

الجمهورية الجزائرية الديمقراطية الشعبية

وزارة التعليم العالي والبحث العلمي

UNIVERSITÉ BADJI MOKHTAR - ANNABA
BADJI MOKHTAR – ANNABA UNIVERSITY



جامعة باجي مختار – عنابة

Faculté : TECHNOLOGIE

Département : ELECTRONIQUE

Domaine : SCIENCES ET TECHNIQUES

Filière : Télécommunications

Spécialité : système de Télécommunications

Mémoire

Présenté en vue de l'obtention du Diplôme de Master

Thème:

**Détection et analyse du COVID-19 dans les images médicales
à l'aide de techniques d'apprentissage profond**

Présenté par : FEZARI Asma

BOUDRAR Nesrine

Encadrant : BOUGHAZI Mohamed

Grade : Professeur

U.B.M. Annaba

Jury de Soutenance :

BOUTERRA Nadia	M.C.A	U.B.M. Annaba	Président
BOUGHAZI Mohamed	PROFESSEUR	U.B.M. Annaba	Encadrant
NASRI Seif Allah El Mesloul	M.C.B	U.B.M. Annaba	Examineur

Année universitaire: 2021/2022

Remerciements

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

En tout premier lieu, nous remercions Allah le Tout Puissant et le Bienveillant qui nous a accordé d'innombrables bénédictions et de nous avoir donné la force et la patience tout au long de notre travail afin de réaliser ce projet avec succès.

Nous tenons à exprimer nos profondes gratitude et respectueuses reconnaissances à notre directeur de mémoire, Monsieur le professeur Boughazi Mohamed, pour l'aide qu'il a fournie, les connaissances qu'il a su nous transmettre. Aussi pour son soutien continu, sa patience et sa disponibilité et surtout ses judicieux conseils qui ont contribué à alimenter notre réflexion tout au long de notre démarche. Nous en sommes reconnaissantes pour avoir accepté de nous encadrer et de veiller à ce que le projet continue de progresser vers une thèse finie et un prototype réussi.

Nos remerciements les plus chaleureux et nos respects les plus dévoués vont également aux membres du jury qui nous auront fait l'honneur de juger ce travail et qui par leur disponibilité et leurs observations nous auront permis d'enrichir ce mémoire.

Nous remercions sincèrement Monsieur Dr. REDJATI Abdelghani ainsi que Dr. HAFS Toufik pour leur assistance et contribution à l'élaboration de ce travail.

Un grand merci également à tous nos enseignants au niveau du Département D'électronique pour leur dévouement et leur collaboration à nos connaissances tout au long de ce cycle universitaire. Nous vous sommes infiniment reconnaissants.

Enfin les mots sont trop pauvres pour exprimer notre reconnaissance à nos chers parents pour leur amour, leur aide, leurs sacrifices et leurs prières pour nous éduquer et nous encourager. Merci beaucoup d'être toujours à nos côtés. Nous n'aurions pas pu faire tout cela sans vous.

Sans oublier bien sûr de remercier profondément tous ceux qui ont contribué de près ou de loin à la réalisation de ce travail.

Merci à toutes et à tous.

Dédicace

Merci Allah le Tout Miséricordieux, mon créateur et ma source d'inspiration, de connaissance et de compréhension .Tes grâces à mon égard m'ont donné la persévérance et le courage pour accomplir ce travail.

Je dédie mon travail à mes très chers parents, source de vie, d'amour et d'affection. Un sentiment exceptionnel de gratitude à vous. Particulièrement à toi maman, ceci est ma profonde gratitude pour ton éternel amour et appui. Que cette thèse soit le meilleur cadeau que je puisse t'offrir. À toi papa aussi pour le goût à l'effort que tu as toujours suscité en moi sans oublier ton soutien moral et financier.

Ce travail est également dédié à mes proches particulièrement ma tante Nassima d'avoir contribué à l'élaboration de ce travail. Je dédie à mes très chères amies en souvenirs des bons moments j'espère de tout mon cœur que notre amitié durera éternellement Et que Dieu vous protège.

Avec L'expression de ma reconnaissance, je dédie ce modeste travail à Monsieur Chibouni Issam et à monsieur Belkharchouche Amar et toute l'équipe de Télécom à Sider El Hadjar Annaba, de m'avoir prodigué les conseils nécessaires pour le bon déroulement de cette nouvelle expérience lors de la période du stage. Je suis infiniment reconnaissant de votre gentillesse.

Fezari Asma

*A ma chère mère & mon père qui me manque tant, que
Dieu ait pitié de lui et le fasse parmi les gens du
Paradis, aucune dédicace ne saurait exprimer mon
respect, mon amour éternel et ma considération pour
les sacrifices que vous avez consenti pour mon
instruction.*

*A ma sœur & mes frères, pour l'amour qu'ils me réservent
et qui ont toujours été présents dans tous mes moments
d'examens par leurs conseils et leur surprises sucrées, je
leurs souhaite une vie pleine de bonheur et de succès.*

*A mes chères amies, qui ont tout ce que j'ai chère au
monde.*

Boudrar NESRINE

Résumé :

L'objectif principal de ce travail est d'étudier et de comparer deux techniques améliorées d'apprentissage en profondeur appliquées aux images médicales à rayon x et à tomodensitométrie pour la détection du COVID-19. Un modèle à apprentissage profond a été proposé et affiné sur un ensemble de données en collectant des images COVID-19 et des radiographies pulmonaires normales. L'exactitude et la validité des algorithmes ont été évaluées à partir de différentes bases de données publiques. Les résultats expérimentaux montrent l'efficacité de notre modèle proposé. Nous avons obtenu une précision de 99,88% pour deux bases de données utilisées.

Mot clés : COVID-19, apprentissage profond, réseaux de neurone Convolutifs, modèle CovNet_BN_FA.

Abstract:

The main objective of this work is to study and compare two improved deep learning techniques applied to medical x-ray and CT images for COVID-19 detection. A deep learning model was proposed and refined on a dataset by collecting COVID-19 images and normal chest X-rays. The accuracy and validity of the algorithms were evaluated on different public databases. The experimental results show the effectiveness of our proposed model. We obtained an accuracy of 99.88% for two databases used.

Keywords: COVID-19, deep learning, Convolutional neural networks, CovNet_BN_FA model.

ملخص:

الهدف الرئيسي من هذا العمل هو التحقيق والمقارنة بين تقنيتي التعلم العميق المحسنتين المطبقة على صور الأشعة السينية الطبية والتصوير المقطعي المحوسب للكشف عن COVID-19. تم اقتراح نموذج التعلم العميق وصقله على مجموعة بيانات من خلال جمع COVID-19 صورة وأشعة سينية طبيعية للصدر. تم تقييم دقة وصحة الخوارزميات من قواعد بيانات عامة مختلفة. تظهر النتائج التجريبية كفاءة نموذجنا المقترح. حصلنا على دقة 99.88% لقاعدتي بيانات مستخدمتين.

الكلمات المفتاحية: COVID-19 ، التعلم العميق ، الشبكات العصبية المعقدة ، نموذج
.CovNet_BN_FA

Liste des acronymes :

Ada Grad	Adaptive Gradient Algorithm
Adam	Adaptive Moment Estimation
ADN	Acide Desoxyribonucleique
ANN	Artificiels Neural Network
ARN	Acide Ribonucléique
CNN	Convolutional Neural Network
COVID	Coronavirus Disease
CovNet_BN_FA	CovidNet_BoudrarNesrine_FezariAsma
CT scan	Computed Tomography
DL	Deep Learning
FC	Fully Connected Layers
IA	Intelligence Artificielle
ILSVRC	Image Net Large scale Visual Recognition Challenge
IRM	l'imagerie par résonance magnétique
Les rayons X	radiographie avec des rayons X
LR	Learning Rate
LRN	la normalisation de la réponse locale
MB	Mini batch size
MERS_cov	Middle East Respiratory syndrome coronavirus
MXP	Max Pooling
NE	Nombre Epochs
OMS	Organisation Mondiale De La Santé
PCR	Polymerase Chain Reaction
ReLU	Rectified linear unit
RGB	Red, Green, Blue (système de codage informatique des couleurs)
RMS prop	Root Mean Square Propagation
RNN	Récurrent Neural Network
RT_PCR	Real timePCR
RTQ PCR	Quantitative Reverse Transcription PCR
RVB	Rouge, Vert, Blue (système de codage informatique des couleurs)
SARS_COV	syndrome respiratoire aigu sévère coronavirus
Sgdm	Stochastic Gradient Descent with Momentum
VGG16	Groupe de Géométrie Visuelle 16

Liste des fonctions :

$\theta_{\ell+1} = \theta_{\ell} - \alpha \nabla E(\theta_{\ell}) + \gamma(\theta_{\ell} - \theta_{\ell-1})$	(III.1)
$M_{\ell} = \beta_1 m_{\ell-1} + (1 - \beta_1) \nabla E(\theta_{\ell})$	(III.2)
$V_{\ell} = \beta_2 v_{\ell-1} + (1 - \beta_2) [\nabla E(\theta_{\ell})]^2$	(III.3)
$\theta_{\ell+1} = \theta_{\ell} - \frac{\text{min}}{\sqrt{v_{\ell}} + \epsilon}$	(III.4)
$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN}$	(IV.1)
$\text{Precision} = \frac{TP}{TP+FP}$	(IV.2)
$\text{Sensitivity/Recall} = \frac{TP}{TP+FN}$	(IV.3)
$\text{Specificity} = \frac{TN}{TN+FP}$	(IV.4)
$\text{F1-Score} = \frac{2 * \text{precision} * \text{recall}}{\text{precision} + \text{recall}}$	(IV.5)

Liste des figures :

Figure I.1: une image montrant la forme du coronavirus.	5
Figure I.2: structure du coronavirus.	6
Figure I.3 : poumon humain.	6
Figure I. 4 : SARS-COV-2 vu au microscope électronique	7
Figure I.5 : l'architecture des types des virus	8
Figure I.6 : Diagnostic du COVID-19 par le test RT-PCR	11
Figure I.7 : carte de coronavirus en Algérie (27 Mai 2022).	11
Figure II.1 : Schéma d'organisation d'intelligence artificielle	15
Figure II.2 : Schéma d'organisation d'apprentissage automatique	16
Figure II.3: Schéma d'apprentissage supervisé "supervised Learning"	16
Figure II.4: Schéma d'apprentissage non supervisé "Unsupervised Learning"	17
Figure II.5 : Apprentissage Supervisé & non supervisé	18
FigureII.6.: Schéma d'apprentissage par renforcement "Renforcement Learning"	18
FigureII.7 : Schéma des réseaux de neurones artificiels	20
Figure II.8: Neurone biologique/ Neurone artificiel	21
FigureII.9: Architecture du réseau de neurones à convolution profonde proposé	23
Figure III.1 : Architecture du modèle VGG-16 CNN par couches.	27
Figure III.2 : l'architecture d'Alex Net avec toutes les couches définies.	28
Figure III.3 : Architecture du ResNet50	30
Figure III.4 : Le modèle proposé (CovNet_BN_FA) pour la détection du COVID19	31
Figure III.5: Architecture du CovNet_BN_FA	32
Figure III.6: Couche image input	33
Figure III.7: Matrice d'entrée avec le masque de convolution	34
FigureIII.8: Première étape de convolution	35
FigureIII.9: Vecteur de caractéristique après l'application de convolution	35
FigureIII.10: Graphique de la Fonction d'activation Relu	36
Figure III .11: L'application de max pooling	37
Figure IV.1: Diagramme global de nos bases de données.	44

Figure IV.2.1 : Des images Chest X-ray représentatives de patients normaux (pour la 1 ^{er} base de données scanner)	45
Figure IV.2.2 : Des images Chest X-ray représentatives de patients COVID-19 (pour la 1 ^{er} base de données scanner)	45
Figure IV.3.1: Des images CT Scan représentatives de patients normaux (pour la 2eme base de données IRM)	46
Figure IV.3.2 : Des images CT Scan représentatives de patients COVID-19 (pour la 2 eme base de données IRM)	46
Figure. IV.4 : Architecture du modèle proposé pour le pré-entraîner (pour la 1 ^{er} base de données scanner)	48
Figure IV.5 : Courbe d'évolution (Accuracy and Loss) d'apprentissage pour Scanner (avec l'option Adam)	50
Figure IV.6 : (a) Matrice de confusion pour split 4, (b). Matrice de confusion globale Pour le jeu de données Scanner (avec l'option Adam).	50
Figure IV.7 : Courbe d'évolution (Accuracy and loss) d'apprentissage pour Scanner (Avec l'option Sgdm)	51
Figure IV.8: (a) Matrice de confusion pour split 3, (b). Matrice de confusion globale Pour le jeu de données Scanner (avec l'option Sgdm).	51
Figure IV.9 : Architecture du modèle proposé pour le pré-entraîner (pour la 2 eme base de données IRM)	52
Figure IV.10 : Courbe d'évolution (Accuracy and loss) d'apprentissage pour IRM (avec l'option Adam).	53
Figure IV. 11 : (a) Matrice de confusion pour split 4, (b). Matrice de confusion globale Pour le jeu de données IRM (avec l'option Adam).	54
Figure IV.12 : Courbe d'évolution (Accuracy and loss) d'apprentissage pour IRM (Avec l'option sgdm)	54
Figure IV.13 : (a) Matrice de confusion pour split 2, (b). Matrice de confusion globale Pour le jeu de données IRM(avec l'option Sgdm).	55
Figure. IV.14 : Architecture du modèle proposé pour le pré-entraîner (pour la 3 eme base de données IRM_Scanner)	55
Figure IV. 15: Courbe d'évolution (Accuracy and loss) d'apprentissage IRM_Scanner (Adam)	58
Figure IV.16 : (a) Matrice de confusion pour split 3, (b). Matrice de confusion	58

globale Pour le jeu de données IRM_ Scanner (avec l'option Adam).	
Figure IV.17: Courbe d'évolution (Accuracy and loss) d'apprentissage IRM_Scanner (Sgdm)	59
Figure IV.18 : Matrice de confusion pour split 3, (b) . Matrice de confusion globale Pour le jeu de données IRM_ Scanner (avec l'option Sgdm).	59
Figure. IV.19: Architecture du modèle proposé pour le pré-entraîner (pour la 4 eme base de données Hybrid)	60
Figure IV.20: Courbe d'évolution (Accuracy and loss) d'apprentissage Hybrid (Adam)	61
Figure IV.21 : Matrice de confusion pour split 2, (b) . Matrice de confusion globale Pour le jeu de données Hybrid (avec l'option Adam).	62
Figure IV.22: Courbe d'évolution (accuracy and loss) d'apprentissage Hybrid (Sgdm)	62
Figure IV.23 : Matrice de confusion pour split 3, (b) . Matrice de confusion globale pour le jeu de données Hybrid (avec l'option Sgdm).	63

Liste des tableaux :

Tableau II.1 : Différence entre l'apprentissage supervisé et non supervisé	17
Tableau IV.2 : Tableau de performance du modèle pour chaque split de la base de données (Chest X-RAY) pour option « Adam »	48
Tableau IV.3 : Tableau de performance du modèle pour chaque split de la base de données (Chest X-RAY) pour option « Sgdm »	49
Tableau IV.4 : Tableau de performance du modèle pour chaque split de la base de données (CT Scan) pour option « Adam »	52
Tableau IV.5 : Tableau de performance du modèle pour chaque split de la base de données (CT Scan) pour option « Sgdm »	53
Tableau IV.6 : Tableau de performance du modèle pour chaque split de la base de données multi classes (ChestX_ray, CT Scan) pour option « Adam »	57
Tableau IV.7 : Tableau de performance du modèle pour chaque split de la base de données multi classes (ChestX_ray, CT Scan) pour option « Sgdm »	57
Tableau IV.8 : Tableau de performance du modèle pour chaque split de la base de données (Hyrid) pour option « Adam »	60
Tableau IV.9 : Tableau de performance du modèle pour chaque split de la base de données (Hyrid) pour option « Sgdm »	61
Tableau IV.10 : Interprétation globale des deux options Adam et Sgdm Pour différentes bases de données	63

Table des matières :

Remerciements	II
Dédicace	IV
Résumé	VI
Liste des acronymes	IX
Liste de fonctions	X
Liste des figures	XI
Liste des tableaux	XIV
Table des matières	XV
Introduction générale	1
Chapitre I : Généralités sur COVID-19	
I.1 Introduction	04
I.2 Définition du COVID-19	05
I.3 Le système respiratoire	06
I.4 Les virus	07
I.4.1 Structure des virus	07
I.4.2 Classification des virus	08
I.5 Les types de coronavirus	08
I.6 Les symptômes	09
I.7 Méthodes de Diagnostic	10
I.8 Coronavirus en Algérie	11
I.9 L'imagerie médicale et la détection du COVID-19	12
I.10 Conclusion	12
Chapitre II : Réseau de neurones et L'apprentissage profond (Deep Learning)	
II.1 Introduction	14
II.2 Intelligence artificielle	14
II.3 Machine Learning (l'apprentissage automatique)	15
II.3.1 L'apprentissage supervisé	16
II.3.2 L'apprentissage non supervisé	17
II.3.3 L'apprentissage par renforcement	18
II.4 L'apprentissage profond (Deep learning)	19
II.4.1 fonctionnement de l'apprentissage profond	19

II.4.2 Domaines d'application de l'apprentissage profond	20
II.5 Quelques algorithmes de l'apprentissage profond	21
II.5.1 Neurones biologiques	21
II.5.2 Réseaux de neurones artificiels (ANN)	22
II.5.3 Réseaux de neurones récurrents	22
II.5.4 Réseaux de neurones profonds	22
II.5.5 Réseaux de neurones Convolutifs	22
II.6 Architecture d'un réseau CNN profond	23
II.7 Conclusion	24
Chapitre III : Modèle proposé pour la détection du COVID 19	
III.1 Introduction	26
III.2 Les modèles existants de CNN	26
III.2.1 VGG-16	27
III.2.2 Alex Net	27
III.2.3 ResNet50	29
III.3 Modèle proposé	31
III.4 Les différentes couches du modèle CovNet _BN_FA	33
III.4.1 Couche d'entrée « image input »	33
III.4.2 Couche de convolution 1	34
III.4.3 Couche batch normalisation 1	36
III.4.4 Couche Correction Relu 1	36
III.4.5 Couche max pooling 1	36
III.4.6 Couche entièrement connectée (FC)	37
III.4.7 Couche de Soft max	38
III.4.8 Couche de sortie (classification output)	38
III.5 Les options d'apprentissage Sgdm et Adam	38
III.5.1 Sgdm (Stochastic Gradient Descent with Momentum)	38
III.5.2 Adam (adaptive moment estimation)	39
III.6 Conclusion	41
Chapitre IV: Résultats et Interprétations	
IV.1 Introduction	43
IV.2 Description des bases de données	43
IV.3 Performance métriques	47

IV.4 Application du modèle pour la base de « scanner »	48
IV.4. 1 Résultats obtenus pour la base de « scanner »	48
IV.5 Application du modèle pour la base de données « IRM »	52
IV.5. 1 Résultats obtenus pour la base de données « IRM »	52
IV.6 Application du modèle pour la base de données « IRM_ Scanner »	55
IV. 6. 1 Résultats obtenus pour la base de données « IRM_ Scanner »	55
IV.7 Application du modèle pour la base de données « Hybrid»	60
IV.7.1 Résultats obtenus pour la base de données « Hybrid»	60
IV.8 discussions sur les résultats	63
IV.9 Conclusion	64
Conclusion générale	66
Bibliographie	68

Introduction générale :

Le COVID-19 est la maladie causée par le coronavirus appelé SRAS-COV-2. COVID-19 est le nom donné par l'organisation mondiale de la santé (OMS), précisément le 11 Février 2020[1] à une nouvelle maladie infectieuse respiratoire apparue en Décembre 2019 responsable d'une épidémie mondiale, disons toujours active. La propagation de cette maladie à travers presque tous les pays fut alarmante depuis la découverte du premier cas dans la Province de Hubei (en Chine Centrale). En conséquence 4 millions de personnes sont décédées et près de 18 millions de cas confirmés selon les statistiques de (l'OMS) en Juin 2021 [2].

Dans le but de comprendre et anticiper l'évolution de l'épidémie, les scientifiques tentent sans relâche d'en apprendre plus sur le SRAS-COV-2 et ses différentes variantes. Malheureusement, aucun traitement avec une activité virale directe n'a fait la preuve scientifique de son efficacité. L'objectif principal de notre étude et de soutenir le travail des virologues et des radiologues à poser un diagnostic d'où l'intelligence artificielle va jouer un rôle très important pour une meilleure détection de cet ennemi invisible (COVID-19).

Dans notre travail, nous allons concevoir un nouveau modèle CNN pour la détection et l'analyse du COVID-19 à l'aide d'une base de donnée conçue au COVID-19 qui sera capable de classer des images médicales et de donner les résultats des deux cas affectés /non affectés. Plus précisément, on a dû utiliser deux types de bases de données IRM, Scanner et on a combiné deux autres : IRM_Scanner et Hybrid. Le modèle qu'on va proposer sera basé sur des couches principales utilisées pour traiter les données nécessaires à l'entraînement du réseau neuronal convolutif à l'aide de techniques d'apprentissage profond. Pour finir, on va tester deux optimiseurs afin de choisir celui avec la meilleure résolution qui conviendra le plus à notre étude.

Tous ces éléments seront traités dans ce mémoire de Master à travers quatre chapitres principaux :

Chapitre 1: Généralités sur COVID19

Dans ce chapitre, nous apprendrons les principes de bases de la structure et de la classification des virus émergents y compris les types et les symptômes présentés chez les

personnes infectés en passant par les méthodes de diagnostic pour aboutir à la procédure la plus recommandée par les protocoles médicaux et sanitaires .

Chapitre 2: Réseaux de Neurones et Deep Learning

Dans ce chapitre , nous allons passer par les concepts généraux de l'intelligence artificielle et ses différentes branches : l'apprentissage automatique et l'apprentissage en profondeur .On discutera sur les trois types d'apprentissage profond par rapport à son fonctionnement, domaines d'application et quelques algorithmes .De plus, nous allons fournir un regard sur les différents principes des réseaux de neurones en insistant sur les réseaux de neurones Convolutifs y compris leur architecture.

Chapitre3: modèle proposé pour la détection du COVID 19

Dans ce chapitre, nous en apprendrons plus sur les différents modèles de CNN, y compris leurs architectures. Nous discuterons sur le modèle proposé (CovNet_BN_FA) en tenant compte de ses différents paramètres et de l'utilisation des deux algorithmes.

Chapitre4: Résultats et Interprétations

Dans ce chapitre, nous citerons les différentes bases de données qu'on va utiliser en termes de performances, nous appliquerons aussi le modèle entraîné en fonction de chacune de ces bases. Nous ferons plusieurs essais pour confirmer l'efficacité de ce modèle .Ensuite, les résultats seront validés en fonction du taux de précision et du taux d'erreur pour l'apprentissage.

CHAPITRE I

GENERALITES SUR COVID-19

I.1. Introduction :

Avec l'apparition d'une maladie inconnue à la fin d'année 2019 en Chine précisément en Wuhan, une ville chinoise. Certaines personnes ont été infectées par cette maladie dans un marché local.

Au départ, cette maladie était totalement inconnue mais les spécialistes ont diagnostiqué ses symptômes comme étant similaires à ceux d'une infection à Coronavirus et de la grippe [3] [4]. Mais aussi après des examens de laboratoires et les analyses des expectorations positives par réaction en Chaîne par polymérase (test PCR) en temps réel, l'infection virale a été Confirmée et éventuellement nommée «COVID-19» suite à la recommandation del'organisation mondiale de la santé(OMS).

Cette dernière a annoncé la propagation de ce virus et la classé comme une pandémie mondiale en Mars 2020.

COVID-19 est considéré comme un virus nocif et c'est pour cette raison que cette épidémie a causé un effet dévastateur non seulement sur la santé mais aussi sur l'économie et le bien-être de la population mondiale [3] [5].D'après les statistiques de World Meter (World Meter info), Jusqu'au 5 janvier 2021, plus de 86 millions de personnes dans le monde ont contracté le COVID-19 dont plus de 1870000 personnes sont officiellement décédées à cause de cette maladie.

Les défis scientifiques les plus importants dans le domaine d'apprentissage en profondeur du deep Learning, tentent de résoudre cette crise pour aider les médecins à détecter ce virus. La détection précoce du COVID-19 est essentielle, non seulement pour les soins aux patients, mais aussi pour la santé publique en assurant bien sûr leur isolement et en contrôlant la pandémie. En raison de sa nouveauté, Les moyens de la combattre paraissent inconnus au début mais les chercheurs ont considéré le dépistage, le diagnostic rapide des patients infectés et leur séparation de la communauté des personnes saines des mesures importantes.

