'importance des activations fortes. Nous présentons sur la figure I.14, un exemple de l'average pooling.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond




Figure I.14 Exemple de l'average pooling

3- Couche de correction ReLU

ReLU est une fonction qui doit être appliquée à chaque pixel d'une image après convolution, et remplace chaque valeur négative par un 0. Si cette fonction n'est pas appliquée, la fonction créée sera linéaire et le problème XOR persiste puisque dans la couche de convolution, aucune fonction d'activation n'est appliquée [30] [32]. Souvent, il est possible d'améliorer l'efficacité du traitement en intercalant entre les couches de traitement une couche qui va opérer une fonction mathématique (fonction d'activation comme mentionné sur la figure I.15) sur les signaux de sortie. Souvent, la correction ReLU est préférable, car il en résulte la formation de réseau neuronal plusieurs fois plus rapide, sans faire une différence significative à la généralisation de précision [29].




Figure I.15 Allure de la fonction ReLU

4- Couche entièrement connectée

La couche entièrement connectée (fully-connected) est un Perceptron multicouche traditionnel qui utilise une fonction d'activation softmax dans la couche de sortie (d'autres classifieurs comme SVM peuvent également être utilisés) [30].

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

Après plusieurs couches de convolution et de max pooling de haut niveau dans le réseau neuronal, des couches entièrement connectées s'intègrent et chaque neurone de la couche précédente est connecté à chaque neurone de la couche suivante. Les neurones dans une couche entièrement connectée ont des connexions vers toutes les sorties de la couche précédente. Leurs fonctions d'activations peuvent donc être calculées avec une multiplication matricielle suivie d'un décalage de polarisation [30] [31].

Cette dernière couche permet de classifier l'image en entrée du réseau : elle renvoie un vecteur de taille N, où N est le nombre de classes dans notre problème de classification d'images [32]. En effet, le but de la couche entièrement connectée est d'utiliser ces fonctionnalités pour classifier l'image d'entrée dans différentes classes en fonction de l'ensemble de données d'apprentissage.

I.5 Les modèles des réseaux de neurone convolutifs

I.5.1 U-NET

U-NET est un modèle de réseau de neurones dédié aux tâches de vision par ordinateur et plus particulièrement aux problèmes de Segmentation Sémantique. L'un des réseaux de neurones les plus utilisés pour la segmentation d'image est U-NET. Il s'agit d'un modèle de réseau de neurones entièrement convolutif et fut initialement développé par Olaf Ronneberger, Phillip Fischer, et Thomas Brox en 2015 pour la segmentation d'images médicales [26].

Le modèle U-Net a été développé pour résoudre des problématiques de segmentation Biomédicale et connaît aujourd'hui un succès élevé avec des applications dans de nombreux domaines en biologie, santé et dans l'industrie. Il se distingue par l'utilisation de connexions résiduelles à chaque résolution, qui retransmettent les cartes de descripteurs du bloc encodeur vers le bloc décodeur correspondant, pour améliorer la localisation de descripteurs de haut-niveau [20].

U-NET est composée de deux "chemins" comme mentionné sur la figure I.16. Le premier est le chemin de contraction, aussi appelé encodeur. Il est utilisé pour capturer le contexte d'une image. Il s'agit en fait d'un assemblage de couches de

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

convolution et de couches de "max pooling" permettant de créer une carte de caractéristiques d'une image et de réduire sa taille pour diminuer le nombre de paramètres du réseau.

Le second chemin est celui de l'expansion symétrique, aussi appelé décodeur. Il permet aussi une localisation précise grâce à la convolution transposée [26] [27].

Après chaque couche convolutive, la fonction d'activation ReLU s'applique pour capturer efficacement les non-linéarités dans les données et accélérer l'apprentissage. Dans le chemin de l'encodeur, l'extraction de caractéristiques est effectuée par convolution qui transforme l'image d'entrée en une représentation de caractéristiques multidimensionnelle. D'autre part, le chemin du décodeur est un générateur de formes qui produit une segmentation d'objets à partir des caractéristiques extraites obtenues à partir du chemin de convolution. La fonction d'activation ReLU améliore la vitesse de calcul de l'étape d'apprentissage des réseaux de neurones.




Figure I.16 Architecture du modèle U-NET.

I.5.2 VGG-16

Le grand nombre de paramètres à apprendre nécessite une grande base de données et des ressources de calcul puissantes. VGG-16 est construit à l'aide de 14 millions d'images de la base de données Image Net et a nécessité à plusieurs semaines d'apprentissage [23].

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

VGG-16 est un réseau Convnet à 16 couches utilisé par le groupe de géométrie visuelle (VGG) de l'Université d'Oxford dans le cadre du concours ILSVRC (Image Net) en 2014. Il prend en entrée une image en couleurs de taille 224×224 px et la classifie dans une des 1000 classes. Il renvoie donc un vecteur de taille 1000, qui contient les probabilités d'appartenance à chacune des classes.

L'architecture de VGG-16 est illustrée par les schémas de la figure I.17.




Figure I.17 Architecture de VGG-16.

Il s'agit actuellement du choix le plus populaire pour l'extraction de caractéristiques à partir d'images. La configuration de poids du VGG est disponible publiquement et a été utilisée dans de nombreuses autres applications et défis en tant qu'extracteur de caractéristiques de base [28].

Alors qu'on ne pouvait pas entraîner intégralement un réseau comme VGG-16 sur une petite base d'images, il est possible d'entraîner uniquement les dernières couches sur cette base, en gardant fixes les poids des couches convolutives.

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

I.5.3 ResNet

C'est un réseau de neurones convolutif basé sur des blocs résiduels [16]. La particularité de cette architecture est l'utilisation de connexions résiduelles (skip connection) pour faciliter l'apprentissage de réseaux très profonds (plusieurs dizaines à quelques centaines de couches). Sans cela, en augmentant la profondeur d'un réseau, on peut parfois observer une stagnation des performances, puis une dégradation si l'on continue à ajouter des couches. Pour améliorer la rétro-propagation du gradient depuis la sortie vers les premières couches, les auteurs proposent un bloc résiduel qui concatène les cartes de descripteurs issues directement de couches précédentes comme mentionné sur la figure I.18. Dans l'architecture ResNet les auteurs utilisent massivement la batch normalization pour s'assurer que l'information propagée a bien une variance non-nulle [20].




Figure I.18 Bloc convolutif résiduel

Le but principal de cette architecture est de résoudre le problème de dégradation de gradient. Ce problème apparaît dans les réseaux très profonds, où la précision commence à être saturée ensuite dégrade rapidement à cause de la diminution des valeurs des gradients. Afin de résoudre ce problème, les blocs résiduels ont été introduits [16].

I.6 L'apprentissage par transfert

L'apprentissage par transfert (transfert Learning) est une méthode d'apprentissage automatique qui permet de réutiliser un modèle développé précédemment pour l'apprentissage d'une tâche A dans une autre tâche B [5]. Il est une

Chapitre I Les appuis majeurs de l'analyse d'image et la vision par ordinateur : préambule à l'apprentissage automatique et l'apprentissage profond

méthode courante qui consiste à optimiser les paramètres du réseau pour une tâche A, puis à réutiliser cette configuration pour résoudre une tâche B. Le transfert d'apprentissage permet dans certaines configurations d'améliorer les performances du modèle B, en bénéficiant d'une base de données A avec de nombreuses annotations, ou encore dans le cas où les tâches A et B sont proches (même type de données).

En pratique, après avoir entraîné un modèle sur la tâche A, on peut soit le réutiliser en tant qu'extracteur de descripteurs, en supprimant la dernière couche totalement connectée, pour utiliser les cartes de caractéristiques en entrée du modèle proposé pour résoudre la tâche B. Une alternative est de remplacer la couche connectée par une nouvelle dont la sortie est adaptée au nombre de classe du problème B, puis d'optimiser ses paramètres en fixant tous les autres, généralement en réduisant la vitesse d'apprentissage par rapport à l'apprentissage original du réseau [20].

I.7 Conclusion

Dans ce chapitre, nous avons présenté une vue détaillée des principaux appuis majeurs de l'analyse d'image et la vision par ordinateur notamment l'apprentissage automatique et l'apprentissage profond.

Durant le prochain chapitre, nous allons introduire la pandémie du COVID-19 et comment ce virus dangereux a bouleversé la vie quotidienne du monde entier. En effet, nous allons booster l'application de l'intelligence artificielle ainsi que ses paradigmes pour la détection automatique du Covid-19 en vue de contrôler la propagation de ce dangereux virus.



Chapitre II :

Pronostic automatique de COVID-19

II.1 Introduction

Devant la propagation du Covid-19 et en devenant une pandémie inquiétante, Il existe un besoin d'implémentation de systèmes efficaces et fiables qui effectuent une détection automatique et un dépistage des lésions du Covid-19 en tant qu'option de diagnostic alternative et rapide pour contrôler la propagation de ce dangereux virus.

Nous allons démontrer à travers ce chapitre l'avantage des images échographiques (CXR) par rapport aux images CT, ce qui rend cette modalité un chemin plus étendu vers les patients.

L'évolution des techniques d'apprentissage automatique et profond a fournie des outils performants pour l'analyse et le traitement d'image, entrainant la prédominance des systèmes d'aide au diagnostic médical assistés par ordinateur (CAD) qui peuvent contribuer à la maitrise du Covid-19.

II.2 Aperçu sur la pandémie de Covid-19

Le nouveau coronavirus, est apparu pour la première fois à Wuhan, la capitale du Hubei en Chine centrale province, en décembre 2019 [1] [34]. Le 11 février 2020, « Coronavirus-2 du syndrome respiratoire aigu sévère » (SARSCoV- 2) a été nommé COVID-19 par l'Organisation mondiale de la santé (WHO : World Health Organization) [1].

Des symptômes tels que fièvre, toux sèche, fatigue, nausées, essoufflement, infiltrats pulmonaires et dyspnée sont liés au Covid-19. Par la suite, l'organisation mondiale de la santé a revendiqué le PHEIC (Public Health Emergency of International Concern) le 30 janvier 2020, et l'a reconnu comme pandémie le 11 mars, 2020 [35].

Les coronavirus (CoV) sont une grande famille de personnes vulnérables et virus dangereux. Le coronavirus tire son nom de la Couronne comme structure. Cette famille de virus comprend le MERS-CoV (Middle East respiratory syndrome), SARS-CoV-2 (COVID-19) et SARSCoV (severe acute respiratory syndrome).

COVID-19 peut être grave chez les patients présentant des comorbidités ou des maladies chroniques. Il était urgent de prendre une mesure efficace pour le confinement du COVID-19 en effectuant des tests de dépistage sur un sujet suspect afin que la personne infectée puisse recevoir des soins immédiats avec un traitement plus spécifique et que la quarantaine du patient puisse être assurée pour limiter la propagation du virus.

L'infection par le SRAS-CoV-2 présente un large éventail de manifestations cliniques allant d'une infection asymptomatique et d'une maladie bénigne des voies respiratoires supérieures à une pneumonie virale grave pouvant aboutir à une défaillance du système respiratoire et parfois à la mort. Des tests en temps réel de (RT-PCR : Reverse Transcription Polymerase Chain Reaction) sont effectués pour la détection qualitative des acides nucléiques à partir d'échantillons des voies respiratoires supérieures et inférieures de la personne infectée.

La réalisation de tests RT-PCR pour COVID-19 restera très probablement la principale méthode de détection. Cependant, il est coûteux, compliqué et prend du temps pour d'innombrables patients qui manquent de temps. En raison de la pénurie de kits pour la RT-PCR et du taux de faux

négatifs relativement élevé, des méthodes alternatives telles que l'examen des radiographies pulmonaires (CXR ou chest x-ray) peuvent être utilisées pour le dépistage.

Nous présentons sur la figure II.1, un exemple du virus SARS-COV-2 s'agissant d'un membre de la «famille des Coronaviradae». Le SARS-COV-2 constitue 14 résidus liés qui se connectent précisément avec "l'enzyme humaine de conversion de l'angiotensine 2"[35].




Figure II.1 Exemple du virus SARS-COV-2. Source [35]

Nous allons évoquer quelques statistiques sur les atteintes par ce dangereux virus comme suit :

- Plus de 3,27 millions de cas de COVID-19 ont été signalés dans 187 pays et territoires au 1er mai 2020, entraînant plus de 233 000 décès [36].
- Le virus infecte 38 86 230 cas de COVID-19 jusqu'au 8 mai 2019 dont 268 908 rapports de décès et 13 31 014 rapports récupérés [35].