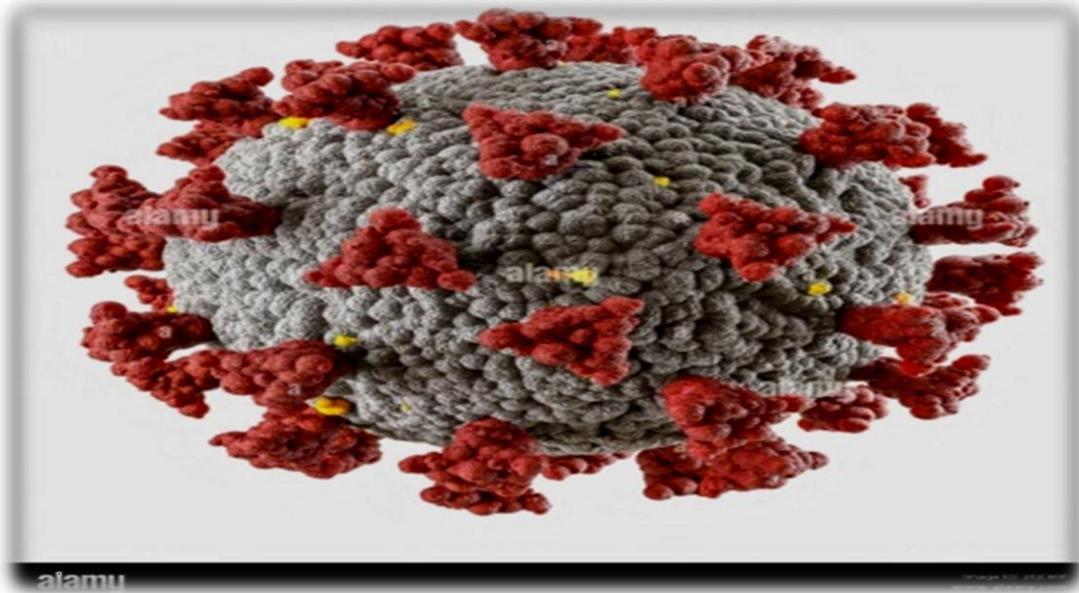


Figure I.1: une image montrant la forme du coronavirus .

I.2. Définition du COVID-19 :

Il s'agit d'un groupe de virus qui causent des maladies qui peuvent endommager le système respiratoire en particulier et le reste du corps en général.

COVID-19 fait référence à coronavirus de la famille des «*coronaviridae* » . COVID-19 est un sigle : il est composé à partir du «*Co* »de corona, «*vi* » de virus et «*d* » *disease* (maladie) en Anglais.

C'est une maladie infectieuse due au SARS .COV2 virus. Ce dernier est considéré comme un virus enveloppé à ARN simple -brin Linéaire de la famille des bêta coronavirus. Il possède une protéine de surface présentant une différence notable par rapport à d'autres coronavirus génétiquement proches .Cette différence serait importante pour l'évolution et l'émergence du virus [6].

La transmission du coronavirus s'effectue a proximité des personnes malades a travers la projection de petites particules liquides qui sont expulsées par la bouche ou par le nez quand une personne infectée tousse, éternue ou respire. Ces particules sont de différentes tailles allant de grosses gouttelettes respiratoires à des aérosols plus petits.

Structure du coronavirus

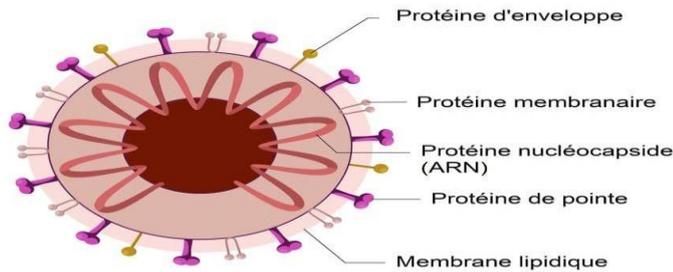


Figure I.2: structure du coronavirus.

I.3. Le système respiratoire :

Ces Coronavirus provoquent des infections respiratoires sévères, précisément « le système respiratoire » c'est la zone la plus sensible, Ce système ventilatoire est un système biologique composé d'un ensemble d'organes et de structures spécifiques. Son importance se situe dans les échanges gazeux chez l'être humain. Il comprend les voies respiratoires et les poumons gauche et droit : Ce sont les organes responsables de la respiration, ils transfèrent dans le sang l'oxygène présent dans l'air et évacuent le dioxyde de carbone présent dans le sang.

Le poumon droit, le poumon gauche et la trachée sont les principales parties du système respiratoire. L'échange entre l'air et le sang se déroule au niveau des alvéoles dans les poumons .Ces derniers se gonflent et se dégonflent suite à des contractions musculaires du diaphragme et de la cage thoracique [7].

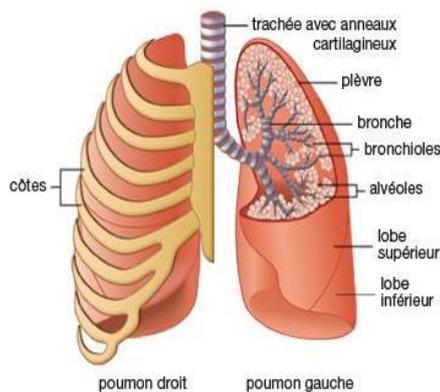


Figure I.3 : poumon humain.

I.4. Les virus :

Les virus sont des structures biologiques ayant le pouvoir de déclencher des maladies virales plus ou moins graves et toujours contagieuses. Ils sont environ 10 fois plus petits que les bactéries et 100 fois plus petits que les cellules. Ces derniers se multiplient dans une cellule hôte (des cellules vivantes, d'animaux, de plantes ou de bactéries car elle est incapable de se reproduire de façon autonome).

Ce qui concerne le virus SARS-COV-2 en particulier, appartient à l'espace SARS-COV, son diamètre est de 125 nanomètres, la morphologie de ses virions est typique de celle des coronavirus il forme une souche virale génétiquement différente des autres coronavirus humains ex : (SARS-COV-1, MERS-COV) son génome est constitué d'un ARN simple brin de 29903 nucléotides.

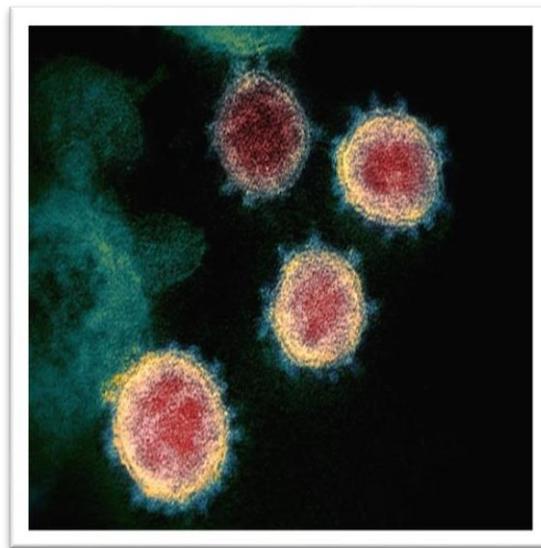


Figure I. 4 : SARS-COV-2 vu au microscope électronique.

I.4.1. Structure des virus :

Les virus sont composés :

- D'un acide nucléique (ADN ou ARN) sous forme de filaments.
- D'une structure de protection protéique compacte appelée : capside.

On appelle nucléocapside la structure compacte formée par l'assemblage de la capsid autour du génome. Les capsides ambulances comme Polyédriques sont faites de protéines virales polymérisées [8].

I.4.2. Classification des virus :

Les virus sont classés selon 3 critères essentiels :

- La nature du matériel génétique.
- Le type de symétrie de la capsid.
- Le caractère nu ou enveloppé de la capsid.

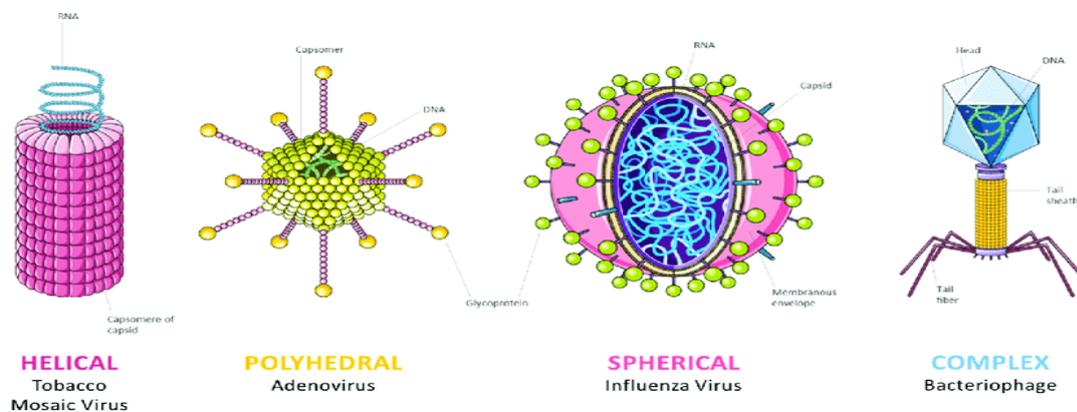


Figure I.5 : l'architecture des types des virus

I.5. Les types de coronavirus :

Depuis décembre 2019, le monde est aux prises avec un autre coronavirus c'est le coronavirus 2 du syndrome respiratoire aigu sévère (SRAS-COV-2) qui est responsable de la pandémie (COVID-19).

Parmi tous les coronavirus, sept formes différentes de coronavirus ont touché l'homme. Quatre d'entre elles sont courantes et présentent moins de risques : Généralement que des maladies bénignes des voies respiratoires chez les adultes humains en bonne santé. Il existe également quatre sous-groupes principaux de coronavirus appelés : alpha, bêta, gamma et delta.

1. 229E (alpha coronavirus)
2. NL63 (alpha coronavirus)
3. OC43 (bêta-coronavirus)
4. HKU1 (bêta-coronavirus)

Par contre, les trois autres peuvent provoquer des maladies à long terme potentiellement mortelles chez les personnes dont le système immunitaire est faible.

5. SRAS-COV (le bêta-coronavirus qui cause le Syndrome respiratoire aigu sévère, ou SRAS, identifié en Chine en 2002).

6. MERS-COV (le bêta-coronavirus qui provoque le syndrome respiratoire du Moyen-Orient, ou MERS découvert en Arabie Saoudite en 2012).

7. SARS-COV-2 ou COVID-19 est pour la première fois identifié en Chine (Wuhan) en décembre 2019. Ce coronavirus a beaucoup de similitudes avec celui du SRAS (origine animale, identique génétiquement à 80%, responsable d'infections pulmonaires). Il est contagieux dès le début des symptômes.

Dans ce contexte pandémique, les coronavirus humains ont pu être transmis à l'homme par d'autres animaux. Ces derniers infectent les poumons (au niveau des alvéoles pulmonaires).

La maladie aiguë du COVID-19 est nocive car elle empêche le passage normal de l'oxygène des poumons vers la circulation sanguine.

I.6. Les symptômes :

Le COVID-19 se caractérise par son étrangeté et sa rapidité de propagation, il affecte les personnes de différentes manières de plus ses symptômes différents d'un patient à l'autre.

Dans la plupart des cas les symptômes se manifestent par :

- La fièvre
- La toux
- Les maux de tête
- La perte du goût et de l'odorat
- Les douleurs abdominales et musculaires
- Les courbatures
- Les difficultés à respirer
- L'écoulement nasal

Cependant, ces symptômes n'indiquent pas toujours la présence du COVID -19.

I.7. Méthodes de Diagnostic:

De nombreuses recherches ont fourni beaucoup d'efforts pour détecter le COVID-19 en utilisant plusieurs méthodes de diagnostic.

Parmi les tests diagnostiques permettant la confirmation du COVID, La réaction de transcription inverse suivie d'une réaction de polymérisation en chaîne quantitative en temps réel (RTQ PCR), et le test de diagnostic rapide basé sur la détection de l'antigène spécifique du SARS-COV-2 sont les deux méthodes utilisées dans la phase précoce des manifestations infectieuses. Par contre (Elisa et test de flux latéral) sont des tests de détection des anticorps sériques sauf qu'ils sont utilisés dans la phase ultérieure et après que le patient soit guéri.

Bien que le test RT_PCR soit L'étalon-or pour le diagnostic du COVID-19, il présente des aspects limitatifs avec certaines caractéristiques qui rendent le diagnostic difficile : la RTPCR est un processus qui prend beaucoup de temps, complexe, coûteux et manuel.

L'un des inconvénients de cette méthode est la nécessité d'un kit de laboratoire, dont la mise à disposition est difficile ou même impossible pour de nombreux pays en période de crise et d'épidémie.

Comme toutes les méthodes de diagnostic et de laboratoire dans les systèmes de santé, cette méthode est biaisée et elle n'est pas exempte d'erreurs. Elle nécessite aussi l'intervention d'un technicien de laboratoire expert pour faire les prélèvements des échantillons de la muqueuse nasale et de la gorge cette méthode paraît douloureuse vu la sensibilité de cette zone.

De plus, de nombreuses études ont indiqué une diminution de la précision du diagnostic du COVID-19 par le test RT. PCR.

En vérité, le but de ces études est de minimiser les faux positifs et négatifs pour améliorer les résultats de précision et de qualité.

L'un des moyens les plus importants pour diagnostiquer le COVID-19 se base sur la lecture d'images radiologiques, y compris les rayons X et la tomodensitométrie (CT scan). Tomographie (CT).

L'image thoracique est la procédure la plus rapide et la plus facile d'autant plus, la plus recommandée par les protocoles médicaux et sanitaires.



Figure I.6 : Diagnostic du COVID-19 par le test RT-PCR

I.8. Coronavirus en Algérie :

Nous, voici confrontés depuis plus de 2 ans à une pandémie liée à un virus jusqu'ici inconnu pour l'espèce humaine : Le SARS-COV-2. L'organisation mondiale de la santé (OMS) a reconnu cette réalité en deux temps : le 30 janvier 2020 puis le 11 mars de la même année.

Après avoir frappé la Chine, l'épidémie s'est propagée dans le reste du monde. De l'autre côté de la Méditerranée, l'Algérie fait face à cette crise sanitaire et progressivement, la pandémie du corona virus s'évolue pour toucher tout le territoire Algérien ensuite plusieurs cas de COVID sont détectés .Il y' a eu 265 876 cas de contamination ,6881 de décès et 178 367 de rétablis depuis le début de l'épidémie.

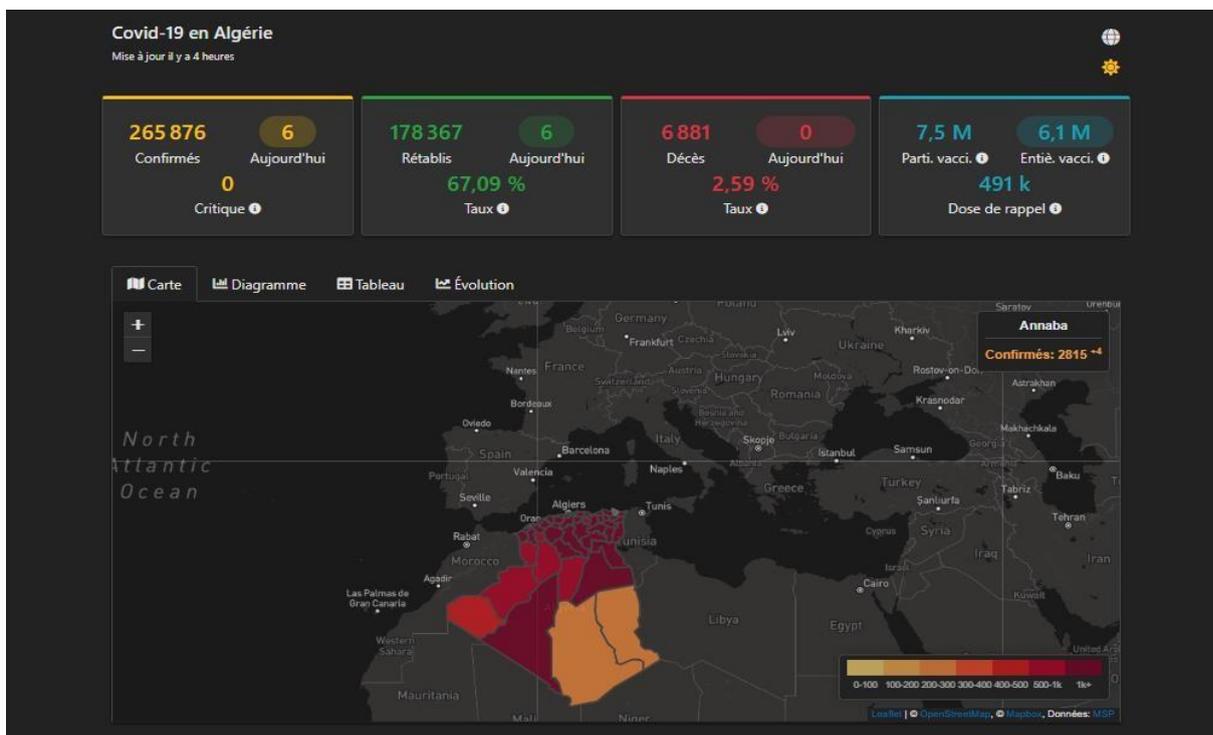


Figure I.7 :carte de coronavirus en Algérie (27 Mai 2022).

I.9. L'imagerie médicale et la détection du COVID-19 :

L'imagerie médicale fait référence à plusieurs technologies différentes qui sont utilisées pour visualiser le corps humain afin de diagnostiquer ou de traiter des conditions médicales. Chaque type de technologie donne des informations différentes sur la zone du corps étudié, liée à une éventuelle maladie ou à l'efficacité d'un traitement médical.

La radiographie est née à la fin du siècle *XIX*^e avec l'utilisation des rayons X. Puis de nouvelles techniques d'imagerie médicale sont apparues telles que le scanner et l'IRM qui vont être plus détaillées dans le chapitre (IV).

Cependant, de diverses études ont été menées sur l'utilisation de l'apprentissage profond (DL) dans l'analyse des images radiologiques.

Les approches d'apprentissage basées sur l'apprentissage en profondeur ont été préférées dans la détection du COVID-19 en raison du nombre limité de données disponibles.

I.10. Conclusion :

À la fin de ce chapitre, nous avons une idée de la plus part des éléments abordés dans ce projet non seulement du point de vue technique mais tant de plus du point de vue biologique. Nous avons parlé sur le système respiratoire ainsi que la structure et la classification du virus corona. Ce syndrome respiratoire aigu sévère est difficile à combattre en raison de son aspect mystérieux et sa biologie inconnue, Il va falloir prendre des mesures de précautions et des leçons tirées d'autres flambées de santé publique.

Dans ce contexte, le diagnostic qu'on va utiliser pour détecter le COVID-19 est basé sur le Deep Learning .Le concept de cet apprentissage sera entamé dans le deuxième chapitre y compris d'autres notions concernant cette technique.

Chapitre II :
Réseau de neurones et
L'apprentissage profond
(Deep Learning)

II.1. Introduction:

Les techniques de Deep Learning ont fait une révolution depuis quelques années et ont complètement bouleversé le scénario de nombreux domaines de recherche. En particulier, dans le domaine médical, les ensembles de données d'image tels que l'image de la rétine, la radiographie pulmonaire et l'IRM cérébrale fournissent des résultats prometteurs avec une précision étendue en utilisant les techniques d'apprentissage en profondeur. Comme nous le savons, les appareils à rayons X fournissent des résultats peu coûteux et plus rapides pour la numérisation de divers organes humains dans les hôpitaux. L'interprétation des différentes images radiographiques est généralement effectuée manuellement par des radiologues experts. En tant que scientifique, si nous entraînons ces images capturées avec l'importance de l'apprentissage en profondeur, cela sera d'une grande aide pour les experts médicaux pour détecter les patients COVID-19. Cela aidera les pays en développement où l'installation de radiographie est disponible, mais la disponibilité d'un expert est encore un rêve. À cet avantage, nous visons également à développer un réseau de neurones profonds nommé « CovidNet_BN_FA » qui peut analyser les images radiographiques des poumons et détecter si la personne est testée positive pour le virus ou non.

Ces dernières années, l'intelligence artificielle (IA) a progressé rapidement. Pour comprendre les avancées les plus récentes dans ce domaine, nous devons d'abord étudier deux concepts très populaires : l'apprentissage automatique (ML) et l'apprentissage profond (DL) [9].

II.2. Intelligence artificielle :

L'intelligence artificielle est un processus qui évolue et permet à des machines de simuler une forme d'intelligence réelle grâce à l'assemblage de théories et de techniques permettant de vérifier cette pratique pluridisciplinaire est principalement utilisée dans des domaines tels que les logiciels industriels, la gestion scientifique, etc. L'intelligence artificielle est aujourd'hui revendiquée par une grande partie du secteur socio-économique.

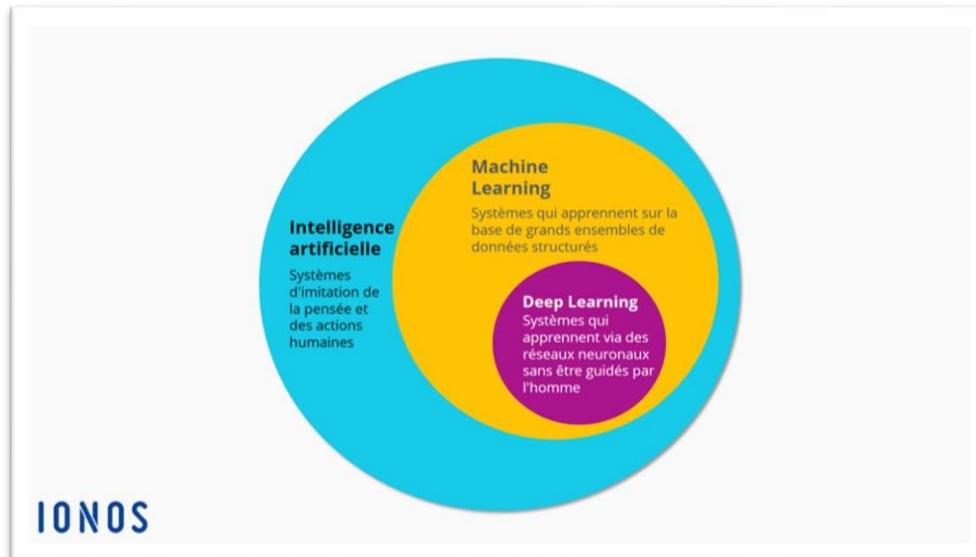


Figure II.1 : Schéma d'organisation d'intelligence artificielle

II.3. Machine Learning (l'apprentissage automatique) :

le machine Learning est un modèle d'intelligence artificielle qui apprend seul grâce à l'analyse d'un jeu de données. Pour cela, il utilise des procédés automatiques issus des statistiques et des probabilités. Son objectif est d'aider les humains à exploiter des volumes de données inenvisageables et leur faire gagner du temps dans des activités à faible valeur ajoutée.

Par exemple : examiner des images médicales, segmenter une base de clients en marketing ou évaluer la probabilité qu'une machine tombe en panne.

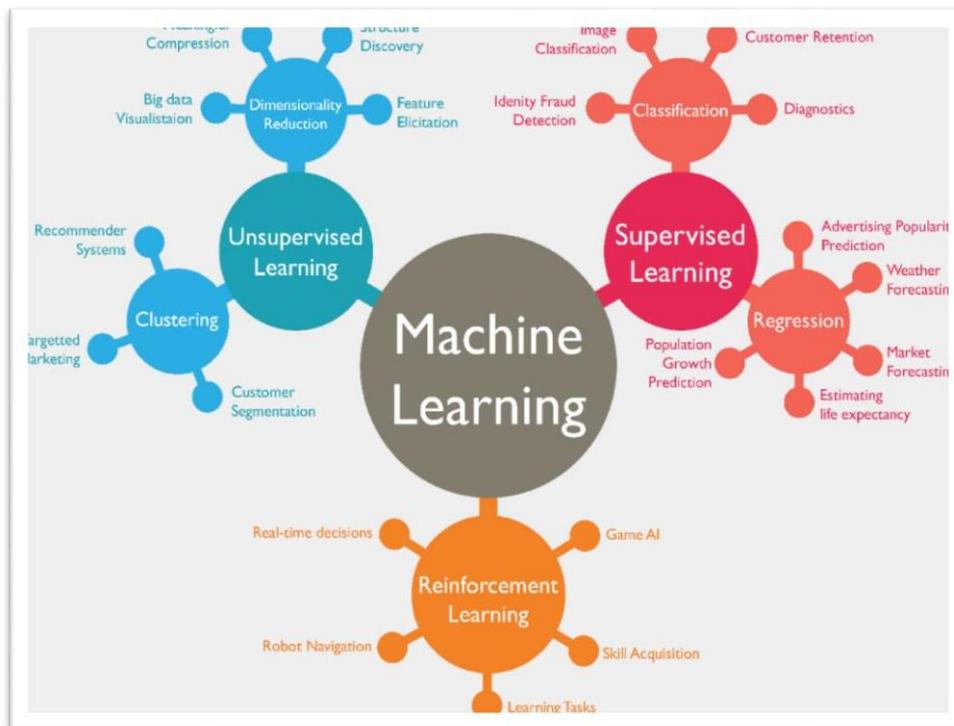


Figure II.2 : Schéma d'organisation d'apprentissage automatique

Parmi les techniques qui permettent aux experts de concevoir des machines apprenantes, on distingue trois types d'apprentissage :

II.3.1 L'apprentissage supervisé

L'apprentissage supervisé (figure II.3), est un processus consistant à fournir des données d'entrée ainsi que des données de sortie correctes au modèle d'apprentissage automatique, en d'autres termes est une tâche d'apprentissage automatique consistant à apprendre une fonction de prédiction à partir d'exemples annotés.

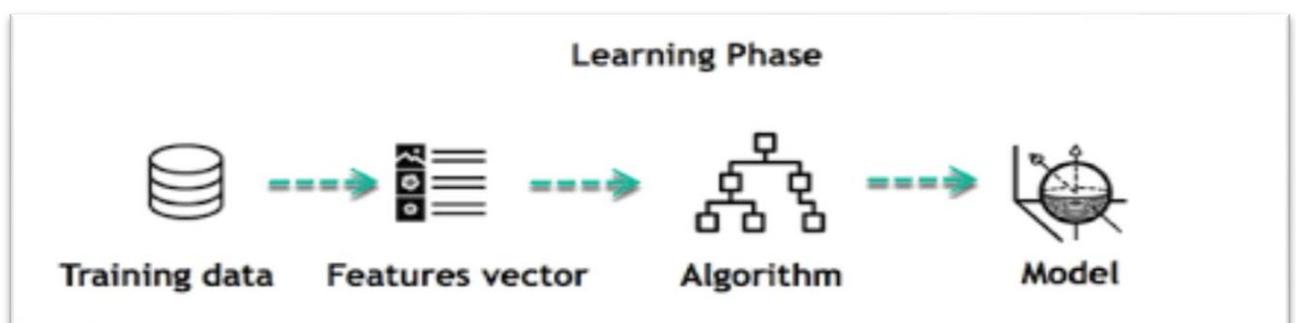


Figure II.3 : Schéma d'apprentissage supervisé "supervised Learning"

II.3.2 L'apprentissage non supervisé :

L'apprentissage non supervisé (figure II.4), consiste à apprendre à un algorithme d'intelligence artificielle (IA), des informations qui ne sont ni classées, ni étiquetées et à permettre à cet algorithme de réagir à ces informations sans supervision, les algorithmes regroupent les données en fonction de leur similitude, sans aucune intervention humaine.

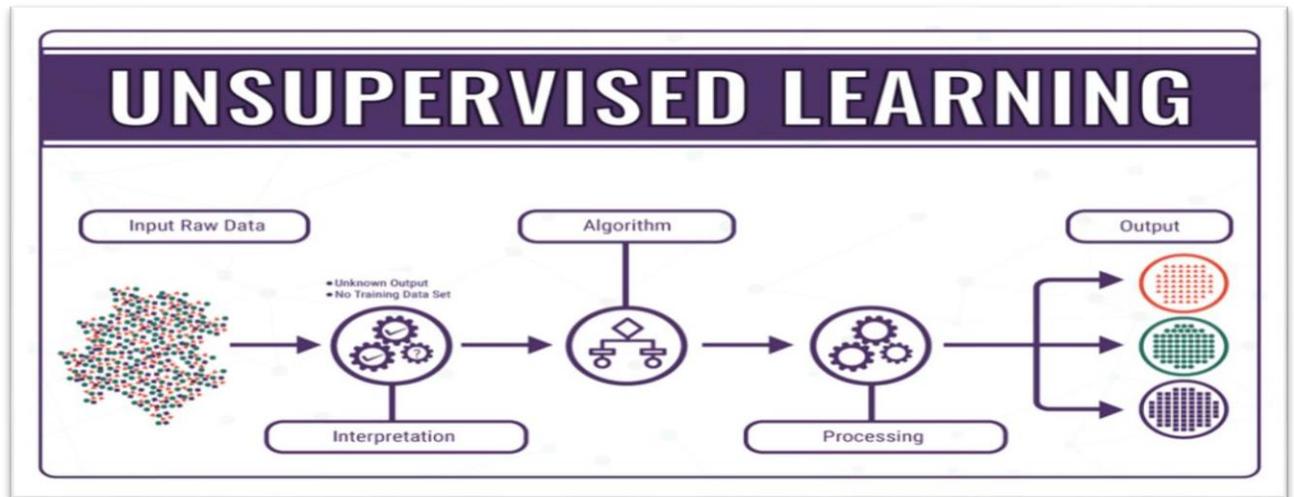


Figure II.4 : Schéma d'apprentissage non supervisé "Unsupervised Learning"

La section suivante présente une étude comparative entre les deux méthodes d'apprentissage citées précédemment qu'on peut trouver dans le tableau ci-dessous

	Supervised Learning	Unsupervised Learning
Les données d'entrées	Utilise Des données connues et Etiquetées en tant qu'entrée	Utilise des données inconnues est Non étiquetées en tant qu'entrée
Nombre des Classes	Connues	Inconnues
Précision du résultat	Résultats précis et fiables	Précision et fiabilité Modérés

Tableau II .1 : Différence entre l'apprentissage supervisé et non supervisé

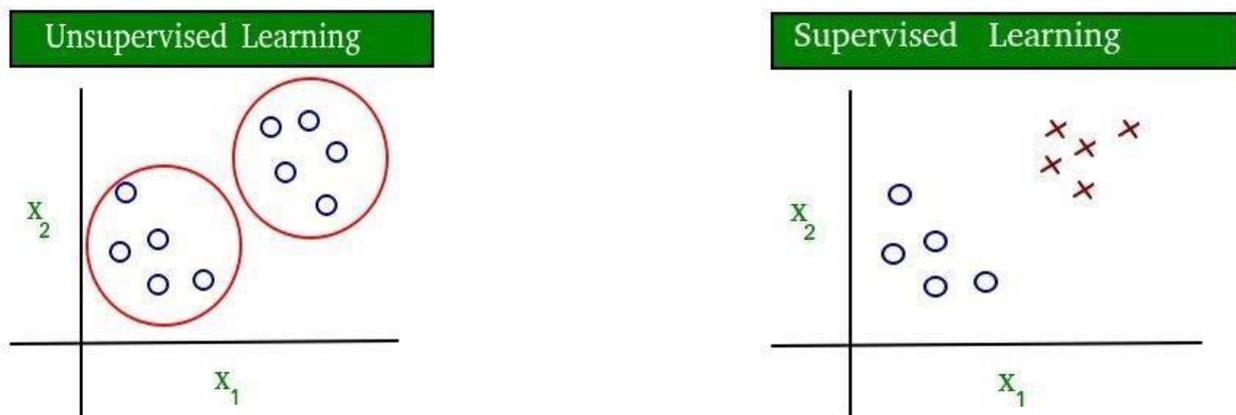


Figure II.5 : apprentissage Supervisé & non Supervisé

II.3.3 L'apprentissage par renforcement :

Généralement utilisé pour apprendre à une machine à exécuter une séquence d'étapes, l'apprentissage par renforcement est différent de l'apprentissage supervisé et non supervisé. Les scientifiques programment un algorithme pour effectuer une tâche, en lui donnant des indices positifs ou négatifs au fur et à mesure qu'il travaille sur la façon d'effectuer la tâche. Le programmeur fixe les règles pour les récompenses, mais laisse à l'algorithme le soin de décider lui-même des étapes à suivre pour maximiser la récompense, et donc accomplir la tâche.

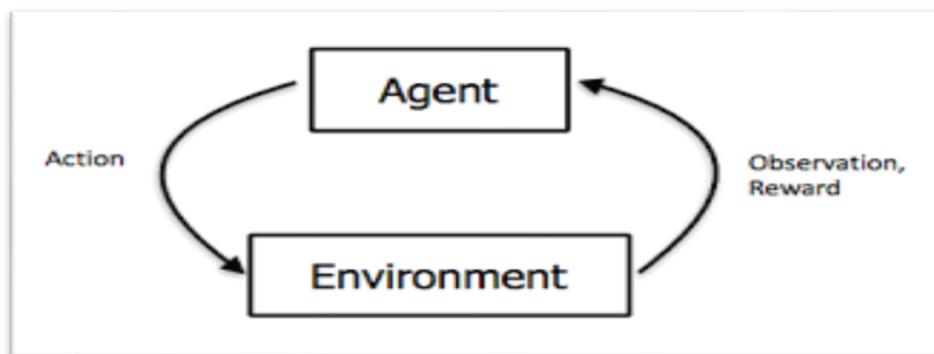


Figure II.6 : Schéma d'apprentissage par renforcement "Reinforcement Learning"

II.4 L'apprentissage profond (Deep Learning) :

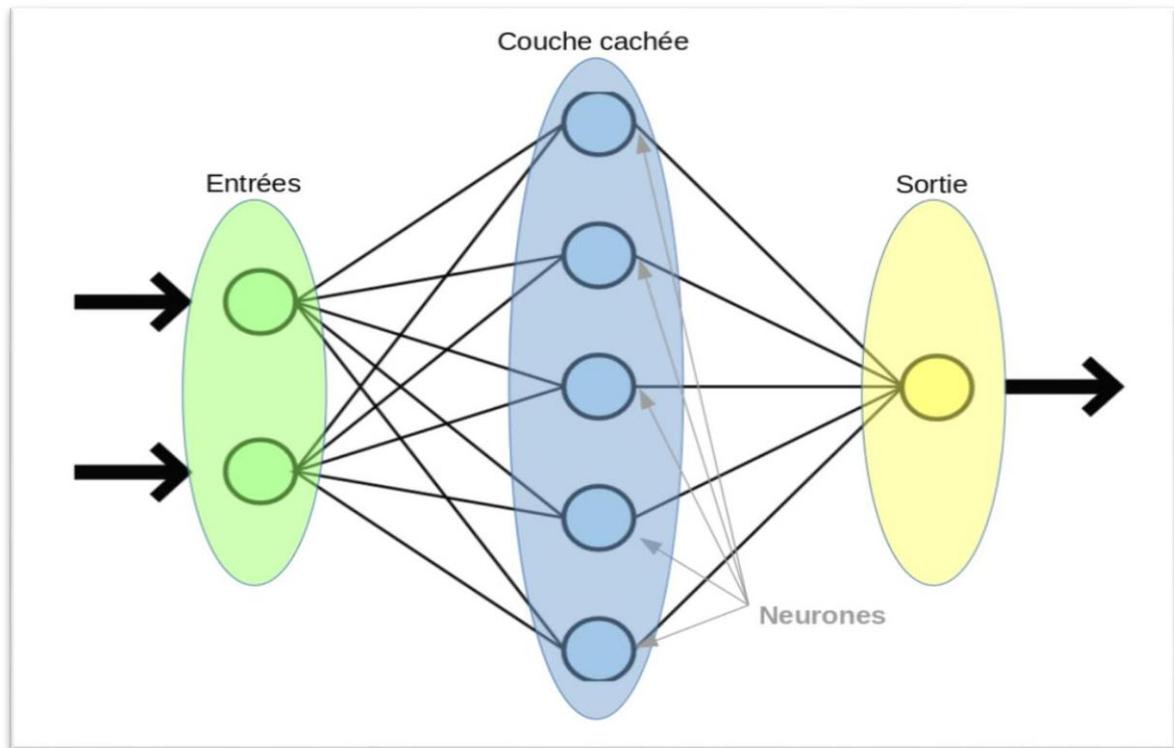
Le Deep Learning est un domaine du machine Learning dans lequel au lieu de développer un des modèles que l'on vient de citer, on développe à la place ce qu'on appelle des réseaux de neurones artificiels.

Et en d'autre terme, l'apprentissage profond comprend un sous-ensemble de l'intelligence artificielle dérivée de l'apprentissage automatique dans lequel la machine peut apprendre pareille-même, par opposition à la programmation, qui se contente de suivre à la lettre des règles prédéterminées.

II.4.1 Fonctionnement de l'apprentissage profond:

Le Deep Learning est basé sur un réseau de neurones artificiels d'inspiration humaine. Ce réseau est constitué de dizaines, voire de centaines de "couches" de neurones, chacune d'entre elles recevant et interprétant les données de la couche précédente. Le réseau neuronal étant composé de trois réseaux neuronaux, chacun comportant trois couches significatives comme le montre la figure II.6.

- La couche d'entrée.
- La couche cachée.
- La couche résultante.



FigureII.7 : Schéma des réseaux de neurones artificiels

II.4.2 Domaines d'application de l'apprentissage profond :

Le deep Learning est un domaine à croissance rapide est d'une grande utilité dans l'univers des technologies de l'information et de la communication, [10]. Il est très utilisé dans de nombreux domaines :

- reconnaissance d'image
- traduction automatique
- diagnostic médical
- recommandations personnalisées
- modération automatique des réseaux sociaux
- identification de pièces défectueuses

- détection de malwares ou de fraudes
- exploration spatiale
- robots intelligents.

II.5 Quelques algorithmes de l'apprentissage profond:

Pour former des machines à effectuer des calculs complexes sur de grandes quantités de données, un algorithme de deep Learning est nécessaire. Il s'agit d'un type d'apprentissage automatique qui s'inspire du fonctionnement du cerveau humain. Et il existe plusieurs algorithmes de deep learning permis ces réseaux on peut citer :

II.5.1 Neurones biologiques :

Le neurone biologique reçoit en entrée des signaux transmis par d'autres neurones via d'une interaction entre les dendrites et les synapses. Figure (II.8).

Le signal reçu est analysé et traité en additionnant les signaux d'entrée, et le résultat est comparé à un seuil d'activation : s'il est supérieur, une décharge est envoyée le long de son axone vers d'autres neurones.

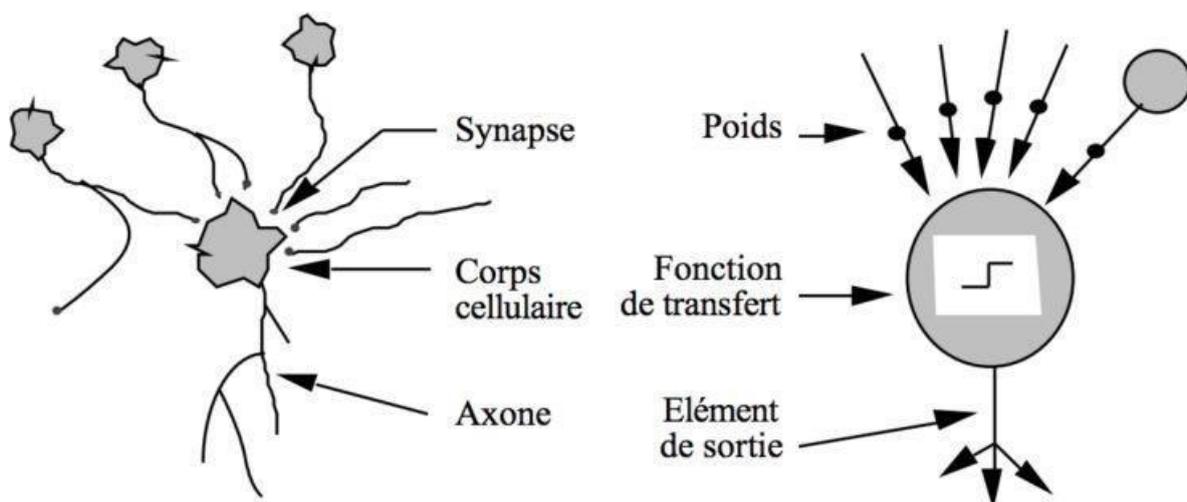


Figure II. 8:Neurone biologique/ Neurone artificiel

L'apprentissage profond est la version artificielle des neurones biologiques, appelés aussi réseaux neuronaux artificiels (ANN).

II.5.2 Réseaux de neurones artificiels (ANN) :

Les neurones peuvent avoir des états, qui sont généralement représentés par des nombres réels allant de 0 à 1. Les neurones et les synapses peuvent également avoir des poids variables au fur et à mesure de leur apprentissage, ce qui peut modifier la force du signal qu'ils envoient en aval [11].

II.5.3 Réseaux de neurones récurrents :

Un réseau neuronal récurrent (RNN) est un type de réseau neuronal artificiel dans lequel les connexions entre les nœuds forment un graphe vectoriel le long d'une séquence temporelle, ce qui leur permet de présenter un comportement dynamique. Les RNN peuvent gérer la séquence d'entrée en utilisant leur état interne (mémoire) [12]. Par conséquent, ils peuvent être utilisés pour des tâches telles que la reconnaissance de l'écriture manuscrite non segmentée et connectée ou la reconnaissance vocale [13].

II.5.4 Réseaux de neurones profonds :

Les réseaux neuronaux profonds (DNN) sont des réseaux à flux direct dans lesquels les données vont de la couche d'entrée à la couche de sortie sans faire l'aller-retour, et les liens entre les couches sont à sens unique et ne touchent jamais un nœud à nouveau.

Il contient une classe de réseaux de neurones profonds, les réseaux de neurones convolutifs (Convolutional Neural Network : CNN ou ConvNet) les plus couramment utilisés dans l'analyse d'images visuelles. Ses autres applications incluent la compréhension vidéo, Reconnaissance vocale et compréhension du traitement du langage naturel. L'environnement est généralement représenté sous la forme d'un processus de décision de Markov en apprentissage automatique (MDP). Les techniques de programmation dynamique sont utilisées par de nombreux algorithmes d'apprentissage par renforcement [14].

II.5.5 Réseaux de neurones Convolutifs :

Les réseaux neuronaux convolutifs (CNN ou ConvNet) sont un type de réseau neuronal profond qui est le plus souvent utilisé pour analyser les images visuelles. D'autres applications comprennent la compréhension de vidéos, la reconnaissance audio et la compréhension du traitement du langage naturel [15].

II.6 Architecture d'un réseau CNN profond :

Les CNN sont désormais considérés comme les algorithmes les plus utilisés parmi les approches d'intelligence artificielle (IA) d'inspiration biologique. Les origines des CNN remontent aux recherches neurobiologiques de Hubel et Wiesel [16]. Leurs travaux ont servi de base à de nombreux modèles cognitifs, que le CNN a largement supplantés. Divers efforts ont été entrepris au fil des ans pour améliorer les performances des CNN et la figure ci-dessous représente l'architecture d'un réseau CNN.

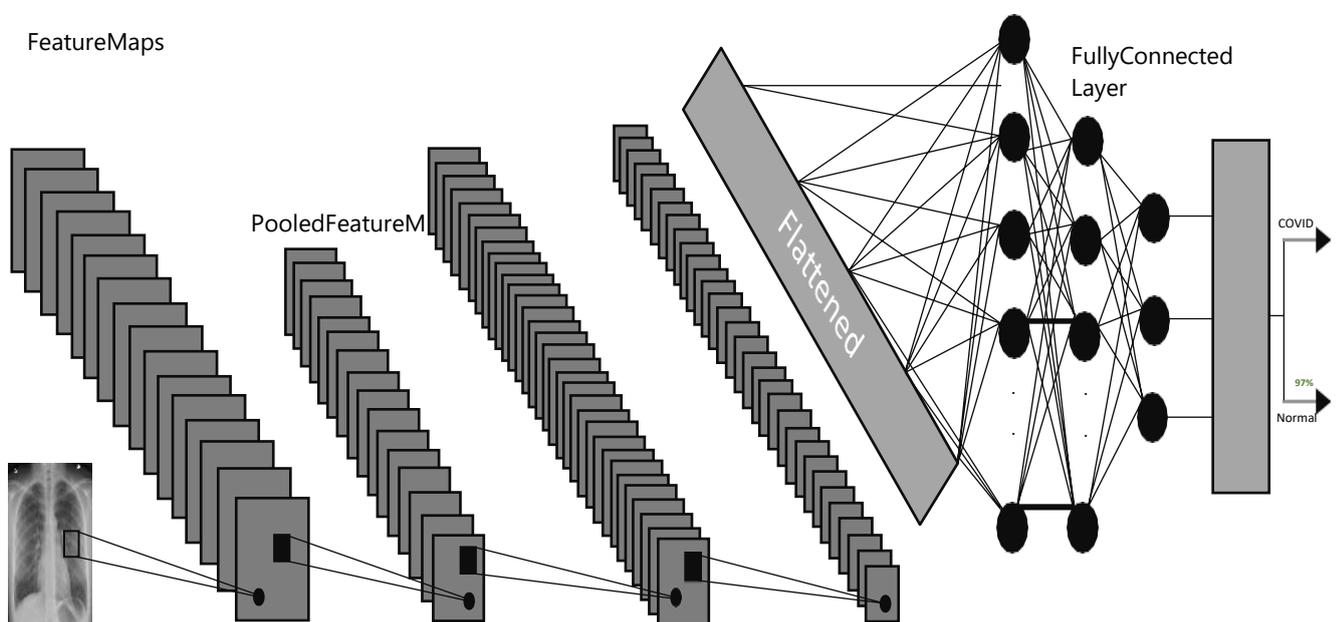


Figure II.9 : Architecture du réseau de neurones à convolution profonde proposé.

Nous présenterons quelques modèles inspirés des réseaux CNN profonds :

- LeNet_5 (1998) Apprentissage par gradient appliqué à la reconnaissance de documents.
- Alex Net (2012) Classification d'images nettes avec des réseaux de neurones convolutifs profonds.
- VGG-16(2014) Réseaux convolutifs très profonds pour la reconnaissance d'images à grande échelle.
- ResNet-50(2015) Apprentissage résiduel profond pour la reconnaissance d'images.

II.7 Conclusion :

Dans ce chapitre, on a fait un tour d'horizon sur les concepts de base d'apprentissage profond. On a mis l'accent sur les différents principes des réseaux de neurones en insistant sur les réseaux de neurones convolutifs.

Le chapitre suivant sera dédié à la présentation des différents modèles prédéfinis qui existe dans ce domaine ainsi que la structure générale de chacun de ces modèles.

***Chapitre III : Modèle proposé pour
la détection du COVID 19***

III.1. Introduction :

Depuis le début de 2020, la pneumonie due au COVID-19 s'est largement répandue dans le monde avec un diagnostic préférentiellement obtenu par scanner thoracique mais sauf que le dépistage par cette voie n'a pas été retenu par manque de spécificité de cet examen pour telle pathologie spécifique. Le 19 Mars de la même année , une étude chinoise a été effectuée sur le développement d'un cadre automatique d'intelligence artificielle (IA) afin de détecter le COVID-19 à l'aide d'une tomodensitométrie thoracique et évaluer ses performances .Un modèle de Deep Learning appelé COV-NET a été développé pour extraire les caractéristiques visuelles des scanners thoraciques pour la détection du COVID-19.

L'urgence sanitaire mondiale en raison du syndrome respiratoire aigu sévère est représentée par la progression rapide de cette pandémie .L'aspect compliqué de la propagation du COVID-19 peut être dû à des individus asymptomatiques .Ces derniers ne peuvent pas être détectés aux premiers stades de l'infection malgré la recherche épidémiologique afin de prévenir la propagation dans la communauté .Ce contexte partage une opinion à travers la proposition d'un modèle de recherche pour la détection du COVID-19 chez les porteurs asymptomatiques [17].

L'objectif principal de notre nouvelle approche est de proposer un nouveau modèle CNN modifié basé sur l'apprentissage profond pour obtenir la plus grande précision , une efficacité et un temps de compilation minimal sur un grand volume de données tout en utilisant des techniques d'amélioration et d'identification du modèle le mieux adapté à cette approche. Notre mission est également de mettre à la disposition du corps médical un outil de travail conçu pour détecter automatiquement le COVID-19.