- Les statistiques de l'épidémie de COVID-19 au 20 juin 2020 indiquent qu'il y a au total de 8 804 268 personnes touchées dans le monde, 463 510 décès causés et 4 656 912 en ont été guéris [37].
- Jusqu'au 16 septembre 2020, plus de 29,5 millions de cas ont été signalés dans plus de 188 pays, et environ 1 million de morts [34].
- En février 2021, le COVID-19 avait été confirmé à environ 107 millions personnes dans le monde et a causé plus de 2,3 millions de décès signalé [38].
- Il y a plus de vingt et un millions de cas actifs et plus de deux millions et demi de décès dans le monde, en mars 2021 [2].

II.3 Dépistage de covid-19

Les opacités bilatérales et périphériques (zones d'opacité floue) sont les caractéristiques communes du rapport radiographique des patients atteints de COVID-19 [34] avec des consolidations des poumons (tissu pulmonaire compressible rempli de liquide au lieu d'air). La présence d'opacités de l'espace aérien dans plus d'un lobe est peu probable pour une pneumonie bactérienne, car la pneumonie bactérienne est susceptible d'être unilatérale et implique un seul lobe. Les autres signes significatifs de COVID-19 sont la consolidation, les opacités de l'espace aérien périphérique et diffus.

II.3.1 Dépistage par radiographie thoracique CXR (Chest X-Ray)

La radiographie numérique CXR (Chest X-Ray) est privilégiée pour l'imagerie médicale vu qu'elle est facilement disponible et moins cher [35]. En effet, ceci pour le dépistage du cancer, des maladies cardiaques et de l'ostéoporose.

Initialement, les chercheurs de COVID-19 ont découvert que la maladie de l'espace aérien avait probablement une distribution pulmonaire inférieure et était le plus souvent bilatérale et périphérique. Ces types d'opacités pulmonaires périphériques ont également des caractéristiques pour être confluentes, inégales ou multifocales, et peuvent être facilement reconnu sur les images de la radiographie pulmonaire.

Certains autres résultats rares chez les patients atteints de COVID-19 sont le pneumothorax, la cavitation pulmonaire et l'épanchement pleural (eau dans les espaces pleuraux du poumon) qui ont été principalement trouvés à un stade ultérieur de la maladie. Nous présentons sur la figure II.2, diverses radiographies thoraciques de patients infectés par le 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 [34].

II.3.2 Dépistage par Tomodensitométrie (CT scan)

Dans un scan haute résolution, l'image est produite à partir d'une seule rotation par le tube à rayons X. Les aspects cruciaux de la tomodensitométrie couvrent la consolidation, l'opacité du verre dépoli, la distribution des lésions, nodules et récitation de septa interlobulaires [35]. Nous présentons sur la figure II.3, diverses tomodensitométries d'un patient atteint du covid-19.




Figure II.3 Tomodensitométrie après le symptôme de COVID-19, en a Jour 5, en b Jour 15 et en c Jour 20. Source [35]

II.3.3 Bilan

Durant ce travail, nous nous intéresserons à la radiographie thoracique durant la détection du Covid-19 pour les raisons suivantes :

- Des études confirment des anomalies visibles dans les images radiographiques [39], ce qui en fait un outil de prise de décision important. Cependant, 50 % des patients ont une tomodensitométrie normale dans les deux premiers jours après l'apparition des symptômes de COVID-19.
- L'utilisation de la tomodensitométrie comme méthode de diagnostic pour COVID-19 présente plusieurs inconvénients [39]. Dans de nombreux hôpitaux, l'équipement nécessaire pour acquérir l'image n'est pas disponible et le coût d'une étude tomographique n'est pas évident. La dose d'ionisant du rayonnement délivré au patient dans cet équipement est relativement élevée. D'autre part, la radiographie est disponible en la plupart des établissements de santé.
- Pour la radiographie thoracique, nous distinguons une modalité portable qui empêche le patient de bouger, minimisant la possibilité de propager le virus et exposer le patient à une dose plus faible des rayonnements ionisants et c'est moins cher qu'un scanner. Tandis que Le temps de désinfection chez les patients pour l'équipement CT et la salle est d'environ 15 min.

- Un autre inconvénient est que la CT n'est pas disponible dans le monde entier, et dans la plupart des cas, cher et, par conséquent, a une faible portée. C'est pourquoi les radiographies pulmonaires sont les plus courantes méthode de diagnostic et de pronostic non seulement de COVID-19 mais la plupart des autres anomalies pulmonaires [40] comme la pneumonie, MERS-CoV SARS-CoV [1].

II.4 Limites des images échographiques durant la détection de Covid-19

Des études montrent que l'un des premiers organes touchés dans les cas d'atteintes par le Covid-19 est le poumon. Ainsi, les images radiographiques des poumons pourraient donner un aperçu de leur état. Cependant, les radiologues échouent souvent à diagnostiquer avec succès le COVID-19 uniquement des images en raison de la similitude entre les lésions de COVID-19, de la pneumonie et parfois même des images pulmonaires normales [40].

La lecture manuelle de la radiographie pulmonaire pour le diagnostic des patients peut prendre beaucoup de temps, et aussi, les radiologues doivent se familiariser avec l'apparence de la radiographie relative à une infection par le coronavirus. Les radiologues doivent être extrêmement prudent en pratiquant cela, car l'imagerie thoracique peut manquer de spécificité et peut également se chevaucher avec certaines infections telles que la grippe, le SARS ou le MERS [1].

Même si la radiographie demeure la méthode d'imagerie diagnostique la plus courante et la plus répandue ; cependant, la lecture des images radiographiques par un personnel moins expert et souvent surchargé peut conduire à des taux d'erreur élevés. Au cours de la pandémie, en ambulatoire, 20 % des radiographies lues comme « normales » auraient été changées en « anormales » après une deuxième lecture [41].

II.5 Diagnostic assisté par ordinateur (CAD) de Covid-19

Comme nous l'avons discuté à la section précédente la lecture des radiographies désigne une tâche complexe et au lieu de dépendre d'un médecin qualifié, développer un système automatisé et efficace de diagnostic par radiographie thoracique peut s'avérer être plus bénéfique [1]

Avec les progrès rapides de l'informatique et de la technologie d'imagerie électronique, il y a un intérêt croissant pour le développement de systèmes de diagnostic assisté par ordinateur (CAD : Computer Aided Diagnosis) pour améliorer le service médical. Le CAD est en train de devenir un outil interdisciplinaire avancé de la technologie qui combine des éléments fondamentaux de différents domaines tels que le traitement d'images, l'analyse d'images, la reconnaissance de formes [CAD-2]. Cette technologie peut être appliquée à toutes les modalités d'imagerie, y compris la radiographie par projection, la tomodensitométrie (CT), la résonance magnétique l'imagerie (IRM), l'échographie (US) ainsi que pour toutes les parties du corps telles que le crâne, le thorax, le cœur, l'abdomen et les extrémités. Les fonctionnalités d'un système d'aide au diagnostic médical sont présentées sur la figure II.4.

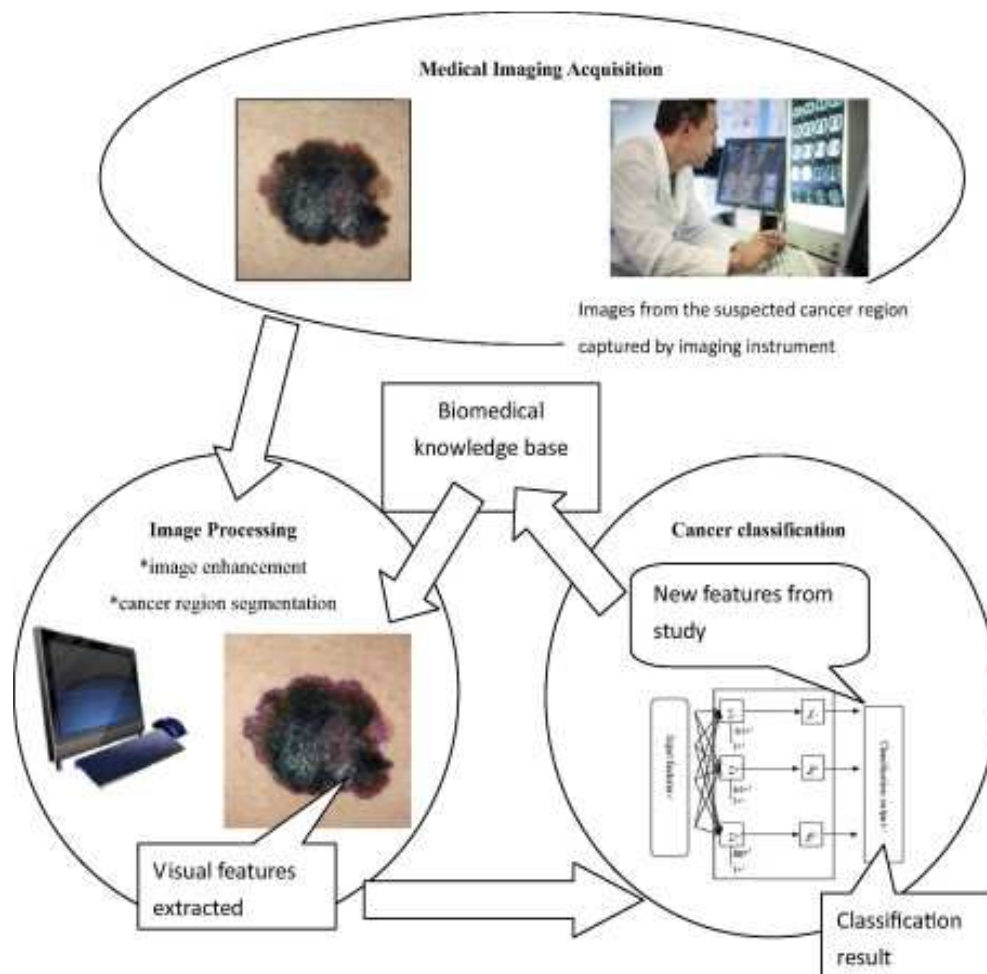


Figure II.4 Fonctionnalités d'un système d'aide au diagnostic médical assisté par ordinateur (CAD)

L'année 1998 est l'une des années les plus importantes de l'histoire des systèmes CAD, en effet, elle a marqué le passage des technologies de CAD de la phase de recherche à la phase industrielle pratique avec le succès de l'Image Checker™ (R2 Technology, Inc., Sunnyvale, CALIFORNIE : acquis plus tard par Hologic, Inc. en 2006) qui était destiné à marquer les régions d'intérêt sur les mammographies de dépistage.

Bien que les systèmes de CAD actuels ne puissent pas complètement remplacer les médecins humains pour détection/diagnostic en pratique clinique, le CAD est utilisé comme « deuxième avis » par les médecins des rapports d'examen [42]. Les résultats analytiques aideront les médecins à fournir des fonctionnalités pour le diagnostic, le traitement, un suivi adéquat et en temps opportun.

Le CAD est devenu l'un des sujets de recherche majeurs en diagnostic d'imagerie médicale et en radiologie. En fait, un grand nombre de systèmes de CAD ont été utilisés pour aider les médecins dans la détection précoce du cancer (tumeurs du sein dans les mammographies, nodules pulmonaires sur les radiographies thoraciques/TDM, polypes colorectaux dans CT colonography ou de maladies musculo-squelettiques (fracture ou déformation vertébrale due à ostéoporose en radiographies/IRM. Le CAD se compose des deux phases suivantes :

II.5.1 Détection des régions d'intérêt assistée par ordinateur (CADe)

La segmentation d'images médicales est une étape fondamentale dans les systèmes de diagnostic assisté par ordinateur à travers plusieurs applications [43]. La segmentation d'images est considérée comme le processus d'imagerie médicale le plus important car elle extrait la région d'intérêt (ROI : Region of interest) via un processus semi-automatique ou automatique. En effet, cette région cruciale pouvant consister en des lésions infectées, des lobes, des poumons [35]. La région d'intérêt segmentée est utilisée pour extraire les caractéristiques

La segmentation peut aider à fournir des informations quantitatives nécessaire pour détecter le COVID-19 en analysant la gravité et extrayant la région d'intérêt. Néanmoins, une minorité des travaux a utilisé la segmentation pour améliorer la performance des approches proposées [44].

L'utilisation de cette technique de segmentation dans le traitement d'images permet de simplifier la représentation de l'image en quelque chose de plus utile et plus facile à utiliser [39]. La segmentation peut aider à une détection plus fiable du COVID-19 en extrayant la région des

poumons. De cette façon, les zones qui n'appartiennent pas à la région d'intérêt (ROI) sont exclus de l'analyse.