III.2. Les modèles existants de CNN :

Dans ce projet nous allons tester une variété de modèles existants tels que VGG16, Alex Net et ResNet50. Un grand succès a été obtenu en utilisant le réseau de neurones convolutifs Neural Network (CNN) aussi parfois appelé CovNet. C'est la classe de réseaux de neurones profonds, la plus appropriée pour la vision par ordinateur. Il utilise une approche hiérarchique et à partir de modèles plus petits et simples, il assemble des modèles plus élevés et complexes. On va entamer quelques modèles qui appartiennent à ce réseau (CNN) qui est considéré comme l'un des réseaux Deep Learning les plus populaires.

III.2.1. VGG-16 :

VGG est un réseau de neurones convolutionnels. Le Groupe de Géométrie Visuelle est abrégé en VGG / Le 16 dans VGG -16 fait référence à 16 couches qui ont des poids dont la couche de convulsion à softmax : C'est pourquoi il est nommé VGG-16. La dernière couche de ce modèle est remplacée par 2 couches FC avec activation softmax au lieu de 10 couches FC avec softmax .Le VGG-16 est construit en utilisant plusieurs filtres de la taille d'un noyau (3×3) et (11 et 5 dans la première et la deuxième couche convolutive, respectivement).

Ce réseau est assez vaste et compte environ 138 millions de paramètres mais son architecture se caractérise par sa clarté et sa simplicité. Le VGG a acquis une notoriété en gagnant la compétition ILSVRC (Image Net Large-scale Visual Recognition Challenge) en 2014 avec une précision de 92,7%. Ce meilleur score a marqué une progression par rapport aux autres modèles précédents.

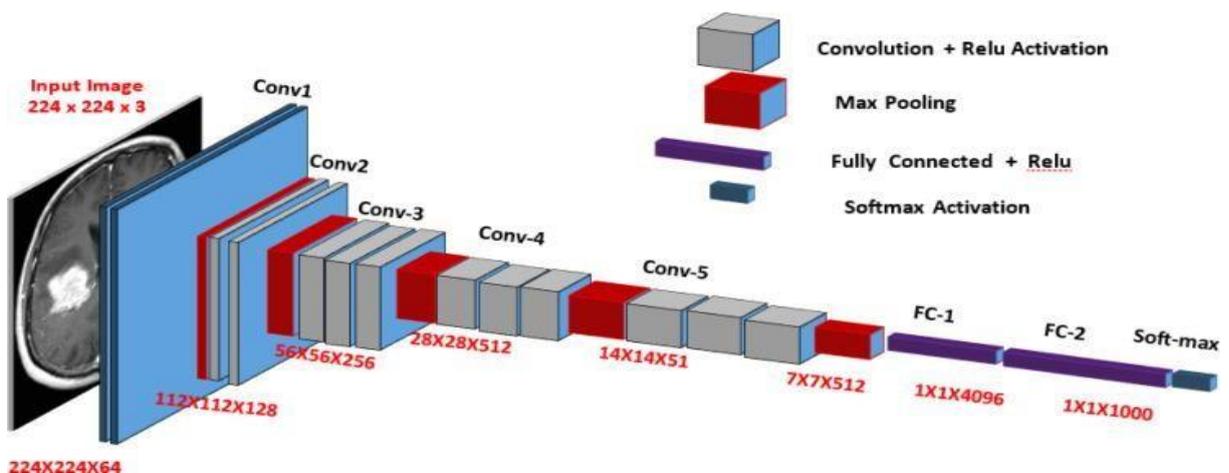


Figure III.1 : Architecture du modèle VGG-16 CNN par couches [18].

III.2.2. AlexNet :

Alex Net est le nom d'une architecture de réseaux de neurones convolutifs .La méthode Alex net a été publiée en 1998, Cela a été entendu par le monde entier lors du concours de classification (ILSVRC) : Alex Net a participé et a remporté le premier prix le 30 septembre 2012. Ce modèle est développé par Alex Krizhevsky en collaboration avec Ilya Sutskever et Geoffrey Hinton. Alex Net se compose de 5 couches convolutionnelles, 3

couches de mise en commun et 2 couches entièrement connectées (FC) pour réduire le problème d'overfitting, Ces couches entièrement connectées sont utilisées avec couche d'exclusion.

Dans cette architecture, la première couche conv1 effectue une opération avec le max-pooling (MXP) et la normalisation de la réponse locale (LRN) qui utilise 96 filtres de taille 11×11 pour filtrer une image d'entrée avec un pas de 4 pixels. La fonction d'activation ReLU (Rectified linear unit) est appliquée à toutes les couches de sortie de la convolution, y compris les couches entièrement connectées car, au cours du processus de convolution, elle effectue des opérations non linéaires et change toutes les valeurs d'activation négatives en 0. La sortie de la première couche conv1 est filtrée par une couche conv2 avec 256 noyaux d'une taille de 5×5 . Les couches conv3 et conv4 ont 384 noyaux de taille 3×3 alors que la cinquième couche convolutionnelle a 256 noyaux de taille 3×3 . L'architecture d'Alex Net est illustrée dans la figure III.2.

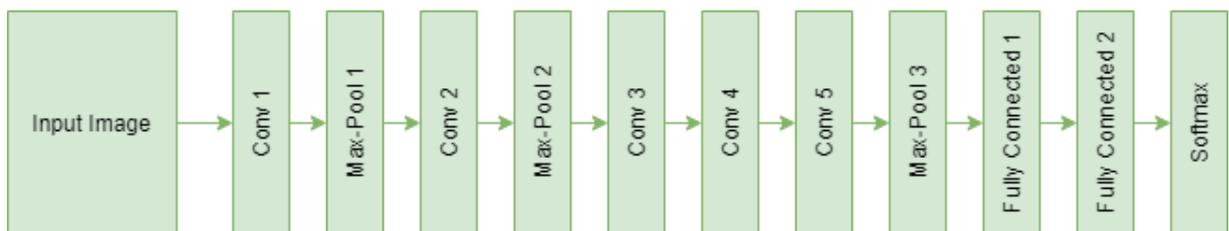


Figure III.2 : l'architecture d'Alex Net avec toutes les couches définies.

Le taux de précision de la reconnaissance informatisée des objets s'est amélioré de 10,8 pour atteindre 83,6%. En raison de l'existence de couches complètement reliées l'entrée $224 \times 224 \times 3$ est fixée. Si l'image d'entrée est en niveau de gris, elle est convertie en RGB en dupliquant le canal unique pour créer une image RVB à 3 canaux. Le nombre total de paramètres d'Alex Net est de 60 millions, avec une taille de lot de 128. Ce modèle est considéré comme l'un des articles les plus influents publiés dans le domaine de la vision par ordinateur. En 2021, l'article Alex Net a été cité plus de 80 mille fois.

III.2.3. ResNet50 :

ResNet50 est une variante du modèle ResNet. Ce réseau de neurones possède 48 couches de Convolution ainsi qu'une couche Max Pool et une couche average Pool. Il compte $3,8 \times 10^9$ opérations en virgule flottante. L'empilage de plus de couches nous donne généralement une meilleure précision. Ce modèle a été pré-entraîné sur plus d'1 million d'images de la base de données Image Net .Il peut classer les images dans 1000 catégories d'objets, comme le clavier, la souris, le crayon et de nombreux animaux : Par conséquent, le réseau a appris des représentations de caractéristiques riches pour un large éventail d'images ce réseau a une taille d'entrée d'image de $224 \times 224 \times 224$. La figure **III.3** illustre son architecture.

Grâce au cadre présenté par ResNet , il a été possible de former des réseaux neuronaux ultra profonds c'est à dire des réseaux qui peuvent contenir des centaines ou des milliers de couches Pour identifier les caractéristiques de bas, moyen et haut niveau des images tout en obtenant d'excellentes performances. Les ResNets ont été initialement appliqués à la tâche de reconnaissance d'image, mais comme il est mentionné dans le document, le cadre peut également être utilisé pour des tâches de vision non informatique afin d'obtenir une précision bien définie. ResNet a été la chose la plus intéressante qui soit arrivée au monde de la vision par ordinateur et de l'apprentissage profond.

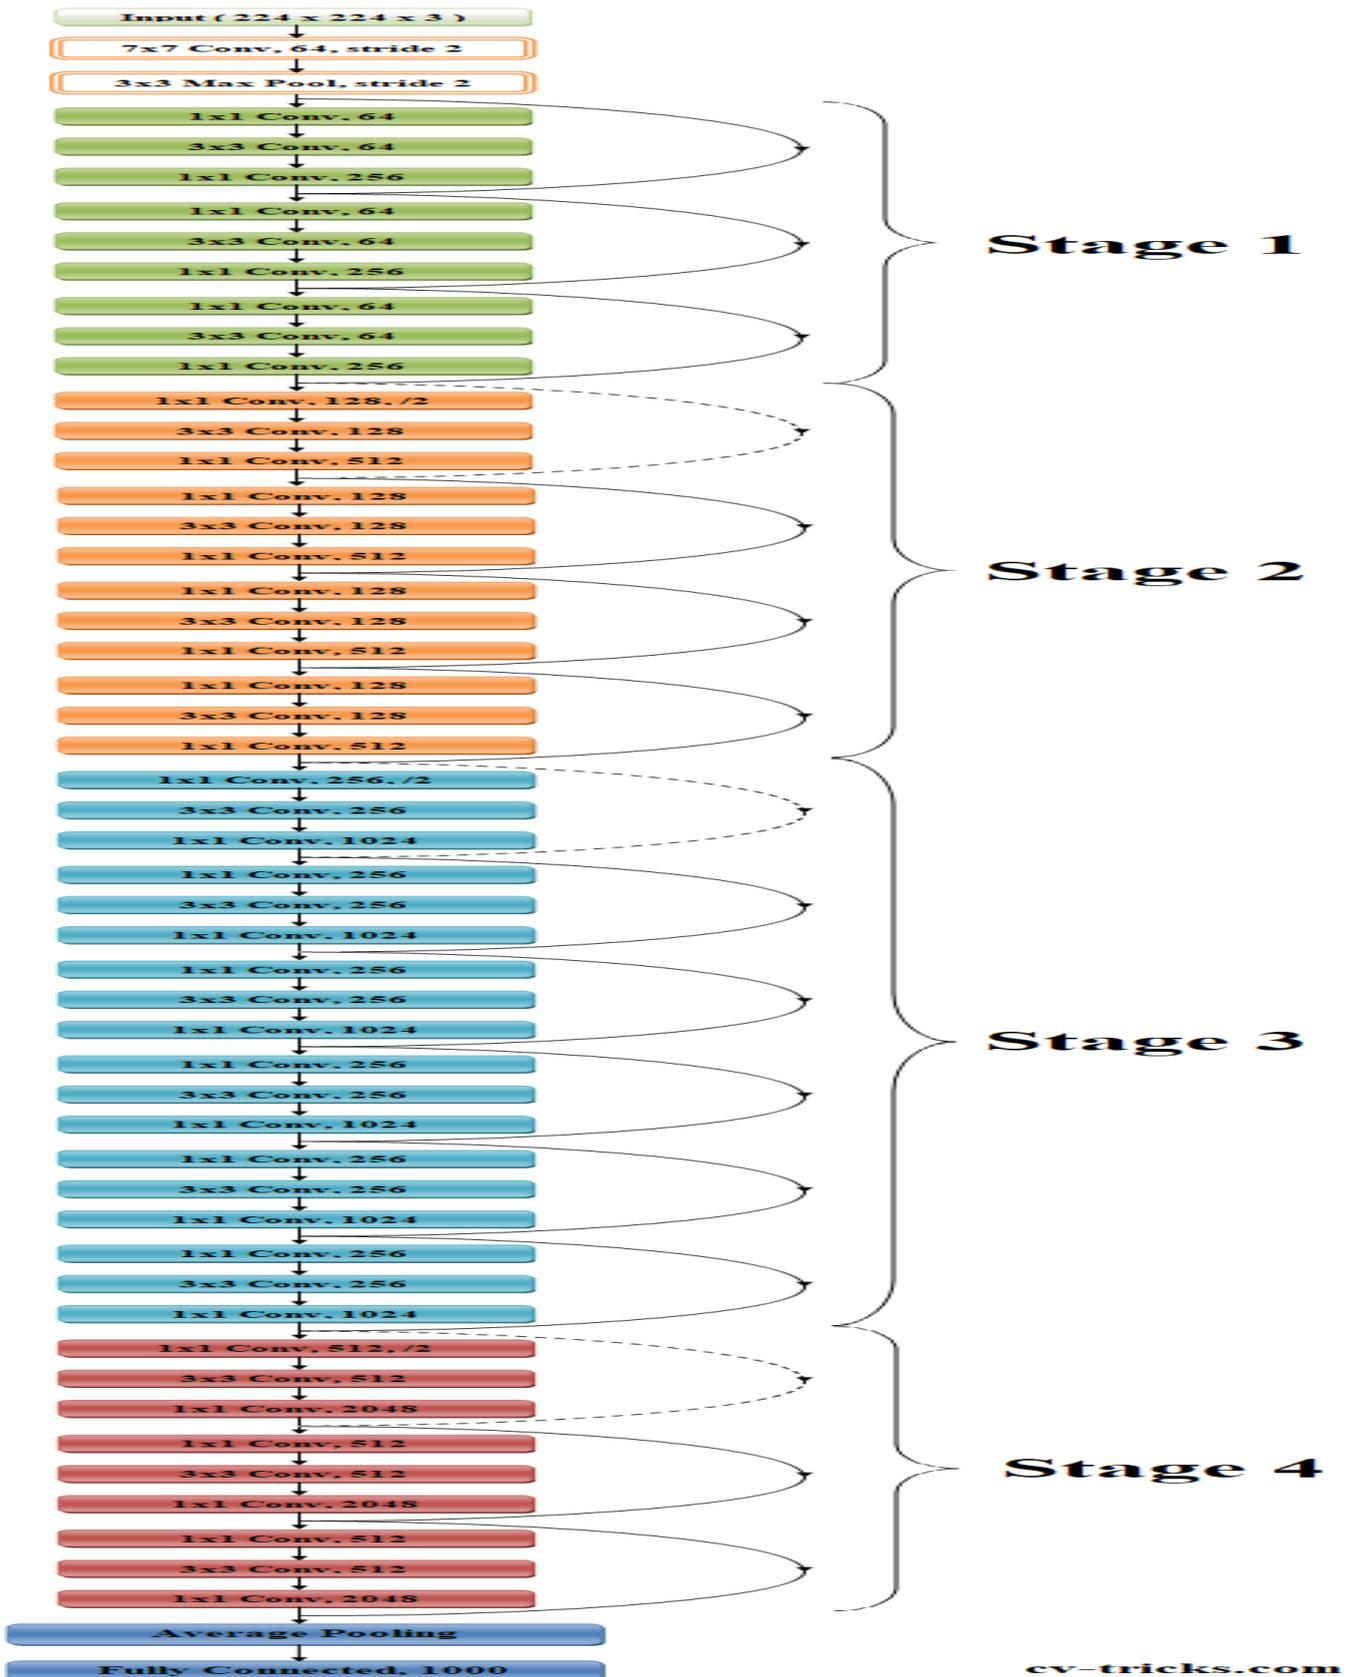


Figure III.3: Architecture du ResNet50.

III.3. Modèle proposé :

Cette recherche a été entreprise pour choisir un nouveau modèle proposé désigné : **CovNet_BN_FA**. Ce modèle sera approprié pour l'étude de la détection du COVID-19. On procède ainsi dans le sillage des modèles existants de CNN d'où notre modèle sera inspiré donc à partir des modèles prédéfinis c'est à dire prêts à être utilisés, on essaiera de créer un modèle de telle sorte que le nombre de couches soit réduit tout en respectant les grandes couches importantes existantes au point de vue (CNN) qui sont conçues pour le traitement des images et spécifiquement des données de pixels . Le modèle proposé contiendra quinze couches qui vont être décrits aux dépens de leur fonction par la suite .L'un des principaux objectifs de cette recherche est d'obtenir une meilleure précision et des résultats prometteurs, qui peuvent être améliorés et mis en œuvre à l'échelle commerciale.



Figure III.4 : Le modèle proposé (CovNet_BN_FA) pour la détection du COVID19

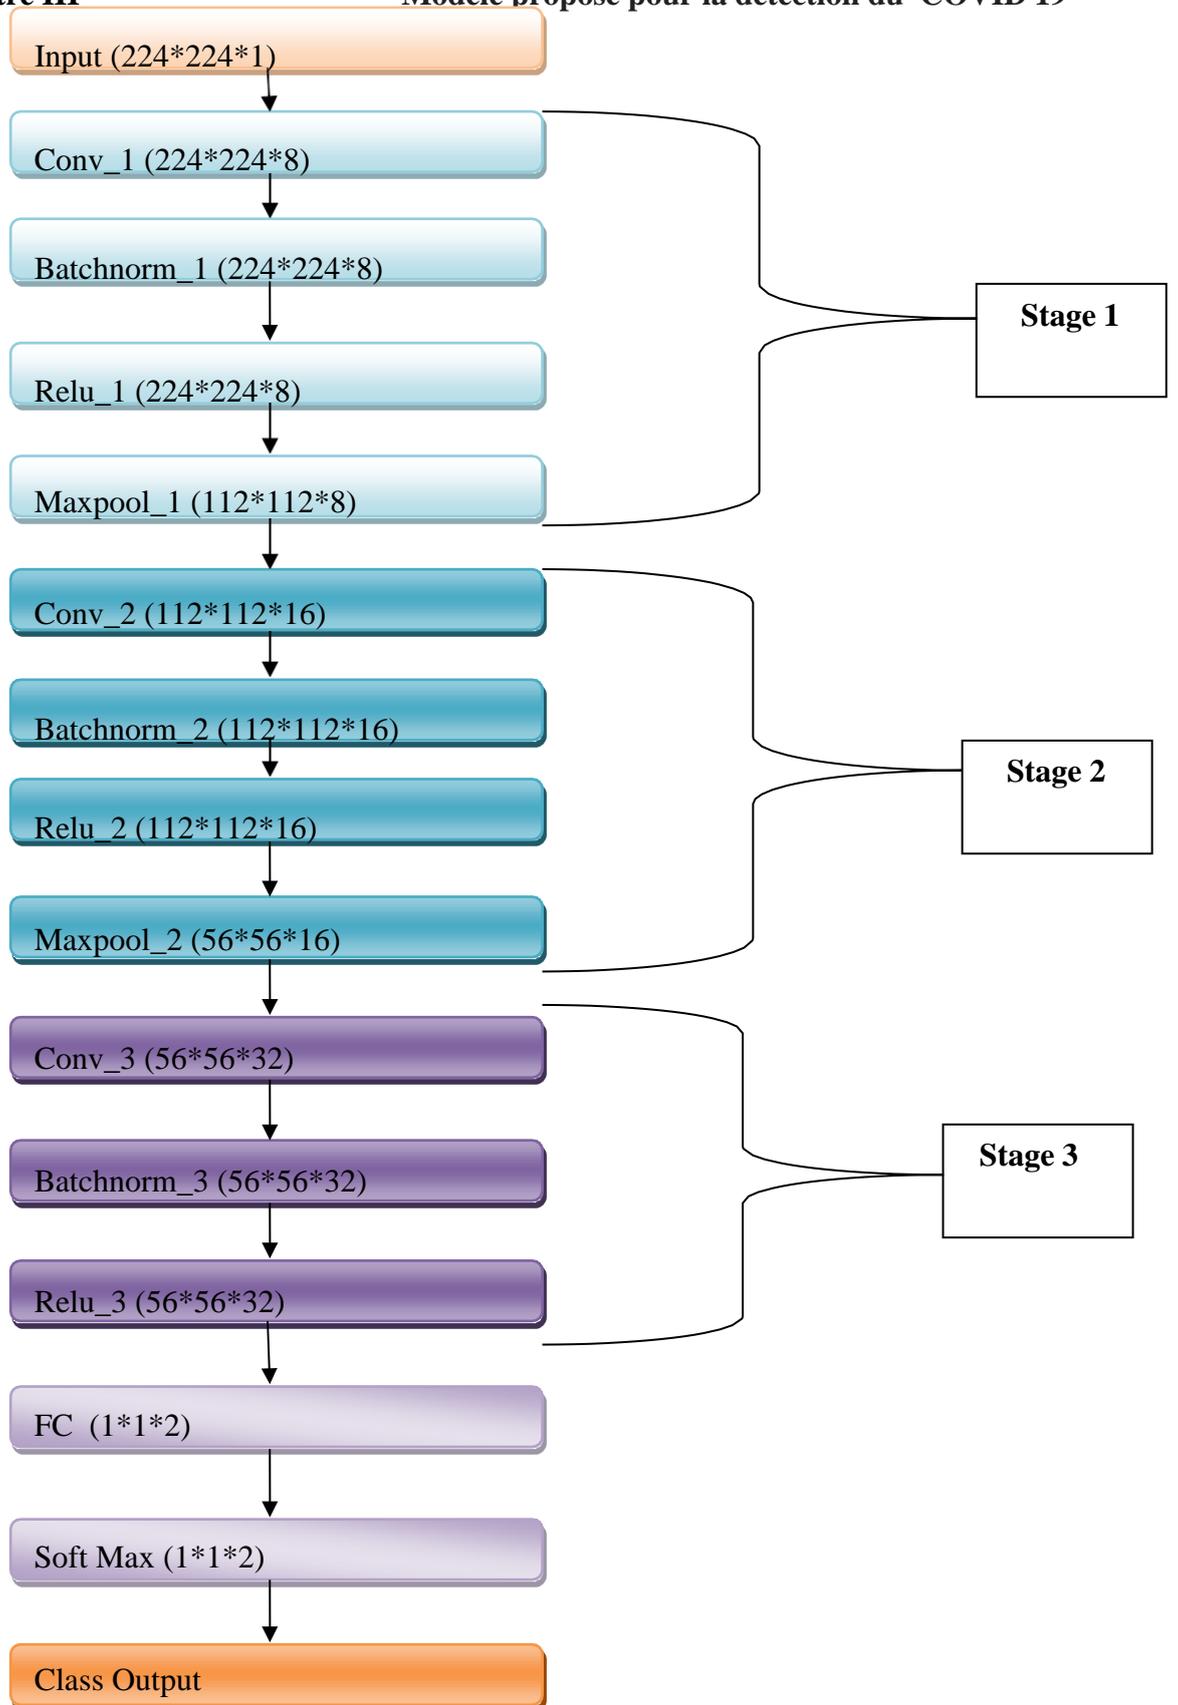


Figure III.5: Architecture du CovNet_BN_FA.

III.4. Les différentes couches du modèle CovNet_BN_FA :

III.4.1. Couche d'entrée « *image input* » :

Couche d'entrée d'image Une image Input Layer est l'endroit où on spécifie la taille de l'image, qui dans ce cas, est de $224 * 224 * 1$. Ces nombres correspondent à la hauteur, la largeur et la taille du canal. Les données numériques sont constituées d'images en niveaux de gris, de sorte que la taille du canal (canal de couleur) est 1. Pour une image couleur, la taille du canal est 3, correspondant aux valeurs RVB va être convertie en une image NG de taille $224, 224, 1$. Vous n'avez pas besoin de mélanger les données car train Network, par défaut, mélange les données au début de l'apprentissage. Train Network peut également mélanger automatiquement les données au début de chaque époque pendant l'apprentissage [19] [20].

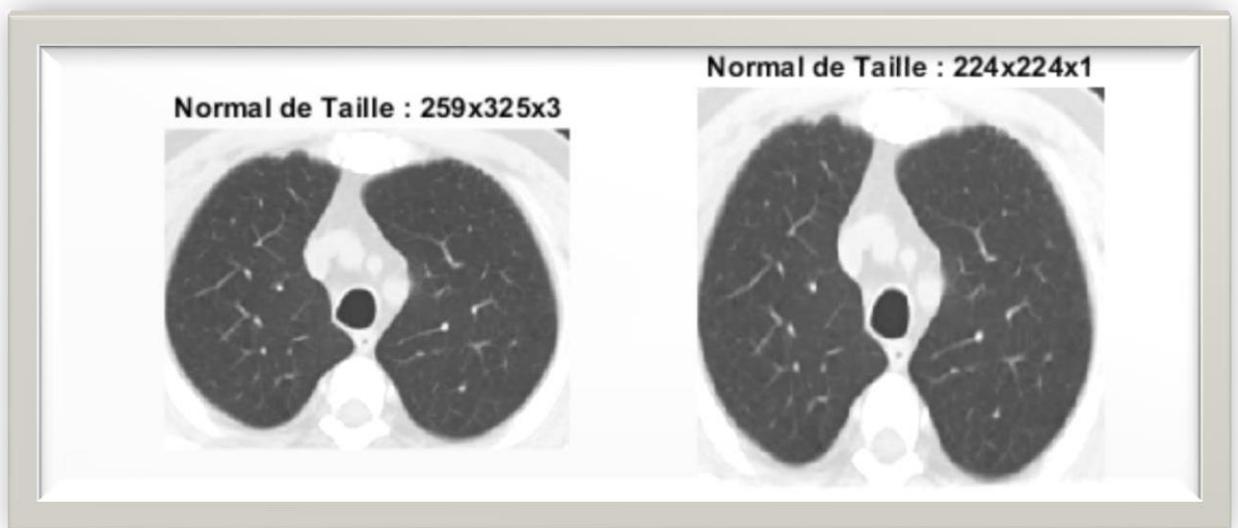


Figure III.6: Couche « image input »

III.4.2. Couche de convolution 1 :

La Couche convolution est la composante clé des réseaux de neurones convolutifs, et constitue toujours au moins leur première couche. Le premier argument est filtre Size, qui correspond à la hauteur et à la largeur des filtres que la fonction d'apprentissage utilise lors du balayage des images. Dans cet exemple, le nombre 3 indique que la taille du filtre est de 224 par 224 avec 8 profondeurs. Vous pouvez spécifier différentes tailles pour la hauteur et la largeur du filtre. Le deuxième argument est le nombre de filtres, numFiltres, qui est le nombre de neurones qui se connectent à la même région de l'entrée. Ce paramètre détermine le nombre de cartes d'entités.

On Utilise la paire nom- valeur "Remplissage" pour ajouter un remplissage à la carte des entités en entrée. Pour une aille de sortie spatiale est la même que la taille d'entrée. On peut également définir la foulée et les taux d'apprentissage pour cette couche à l'aide des arguments de pair nom- valeur de *convolution2dLayer*.

Dans la convolution 2 et 3, on garde le même principe de la convolution 1 mais on augmente les nombres des masques (convolution 2 : à la place 8 on met 16 masques, convolution 3 : à la place 16 on met 32 masques).

Sur le côté gauche de la figure(III.6) Se trouve l'entrée de la couche de convolution, par exemple l'image d'entrée. Et à droite se trouve le masque de convolution. C'est ce qu'on appelle une convolution 3x3 en raison de la forme du masque.

66	65	63	62	60	55
66	65	63	61	60	72
66	64	62	60	59	107
68	73	55	59	97	191
72	64	49	79	137	231
74	54	56	122	195	255

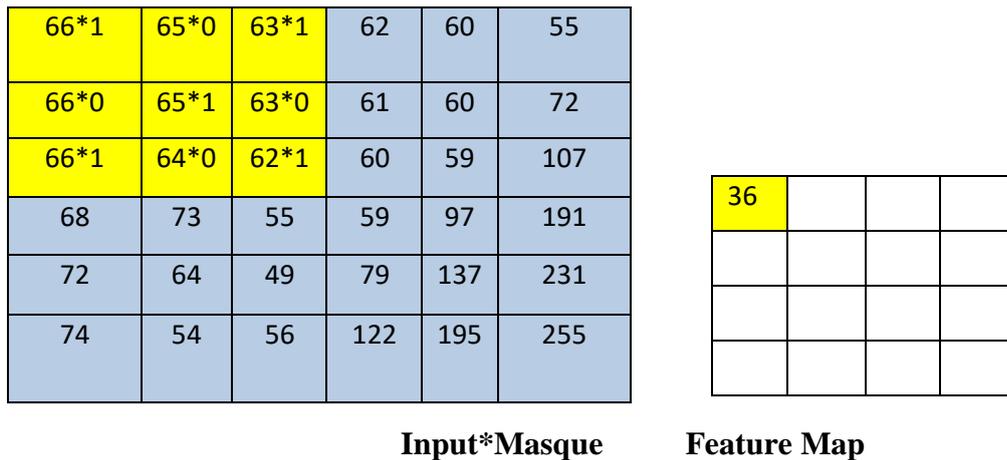
1	0	1
0	1	0
1	0	1

INPUT

Le masque

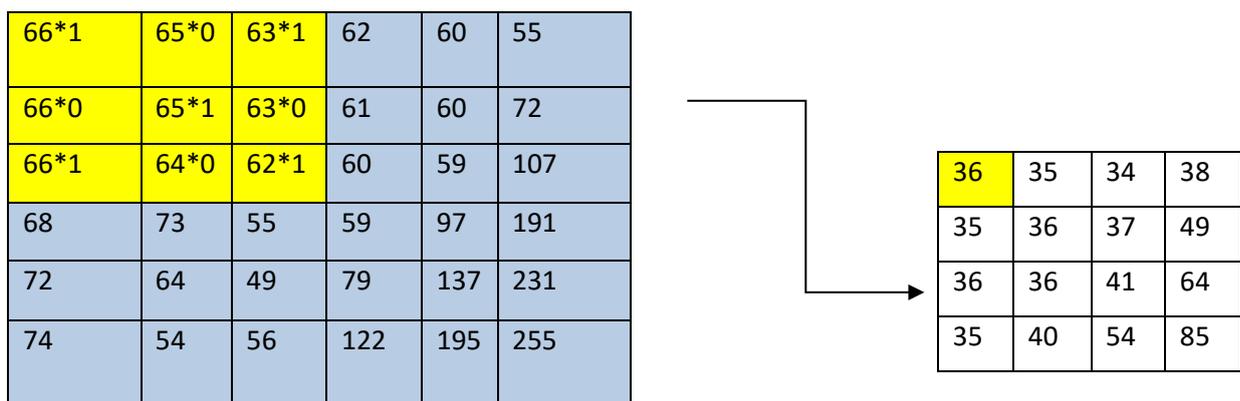
Figure III.7: Matrice d'entrée avec le masque de convolution.

L'opération de convolution est effectuée plusieurs fois en déplaçant ce masque sur toute la matrice ou l'image d'entrée, on multiplie la matrice avec le masque et on additionne le résultat. Ce résultat va à vecteur des caractéristiques. Nous faisons ce processus pour couvrir toutes les parties de l'image.



FigureIII.8: première étape de convolution.

Encore nous répétons le processus jusqu'à ce que nous couvrions toute l'image.



FigureIII.9: Vecteur de caractéristique après l'application de convolution.

III.4.3. Couche batch normalisation 1

Couche de normalisation par lots Les activations et gradients se propageant dans un réseau sont normalisés par des couches de normalisation par lots. Ce qui fait de l'entraînement du réseau un problème d'optimisation plus simple [21]. Pour accélérer l'apprentissage du réseau et minimiser la sensibilité à l'initialisation du réseau, on utilise des couches de normalisation par lots entre les couches convolutionnelles et les non-linéarités, telles que les couches Relu.

Toutes les images doivent être normalisées de cette taille 224, 224 ,1.

On Utilisée batch Normalisation Layer pour créer une couche de normalisation par lots.

III.4.4. Couche Correction Relu 1:

Couche de Relu c'est une fonction d'activation non linéaire suit la couche de normalisation des lots. L'unité linéaire rectifiée est la fonction d'activation la plus couramment utilisée (*Relu*)

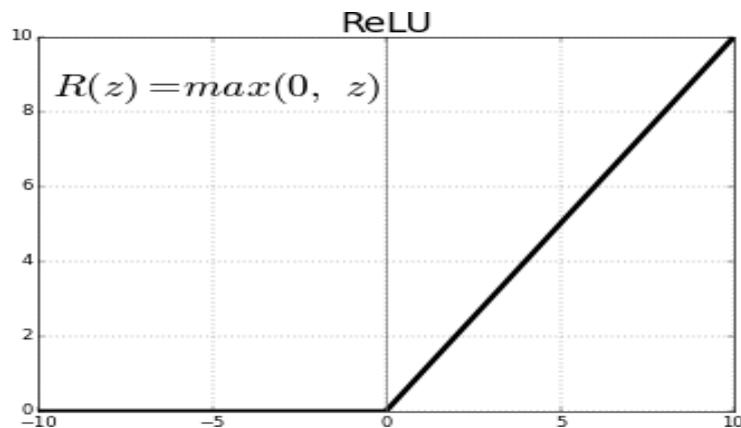


Figure III.10: Graphique de la Fonction d'activation Relu

On supprime Les valeurs négatives qui vont être remplacé avec des zéros et aussi en garde la valeur positive .Pour créer une couche Relu, on utilise *relu Layer*.

III.4.5. Couche max pooling 1:

Les couches convolutives (avec des fonctions d'activation) sont parfois suivies d'une opération de sous-échantillonnage qui réduit la taille spatiale de la carte d'entités et

supprime les informations spatiales redondantes. Le sous-échantillonnage permet d'augmenter le nombre de filtres dans des couches convolutionnelles plus profondes sans augmenter la quantité de calcul requise par couche. Une façon de sous-échantillonner consiste à utiliser un regroupement maximum, que vous créez à l'aide de *maxPooling2dLayer*. La couche de regroupement max renvoie les valeurs maximales des régions rectangulaires d'entrées, spécifiées par le premier argument, pool Size [22]. La taille de la région rectangulaire est [2,2]. L'argument de la paire nom- valeur ' *Stride* ' spécifie la taille de pas que la fonction d'apprentissage prend lorsqu'elle analyse l'entrée.

Nous avons réduit la taille des images en 2 la taille était 224*224 est devenue à taille 112 *112 avec le même masque de 8, et dans le max pooling 2 .On garde le même principe de max pooling 1 (la taille 112, 112 et est devenue à taille 56 *56 avec le même masque de 16).

On sélectionne l'élément maximal dans la région du vecteur des caractéristiques Figure (III.9) couvertes par le masque.

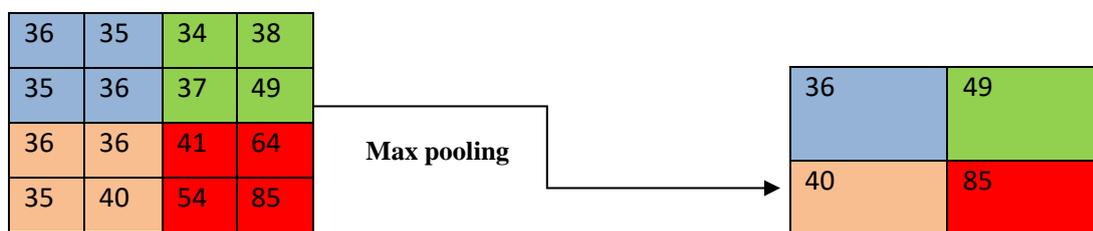


Figure III .11: L'application de max pooling.

III.4.6 Couche entièrement connectée (FC):

Couche entièrement connectée Les couches de convolution et de sous-échantillonnage sont suivies d'une ou plusieurs couches entièrement connectées. Comme son nom l'indique, une couche entièrement connectée est une couche dans laquelle les neurones se connectent à tous les neurones de la couche précédente. Cette couche combine toutes les caractéristiques apprises par les couches précédentes sur l'image pour identifier les motifs plus grands.

La dernière couche entièrement connectée combine les caractéristiques pour classer les images. Par conséquent, le paramètre Output Size dans la dernière couche entièrement connectée est égal au nombre de classes dans les données cibles.

On Utilisée Fully Connected Layer pour créer une couche entièrement connectée.

III.4.7. Couche de Softmax :

La fonction d'activation *softmax* normalise la sortie de la couche entièrement connectée. La sortie de la couche *softmax* consiste en des nombres positifs qui totalisent un, qui peuvent ensuite être utilisés comme probabilités de classification par la couche de classification [23].

On Crée une couche *softmax* à l'aide de la fonction *softmax* Layer après la dernière couche entièrement connectée.

III.4.8 Couche de sortie (*classification output*) :

Couche de classification La dernière couche est la couche de classification. Cette couche utilise les probabilités renvoyées par la fonction d'activation softmax pour chaque entrée pour affecter l'entrée à l'une des classes mutuellement exclusives et calculer la perte.

Pour créer une couche de classification, on utilisée *classification layer*.

III.5. Les options d'apprentissage « Sgdm » et « Adam » :

Dans cette partie, nous allons présenter deux méthodes d'optimisation dans l'apprentissage profond. Les optimiseurs sont des algorithmes ou des méthodes modernes utilisées pour modifier les attributs du réseau de neurones tels que les points et le taux d'apprentissage afin de minimiser les pertes.

III.5.1. Sgdm (*Stochastic Gradient Descent with Momentum*) :

L'idée de base derrière l'approximation stochastique remonte à l'algorithme de Robbins - Monro des années 1950, la descente de gradient stochastique est devenue une méthode d'optimisation importante dans l'apprentissage automatique. Cet optimiseur met à jour les paramètres du réseau (poids et biais) pour minimiser la fonction de perte. Le facteur d'impulsion supplémentaire permet de réduire l'oscillation qui peut apparaître le long de la trajectoire de descente la plus abrupte vers l'optimum.

L'ajout d'un terme de Momentum à la mise à jour des paramètres est un moyen de réduire cette oscillation [24]. Cette mise à jour est la suivante :

$$\theta_{l+1} = \theta_l - \alpha \nabla E(\theta_l) + \gamma (\theta_l - \theta_{l-1}) \quad (\text{III.1})$$

Où γ détermine la contribution de l'étape de gradient précédente à l'itération actuelle. Vous pouvez spécifier cette valeur à l'aide de l'option de formation Momentum. Pour former un réseau neuronal à l'aide de l'algorithme de descente de gradient stochastique avec Momentum, spécifiez « Sgdm » comme premier argument d'entrée de training options et pour spécifier la valeur initiale du taux d'apprentissage α , utilisez l'option de formation Initial Learn-Rate.

Cet algorithme utilise un seul taux d'apprentissage pour tous les paramètres. Il peut également obtenir de nouveaux minima.

III.5.2. Adam (*adaptive moment estimation*) :

C'est un algorithme d'optimisation qui peut être utilisé à la place de procédure classique de descente de gradient stochastique pour mettre à jour les poids de réseau itératifs en fonction des données d'apprentissage.

Adam décrit la combinaison des avantages des deux extensions de la descente de gradient stochastique spécifiquement (Ada Grad) et (RMS prop).

Adam utilise également la moyenne des seconds moments des gradients (la variance non centrée). C'est un algorithme populaire dans le domaine de l'apprentissage profond car il obtient rapidement de bons résultats. Adam est relativement facile à configurer car les paramètres de configuration par défaut fonctionnent bien sûr la plupart des problèmes. Lors de l'introduction de l'algorithme, certains avantages intéressants de l'utilisation d'Adam sur des problèmes d'optimisation sont indiqués comme suit :

- Simple à mettre en œuvre.
- Efficace en termes de calcul.
- Peu de besoins en mémoire.
- Bien adapté aux problèmes importants en termes de données et / ou de paramètres.
- Convient aux objectifs non stationnaires.
- Convient aux problèmes avec des gradients très bruyants / ou clairsemés.

- Invariant au redimensionnement diagonal des dégradés.
- Les hyper-paramètres ont une interprétation intuitive et nécessitent généralement peu de réglages.

Concernant cette option d'apprentissage, cet optimiseur conserve une moyenne mobile par élément des gradients de paramètres et de leur valeur au carré,

$$M_t = \beta_1 m_{t-1} + (1 - \beta_1) \nabla E(\theta_t) \tag{III.2}$$

$$V_t = \beta_2 v_{t-1} + (1 - \beta_2) [\nabla E(\theta_t)]^2 \tag{III.3}$$

On peut spécifier les taux de décroissance β_1 et β_2 à l'aide des options d'entraînement Gradient Decay factor respectivement. Adam utilise les moyennes mobiles pour mettre à jour les paramètres du réseau comme :

$$\theta_{t+1} = \theta_t - \frac{\alpha m_t}{\sqrt{v_t} + \epsilon} \tag{III.4}$$

C'est une méthode qui calcule les taux d'apprentissage adaptatifs pour chaque paramètre et stocke une moyenne à décroissance exponentielle des gradients carrés. Cet Algorithme conserve également une moyenne des gradients passés qui décroît de façon exponentielle (m_t) semblable au Momentum (M_t) et (V_t). Si les gradients sur de nombreuses itérations sont similaires, l'utilisation d'une moyenne mobile du gradient permet aux mises à jour des paramètres de prendre de l'élan dans une certaine direction. Si les gradients contiennent principalement du bruit, alors la moyenne mobile du gradient devient plus petite, et donc les mises à jour des paramètres deviennent également plus petites. La mise à jour complète d'Adam comprend également un mécanisme permettant de corriger un biais qui apparaît au début de la formation [25].

Cet optimiseur utilise également le concept de moment adaptatif en ajoutant des fractions de gradients précédents au gradient actuel.

Enfin, Adam est devenu assez répandu, il est pratiquement accepté pour être utilisé dans les réseaux neuronaux d'entraînement et spécifié comme premier argument d'entrée.

Suivant les types d'options, ces deux algorithmes utilisent les mêmes paramètres qui sont représentés comme suit :

- Nombre epochs :

(Epoch) signifie un passage sur l'ensemble d'entraînement complet. Un epoch correspond à un apprentissage sur toutes les données, plus ce nombre est grand plus on devrait obtenir une bonne précision sauf que c'est plus long.

- LR (Learning-Rate) :

Le taux d'apprentissage est un hyper paramètre qui contrôle à quel point nous ajoutons les poids de notre réseau par rapport au gradient de perte .Dans l'apprentissage automatique et les statistiques, le taux d'apprentissage est un paramètre de réglage dans un algorithme d'optimisation qui détermine la taille du pas à chaque itération tout en se déplaçant vers un minimum d'une fonction de perte. Plus la valeur est faible, plus nous avançons lentement, le long de la pente descendante.

- Mini batch size :

(Batch ou lot) le Mini Batch size signifie que vous ne prenez qu'un sous-ensemble de toutes vos données au cours d'une itération pour évaluer le gradient de la fonction de perte et mettre à jour la pondération.

III.6.Conclusion :

Dans ce chapitre, nous avons développé les grandes lignes qui concernent les différents modèles de réseau de neurone convolutif (CNN). Ensuite, nous avons illustré les différentes étapes de notre système proposé en expliquant tous les composants de notre modèle. De plus, nous avons abordé les options d'apprentissage en utilisant les algorithmes d'optimisation (ADAM, SGDM). Le chapitre suivant sera consacré à la présentation des résultats expérimentaux obtenus par notre modèle proposé.

Chapitre IV: Résultats et Interprétations

IV.1. Introduction :

Après avoir décrit le nouveau modèle qu'on a créé dans le chapitre précédent, cette partie sera consacrée à la mise en œuvre de son application pour la détection de COVID-19. Pour cela, nous allons utiliser deux catégories d'images sélectionnées à partir de deux bases de données.

Ensuite, on va présenter les résultats expérimentaux obtenus par l'application de notre modèle (COVID Net _BN_FA) sur des bases de données de la maladie du COVID-19. A signaler qu'on a utilisé deux bases de données distinctes: une base qui contient des images issues d'un scanner et une autre qui contient des images IRM.

IV.2. Description des bases de données:

○ 1^{ère} base de données Scanner (tomodensitométrie) :

Cette base de données a été élaboré par 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 la Malaisie, en collaboration avec des médecins [26]. Cette équipe de chercheurs a créé une base de données d'images radiographiques pulmonaires pour les cas positifs au COVID-19 ainsi que des images de pneumonie normale et virale. Cet ensemble de données sur le COVID-19, les infections pulmonaires normales et autres contient 3616 cas positifs au COVID-19 ainsi qu'à 10 192 images normales, 6012 d'opacité pulmonaire (infection pulmonaire non COVID) et 1345 images de pneumonie virale et les masques pulmonaires correspondants. Les images de cette base de données sont au format PNG et de résolution 229×229.

○ 2^{ème} base de données IRM (l'imagerie par résonance magnétique) :

L'ensemble de données proposé est composé de 2482 images qui se répartissent entre 1252 pour les patients infectés par le SARS-COV-2, et 1230 images pour les patients non infectés par le SRAS-COV-2, mais qui présentaient d'autres maladies pulmonaires. Ces données ont été collecté dans les hôpitaux de Sao Paulo, Brésil [27] .Les images de cette base de données sont au format PNG et de résolution variable.

IRM_Scanner : création de 4 classes

Covid /covid1

Normal /Normal1

Hybride : création des deux bases dans deux classes

Covid/ Normal

Chacune de ces deux bases contient deux données principales : une nommée « COVID » pour les images médicales thoraciques des patients (COVID) et la seconde nommée « Normal » pour les images médicales thoraciques des patients normaux. Chaque classe est composée d'environ 400 images confirmées.

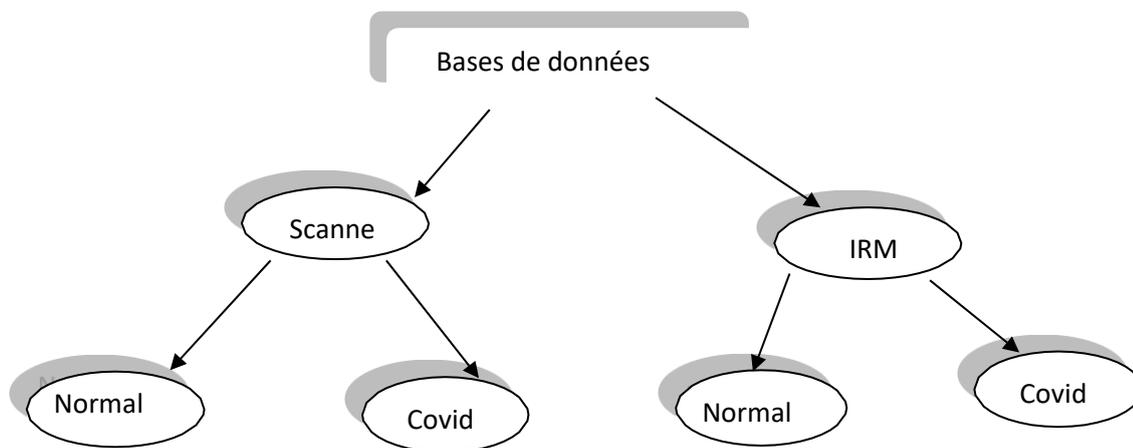


Figure IV.1: Diagramme global de nos bases de données.