Nous présentons sur la figure II.5, l'un des variantes utilisées par les chercheurs, où l'on part d'une image complète CXR et on arrive à une image recadrée, qui ne contient que la région des poumons.

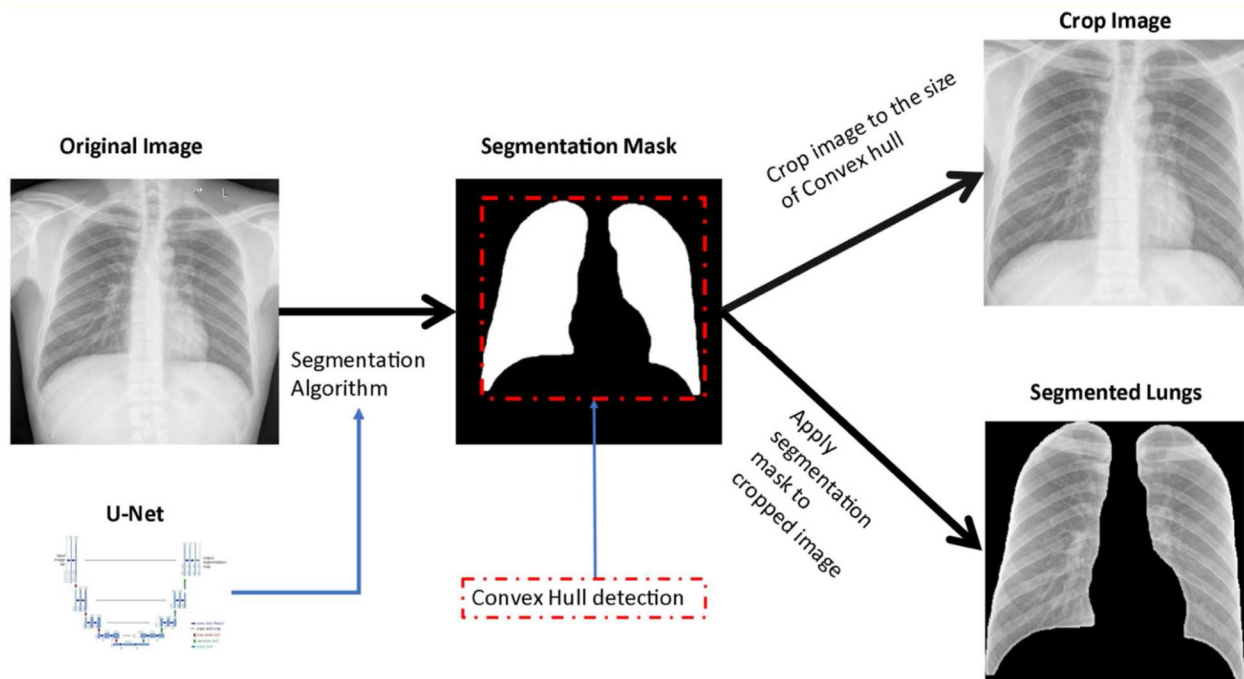


Figure II.5 Processus d'extraction de la région des poumons. U-Net est appliqué comme méthode de segmentation et une image recadrée est obtenue. Source [39].

II.5.2 Diagnostic des régions d'intérêt assisté par ordinateur (CADx)

Les systèmes relatifs au diagnostic assisté par ordinateur (CADx) effectuent le calcul ou l'extraction de descripteurs discriminants à partir des régions d'intérêt segmentées. Par la suite, ces descripteurs sont utilisés comme des prédictions d'entrée à un classifieur. En effet, un modèle prédictif est construit en ajustant les poids des descripteurs 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.

II.6 Application de l'apprentissage automatique pour la détection de Covid-19

Nous exposons sur le tableau II.1 diverses approches CAD basées apprentissage automatique, de détection de Covid-19 tout en évoquant les classifieurs et méthodes d'extraction de descripteurs utilisés, voir plus, les mesures de performance les plus fréquemment utilisées seront soulignées.

Dans [89], les auteurs sont orientés vers une étude approfondie comprenant les techniques de l'apprentissage automatique ainsi que les différentes modalités de l'imagerie médicale, utilisées lors de la détection du Covid-19.

Tableau II.1 Approches CAD basées apprentissage automatique de détection du Covid-19

Référence	Modalité utilisée	Contribution	Evaluation des performances
[69]	X-rays	Utilisation de ResNet152 et un classifieur d'apprentissage automatique (Random Forest) pour la classification de COVID-19 et pneumonie.	Acc = 97.3%
[70]	CT scans	Une approche basée les descripteurs de Grey-Level Size Zone Matrix (GLSZM) et le classifieur des SVM.	Acc = 99.68%
[71]	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%
[72]	X-rays	Une approche de classification en Covid-19, normal et pneumonie basée les descripteurs extraits par VGG19,	Acc = 99.38%

		AlexNet, ResNet et GoogleNet à travers le classifieur des SVM.	
[73]	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%
[74]	X-rays	Une approche de détection de Covid-19 par les descripteurs Deep features à travers le classifieur des SVM.	Acc = 97.48%
[75]	X-rays	Une approche de détection de Covid-19 par les descripteurs Deep features : Resnet50 à travers le classifieur des SVM.	Acc = 95.33%
[76]	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%
[77]	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%
		Une approche de détection de Covid-19 qui utilise des descripteurs	

[78]	CT scans et X-rays	deep features : DenseNet121 à travers le classifieur de Bagging tree.	Acc = 99%
[79]	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.7 Application de l'apprentissage profond pour la détection de Covid-19

Nous allons présenter sur le tableau II.2 quelques approches CAD basées apprentissage profond de diagnostic de cancer du sein.

Dans [44] [40], les auteurs sont pointés vers une étude des différentes techniques d'apprentissage profond pour la détection du Covid-19.

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

Référence	Modalité utilisée	Contribution	Evaluation des performances
[80]	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	Acc = 97.36%

		normaux et d'autres de pneumonie.	
[81]	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%
[82]	X-rays	Le modèle de reseau 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%
[83]	X-rays	Un nouvel modèle de reseau 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%
[84]	X-rays	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 une classe particulière de pneumonie/COVID-19. Ceci avec l'ultime but d'extraire des descripteurs discriminants durant la classification.	Acc = 99.80%


[85]	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%
[86]	X-rays	Le modèle DarkNet a été utilisé comme classifieur pour le modèle (YOLO) où 17 couches de convolutions ont été implémenté 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%
[87]	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%
[88]	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.8 Conclusion

L'intelligence artificielle est un outil dynamique pour la prédiction et l'analyse du COVID-19. Nous avons démontré qu'actuellement, divers chercheurs utilisent les paradigmes de l'IA pour la détection du Covid-19.

Dans ce sens, les méthodes d'apprentissage automatique entraînent les données d'entrée et analysent statistiquement les données de sortie. D'autre part, les approches de l'apprentissage profond suggèrent une meilleure performance des réseaux de neurones en consistant en un type de réseau de neurone artificiel mais multicouches. En effet, plus les couches sont augmentées, meilleure la précision sera.

Nous allons exposer dans le chapitre prochain la problématique tirée dans ce domaine d'actualité ainsi que le cadre méthodologique suivi pour l'implémentation de l'approche proposée avec l'ultime but de détection du Covid-19.



Chapitre III :

Problématique extraite et approche

suggérée

III.1 Introduction

Nous allons évoquer durant ce chapitre la problématique de recherche consistant en la création de modèles prédictifs basés algorithmes d'apprentissage automatique ainsi que profond. En effet, nous allons détailler le pipeline de détection automatique du COVID-19.

III.2 Problématique et plan d'action

La détection virale utilisant la réaction de polymérisation en chaîne en temps réel (RT-PCR) est actuellement la méthode standard pour le diagnostic de COVID-19 [41] mais dans l'urgence actuelle, la faible sensibilité du test (60-70%), infection asymptomatique (17,9-33,3 %), la disponibilité insuffisante de kits de prélèvement d'échantillons et de fournitures pour les tests de laboratoire, ainsi que la surcharge de l'équipement ont rendu impossible la réalisation d'un nombre suffisant de tests pour tous les patients suspects. En effet, il a été constaté qu'il existe une corrélation positive directe entre les décès par covid et les charges auxquelles sont confrontés les agents de santé [44]. Avec des millions de personnes infectées et un nombre minimal de kits de test et de systèmes de diagnostic, les systèmes de santé de nombreux pays sont arrivés à un stade d'effondrement [1].

A noter que la sensibilité des spécialistes humains est d'environ 65% uniquement [39], de plus, les schémas de détection par RT-PCR ont montré un faible taux de positif [36], c'est-à-dire la plus faible valeur de sensibilité pour les échantillons testés pour COVID-19, dans les phases initiales de la maladie.

Les résultats rapportés à ce jour semblent être plus favorables pour la radiographie que pour la tomodensitométrie [39]. En effet, il a été constaté que les classifications automatiques en utilisant CXR obtiennent de meilleurs résultats que lors de l'utilisation de CT : la précision moyenne (Acc) pour CT est de 90 % et pour CXR 96 % [39].

Dans la situation actuelle de la pandémie de COVID-19, des moyens avancés de diagnostic pour traiter et gérer la maladie sont en effet en demande. L'exploration d'approches basées sur l'Intelligence Artificielle semble une solution prometteuse pour une analyse efficace de la maladie. Dans une situation aussi inédite, les solutions alternatives explorées devraient trouver des approches moins coûteuses pour reconnaître, contrôler et traiter cette pandémie mondiale. De plus, la méthode suggérée devrait aider les chercheurs à comprendre en profondeur les raisons fondamentales et l'avancement de la maladie. Des techniques d'ingénierie telles que le traitement d'images et des algorithmes d'apprentissage automatique innovants peuvent faciliter l'identification des caractéristiques marquantes et des lésions survenues, permettant ainsi la catégorisation de l'échantillon d'entrée en tant que cas normal ou atteint d'une maladie. En effet, Au milieu d'une

situation aussi effrayante, l'accès des CAD à l'apprentissage en profondeur semble une solution logique.

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 [40]. De plus, un cas de COVID-19 ne présente souvent aucun symptôme ou des symptômes légers, et donc, souvent impossible à distinguer des images pulmonaires normales à vue d'œil. Dans le pire des cas, ceux-ci entraînent une faible probabilité de détection, c'est-à-dire un taux de vrais positifs faible et un taux élevé de faux négatifs pour les cas de COVID-19. Ceci engendra une conséquence consistant en les sujets qui sont dépistés comme COVID-19 négatif dans les cas de faux négatifs peuvent finir par contaminer d'autres sans tenter un deuxième test.

Suite aux points problématiques discutés précédemment, nous avons souligné des étapes du plan d'action pour pallier à la problématique de ce travail s'énoncent comme suit :

- 1- Le développement d'une approche complète de détection automatique de Covid-19 comprenant la segmentation sémantique de la région d'intérêt ainsi que leur classification avec un aspect important qui manque dans d'autres travaux récents. En effet, dans la plupart des travaux, un petit nombre d'images COVID-19 CXR ont été utilisées pour former et tester les modèles CNN tandis que dans ce travail nous utiliserons un grand nombre d'échographies thoraciques.
- 2- Diverses approches existent pour séparer la lésion pulmonaire du tissu adjacent pour « découper » la région d'intérêt ; les traitements effectués par ces algorithmes sont soit : Manuels, Semi-automatique, le volume est extrait automatiquement et l'utilisateur édite les contours manuellement ou bien automatique, rapide et précis, réalisé par l'apprentissage profond généralement [41]. Néanmoins, la formation d'un réseau de segmentation d'images robuste nécessite un volume suffisamment important de données étiquetées qui ne sont pas toujours facilement accessibles.