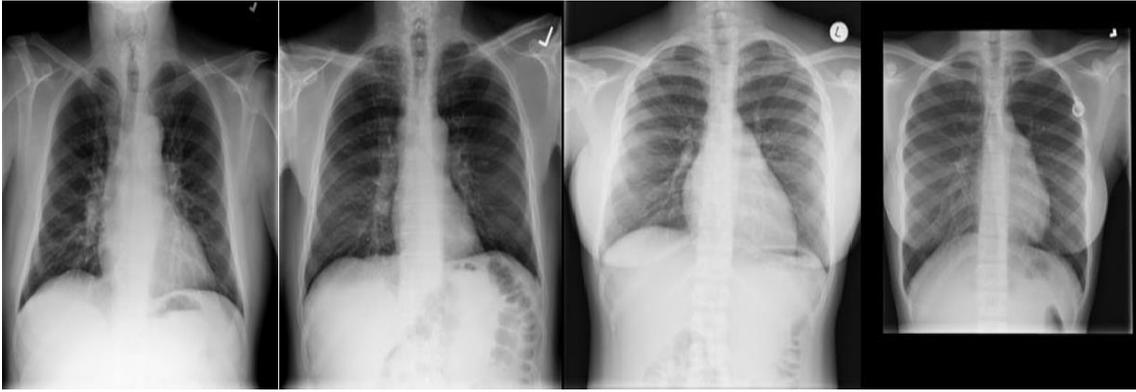


Figure IV.2.1 : Des images Chest X-ray représentatives de patients normaux
(Pour la 1^{ère} base de données Scanner)



Figure IV.2.2 : Des images Chest X-ray représentatives de patients COVID-19
(Pour la 1^{ère} base de données Scanner)

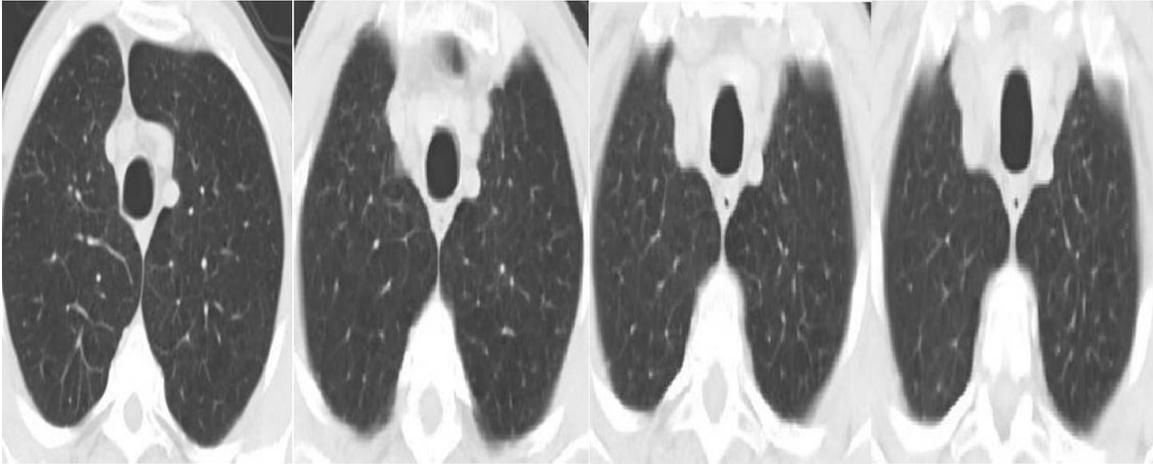


Figure IV.3.1: Des images CT Scan représentatives de patients normaux

(Pour la 2eme base de données IRM)

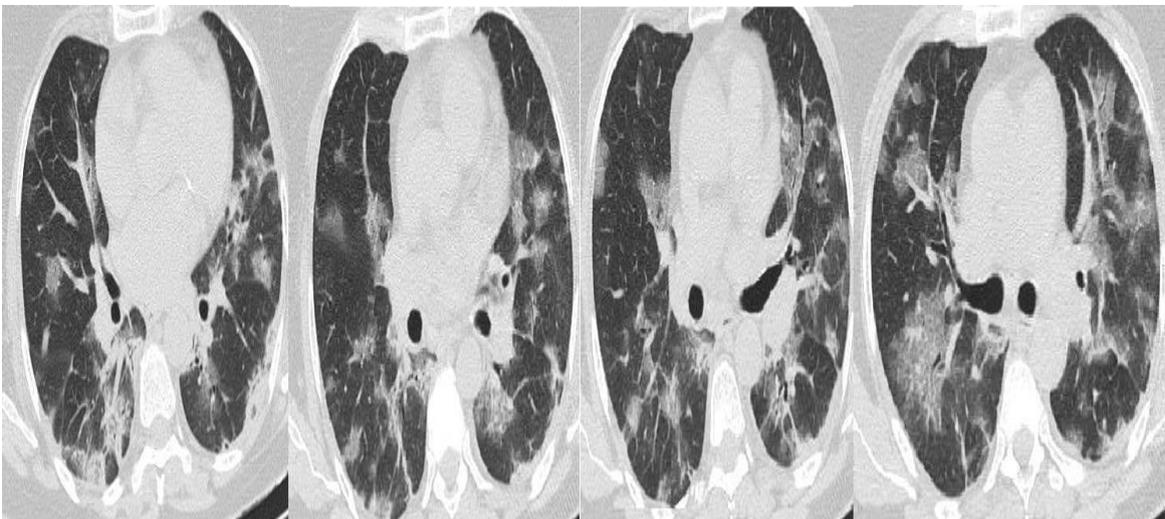


Figure IV.3.2 : Des images CT Scan représentatives de patients COVID-19

(Pour la 2eme base de données IRM)

IV.3 .Performances métriques:

L'analyse des performances du modèle proposé est évaluée à partir de la matrice de confusion en fonction de l'exactitude, de la *precision*, *Recall* et du score F1 .Cette performance est déterminée en utilisant les termes vrais positifs (TP), faux positifs(FP), vrai négatifs (TN) et faux négatifs (FN). Le taux de détection correct des photographies atteintes parmi toutes les images est appelé *Recall* . Le score F1 et la mesure combinée de la précision et du rappel qui montre combien de fois la valeur prédite est exacte. Ce score est également connu comme la moyenne harmonique de p et r en mathématiques .La précision est une mesure de l'efficacité du fonctionnement d'un modèle ou d'un système : (c'est à dire le nombre de fois ou le modèle a correctement prédit le résultat réel et doit être calculé). Les formules mathématiques pour déterminer la précision sont exprimées dans les équations ci-dessous : [28]

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (\text{IV.1})$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (\text{IV.2})$$

$$\text{Sensitivity/Recall} = \frac{TP}{TP+FN} \quad (\text{IV.3})$$

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (\text{IV.4})$$

$$\text{F1-Score} = \frac{2 * \text{precision} * \text{recall}}{\text{precision} + \text{recall}} \quad (\text{IV.5})$$

IV.4. Application du modèle pour la base de données « scanner » :

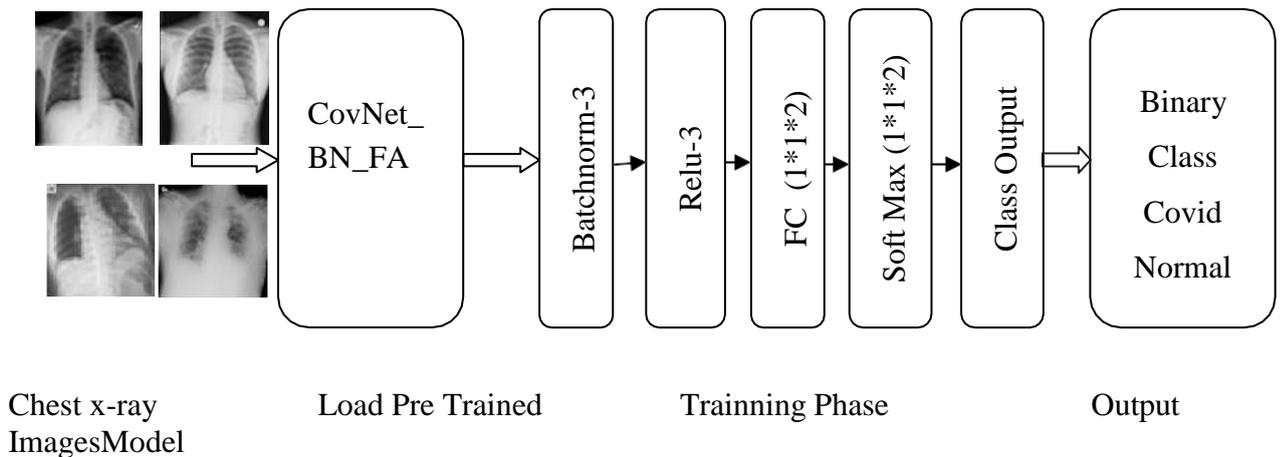


Figure. IV.4 : Architecture du modèle proposé pour le pré-entraîner
(Pour la 1^{ère} base de données Scanner)

IV.4.1. Résultats obtenus pour la base de données « scanner » :

Dans ces expériences, nous avons utilisé notre ensemble de données de ChestX_ray pulmonaire préparé pour examiner l'efficacité de notre modèle proposé. Les performances de classification du modèle pour le problème de classification binaire (Normal /Covid) sur les images radiographiques sont fournies dans les tableaux **IV.2** et **IV.3**, respectivement. Les matrices de confusion pour les problèmes de classification binaires des deux options sont présentées aux figures **IV.6** et **IV. 8**, respectivement. Les figures **IV.5** et **IV.7** montrent les diagrammes de précision et de perte obtenus sur la division 80% pour l'apprentissage et 20% pour la validation.

	Accuracy%	Précision%	Sensitivity/Recall%	Specificity %	F1-Score %
Split 1	98.75	100	97.5	100	97.5
Split 2	99.4	98.8	100	98.8	100
Split 3	98.8	97.5	100	97.6	100
Split 4	100	100	100	100	100
Split 5	98.8	98.8	98.8	98.8	98.8
Moyenne	99.1	99	99.2	99	99.3

Tableau IV.2 : Tableau de performance du modèle pour chaque split de la base de données(Chest X-RAY) pour option « Adam »

	Accuracy%	Précision%	Sensitivity%	Specificity%	F1-Score%
Split 1	100	100	100	100	100
Split 2	100	100	100	100	100
Split 3	100	100	100	100	100
Split 4	99.4	100	98.8	100	98.8
Split 5	99.4	98.8	100	98.8	100
Moyenne	99.8	99.8	99.8	99.8	99.8

Tableau IV.3 : Tableau de performance du modèle pour chaque split de la base de données(Chest X-RAY) pour option « Sgdm »

A/Suivant les paramètres NE=15 ; MB=10 ; LR=0.001 et l'option Adam :

La figure **IV.5** présente la progression du processus de formation des réseaux d'apprentissage profond.

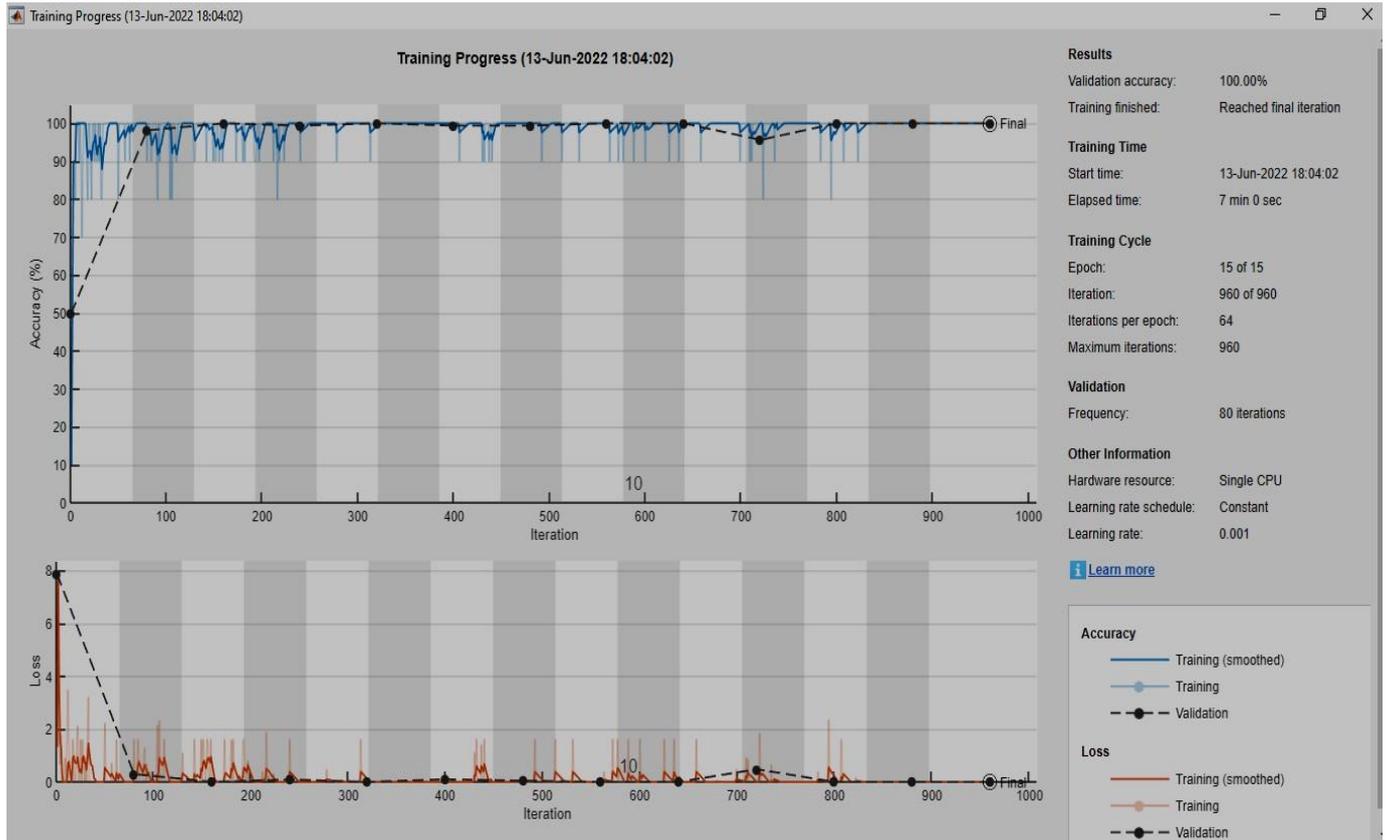
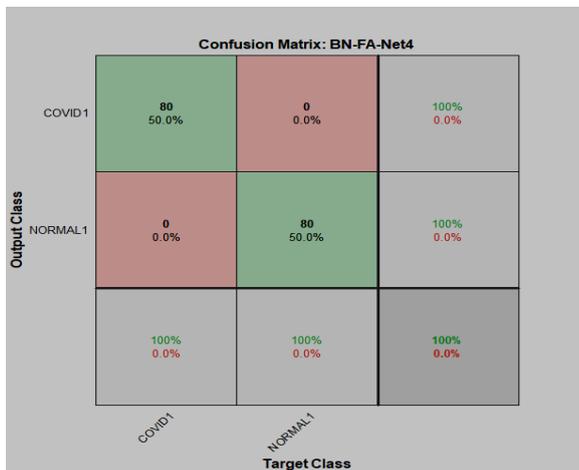
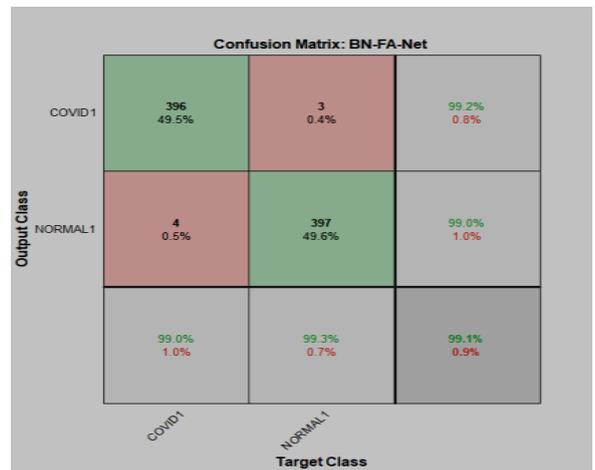


Figure IV.5 : Courbe d'évolution (accuracy and loss) d'apprentissage pour Scanner.
 (Avec l'option Adam)



(a)



(b)

Figure IV.6 : (a) .Matrice de confusion pour split 4, (b). Matrice de confusion globale pour le jeu de données Scanner (avec l'option Adam).

B/ Suivant les paramètres NE=15 ; MB=10 ; LR=0.001 et l'option Sgdm :

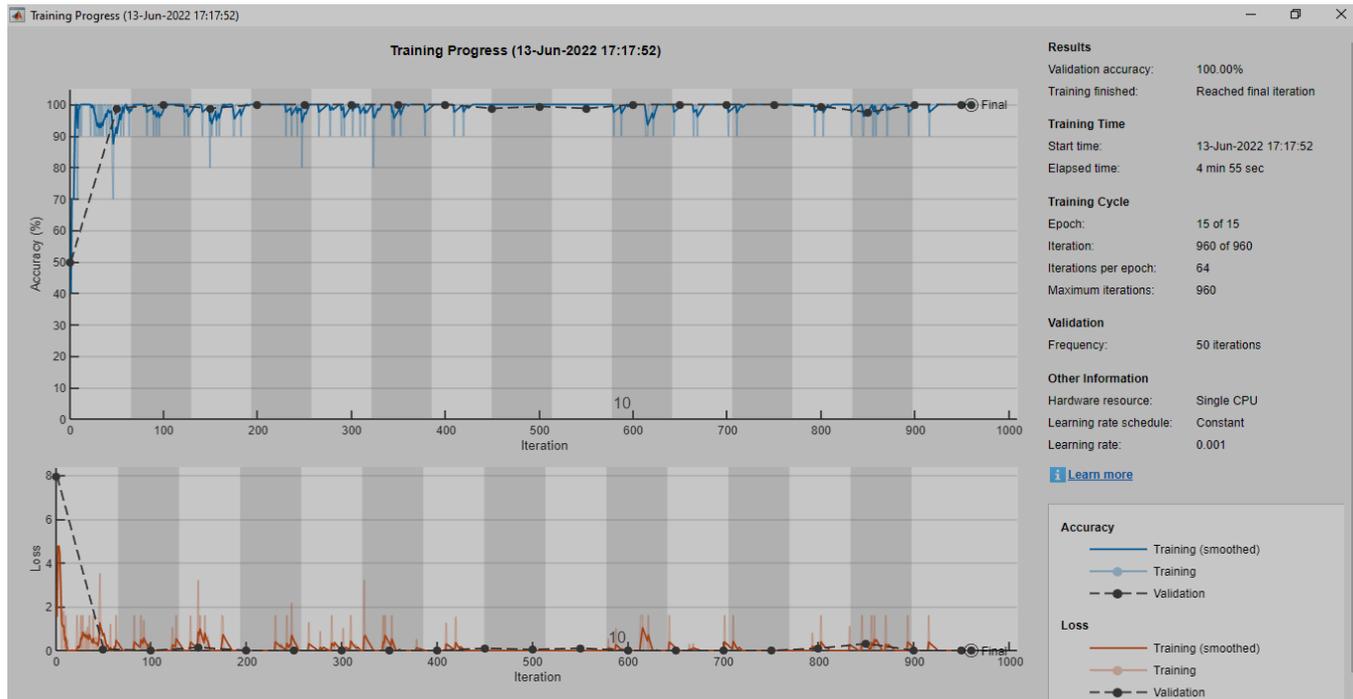


Figure IV.7 : Courbe d'évolution (accuracy and loss) d'apprentissage pour Scanner. (Avec l'option Sgdm)

Confusion Matrix: BN-FA-Net3

Output Class	COVID	80 50.0%	0 0.0%	100% 0.0%
	NORMAL	0 0.0%	80 50.0%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%
		COVID	NORMAL	Target Class

(a)

Confusion Matrix: BN-FA-Net

Output Class	COVID	399 49.9%	1 0.1%	99.8% 0.2%
	NORMAL	1 0.1%	399 49.9%	99.8% 0.2%
		99.8% 0.2%	99.8% 0.2%	99.8% 0.2%
		COVID	NORMAL	Target Class

(b)

Figure IV.8: (a) .Matrice de confusion pour split 3, (b). Matrice de confusion globale Pour le jeu de données Scanner (avec l'option Sgdm).

IV.5. Application du modèle pour la base de données « IRM » :

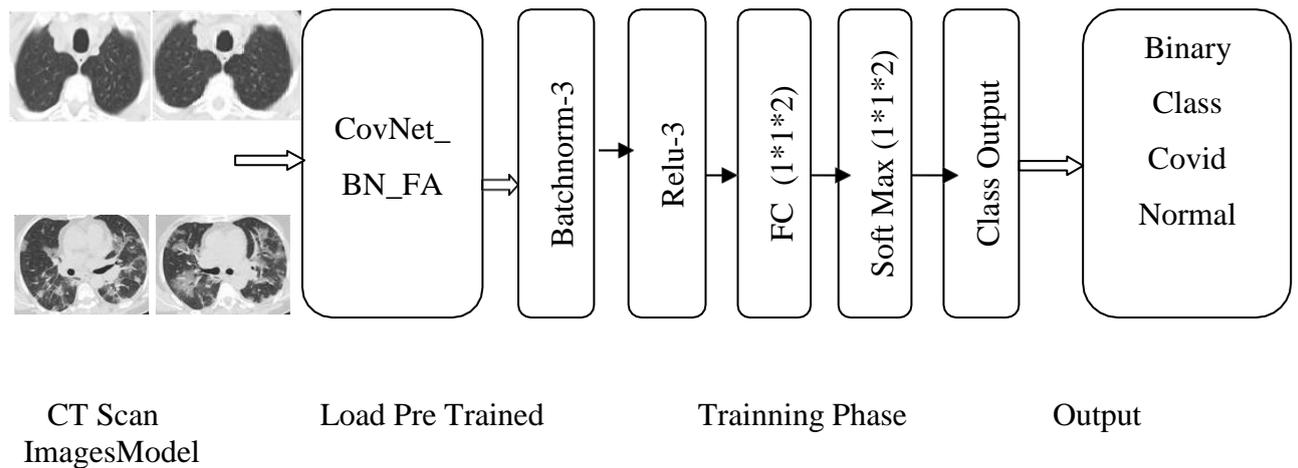


Figure IV.9 : Architecture du modèle proposé pour le pré-entraîner
(Pour la 2 eme base de données IRM)

IV.5.1. Résultats obtenus pour la base de données « IRM » :

Dans ces expériences, nous avons utilisé notre ensemble de données de CT Scan pulmonaire préparé pour examiner l'efficacité de notre modèle proposé. Les performances de classification du modèle pour le problème de classification binaire (Normal /Covid) sur les images radiographiques sont fournies dans les tableaux **IV.4** et **IV.5**, respectivement. Les matrices de confusion pour les problèmes de classification binaires des deux options sont présentées aux figures **IV.11** et **IV. 13**, respectivement. Les figures **IV.10** et **IV.12** montrent les diagrammes de précision et de perte obtenus sur la division 80% pour l'apprentissage et 20% pour la validation.

	Accuracy%	Précision%	Sensitivity%	Specificity%	F1-Score%
Split 1	99.4	100	98.8	100	98.8
Split 2	98.8	100	97.6	100	97.5
Split 3	99.4	100	98.8	100	98.8
Split 4	98.1	100	96.4	100	96.3
Split 5	98.1	96.3	100	96.4	100
Moyenne	98.8	99.3	98.3	99.2	98.3

Tableau IV.4 : Tableau de performance du modèle pour chaque split de la base de données(CT Scan) pour option « Adam »

	Accuracy%	Précision%	Sensitivity%	Specificity%	F1-Score%
Split 1	100	100	100	100	100
Split 2	100	100	100	100	100
Split 3	100	100	100	100	100
Split 4	99.4	100	98.8	100	98.8
Split 5	99.4	98.8	100	98.8	100
Moyenne	99.8	99.8	99.8	99.8	99.8

Tableau IV. 5 : Tableau de performance du modèle pour chaque split de la base de données(CT Scan) pour option « Sgdm »

A/Suivant les paramètres NE = 15 ; MB = 10 ; LR=0 ,001 et l’option Adam :

La figure IV.10 présente la progression du processus de formation des réseaux d’apprentissage profond.