Notre approche de segmentation de la région d'intérêt était basée sur un réseau de neurones convolutifs (CNN), consistant en est une classe de réseaux de neurones profonds qui sont principalement utilisés pour le traitement d'images médicales [44]. En effet, les raisons du choix de l'architecture U-Net sont les suivantes :

- L'architecture U-Net s'est déjà avérée supérieure aux autres méthodes antérieures disponibles pour l'analyse d'images biomédicales.
 - Les exigences de formation de bout en bout peuvent être satisfaites avec très peu d'échantillons, ce qui s'avère sans aucun doute bénéfique, car une grande cohorte d'échantillons d'entraînement peut ne pas être disponible pour tous les chercheurs.
 - L'inclusion de la capture de contexte contractuel et des expansions de chemins symétriques permet à l'architecture U-Net de trouver des emplacements précis de pixels par rapport aux données convolutives disponibles.
- 3- Bien que l'apprentissage en profondeur ait fait de grands progrès dans la segmentation des images médicales, cela demeure une tâche difficile dans le domaine de l'infection pulmonaire au COVID-19 dû au fait que les bases de données publiques existantes sur le COVID-19 sont relativement petites et faiblement étiquetées. Ainsi, l'entraînement des réseaux de neurones profonds à partir de zéro avec des données inadéquates peut conduire à une mauvaise généralisation engendrant un overfitting [45]. Nous avons appliqué l'apprentissage par transfert pour résoudre ce problème qui a complètement changé la façon dont les chercheurs percevaient la boîte noire du Deep Learning [2]. En effet, nous avons utilisé ces modèles d'apprentissage pour améliorer la généralisation et l'efficacité des modèles d'apprentissage profond.
- 4- Réaliser une classification des régions d'intérêt par les SVM et basée sur l'analyse de la texture. En effet, ce descripteur a prouvé sa puissance incontournable en vision par ordinateur.

III.3 Segmentation des régions d'intérêt dans les radiographies thoraciques basée Deep Learning

III.3.1 Base de données utilisée

Nous avons utilisé divers segments de radiographies thoraciques comme suit :

1- Premier ensemble de radiographies thoraciques

QaTa-COV19 Dataset [46] : Les chercheurs de l'Université du Qatar et de l'Université de Tampere ont compilé l'ensemble de données QaTa-COV19, qui comprend 4603 radiographies

pulmonaires (CXY) COVID-19. Sur 4603 images, 2951 d'entre elles ont leurs masques de segmentation du ground-truth correspondants comme mentionné sur la figure III.1 et nous considérons que les radiographies thoraciques avec leurs masques de segmentations respectifs. Nous avons rajouté 855 radiographies thoracique de la « Pneumonie » à cet ensemble de données à partir de [47]. Donc au total nous aurons 3806 radiographies thoraciques.




Figure III.1 Quelques exemples des échographies thoraciques avec leur msques de lésions de COVID-19 de la base de donnée QaTa-COV19.

2- Deuxième ensemble de radiographies thoraciques

Nous avons utilisé 704 radiographies thoracique des poumons avec leur masques respectifs de segmentation des poumons comme exposé sur la figure III.2, ceci à partir de [48].




Figure III.2 Quelques exemples des échographies thoraciques avec leur msques poumons.

3- Troisième ensemble de radiographies thoraciques

Une équipe de chercheurs de l'Université du Qatar, Doha, Qatar, et de l'Université de Dhaka, Bangladesh, ainsi que leurs collaborateurs du Pakistan et de Malaisie, en collaboration

avec des médecins, ont créé une base de données d'images radiographiques thoraciques pour les cas positifs au COVID-19 ainsi que Images de pneumonie normale et virale [49]. En effet, nous avons pris à partir de cette base de données 4000 échographies thoracique normales, 3616 échographies thoracique du Covid-19 et nous avons rajouté les 3418 radiographies thoraciques de la pneumonie à partir de [47]. Donc pour cet ensemble de données nous aurons 11 034 radiographies thoraciques.

III.3.2 Pipeline suivi basé U-Net pour la segmentation des régions d'intérêt

- **Prétraitement**

Il est extrêmement difficile pour les modèles d'apprendre à classifier à partir de deux classes très similaires (pneumonie et COVID-19), dans ce sens, le prétraitement devient une étape importante.

L'objectif principal du prétraitement de l'image est d'améliorer l'interprétabilité ou la perception des informations contenues dans l'image pour l'œil humains ou l'extraction de caractéristiques et de créer une image subjectivement meilleure que l'image d'origine en modifiant l'intensité des pixels de l'image d'entrée. Une préoccupation majeure est de ne pas altérer les informations pendant le processus d'amélioration de l'image. Diverses techniques d'amélioration de l'image telles que les algorithmes de dé-bruitage, le filtrage, l'interpolation, les ondelettes [2]. L'égalisation adaptative d'histogramme (Adaptive Histogram Equalization) effectue une égalisation d'histogramme sur de petites régions dans l'image, et ainsi, il améliore le contraste de chaque région individuellement. Par conséquent, il améliore le contraste local et les bords de manière adaptative dans chaque région de l'image à la distribution locale des intensités de pixels au lieu des informations globales de l'image. Cependant, AHE pourrait suramplifier la composante de bruit dans l'image [2]. Cependant, les images améliorées avec l'égalisation d'histogramme adaptative limitée en contraste (CLAHE) sont d'apparence plus naturelle que celles produites par l'égalisation d'histogramme. Lorsque la technique d'égalisation d'histogramme a été appliquée aux images radiographiques, il a été observé qu'elle saturait certaines régions. Pour résoudre ce problème, CLAHE utilise la même approche que AHE, mais la quantité d'amélioration du contraste qui peut être produite dans la région sélectionnée est limitée par un paramètre de seuil.

Nous avons appliqué la technique d'égalisation d'histogramme adaptative limitée en contraste (CLAHE) sur toutes les radiographies thoraciques utilisées comme mentionné sur la figure III.3.




Figure III.3 Exemple de l'application d'un prétraitement par l'égalisation d'histogramme adaptative limitée en contraste (CLAHE) : à gauche les échographies originales et à droite après le prétraitement.

Maintenant que l'image radiographique est améliorée, elle est beaucoup plus précise, et nous pouvons voir toutes les parties de l'image. L'image contenait plus de bruit et de détails inutiles qui pourraient potentiellement affecter notre modèle.

- **Segmentation basée U-Net**

Il a été rapporté dans la littérature récente que les modèles d'apprentissage en profondeur peuvent apprendre des domaines non pertinents et peuvent prendre une décision à partir des informations non pertinentes [2] et donc même si les performances d'un réseau hautement performant ne peuvent pas être généralisées dans des applications du monde réel. Par conséquent, les poumons segmentés ont aidé le CNN à décider de la principale région d'intérêt par rapport aux rayons X simples. Ainsi, dans le cas de détection de COVID-19, la segmentation est souvent une étape critique de prétraitement qui peut permettre au modèle d'apprendre, provenant uniquement de l'organe affecté, à savoir les poumons, pour fournir des prédictions plus précises [40].

Autrement, il a été montré que les principaux résultats que les réseaux utilisent pour effectuer une classification en utilisant l'image entière apparaissent principalement en dehors de la région du poumon et elle est liée aux marques que présentent les images. Ces résultats suggèrent que les CNN sont des modèles d'apprentissage qui ne sont pas directement liés aux pathologies associées aux images. En utilisant les images complètes, les réseaux apprennent des caractéristiques en dehors de la région des poumons [39].

Nous avons réalisé deux types de segmentation basées le modèle U-Net dont l'architecture est la suivante :




Figure III.4 Architecture du modèle U-Net utilisé

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 :

1- Segmentation des lésions pulmonaires

Dans ce type de segmentation, nous avons utilisé le premier ensemble de données. En effet, nous avons entraîné l'algorithme U-Net sur les 2951 échographies thoraciques côte à côte avec leurs 2951 masques de segmentation pour segmenter les lésions du Covid-19.

Par la suite nous avons réalisé un apprentissage par transfert, à savoir que le modèle construit suite à la segmentation des lésions du Covid-19 soit appliqué sur les 855 radiographies thoraciques pour en segmenter les lésions de la pneumonie en s'appuyant sur les points suivants :

- Les masques des lésions de la pneumonie étaient indisponibles d'un coté et de l'autre l'apprentissage par transfert est devenu une technique largement utilisée qui tire parti des connaissances acquises tout en résolvant un problème et en l'appliquant à un problème différent mais connexe. Les résultats révèlent les avantages du transfert de connaissances à partir de lésions pulmonaires non Covid-19 ou le contraire [45].
- Les lésions du COVID-19 ressemblent à celles de la pneumonie. En effet, dans de nombreux cas bénins de COVID-19, les symptômes sont similaires à ceux du rhume [40].
- Un autre défi en raison de l'accessibilité limitée des bases de données médicales est la classification des images médicales pour le diagnostic clinique. En raison de la similitude qu'existe entre le COVID-19 et d'autres types de bactéries ou pneumonie virale, il est difficile de se concentrer sur le contraste entre eux [44]. Dans ce sens, un transfert de modèles pré entraîné est possible d'un type de lésion à un autre.

2- Segmentation des poumons

Dans ce type de segmentation, nous avons utilisé le deuxième ensemble de données. En effet, nous avons entraîné l'algorithme U-Net sur les 704 échographies thoraciques côte à côte avec leurs 704 masques de segmentation pour segmenter l'organe entier du poumon.

Par la suite nous avons réalisé un apprentissage par transfert, à savoir que le modèle construit suite à la segmentation des poumons soit appliqué sur les 11034 radiographies thoraciques du troisième ensemble de données pour en segmenter les poumons en éliminant la cage thoracique, la colonne vertébrale et les épaules.

III.4 Classification des régions d'intérêt basée SVM

III.4.1 Régions d'intérêt obtenues

Nous avons obtenu deux types de régions d'intérêt, à savoir :

- **Régions d'intérêt des lésions pulmonaires**

Où nous avons obtenus des lésions relatives au Covid-19 et d'autres relatives à la pneumonie. Dans ce sens, le premier processus de classification sera consacré à une classification binaire : Covid-19 ou pneumonie.

- **Régions d'intérêt de l'organe du poumon**

Où nous avons obtenu la segmentation de l'intégralité du poumon. Dans ce sens, le deuxième processus de classification sera consacré à une classification en 3 classes : Covid-19, pneumonie ou normal sans la présence d'aucune maladie.

III.4.2 Pipeline de classification des régions d'intérêt basé l'algorithme des SVM

Nous présentons sur la figure III.5, 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 comme nous l'avons indiqué dans la sous-section III.3.2.

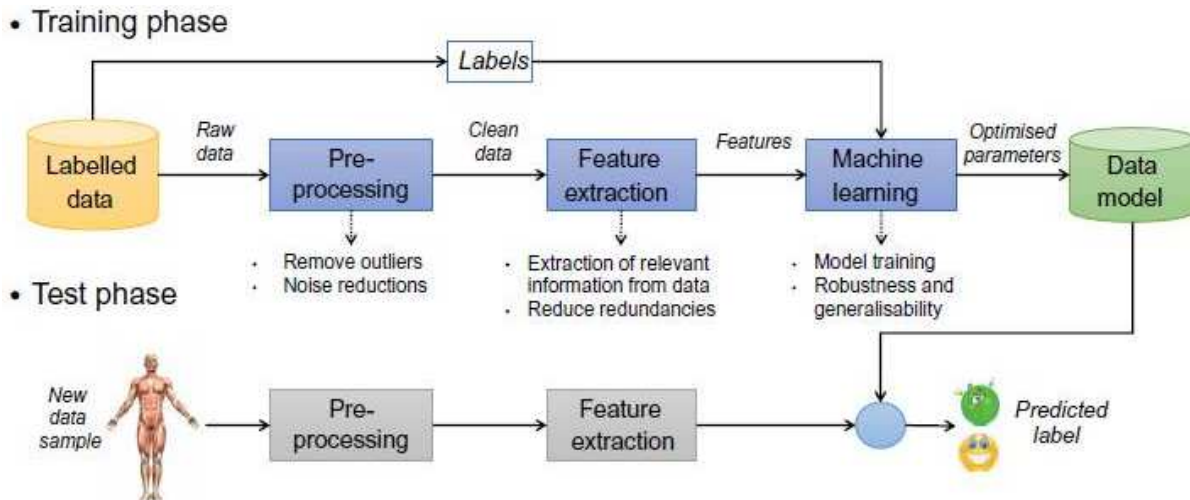


Figure III.5 Pipeline suivi pour la classification des régions d'intérêt. Source [50].

- **Extraction des descripteurs**

La technique de segmentation d'image appartenant au pré-traitement d'image est la plus cruciale partie de l'étape d'extraction des caractéristiques car elle nous a aidé à séparer les

poumons de la radiographie pulmonaire. De plus, cela a aidé le modèle proposé à se concentrer uniquement sur les caractéristiques essentielles : les poumons [37].

Les lésions COVID-19 telles que GGO, crazy paving, air-space consolidation, bronchovascular thickening, et traction bronchiectasis ont des apparences complexes. En effet, les images de radiographie pulmonaire des patients COVID-19 ont une forme, des structures géométriques et une texture différente par rapport aux personnes normales ou aux personnes atteintes d'autres types de maladies. Ainsi, l'extraction de caractéristiques de forme et de texture peut être utile pour la classification des images de coronavirus [51] [44].

L'extraction des descripteurs discriminants désigne la seule information donnée à l'algorithme d'apprentissage automatique en vue de prise de décision.

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 comme exposées sur les figures III.6, III.7 et III.8 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.

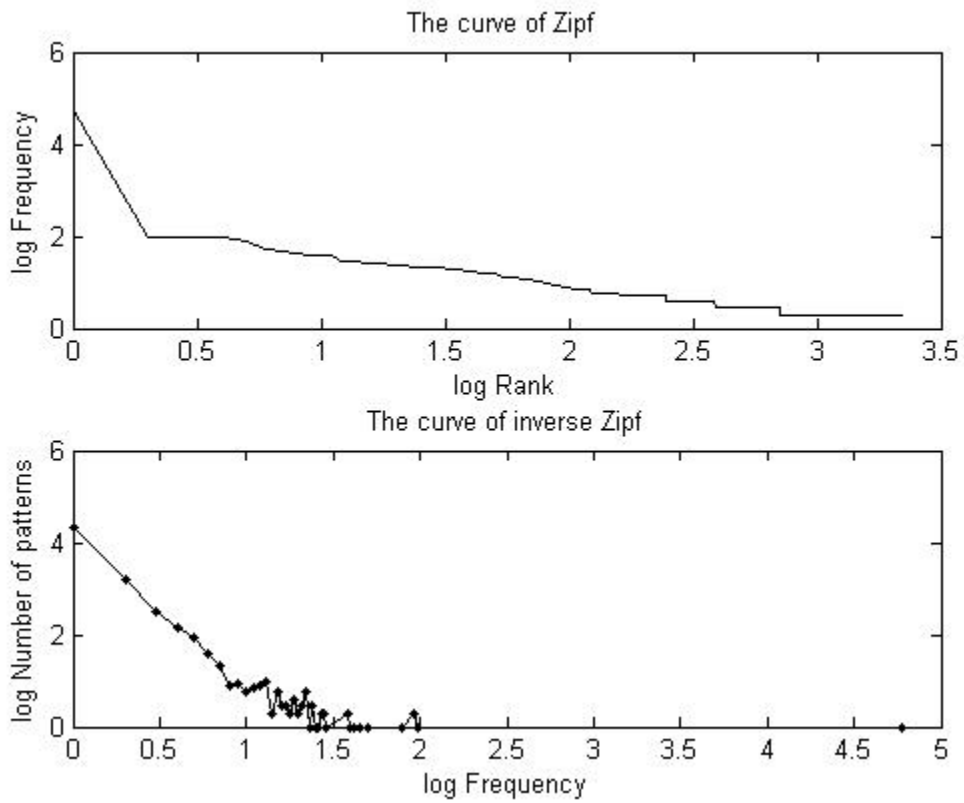


Figure III.6 Courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19.




Figure III.7 Courbes de Zipf et de Zipf inverse d'un poumon sein.


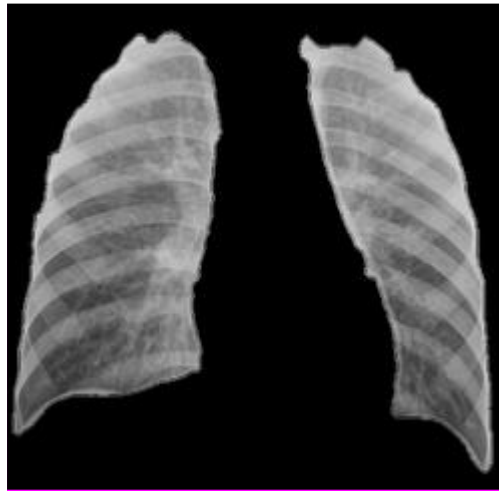


Figure III.8 Courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie.

Les descripteurs dérivés des courbes de Zipf et de Zipf inverses sont les suivants [52] :

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 [53]. La formule du filtre de Gabor 2D est donnée par [53] :

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

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 [53] 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 génèrera 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 $N*N$ 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.9 :

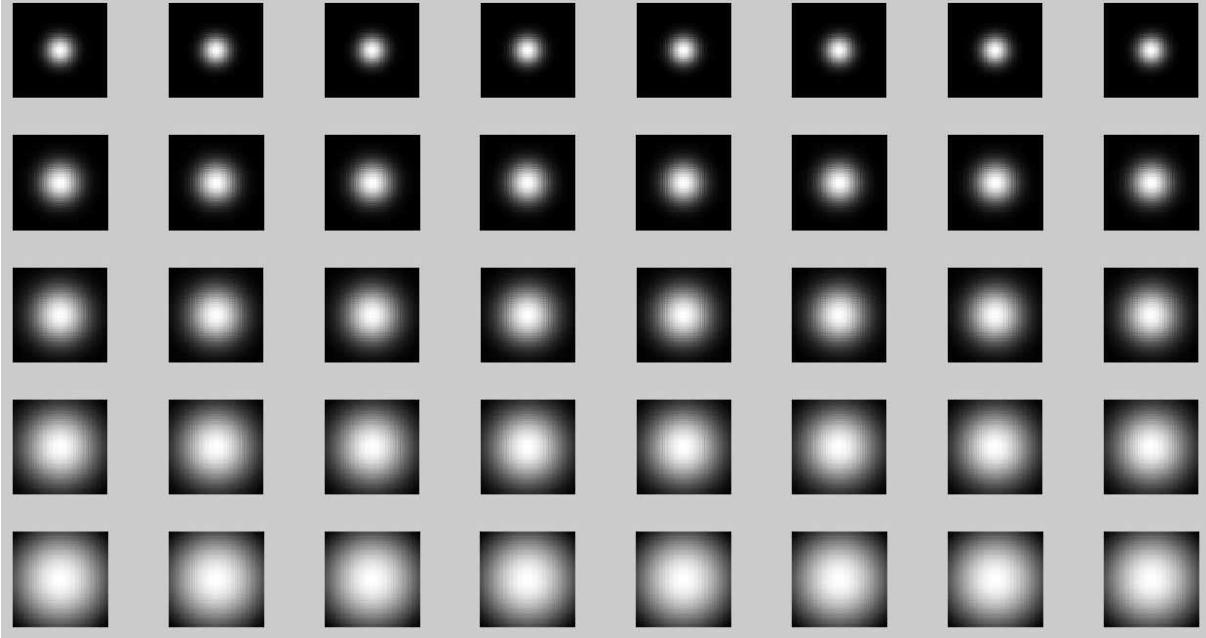


Figure III.9 Les divers filtres de Gabor appliqués dans le domaine fréquentiel.

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.10, démontre la partie réelle de ces filtres.




Figure III.10 Parties réelles des filtres de Gabor utilisés.

Nous allons démontrer sur la figure III.11, la partie réelle des régions d'intérêt filtrées :




Figure III.11 Parties réelles des régions d'intérêt filtrées

A ce stade, nous allons exposer sur la figure III.12, la magnitude de la réponse des régions d'intérêt filtrées.




Figure III.12 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 [54].

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

Après la phase d'extraction de descripteurs, nous avons utilisé les SVM pour la classification. Cet algorithme est connu pour son potentiel à effectuer la classification des éléments hautement non linéaires [1].

Les algorithmes d'apprentissage automatique, tels que les SVM peuvent être supérieurs aux CNN. En effet, il a été prouvé que les SVM fournissent des résultats efficaces dans la détection de COVID-19 avec certains avantages attributifs [40].

Dès que l'algorithme des SVM termine son optimisation, le modèle prédéfini d'apprentissage automatique est orienté au test. Effectivement, nous aurons à tester la généralisabilité du modèle 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.

Il est crucial de mentionner que la généralisabilité fera recours à l'overfitting, 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.

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.13 Aperçu schématique du pipeline de l’approche proposée de détection du Covid-19.

III.6 Conclusion

Nous avons défini l'approche proposée de détection automatique de COVID-19 où la validation des résultats obtenus sera réalisée au long du chapitre suivant. En effet, une comparaison avec l'état de l'art sera envisagée également malgré les difficultés rencontrées du moment que les chercheurs utilisent diverses bases de données ainsi que la répartition différente des radiographies thoraciques entre apprentissage et test.



Chapitre IV :

Evaluation des résultats obtenus par

l'approche suggérée

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)
Lenovo G50	intel (R) Core (TM) i3-5005U CPU 2.00GHz	windows 10 64 bits	4 GB

IV.2.2 Kaggle

C'est un site internet américain créé en 2010 qui permet aux amateurs comme aux professionnels de s'exercer seuls ou par équipes à des challenges de machine learning proposés par des entreprises ou par le site Kaggle lui-même. Pour chaque challenge, un échantillon d'entraînement et un échantillon de test sont proposés. L'échantillon d'entraînement est une liste d'individus pour lesquels sont fournis un certain nombre de critères ainsi que la donnée sur laquelle se feront les prédictions. Il permet de construire et de perfectionner notre algorithme. Il est aussi fourni un échantillon de test contenant les individus pour lesquels la prédiction doit être faite à partir de notre algorithme. La performance de cet algorithme est ensuite évaluée par Kaggle en fonction du taux de prédictions correctes pour ce jeu de données [55].

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.

IV.2.3 Python

Python 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 [56].

Nous avons opté pour la version Python 3.7.10. Nous avons utilisé l'ensemble de packages fournis par Anaconda, une distribution de Python : ceux-ci comprennent Python. 3.7.10, toute la bibliothèque: numpy , torch, torchvision, tqdm, argparse, os, matplotlib, sklearn, pandas, PIL, cv2, scipy, pickle, csv.

Torchvision: est une bibliothèque pour Computer Vision qui va de pair avec PyTorch. Il contient des utilitaires pour des transformations d'images et de vidéos efficaces, des modèles pré-formés couramment utilisés et des ensembles de données (torchvision n'est pas fourni avec PyTorch, vous devrez l'installer séparément.) [57].

Scikit-learn: est une bibliothèque libre Python dédiée à l'apprentissage automatique. Elle est développée par de nombreux contributeurs notamment dans le monde académique par des instituts français d'enseignement supérieur et de recherche.

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 [56].

Anaconda: est une distribution libre et open source des langages de programmation Python et R appliquée au développement d'applications dédiées à la fouille de données et à l'apprentissage automatique (traitement de données à grande échelle, analyse prédictive, calcul scientifique), qui vise à simplifier la gestion des paquets et de déploiement. La distribution Anaconda est utilisée par plus de 6 millions d'utilisateurs et comprend plus de 250 paquets populaires fouille de des données adaptés pour Windows, Linux et MacOS [56].



Figure IV.2 Bibliothèque Pytorch en Python

IV.2.4 HTML5

HTML5 (HyperText Markup Language 5) est la cinquième révision du langage de programmation HTML qui permet de décrire le contenu et l'apparence des pages Web. HTML5 a été développé pour résoudre les problèmes de compatibilité de la norme actuelle, HTML4. Cette version, à la différence des précédentes, n'exige pas l'utilisation d'API ou de plug-ins propriétaires. HTML5 a été adopté en 2007 par le nouveau groupe de travail du World Wide Web Consortium (W3C). Ce groupe a publié la première version de la norme en janvier 2008. Lancée en octobre 2014, cette version HTML5 apporte de nouveaux éléments et de nouveaux attributs par rapport à la version précédente [58].

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.

L'un des objectifs qui sous-tendent la création de HTML5 est la prise en charge des documents multimédia sur les terminaux mobiles. Pour cela, des fonctions syntaxiques ont été créées, comme les balises vidéo, audio et canvas.

Les nouvelles fonctionnalités de HTML5 modifient réellement les interactions avec les documents. Par exemple :

- de nouvelles règles d'analyse pour plus de flexibilité ;
- de nouveaux attributs ;
- la suppression des attributs obsolètes ou redondants ;
- la possibilité de faire glisser-déplacé des éléments d'un document HTML5 à un autre ;
- l'édition hors connexion ;
- l'amélioration des fonctions de messagerie ;
- des règles détaillées pour l'analyse ;
- l'enregistrement des gestionnaires de MIME et de protocole ;

- une norme commune de stockage des données dans les bases de données SQL (Web SQL) [59].



Figure IV.3 Logo HTML5

IV.2.5 CSS3

Le CSS pour Cascading Style Sheets, est un langage informatique utilisé sur Internet pour la mise en forme de fichiers et de pages HTML.