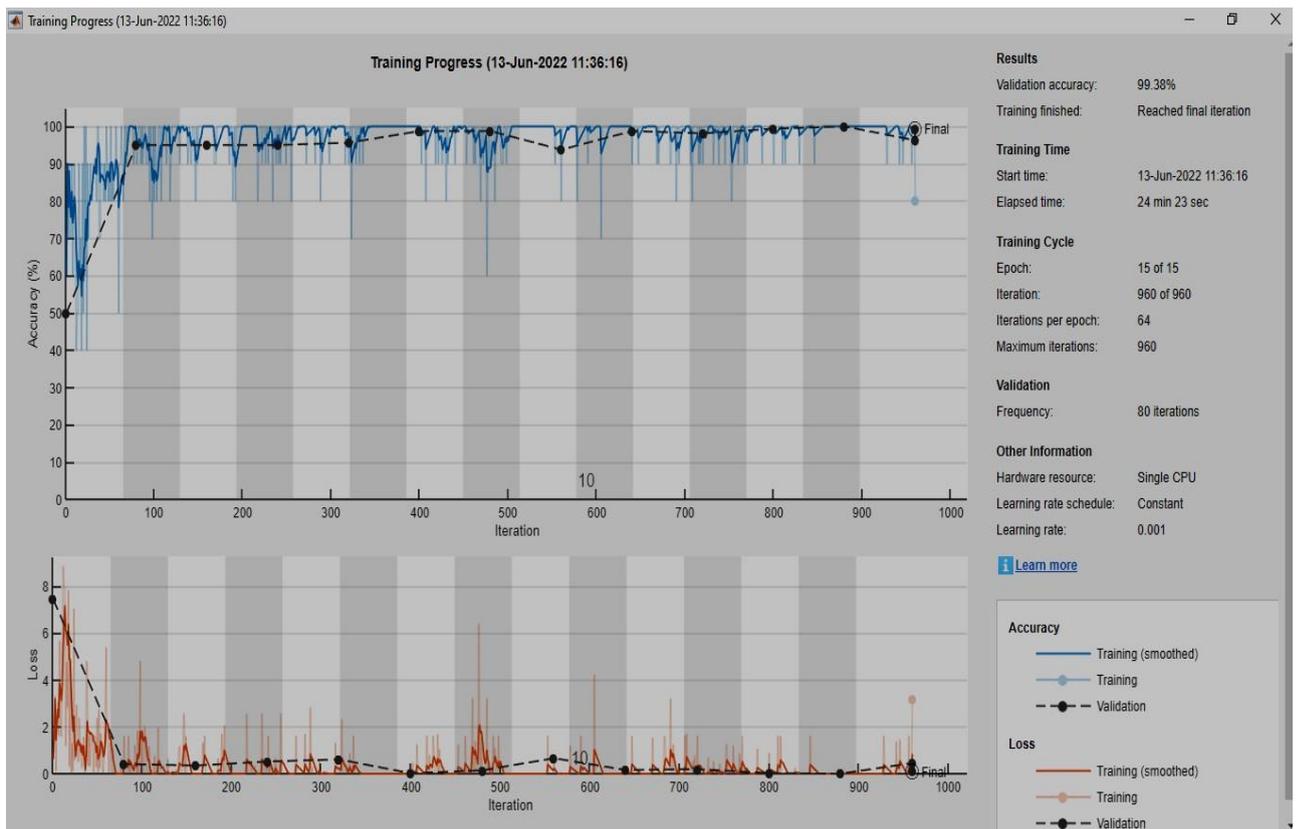
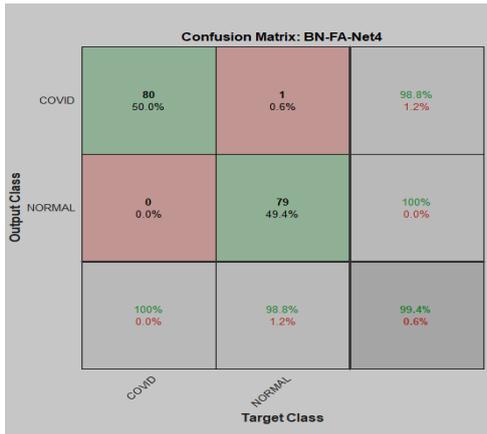
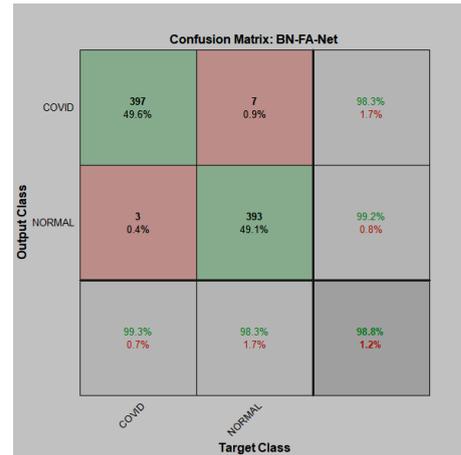


Figure IV.10 : Courbe d’évolution (accuracy and loss) d’apprentissage pour IRM (Avec l’option Adam)



(a)



(b)

Figure IV. 11 : (a) .Matrice de confusion pour split 4, (b). Matrice de confusion globale pour le jeu de données IRM (avec l’option Adam).

B/ Suivant les paramètres NE =20, MB = 10, LR = 0,001 et l’option Sgdm :

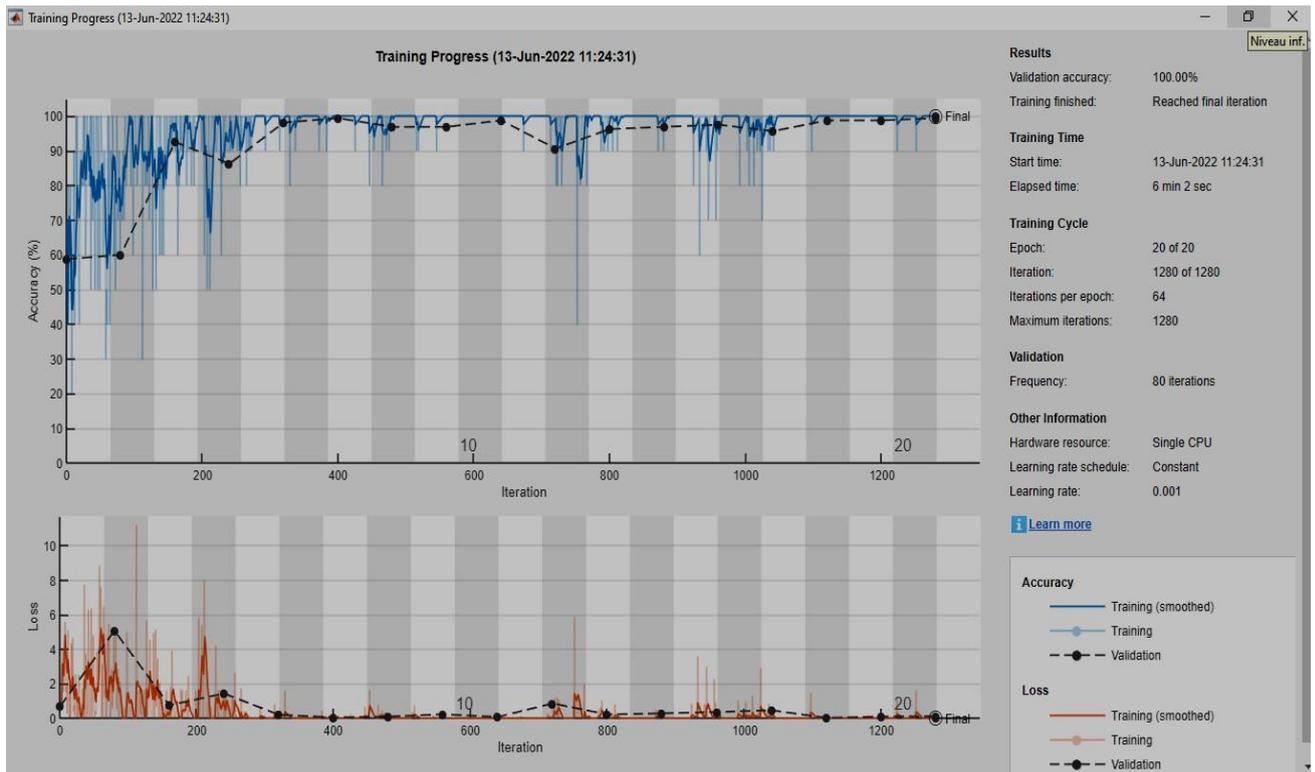


Figure IV.12 : Courbe d’évolution (accuracy and loss) d’apprentissage pour IRM (avec l’option Sgdm)

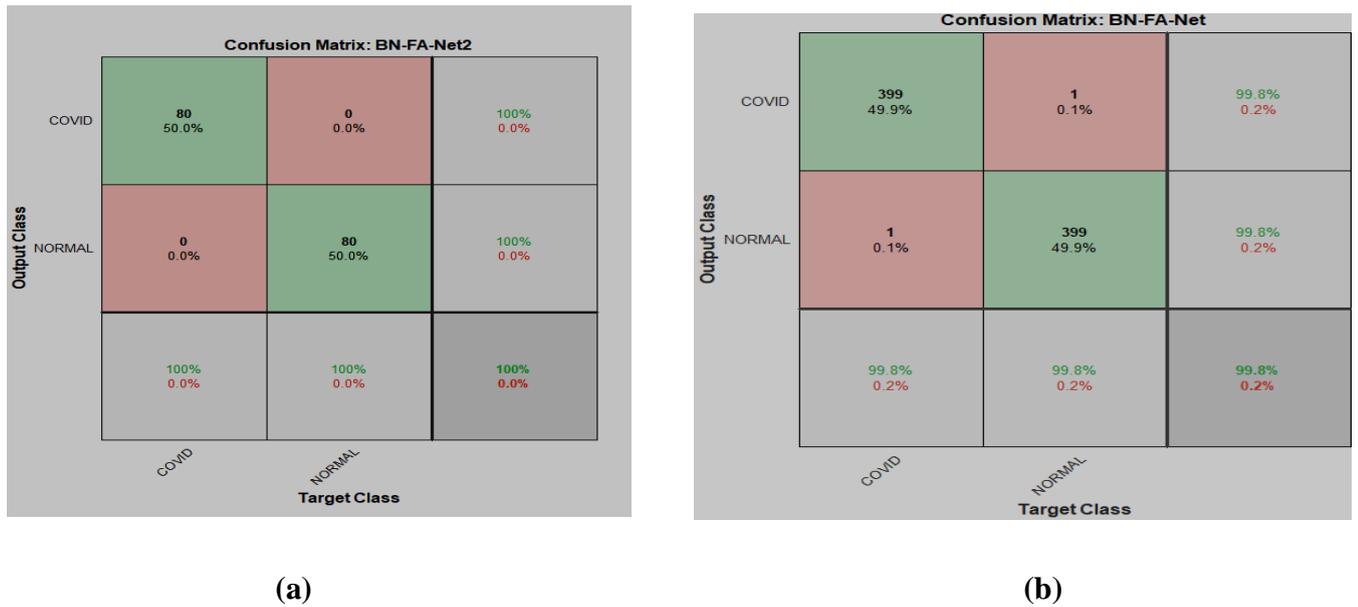


Figure IV.13 : (a).Matrice de confusion pour split 2, (b). Matrice de confusion globale Pour le jeu de données IRM (avec l’option Sgdm).

IV.6. Application du modèle pour la base de données « IRM_Scanner » :

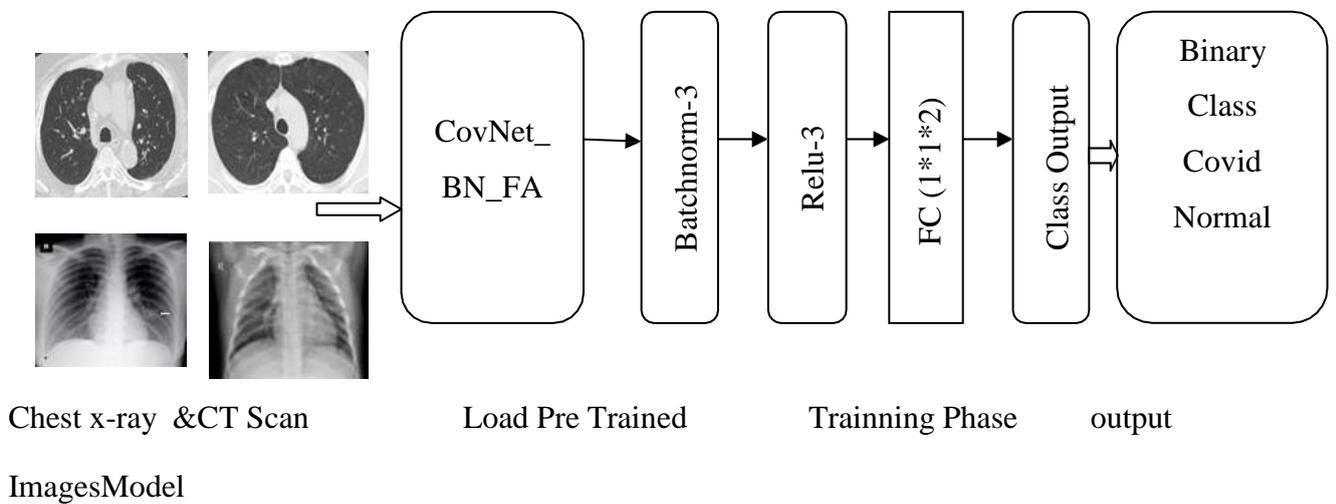


Figure. IV.14 : Architecture du modèle proposé pour le pré-entraîner (Pour la 3eme base de données IRM_Scanner)

IV.6.1. Résultats obtenus pour la base de données « IRM_Scanner » :

Dans ces expériences, nous avons utilisé notre ensemble de données de ChestX_ray et CT Scan pulmonaire préparé pour examiner l’efficacité de notre modèle proposé. Les performances de classification du modèle pour le problème de classification binaire (Normal /Covid) sur les images radiographiques sont fournies dans les tableaux IV.6 et IV.7, respectivement. Les matrices de confusion pour les problèmes de classification

binaires des deux options sont présentées aux figures **IV.15** et **IV.17** respectivement. Les figures **IV.16** et **IV.18** montrent les diagrammes de précision et de perte obtenus sur la division 80% pour l'apprentissage et 20% pour la validation.

	Accuracy	Precision				Sensitivity				Specificity				F1-Score			
	%	%				%				%				%			
Split3	99.0	98.7	98.7	98.7	98.7	99.8	99.8	100	99.8	100	99.5	99.3	99.3	88.3	99.2	99.3	98.8
Moyenne	99.0	98.71				99.85				99.52				96.43			

Tableau IV.6 : Tableau de performance du modèle pour chaque split de la base de données multi classes (ChestX_ray, CT Scan) pour option « Adam »

	Accuracy	Precision				Sensitivity				Specificity				F1-Score			
	%	%				%				%				%			
Split3	99.0	97.5	100	98.7	100	98.7	100	97.5	100	99.1	100	99.5	99.5	98.1	100	98.0	98.1
Moyenne	99.0	99.05				99.05				99.52				98.55			

Tableau IV.7 : Tableau de performance du modèle pour chaque split de la base de données multi classes (ChestX_ray, CT Scan) pour option « Sgdm »

A/Suivant les paramètres NE = 15, MB =10, LR =0 ,001 et l’option Adam :

La figure ci-dessous présente la progression du processus de formation des réseaux d’apprentissage profond.

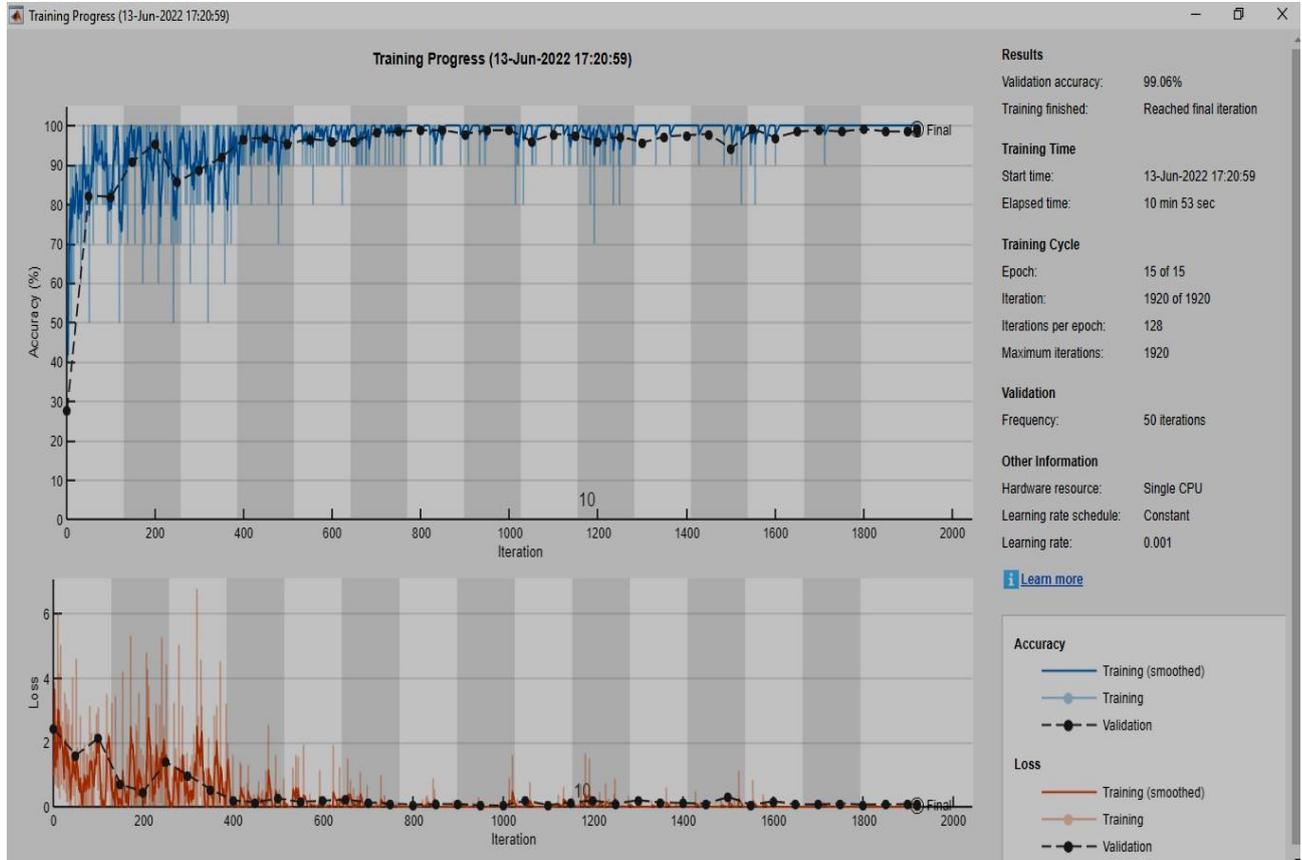


Figure IV. 15: Courbe d’évolution (accuracy and loss) d’apprentissage IRM_ Scanner

Confusion Matrix: BN-FA-Net3

	COVID	COVID1	NORMAL	NORMAL1	
COVID	79 24.7%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
COVID1	0 0.0%	79 24.7%	0 0.0%	1 0.3%	98.8% 1.2%
NORMAL	1 0.3%	0 0.0%	80 25.0%	0 0.0%	98.8% 1.2%
NORMAL1	0 0.0%	1 0.3%	0 0.0%	79 24.7%	98.8% 1.2%
	98.8% 1.2%	98.8% 1.2%	100% 0.0%	98.8% 1.2%	99.1% 0.9%
	COVID	COVID1	NORMAL	NORMAL1	

(a)

Confusion Matrix: BN-FA-Net

	COVID	COVID1	NORMAL	NORMAL1	
COVID	386 24.1%	0 0.0%	7 0.4%	0 0.0%	98.2% 1.8%
COVID1	0 0.0%	395 24.7%	0 0.0%	11 0.7%	97.3% 2.7%
NORMAL	14 0.9%	0 0.0%	393 24.6%	0 0.0%	96.6% 3.4%
NORMAL1	0 0.0%	5 0.3%	0 0.0%	389 24.3%	98.7% 1.3%
	96.5% 3.5%	98.8% 1.2%	98.3% 1.7%	97.3% 2.7%	97.7% 2.3%
	COVID	COVID1	NORMAL	NORMAL1	

(b)

Figure IV.16 : (a) .Matrice de confusion pour split 3, (b). Matrice de confusion globale Pour le jeu de données IRM_Scanner (avec l’option Adam).

B/ Suivant les paramètres NE= 15, MB =10, LR=0,0001 et l'option Sgdm :

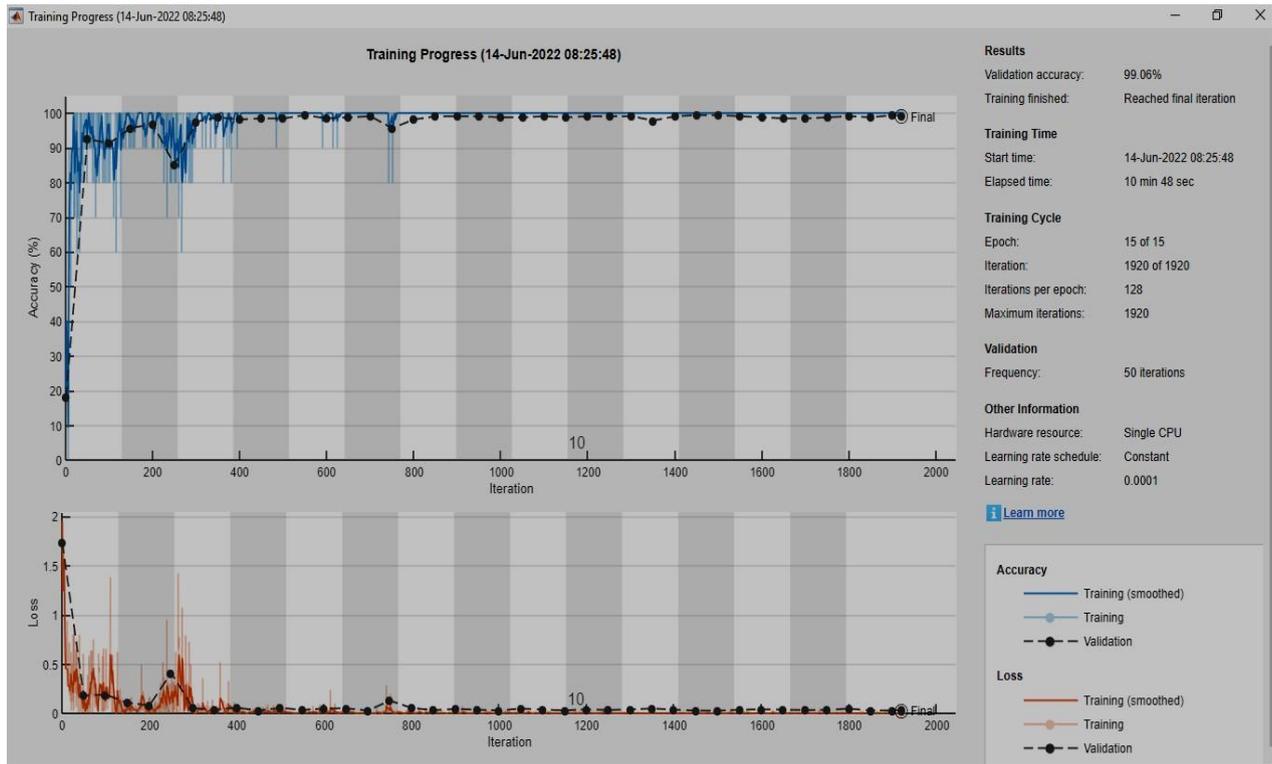


Figure IV.17: Courbe d'évolution (accuracy and loss) d'apprentissage IRM_Scanner (Sgdm)

Confusion Matrix: BN-FA-Net3

COVID	79 24.7%	0 0.0%	2 0.6%	0 0.0%	97.5% 2.5%
COVID1	0 0.0%	80 25.0%	0 0.0%	0 0.0%	100% 0.0%
NORMAL	1 0.3%	0 0.0%	78 24.4%	0 0.0%	98.7% 1.3%
NORMAL1	0 0.0%	0 0.0%	0 0.0%	80 25.0%	100% 0.0%
	98.8% 1.2%	100% 0.0%	97.5% 2.5%	100% 0.0%	99.1% 0.9%
	COVID	COVID1	NORMAL	NORMAL1	

Target Class

(a)

Confusion Matrix: BN-FA-Net

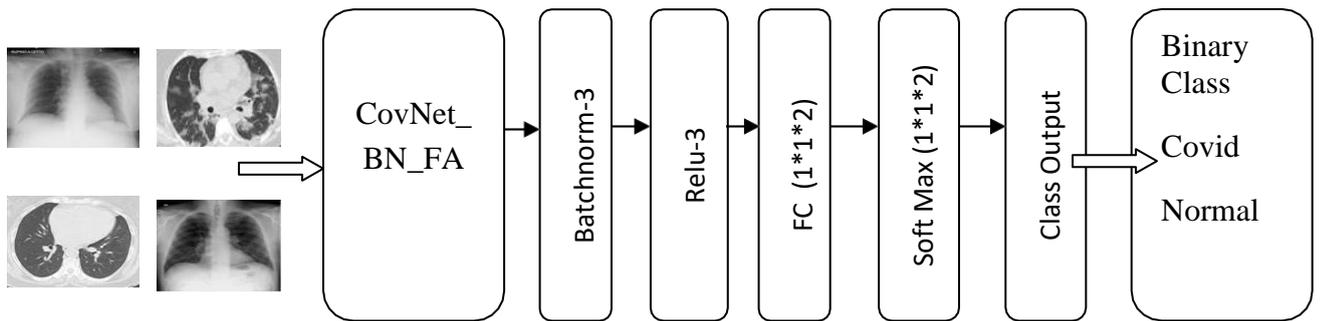
COVID	389 24.3%	0 0.0%	16 1.0%	0 0.0%	96.0% 4.0%
COVID1	0 0.0%	400 25.0%	0 0.0%	4 0.3%	99.0% 1.0%
NORMAL	11 0.7%	0 0.0%	384 24.0%	0 0.0%	97.2% 2.8%
NORMAL1	0 0.0%	0 0.0%	0 0.0%	396 24.8%	100% 0.0%
	97.3% 2.7%	100% 0.0%	96.0% 4.0%	99.0% 1.0%	98.1% 1.9%
	COVID	COVID1	NORMAL	NORMAL1	

Target Class

(b)

Figure IV.18 : (a) .Matrice de confusion pour split 3, (b). Matrice de confusion globale Pour le jeu de données IRM_Scanner (avec l'option Sgdm).