Apparu dans les années 1990, le CSS se présente comme une alternative à la mise en forme via des balises, notamment HTML. Un peu plus complexe à maîtriser, il permet un gain de temps considérable dans la mise en forme d'une page web par rapport à ces balises. Grâce au CSS, vous pouvez en effet appliquer des règles de mise en forme (titrage, alignement, polices, couleurs, bordures, etc.) à plusieurs documents simultanément.

Le but de CSS est séparer la structure d'un document HTML et sa présentation. En effet, avec HTML, on peut définir à la fois la structure (le contenu et la hiérarchie entre les différentes parties d'un document) et la présentation. Mais cela pose quelques problèmes. Avec le couple HTML/CSS, on peut créer des pages web où la structure du document se trouve dans le fichier HTML tandis que la présentation se situe dans un fichier CSS.

Avec CSS on peut par exemple définir un ensemble de règles stylistiques communes à toutes les pages d'un site internet. Cela facilite ainsi la modification de la présentation d'un site entier. CSS permet aussi de définir des règles différentes pour chaque

support d'affichage (un navigateur classique, une télévision, un support mobile, un lecteur braille...). CSS permet aussi d'améliorer l'accessibilité des documents web.

De plus, CSS ajoute des fonctionnalités nouvelles par rapport à HTML au point de vue du style. En effet, HTML permet une gestion assez sommaire du style des documents [60].

Ses standards sont définis par le World Wide Web Consortium (W3C), au même titre que HTML ou XML [61].



Figure IV.4 Logo CSS3

IV.2.6 JavaScript

JavaScript est un langage de programmation qui permet d'implémenter des mécanismes complexes sur une page web, et plus précisément un langage de script orienté objet. À chaque fois qu'une page web fait plus que simplement afficher du contenu statique, afficher du contenu mis à jour à des temps déterminés, des cartes interactives, des animations 2D/3D, des menus vidéo défilants, etc...

JavaScript a de bonnes chances d'être impliqué. C'est la troisième couche des technologies standards du web, les deux premières (HTML et CSS) [62].

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 [63].

Comment fonctionne JavaScript ?

Au lieu de s'exécuter à distance sur des serveurs sur Internet, JavaScript a la particularité d'exécuter des programmes localement, du côté client, comme on dit en informatique. Par conséquent, JavaScript permet aux pages web de programmer, transformer et traiter les données envoyées et reçues. Pour cela, elles interagissent avec le balisage, l'affichage du contenu en langage HTML et la stylisation de ce contenu fournie par le CSS sur ces pages.

Les scripts de code écrits dans ce langage et exécutés dans un navigateur permettent, entre autres, de mettre à jour une partie du contenu d'une page web sans avoir à le charger complètement, après avoir rempli un formulaire. Cela a engendré la création d'une multitude de logiciels fonctionnels à des fins diverses. Par exemple, Google Docs ne marcherait jamais sans l'existence de JavaScript [64].




Figure IV.5 Logo JavaScript

IV.3 Les mesures de performances utilisées

IV.3.1 Matrice de confusion

En apprentissage automatique supervisé, la matrice de confusion est une matrice qui mesure la qualité d'un système de classification. Elle est vérifiant notamment à quelle fréquence ses prédictions sont exactes par rapport à la réalité dans des problèmes de classification [65].

Chaque ligne correspond à une classe réelle, chaque colonne correspond à une classe estimée. La cellule ligne L, colonne C contient le nombre d'éléments de la classe réelle L qui ont été estimés comme appartenant à la classe C1.

Un des intérêts de la matrice de confusion est qu'elle montre rapidement si un système de classification parvient à classer correctement [66].

Tableau décrivant les performances d'un modèle de classification en regroupant les prévisions en 4 catégories:

- **Vrais Positifs:** nous avons correctement prédit qu'ils ont du Covid-19
- **Vrai Négatifs:** nous avons correctement prédit qu'ils ne sont pas Covid-19
- **Faux Positifs:** nous avons prédit à tort qu'ils ont du Covid-19 (erreur de type I)
- **Faux Négatifs:** nous avons prédit à tort qu'ils ne sont pas Covid-19 (Erreur de type II) [67].

IV.3.2 Les formules des accuracy, sensitivity, specificity

Plusieurs termes sont couramment utilisés avec la description de la sensibilité, de la spécificité et de l'exactitude.

Ils sont vrais positifs (TP), vrais négatifs (TN), faux négatifs (FN) et faux positifs (FP). Si une maladie est avérée présente chez un patient, le test de diagnostic donné indique également la présence de la maladie, le résultat du test de diagnostic est considéré comme vrai positif. De même, si une maladie est avérée absente chez un patient, le test de diagnostic suggère que la maladie est également absente, le résultat du test est vrai négatif (TN). Les vrais positifs et les vrais négatifs suggèrent un résultat cohérent entre le test de diagnostic et la condition prouvée (également appelée norme de vérité). Cependant, aucun test médical n'est parfait. Si le test de diagnostic indique la présence d'une maladie chez un patient qui n'a en fait pas une telle maladie, le résultat du test est faux positif (FP). De même, si le résultat du test de diagnostic suggère que la maladie est absente pour un patient atteint de la maladie à coup sûr, le résultat du test est un faux négatif (FN). Les faux positifs et les faux négatifs indiquent que les résultats du test sont opposés à la condition réelle.

La sensibilité, la spécificité et l'exactitude sont décrites en termes de TP, TN, FN et FP.

- **sensitivity** = $TP/(TP + FN)$ = (Nombre d'évaluations vraiment positives)/(Nombre de toutes les évaluations positives)
- **specificity** = $TN/(TN + FP)$ = (Nombre d'évaluations vraiment négatives)/(Nombre de toutes les évaluations négatives)
- $PPV=(TP/(TP+FP))$

Chapitre IV: Evaluation des résultats obtenus par l'approche suggérée

- $VAN = (VN / (VN + FN))$
- **accuracy** = $(VN + TP) / (VN + FN + TP + FP)$ = (Nombre d'évaluations correctes) / (Nombre de toutes les évaluations) [68].

Tableau IV.3 Termes utilisés pour définir accuracy, sensitivity, specificity

Résultat du test diagnostique	État (par exemple, maladie) Tel que déterminé par la norme de vérité		
	Positive	Négative	Total de la ligne
Positive	TP	FP	TP+FP (Nombre total de sujets avec un test positif)
Négative	FN	TN	FN + TN (Nombre total de sujets avec un test négatif)
Total de la colonne	TP+FN (Nombre total de sujets avec une condition donnée)	FP+TN (Nombre total de sujets sans condition donnée)	$N = TP+TN+FP+FN$ (nombre total de sujets dans l'étude)

IV.4 Evaluation des résultats de la segmentation des poumons

IV.4.1 Résultats obtenus pour le modèle 1

Nous avons obtenu une précision de segmentation de 97




Figure IV.6 Entraînement et validation de l'accracy pour modèle 1




Figure IV.7 Entraînement et validation de loss pour modèle 1

Les courbes suivantes montrent l'évaluation de la segmentation proposée




Figure IV.8 Résultat de courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19 de modèle 1.





Figure IV.9 Résultat de courbes de Zipf et de Zipf inverse d'un poumon sein de modèle 1.




Figure IV.10 Résultat de courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie de modèle 1.



Figure IV.11 Exemple de X-ray d'échographie thoracique d'un poumon inpout de modèle 1.




Figure IV.12 Exemple de masque X-ray d'échographie thoracique d'un poumon inpout de modèle 1.




Figure IV.13 Résultat de segmentation X-ray d'échographie thoracique d'un poumon inpout de modèle 1.

IV.4.2 Résultats obtenus pour le modèle 2

Nous avons obtenu une précision de segmentation de 96




Figure IV.14 Entraînement et validation de l'accracy pour modèle 2




Figure IV.15 Entraînement et validation de loss pour modèle 2

Les courbes suivantes montrent l'évaluation de la segmentation proposée:




Figure IV.16 Résultat de courbes de Zipf et de Zipf inverse d'un poumon atteint de COVID-19 de modèle 2.




Figure IV.17 Résultat de courbes de Zipf et de Zipf inverse d'un poumon atteint de pneumonie de modèle 2.




Figure IV.18 Exemple de X-ray d'échographie thoracique d'un poumon inpout de modèle 2.



Figure IV.19 Exemple de masque X-ray d'échographie thoracique d'un poumon inpout de modèle 2.




Figure IV.20 Résultat de segmentation X-ray d'échographie thoracique d'un poumon inpout de modèle 2.

IV.5 Evaluation de l'approche proposée de détection de Covid-19

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 sur le tableau IV.4 les résultats de la classification basée SVM obtenus. En effet, pour le premier modèle distinguant les poumons portants 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 97%.

Tableau IV.4 Précision de la classification obtenue par les approches proposées.

Nom modèle de classification (SVM)	kernel	C	Accuracy
Modèle1	RBF	100.0	0.92
Modèle2	RBF	100.0	0.97

Tableau IV.5 Comparaison de l'approche proposée vis-à-vis des approches de l'état de l'art pour le pronostic automatique de Covid 19

Références	Technique d'apprentissage Automatique	Descripteurs	Evaluation des résultats	Base des Covid 19 utilisée
[69]	CNN	ResNet152	Acc = 97.3%	Chest X-rays
[81]	CNN	VGG16	Acc = 89.2%	Chest X-rays
[82]	CNN	Xception architecture	Acc = 89.6%	ImageNet
[86]	CNN	DarkNet	Acc = 87.02%	Covid-chest-Xrays-Dataset
[88]	CNN	DeTraC	Acc = 95.12%	CXR image dataset
Modèle1	SVM	Zipf et Zipf inverse	Acc = 80.1%	[47], [49]
Modèle1	SVM	Gabor	Acc = 92.0%	[47], [49]
Modèle1	SVM	Zipf et Zipf inverse et Gabor	Acc = 93.2%	[47], [49]
Modèle2	SVM	Zipf et Zipf inverse	Acc = 97.0%	[48]

IV.6 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.21 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.

- Modèle Covid-19/Pneulonia/Normal lung

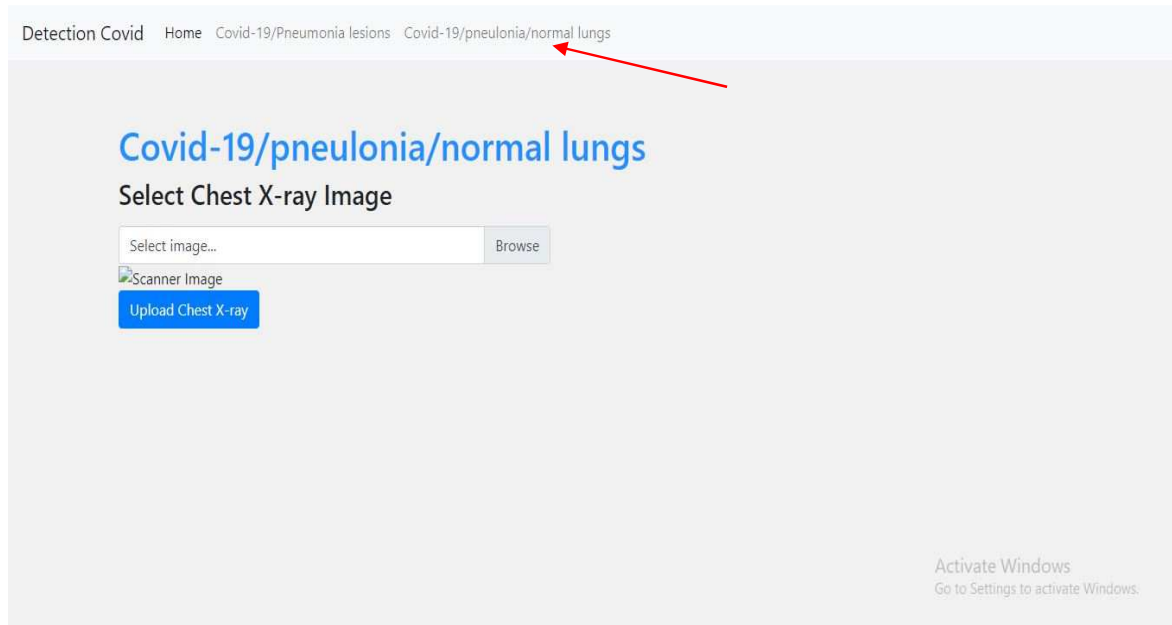


Figure IV.22 Choix du modèle Covid-19/Pneulonia/normal lung.

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

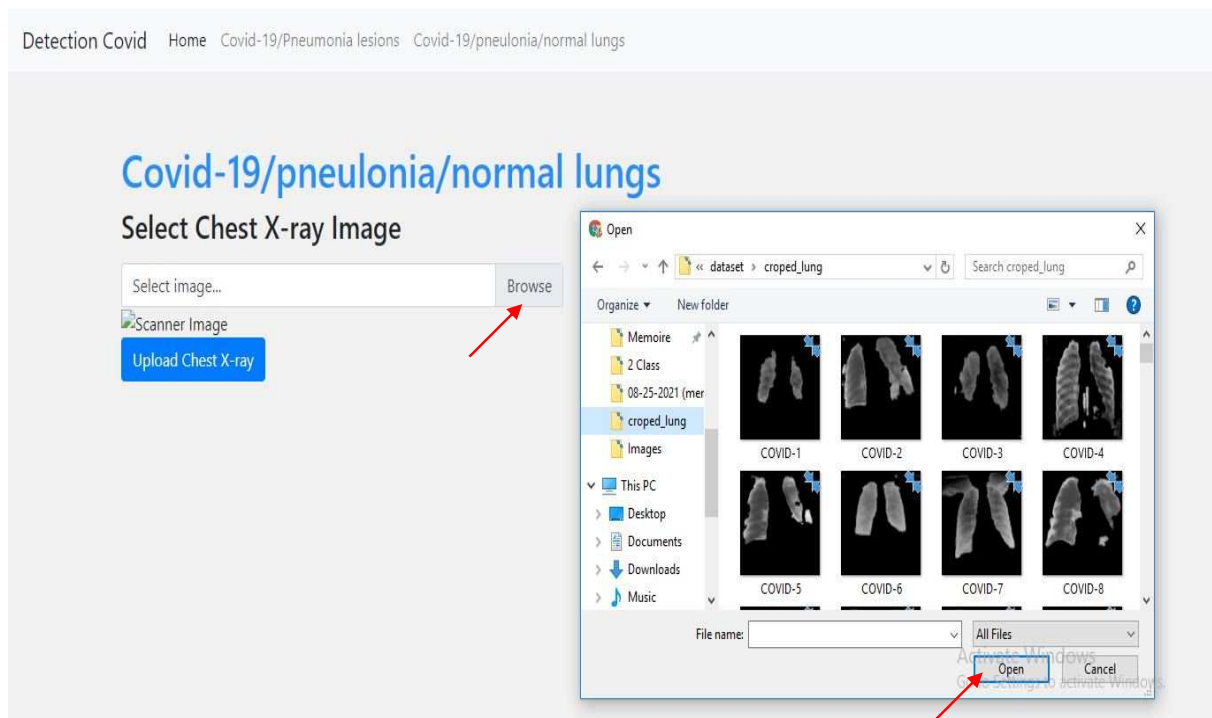


Figure IV.23 Choix de l'échographie thoracique de modèle Covid-19/Pneulonia/normal lung.

L'échographie thoracique sera téléchargée dans l'interface comme illustré sur la figure IV.24.




Figure IV.24 Téléchargement de l'échographie thoracique de modèle Covid-19/Pneulonia/normal lung.

- **Modèle Covid-19/Pneumonia lesions**

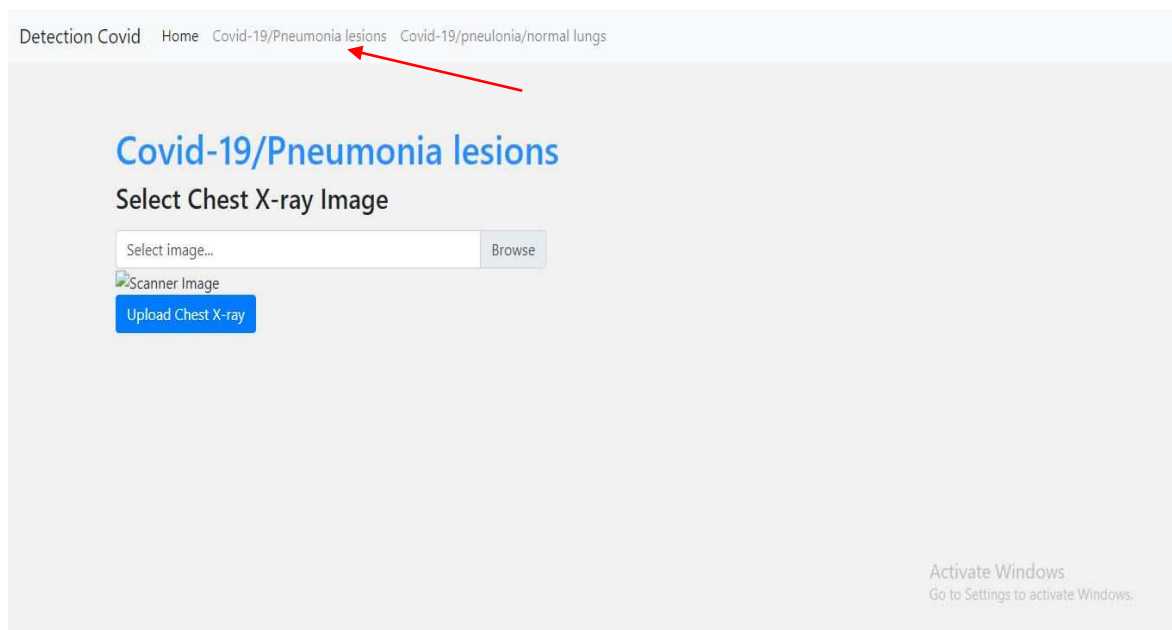


Figure IV.25 Choix du modèle Covid-19/Pneumonia lesions.

Ensuite nous choisissons l'échographie thoracique comme mentionné sur la figure IV.26.

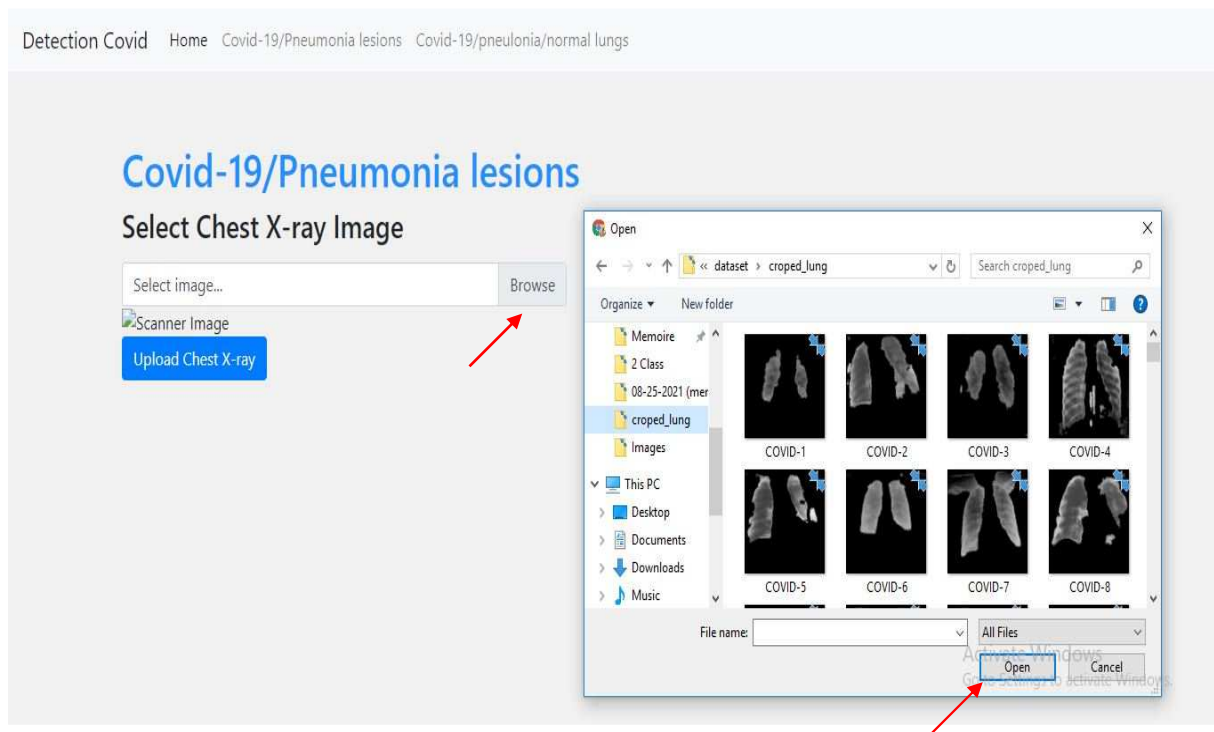


Figure IV.26 Choix de l'échographie thoracique du modèle Covid-19/Pneumonia lesions.

L'échographie thoracique sera téléchargée dans l'interface comme illustré sur la figure IV.27.




Figure IV.27 Téléchargement de l'échographie thoracique du modèle Covid-19/Pneumonia lesions.

Chapitre IV: Evaluation des résultats obtenus par l'approche suggérée

Maintenant si nous désirons faire appel au premier modèle segmentant l'organe du poumon et réalisant sa classification, ceci sera comme exposé sur la figure IV.28 où il s'est avéré que les poumons sont atteints du Covid-19.




Figure IV.28 Segmentation de l'organe du poumon et réalisation de la classification où nous pouvons affirmer que l'approche a classifié correctement le poumon comme atteint du Covid-19.

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.29 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 Covid-

19.

IV.7 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

Face à une croissance exponentielle des cas de COVID-19, le diagnostic assisté par ordinateur pour la détection fiable et rapide de coronavirus est devenu une nécessité ; en vue de l'empêchement de la propagation du virus pendant la pandémie afin d'alléger le fardeau du système de santé [2]. En effet, avec une augmentation du nombre de patients, la charge de travail des radiologues pour ce processus de diagnostic augmente également et le manque de disponibilité des radiologues dans certains endroits est également un défi. Ainsi, il y a un besoin urgent d'un appareil ou d'un système qui identifie la maladie avec un niveau de précision acceptable, même sans l'aide d'un radiologue pour gagner du temps ainsi que pour préserver l'effort pour les plus nécessiteux dans ces contextes de contraintes de temps. Spécialement, avec la disponibilité limitée des kits de test RT-PCR, le temps nécessaire pour traiter le test, les faibles taux de positivité aux premiers stades et l'exigence d'une expertise humaine considérable exigent une méthode innovante de détection du COVID-19.

Dans ce sens, les modèles basés sur l'IA pourraient être une bonne solution en procédant à une analyse d'images médicales grâce à un calcul automatisé, précis et efficace tel qu'un réseau de neurones entraîné, qui est capable de reproduire les précisions d'un cerveau humain [44].

Nous avons proposé un système CAD de segmentation automatique des poumons pour la détection du Covid-19. En effet, nous mettons en évidence les zones suspectes pour apporter un soutien supplémentaire à la décision prise par le professionnel.

Durant la segmentation des poumons ou bien des lésions, nous avons appliqué un modèle d'apprentissage en profondeur U-Net pré-entraîné de poumons ainsi que de lésions pulmonaires qui partagent plus de connaissances avec l'infection COVID-19 et apprennent quelques représentations visuelles à usage général pour les lésions pulmonaires [45].

Par la suite, la quantification texturale des régions d'intérêt était selon diverses fréquences et orientations pour le processus de classification. En effet, les réponses des régions d'intérêt aux filtres de Gabor étaient fusionnées avec les descripteurs issus de l'analyse des régions d'intérêt par les lois de Zipf et de Zipf inverse.

A partir des résultats très satisfaisant obtenus, nous pouvons tirer une variante sur le fait que les médecins et les scientifiques devraient rechercher les meilleurs moyens de fournir de meilleurs soins aux patients par l'utilisation de l'aide des algorithmes de l'apprentissage

Conclusion générale

automatique et profond. En effet, la structure du modèle d'apprentissage profond nécessite des connaissances riches ; par conséquent, la recherche de réseau neuronal remplacera probablement la conception manuelle [2].

Enfin, on espère que ce modeste travail a donné un aperçu sur ce domaine de recherche très actif, intéressant, et défiant, le travail entamé reste ouvert à de futures contributions et améliorations.