IV.7. Application du modèle pour la base de donnée « Hybrid » :



Chest x-ray and
CT Scan Images
Model

Load pre trained

Training phase

Output

Figure. IV.19: Architecture du modèle proposé pour le pré-entraîner

(Pour la 4^{ème} base de données Hybrid (4classes))

IV.7.1. Résultats obtenus pour la base de donnée « Hybrid » :

Dans ces expériences, nous avons utilisé notre ensemble de données de ChestX_ray et CT Scan pulmonaire préparé pour examiner l'efficacité de notre modèle proposé. Les performances de classification du modèle pour le problème de classification binaire (Normal /Covid) sur les images radiographiques sont fournies dans les tableaux IV.8 et IV.9, respectivement. Les matrices de confusion pour les problèmes de classification binaires des deux options sont présentées aux figures IV.20 et IV. 22, respectivement. Les figures IV.21 et IV.23 montrent les diagrammes de précision et de perte obtenus sur la division 80% pour l'apprentissage et 20% pour la validation.

	Accuracy%	Précision%	Sensitivity%	Specificity%	F1-Score%
Split 1	97.5	96.3	98.7	96.3	98.8
Split 2	98.8	98.1	99.4	98.1	99.4
Split 3	96.6	99.4	94.1	99.3	93.8
Split 4	96.9	99.4	94.1	93.3	93.8
Split 5	98.4	98.8	98.1	98.7	98.1
Moyenne	97.6	98	97.1	98	97.1

Tableau IV.8 : Tableau de performance du modèle pour chaque split de la base de données(Hybrid) pour option « Adam »

	Accuracy%	Précision%	Sensitivity%	Specificity%	F1-Score%
Split 1	93.1	89.4	96.6	90.1	96.9
Split 2	96.9	94.4	98.7	94.6	98.8
Split 3	98.8	98.8	98.8	98.8	98.8
Split 4	98.1	98.8	97.5	98.7	97.5
Split 5	98.1	98.8	97.5	98.7	97.5
Moyenne	96.9	96	97.8	96.1	97.9

Tableau IV.9 : Tableau de performance du modèle pour chaque split de la base de données(Hybrid) pour option « Sgdm »

A/Suivant les paramètres NE= 10, MB=10, LR=0,0001 et l’option Adam :

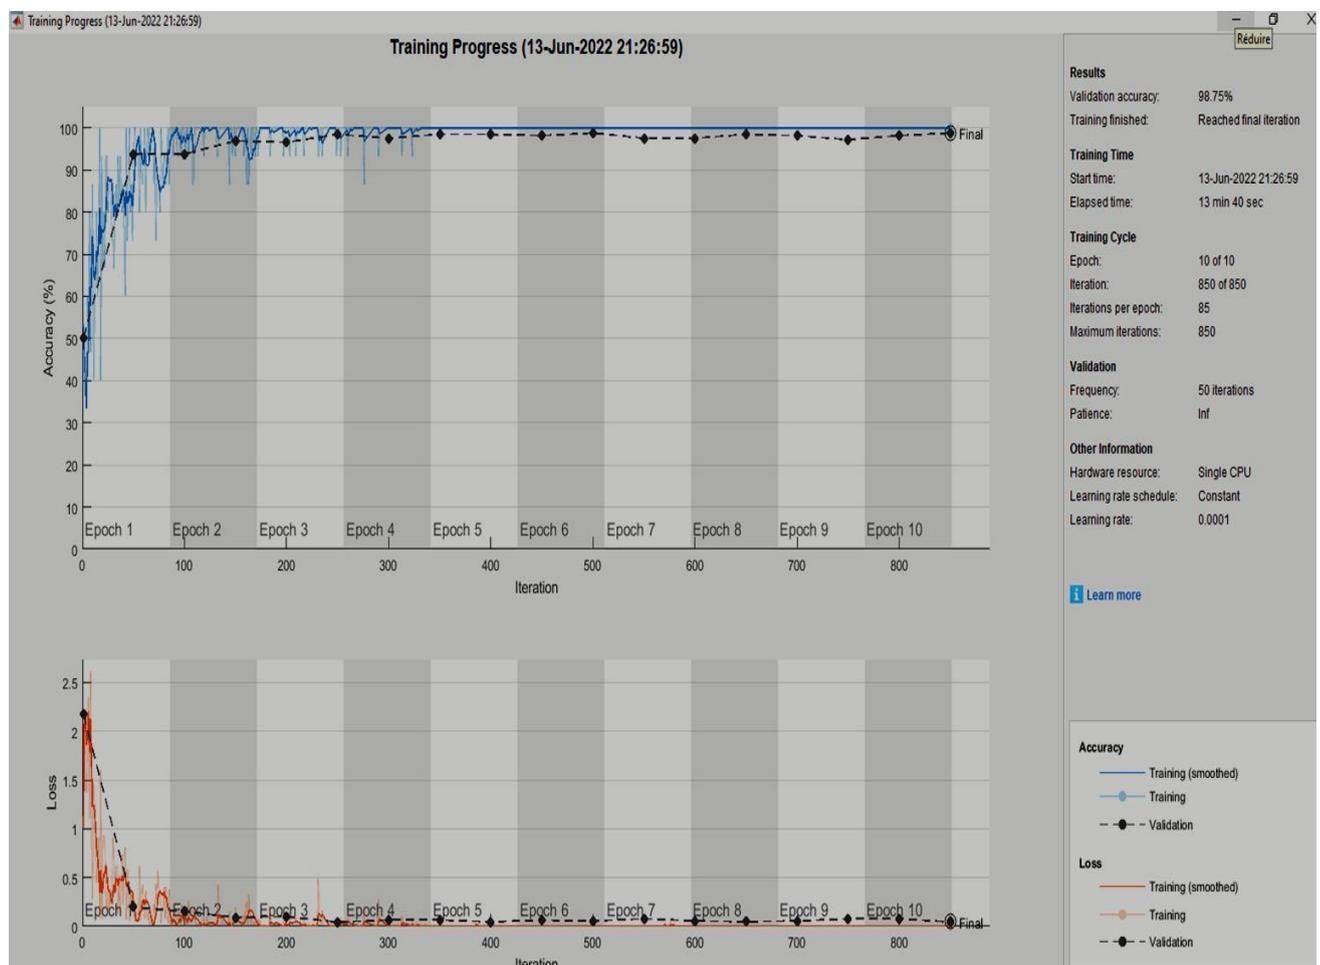
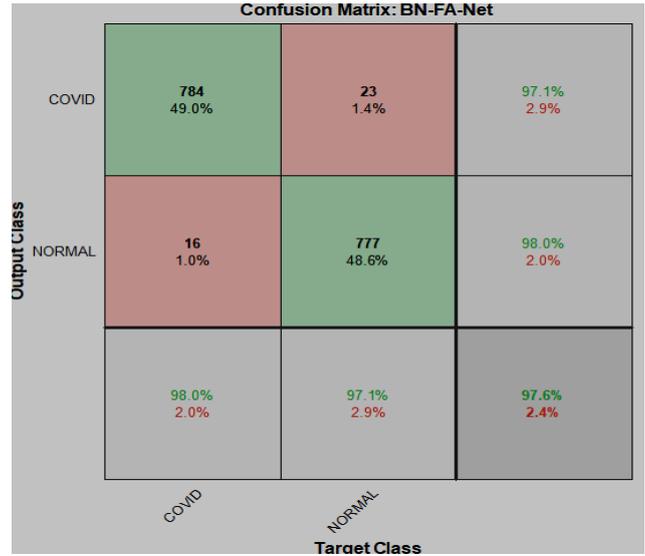


Figure IV.20 : Courbe d’évolution (accuracy and loss) d’apprentissage Hybrid (Adam)



(a)



(b)

Figure IV.21 : (a) Matrice de confusion pour split 2, (b) Matrice de confusion globale Pour le jeu de données Hybrid (avec l'option Adam).

B/ Suivant les paramètres NE =15, MB =10, LR =0,001 et l'option Sgdm :

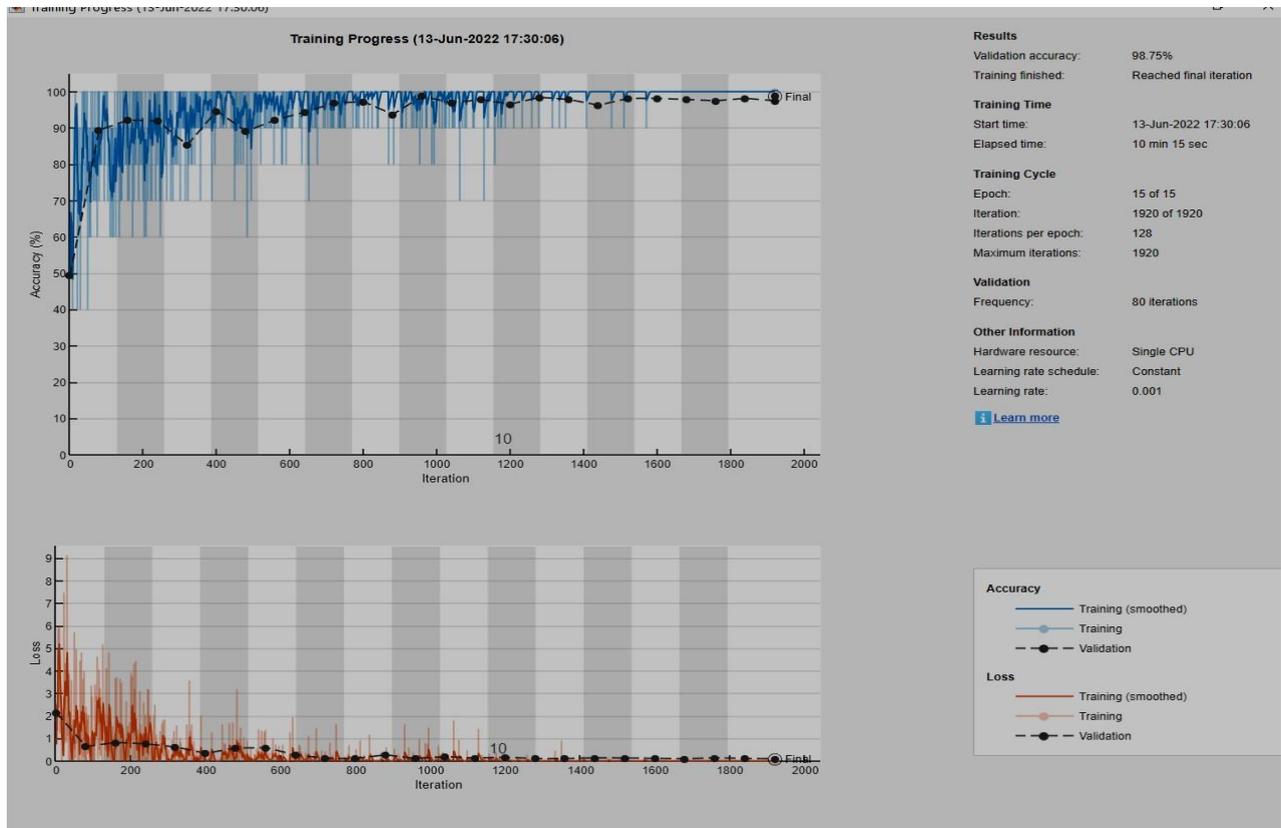
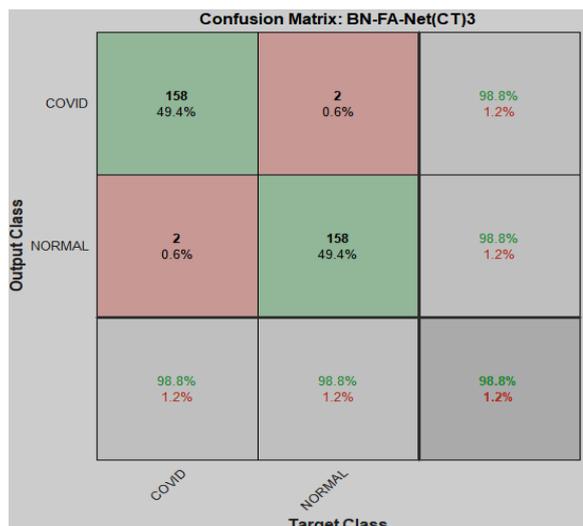
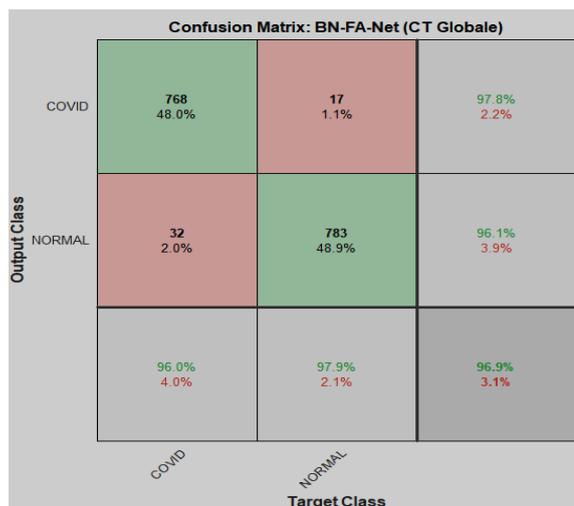


Figure IV.22: Courbe d'évolution (accuracy and loss) d'apprentissage Hybrid (Sgdm)



(a)



(b)

Figure IV.23 : (a) .Matrice de confusion pour split 3, (b). Matrice de confusion globale pour le jeu de données Hybrid (avec l’option Sgdm).

Base de données	Accuracy (%)	
	Option ADAM	Option SGDM
IRM	98.8	99.8
Scanner	99.1	99.8
IRM-Scanner	97.7	98.1
Hybride	97.6	96.9

Tableau IV.10 : Interprétation globale des deux options Adam et Sgdm Pour différentes bases de données.

IV.8 Discussion des résultats obtenus :

Dans nos expériences, nous avons effectué plusieurs tests selon plusieurs paramètres et sur deux bases de données distinctes. Ces tests ont pour objectif de distinguer l’impact de notre modèle proposé sur les performances de reconnaissance. Nous avons aussi mené nos tests selon deux options d’apprentissage : l’option «ADAM » et l’option «SGDM » afin de déterminer

l'option la plus adaptée pour notre modèle. Le tableau IV.10 résume nos meilleurs résultats obtenus.

D'après ces résultats, on peut confirmer l'efficacité de notre modèle proposé qui a été appliqué à des bases de données de nature différentes. On a obtenu des taux de reconnaissance très élevés pour les bases de données des images IRM et scanner où on a obtenu 99.8% et 98.8% respectivement.

Notre modèle proposé a été appliqué sur deux bases de données mélangé entre les deux premières bases ce qui constitue une tâche plus ardue pour notre système proposé. Mais malgré cela, notre modèle proposé a montré ces preuves pour ces deux bases de données en obtenant des scores très encourageants.

De plus, notre approche s'avère adapté pour les deux philosophies d'apprentissage avec une légère avance pour l'option « SGDM ». Cela prouve l'adaptabilité de notre méthode proposée avec les différentes techniques d'apprentissage.

IV.9.Conclusion :

Dans ce chapitre, on a décrit les différentes bases de données tout en utilisant notre modèle de détection pré entraîné. Après avoir terminé la phase d'entraînement et avoir montré les résultats représentés en termes de performance dans les images graphiques et les courbes dans le but de vérifier la validité des résultats obtenus, nous avons testé notre modèle CovNet_BN_FA en fonction des options Adam et Sgdm. Les résultats obtenus sont très encourageants.

CONCLUSION

GENERALE

Conclusion générale:

Durant les dernières années, l'apprentissage profond (Deep Learning) a fait l'objet de nombreuses études et a obtenu des résultats remarquables notamment dans le domaine médical en général et à la classification des images des maladies pulmonaires en particulier. La recherche en apprentissage profond s'efforce toujours de construire de meilleures représentations de la réalité et de créer des modèles capables d'apprendre ces représentations à partir de données non étiquetées à grande échelle. C'est pour cette raison qu'il devient indispensable en raison du grand développement technologique dans tous les secteurs et de la disponibilité des moyens et équipements nécessaires pour l'appliquer.

Dans ce travail, et suivant les modèles prédéfinis on a présenté un nouveau modèle de CNN, appelé (*CovNet_BN_FA*), constitué de quinze couches qui a été adapté à une méthode CNN basée sur l'apprentissage profond qui utilise des images X-ray et CT scan liées à des patients atteints de COVID-19 et à des patients sans COVID-19 pour détecter automatiquement la maladie.

Dans notre recherche, on a conçu ce modèle pour la détection du COVID-19 de manière rapide et précise, où on a obtenu des résultats remarquables par rapport aux autres modèles, ce modèle de classification suggéré est capable d'atteindre une précision de 99,88 %.

Après plusieurs essais, on a trouvé que la précision des modèles CNN améliorés est toujours élevée et les matrices de confusion montrent très peu de faux cas pour la classification binaire d'images. De plus, nous avons utilisé des algorithmes de façon à différencier l'infection par le SARS-COV-2 des autres causes de maladies respiratoires en imagerie.

L'une des conclusions importantes de ce projet est qu'avec un plus grand nombre de bases de données publiques, les modèles de fusion de données peuvent encore augmenter les performances de diagnostic et de prédiction. D'une autre part, notre modèle pourra aider efficacement les virologues à diagnostiquer le COVID-19, aussi augmentera considérablement la compréhension de la biologie grâce à l'intelligence artificielle.

COVID-19 présente une menace pour la communauté mondiale des soins de santé et tue des millions de personnes. En raison du grand nombre de patients vus à l'extérieur ou en urgence, les médecins disposent de peu de temps et l'analyse assistée par ordinateur

pourrait sauver des vies grâce à un dépistage précoce ainsi qu'à des soins appropriés.

Pour conclure, nous souhaitons que ce modèle proposé qui est en phase de test, soit réellement approuvé au niveau des hôpitaux et des centres médicaux et sera mis en œuvre à plus grande échelle dans la lutte contre l'épidémie de COVID-19.

Perspectives « Future Works » :

En tant que travail de perspective future, nous sommes sur le point de penser à combiner d'autres modèles prédéfinis avec ce que nous avons proposé afin d'améliorer considérablement le diagnostic et l'identification des régions suspectées dans les images des cas de COVID-19.

Bibliographie:

- [1]. Sohrabi C, et al. World health organization declares global emergency: A review of the 2019 novel coronavirus (COVID-19) *Int. J. Surg.* 2020; **76:71–76**. Doi: 10.1016/j.ijisu.2020.02.034.
- [2]. World Health Organization. Weekly epidemiological update on COVID-19—29 June 2021, 46th edn. (2021).
- [03].N. Chen, M. Zhou, X. Dong et al. “Epidemiological and clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: a descriptive study,” *The Lancet*, vol. 395, no. 10223, pp. 507–513, 2020.
- [04].T. Struyf, J. J. Deeks, J. Dinnes et al., “Signs and symptoms to determine if a patient presenting in primary care or hospital outpatient settings has COVID-19 disease,” *Cochrane Database of Systematic Reviews*, vol. 7, no. 7, 2020.
- [05].J. Liao, S. Fan, J. Chen et al. “Epidemiological and clinical characteristics of COVID-19 in adolescents and Young adults,” *The Innovation*, vol. 1, no. 1, Article ID 100001, 2020.
- [06]Jaimes JA et al, Phylogenetic Analysis and Structural Modeling of SARS-CoV-2 Spike Protein Reveals an Evolutionary Distinct and Proteolytically Sensitive Activation Loop, *Journal of molecular biology*, doi: 10.1016/j.jmb.2020.04.009.
- [07]. Jaouad Elkhalladi, Techniques radiologiques Viscérales, cours 3em semestre 2014/2015 Institut Supérieur des Professions Infirmières et Techniques de Santé de Agadir.
- [08].Wagner, Robert R. and Krug, Robert M. "Virus". *Encyclopedia Britannica*, 12 Nov. 2020.
- [09].Analyse d’images par méthode de Deep Learning appliquée au contexte routier en conditions météorologiques dégradées KhouloudDahmane le 17 juin 2020, HAL Id: tel-03022934 <https://tel.archives-ouvertes.fr/tel-03022934> Submitted on 25 Nov 2020.
- [10].Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- [11].NicolasLimare,JoseLuisLisani,JeanMichelMorel,AnaBel_enPetro,CatalinaSbert, ‘SimplestColorBalancePublishedinImageProcessingISSN21051232©IPOL,2011.<http://dx.doi.org/10.5201/ipol.2011.llmps-scb>.

- [12].Tealab,Ahmed(201801)."Timeseriesforecastingusingartificialneuralnetworksmethodologies:Asystematicreview".FutureComputingandInformaticsJournal3(2):334–340. Doi:10.1016/j.fcij.2018.10.003. ISSN2314-7288.
- [13].Graves,Alex;Liwicki,Marcus;Fernandez,Santiago;Bertolami,Roman;Bunke,Horst;Schmidhuber,Jürgen(2009)."A Novel Connectionist System for Improved Unconstrained Handwriting Recognition" (PDF). IEEE Transactions on Pattern Analysis and Machine Intelligence .31 (5) : 855–868. CiteSeerX 10.1.1.139.4502. doi:10.1109/tpami.2008.137.PMID19299860.S2CID 14635907.
- [14].vanOtterlo, M.; Wiering, M. (2012). Reinforcement learning and markov decision processes. Reinforcement Learning.Adaptation, Learning, and Optimization. 12. pp. 3–42. Doi: 10.1007/978-3-642-27645-3_1. ISBN 978-3-642-27644-6.
- [15]. Yamashita, R., Nishio, M., Do, R.K.G. and Togashi, K., (2018). Convolutional neural networks: an overview and application in radiology. Insights into imaging, 9(4), pp.611-629.
- [16]. Wiesel et Hubel, «Receptive fields of single neurons in the cat's striate cortex, » The Journal of Physiology, vol. 148, n° 13, p. 574–591, 1959.
- [17].RajendraSantosh AB, Krishnamurthy K, Baddam VRR. Proposal of Research Model for the Detection of COVID-19 among Asymptomatic Carriers.Int Arch Otorhinolaryngol. 2020 Jul; 24(3):e376-e378. Doi: 10.1055/s-0040-1712936. Epub 2020 Jun 2. PMID: 32754250; PMCID: PMC7394606.
- [18].Detection of brain abnormality by a novel Lu-Net deep neural CNN model from MR images.
- [19].Zhang, & Wang, & Xu, Dongdong & Chen, (2019). Research on Scene Classification Method of High Resolution Remote Sensing Images Based on RFPNet. Applied Sciences.9.2028.10.3390/app9102028.
- [20].Deep Convolutional Neural Networks an Introduction <http://mbenhaddou.com/2019/12/23/deep-convolutional-neural-networks-an-introduction/29/05/2021>.
- [21].Salimans, T. and Kingma, D.P., 2016. Weight normalization: A simple reparameterization to accelerate training of deep neural networks. In Advances in neural information processing systems (pp. 901-909).
- [22].Foracchia, M., Grisan, E. and Ruggeri, A., 2005. Luminosity and contrast normalization in retinal images. Medical Image Analysis, 9(3), pp.179-190.

- [23]. Goodfellow, Ian; Bengio, Yoshua; Courville, Aaron (2016). "6.2.2.3 Softmax Units for Multinoulli Output Distributions". *Deep Learning*. MIT Press. pp. 180–184. ISBN 978-0-26203561-3.
- [24]. Murphy, K. P. *Machine Learning: A Probabilistic Perspective*. The MIT Press, Cambridge, Massachusetts, 2012.
- [25]. Kingma, Diederik, and Jimmy Ba. "Adam: A method for stochastic optimization." *arXiv preprint arXiv:1412.6980* (2014).
- [26]. M.E.H. Chowdhury, T. Rahman, A. Khandakar, R. Mazhar, M.A. Kadir, Z.B. Mahbub, K.R. Islam, M.S. Khan, A. Iqbal, N. Al-Emadi, M.B.I. Reaz, M. T. Islam, "Can AI help in screening Viral and COVID-19 pneumonia?" *IEEE Access*, Vol. 8, 2020, pp. 132665 - 132676.
- [27]. Eduardo Soares, Plamen Angelov, Sarah Biaso, Michele Higa Froes, Daniel Kanda Abe "SARS-CoV-2 CT-scan dataset: A large dataset of real patients CT scans for SARS-CoV-2 identification" *medRxiv* 2020.04.24.20078584 doi: <https://doi.org/10.1101/2020.04.24.20078584>.
- [28]. P. D. Ailab, "Evaluation: from Precision, recall and F -measure to ROC, informedness, markedness & correlation," *Machine Learning Technologies*, vol. 2, pp. 37–63, 2011.