Bibliographie

- [1] Priyansh Kedia, Anjum, Rahul Katarya. CoVNet-19: A Deep Learning model for the detection and analysis of COVID-19 patients. *Applied Soft Computing Journal* 104 (2021) 107184.
- [2] Tawsifur Rahman, Amith Khandakar, Yazan Qiblawey, Anas Tahir, Serkan Kiranyaz, Saad Bin Abul Kashem, Mohammad Tariqul Islam, Somaya Al Maadeed, Susu M. Zughaier, Muhammad Salman Khan, Muhammad E.H. Chowdhury. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in Biology and Medicine* 132 (2021) 104319.
- [3] <https://www.numericube.com/la-vision-par-ordinateur>
- [4] <https://www.lebigdata.fr/computer-vision-definition>
- [5] DIF Nassima, L'apprentissage profond pour le traitement d'images, Université Djillali Liabès de Sidi Bel Abbès, 23-12-2020.
- [6] <https://www.universalis.fr/encyclopedie/apprentissage-profond-deep-learning/1-differents-types-d-apprentissage-machine/>.
- [7] <https://www.stemmer-imaging.com/fr-ch/conseil-technique/apprentissage-automatique-et-apprentissage-profond/>
- [8] Martine Automme, Nicole Merle-Lamoot, *Intelligence artificielle - État de l'art et perspectives pour la France*, février 2019.
- [9] <https://azure.microsoft.com/fr-fr/overview/what-is-computer-vision/>
- [10] <https://patrick-bonnin.developpez.com/cours/vision/Bases-du-Traitement-Image/Chap1/>
- [11] Mohammed Khamadja et Said Benierbah, *Traitement d'images*, Université des frères Mentouri Constantine 1, 10/03/2020.

- [12] Alain LE NEGRATE, Azeddine BEGHADADI, Kamel BOUSSAÏD-BELKACEM, Quelques traitements bas niveau basés sur une analyse du contraste local, Université Paris.
- [13] abdelaziz ammadi, Détection automatique de phénomènes présents dans une image satellitaire en composition colorée, universite mohammed 5 rabat, 2006.
- [14] B. Boulebtateche, Analyse D'image : Segmentation Et Reconnaissance De Forme, université annaba, 2020.
- [15] Yann Gousseau, Analyse et synthèse de textures, 2020.
- [16] Olivier Regniers. Méthodes d'analyse de texture pour la cartographie d'occupations du sol par télédétection très haute résolution : application à la forêt, la vigne et les parcs ostréicoles. Université de Bordeaux, Français, 2014.
- [17] Kechida Ahmed, Draï Redouane et Khelil Mohamed, Analyse de Texture et Segmentation par la Transformée en Ondelettes des Images Ultrasonores du type T.O.F.D, Centre de Recherche Scientifique et Technique en Soudage et Contrôle, Chéraga, Alger, 2005.
- [18] François Cabestaing, Analyse d'Images et Vision, université de lille, 2012.
- [19] Zara Islem, L'intelligence artificielle principe, outils et objectifs, UNIVERSITE BADJI MOKHTAR ANNABA, 2019.
- [20] Pierre-Antoine Ganaye, A priori et Apprentissage Profond pour la Segmentation en Imagerie Cérébrale, UNIVERSITE DE LYON, 26/11/2019.
- [21] Marref Nadia, Apprentissage Incrémental et Machines à Vecteurs Supports, Université HADJ LAKHDAR BATNA, 18 /12 /2013.
- [22] <http://biochimej.univ-angers.fr/Page2/COURS/Zsuite/6BiochMetabSUITE/5IntelligenceArtificielle/1IntelligenceArtificielle.htm>

- [23] Frédéric SUR, Introduction à l'apprentissage automatique, École des Mines de Nancy, 2020-2021.
- [24] Labiad Ali, Sélection Des Mots Clés Basée Sur La Classification Et L'extraction Des Règles D'association, Université Du Québec, 06/2017.
- [25] Boughaba Mohammed et Boukhris Brahim, L'apprentissage profond (Deep Learning) pour la classification et la recherche d'images par le contenu, Université Kasdi Merbah Ouargla, 2016/2017.
- [26] <https://datascientest.com/u-net>, 06/2021.
- [27] Victor Dizier, Mathieu Margollé, Réseau de neurones convolutif pour la détection de feux tricolores à partir de traces GPS, École Nationale des Sciences Géographiques (ENSG), Champs-sur-Marne, France, 2017.
- [28] Khalid Bouabdallaoui, Détecter, identifier et localiser des oiseaux ravageurs des cultures, Université de Franche-Comté, Août 2019.
- [29] <http://dspace.univ-jijel.dz:8080/xmlui/bitstream/handle/123456789/8579/Inf.IA.04-20.pdf?sequence=1&isAllowed=y>
- [30] Braikia Oussama, Bouchouicha Nadir, Étude et implémentation d'un réseau de neurones convolutif CNN sur FPGA, UNIVERSITE BADJI MOKHTAR ANNABA, 2020.
- [31] MALKI NARIMENE, Classification automatique des textes par Les réseaux de neurones à convolution, Université LARBI ben M'HIDI d'Oum El Bouaghi, 2018/2019.
- [32] Dr.merzougui ghalia, Réseau de neurones convolutionnel CNN, Université batanna, 2021.
- [33] Aissaoui Houssein Eddine, Belhabri Mohamed Amine, Analyse de la texture: Filtrage et Matrice de cooccurrence, Université Abou Bakr Belkaid– Tlemcen, 06/2014.
- [34] Rakesh 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. *biocybernetics and biomedical engineering* 41 (2021) 239 – 254.
- [35] Anuja Bhargava, Atul Bansal. Novel coronavirus (COVID-19) diagnosis using computer vision and artificial intelligence techniques: a review. *Multimedia Tools and Applications* (2021).
- [36] Prasad Kalane, Sarika Patil, B.P. Patil, Davinder Pal Sharma. Automatic detection of COVID-19 disease using U-Net architecture based fully convolutional network. *Biomedical Signal Processing and Control* 67 (2021) 102518.
- [37] Aly Mostafa, Ahmed Elbehery, Ali Ashraf, Omar Mohamed, and Ali Mahmoud. COVID-19 Patient Chest X-Rays: Automatic Detection Using Deep Learning. *AMLTA 2021, AISC 1339*, pp. 23–32, 2021.
- [38] Hao Jiang, Shiming Tang, Weihuang Liu, Yang Zhang. Deep learning for COVID-19 chest CT (computed tomography) image analysis: A lesson from lung cancer. *Computational and Structural Biotechnology Journal* 19 (2021) 1391–1399.
- [39] José Daniel Lopez-Cabrera, Rubén Orozco-Morales, Jorge Armando Portal-Diaz, Orlando Lovelle-Enriquez, Marlén Perez-Diaz. Current limitations to identify COVID-19 using artificial intelligence with chest X-ray imaging. *Health and Technology* (2021) 11:411–424.
- [40] Sejuti Rahman, Sujan Sarker, Md Abdullah AlMiraj, Ragib Amin Nihal, A. K. M. Nadimul Haque, Abdullah Al Noman. Deep Learning–Driven Automated Detection of COVID-19 from Radiography Images: a Comparative Analysis. *Cognitive Computation* (2021).
- [41] María Dolores Corbacho Abelaira, Fernando Corbacho Abelaira, Alberto Ruano-Ravina, Alberto Fernández-Villar. Use of Conventional Chest Imaging and Artificial Intelligence in COVID-19 Infection. A Review of the Literature. *Open Respiratory Archives* 3 (2021) 100078.

- [42] Pramod Kumar, Sameer Ambekar, Subarna Roy, and Pavan Kunchur. Computer-Aided Diagnosis of Life-Threatening Diseases. Application of Biomedical Engineering in Neuroscience 2019.
- [43] Rachna Jain, Shreyansh Singh, Surykant Swami, and Sanjeev kumar. Deep Learning-Based Techniques to Identify COVID-19 Patients Using Medical Image Segmentation. Computational Intelligence in Healthcare, Health Information Science.2021.
- [44] Sneha Kugunavar and C. J. Prabhakar. Convolutional neural networks for the diagnosis and prognosis of the coronavirus disease pandemic. Visual Computing for Industry, Biomedicine, and Art (2021).
- [45] Yixin Wang, Yao Zhang, Yang Liu, Jiang Tian, Cheng Zhong, Zhongchao Shi, Yang Zhang, Zhiqiang He. Does non-COVID-19 lung lesion help? investigating transferability in COVID-19 CT image segmentation. Computer Methods and Programs in Biomedicine 202 (2021) 106004.
- [46] <https://www.kaggle.com/aysendegerli/qatacov19-dataset>
- [47] <https://www.kaggle.com/prashant268/chest-xray-covid19-pneumonia>
- [48] <https://www.kaggle.com/nikhilpandey360/chest-xray-masks-and-labels>
- [49] <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>
- [50] Nicholas Cummins, Zhao Ren, Adria Mallol-Ragolta, Bjeorn 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.
- [51] Maryam Imani. Automatic diagnosis of coronavirus (COVID-19) using shape and texture characteristics extracted from X-Ray and CT-Scan images. Biomedical Signal Processing and Control 68 (2021) 102602.
- [52] Meriem HAMOUD, Indexation et segmentation d'images basées loi de Zipf et Zipf inverse, mémoire de doctorat UNIVERSITY BADJI MOKHTAR-ANNABA 2015.
- [53] Belkacem ALLEL, Lyes MIHOUBI. Analyse de texture par les filtres de Gabor et Laws. Mémoire de Master en Electronique. 2014.

- [54] 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.
- [55] Céline Duval, Maxime Ollivier, Julian Bustillos, Rapport de projet de spécialité Challenge Kaggle 4, 14/10/2016.
- [56] Hani Zerzaihi, Fouad Zarour, Reconnaissance d images par les réseaux de neurones convolutifs, Université Mohamed Sadik Benyahia de Jijel, 2019/2020.
- [57] <https://medium.com/swlh/understanding-torchvision-functionalities-for-pytorch-391273299dc9>
- [58] <https://www.journaldunet.fr/web-tech/dictionnaire-du-webmastering/1203257-html5-hypertext-markup-langage5-definition-traduction/>
- [59] <https://www.lemagit.fr/definition/HTML5>
- [60] <https://www.futura-sciences.com/tech/definitions/internet-css-4050/>
- [61] <https://www.journaldunet.fr/web-tech/dictionnaire-du-webmastering/1203277-css-cascading-style-sheets-definition-traduction/>
- [62] https://developer.mozilla.org/fr/docs/Learn/JavaScript/First_steps/What_is_JavaScript
- [63] <https://www.journaldunet.fr/web-tech/dictionnaire-du-webmastering/1203585-javascript/>
- [64] <https://www.futura-sciences.com/tech/definitions/internet-javascript-509/>
- [65] <https://www.lebigdata.fr/confusion-matrix-definition>
- [66] https://tice.agroparistech.fr/coursenligne/courses/TELEDETECTION/document/cours_teledection/CONFUSMA.html
- [67] https://datafranca.org/wiki/Matrice_de_confusion
- [68] Wen Zhu, Nancy Zeng, Ning Wang, Sensitivity, Specificity, Accuracy, Associated Confidence Interval and ROC Analysis with Practical SAS Implementations, K&L consulting services, Inc, Fort Washington, PA ,Octagon Research Solutions, Wayne, PA , 2010.

- [69] Kumar R, Arora R, Bansal V, 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>
- [70] Barstugan M, Ozkaya U, Ozturk S. Coronavirus (covid-19) classification using ct images by machine learning methods. arXiv:200309424. 2020.
- [71] 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>.
- [72] 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).
- [73] 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).
- [74] Hassanien, A. 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.
- [75]] Sethy, P. K., Behera, S. 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>.
- [76] Tang, Z., 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.
- [77] Shi, F., 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*.

- [78] Sara Hosseinzadeh Kassani, Peyman Hosseinzadeh 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
- [79] Prottoy Saha, Muhammad Sheikh Sadi, Md. Milon 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.
- [80] Shibly, K. 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>.
- [81] Hall, L. 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.
- [82] Khan, A. 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>.
- [83] Nour, M., Comert, Z., & 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>.
- [84] Karthik, R., Menaka, R., & Hariharan, M. (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>.
- [85] 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.

- [86] Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., & Rajendra 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>.
- [87] Islam, M. Z., Islam, M. M., & Asraf, A. (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>.
- [88] Abbas, A., Abdelsamea, M. M., & Gaber, M. M. (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>.
- [89] Muzammil Khan, Muhammad Taqi Mehran, Zeeshan Ul Haq, Zahid Ullah, Salman Raza Naqvi, Mehreen Ihsan, Haider Abbass. Applications of artificial intelligence in COVID-19 pandemic: A comprehensive review. *Expert Systems With Applications* 185 (2021) 115695.