

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE KASDI MERBAH OUARGLA
Faculté des Nouvelles Technologies de l'Information et de la Communication



Mémoire

Domaine: Sciences et Technologies

Filière: Télécommunication

Spécialité: Système de Télécommunication

Présenté par:

Nassira Barka

Nour Elhouda Aouni

Thème

Apprentissage profond pour la détection du COVID-19

Soutenue publiquement le: 15/06/2022 devant le jury composé de:

F.CHARIF	Maitre de conférence/A	à l'Université de Ouargla	Président
Kh. BENSID	Maitre de conférence/B	à l'Université de Ouargla	Encadrant
B.NAAM	Doctorant	à l'Université de Ouargla	Co-encadrant
A.LATI	Maitre de conférence/B	à l'Université de Ouargla	Examineur

Année Universitaire : 2021 /2022

Dédicace

Le grand remerciement à Allah qui nous a donné la force et la volonté et de patience pour réaliser ce mémoire.

Nos remercie également mon directeur de mémoire l'enseignant: Dr. Khaled BENSID , pour le temps qu'il a consacré a m'apporter les outils méthodologiques indispensables a la conduite de cette recherche. Et un merci spécial au le professeur Bouhafes NAAM.

*Et les mots sont trop pauvres pour exprimer notre gratitude à nos chers **parents** et ma grande soeur ASMA et mes frères SAAD et Rabeh pour leur aide et leurs encouragements durant toutes les années d'études et tous ma famille AOUNI et BRIKI. Et un merci a mon ami Ibrahim elkhalil pour nous avoir aidé a résoudre nos problèmes au cours des derrières années et pour nous avoir soutenu.*

Sans oublier bien sûr de remercier profondément tous ceux mon binome Nassira Barka et mes collègues Manel, Anissa, Mohamed Larbi, Fares, Fateh, Achref, Anes, Hassen qui ont contribué de près ou de loin à la réalisation de ce travail Et tous les amis universitaires. Et je remercie mon fidèle ami Mostapha, et tous mes amis Meriam, Imene, Roumaissa, Rym, Chaima, Malek, , Djenat, Bouthina, Nour Elfida, Wiam, Marwa, Rania, Zahra, Zohra, Selma, Ismail, Amine, Tarek et un merci très special à la personne la plus chère S qui s'est tenue à mes cotes dans mes joies et mes peines et m'a soutenu. A mon ami Aya cheghli qui est parti et qui est resté dans mon coeur je t'aime.

Tous ceux qui me sont chers, à vous tous Merci.

- Nour Elhouda



Dédicace

Le grand remerciement à Allah qui nous a donné la force et la volonté et de patience pour réaliser ce mémoire.

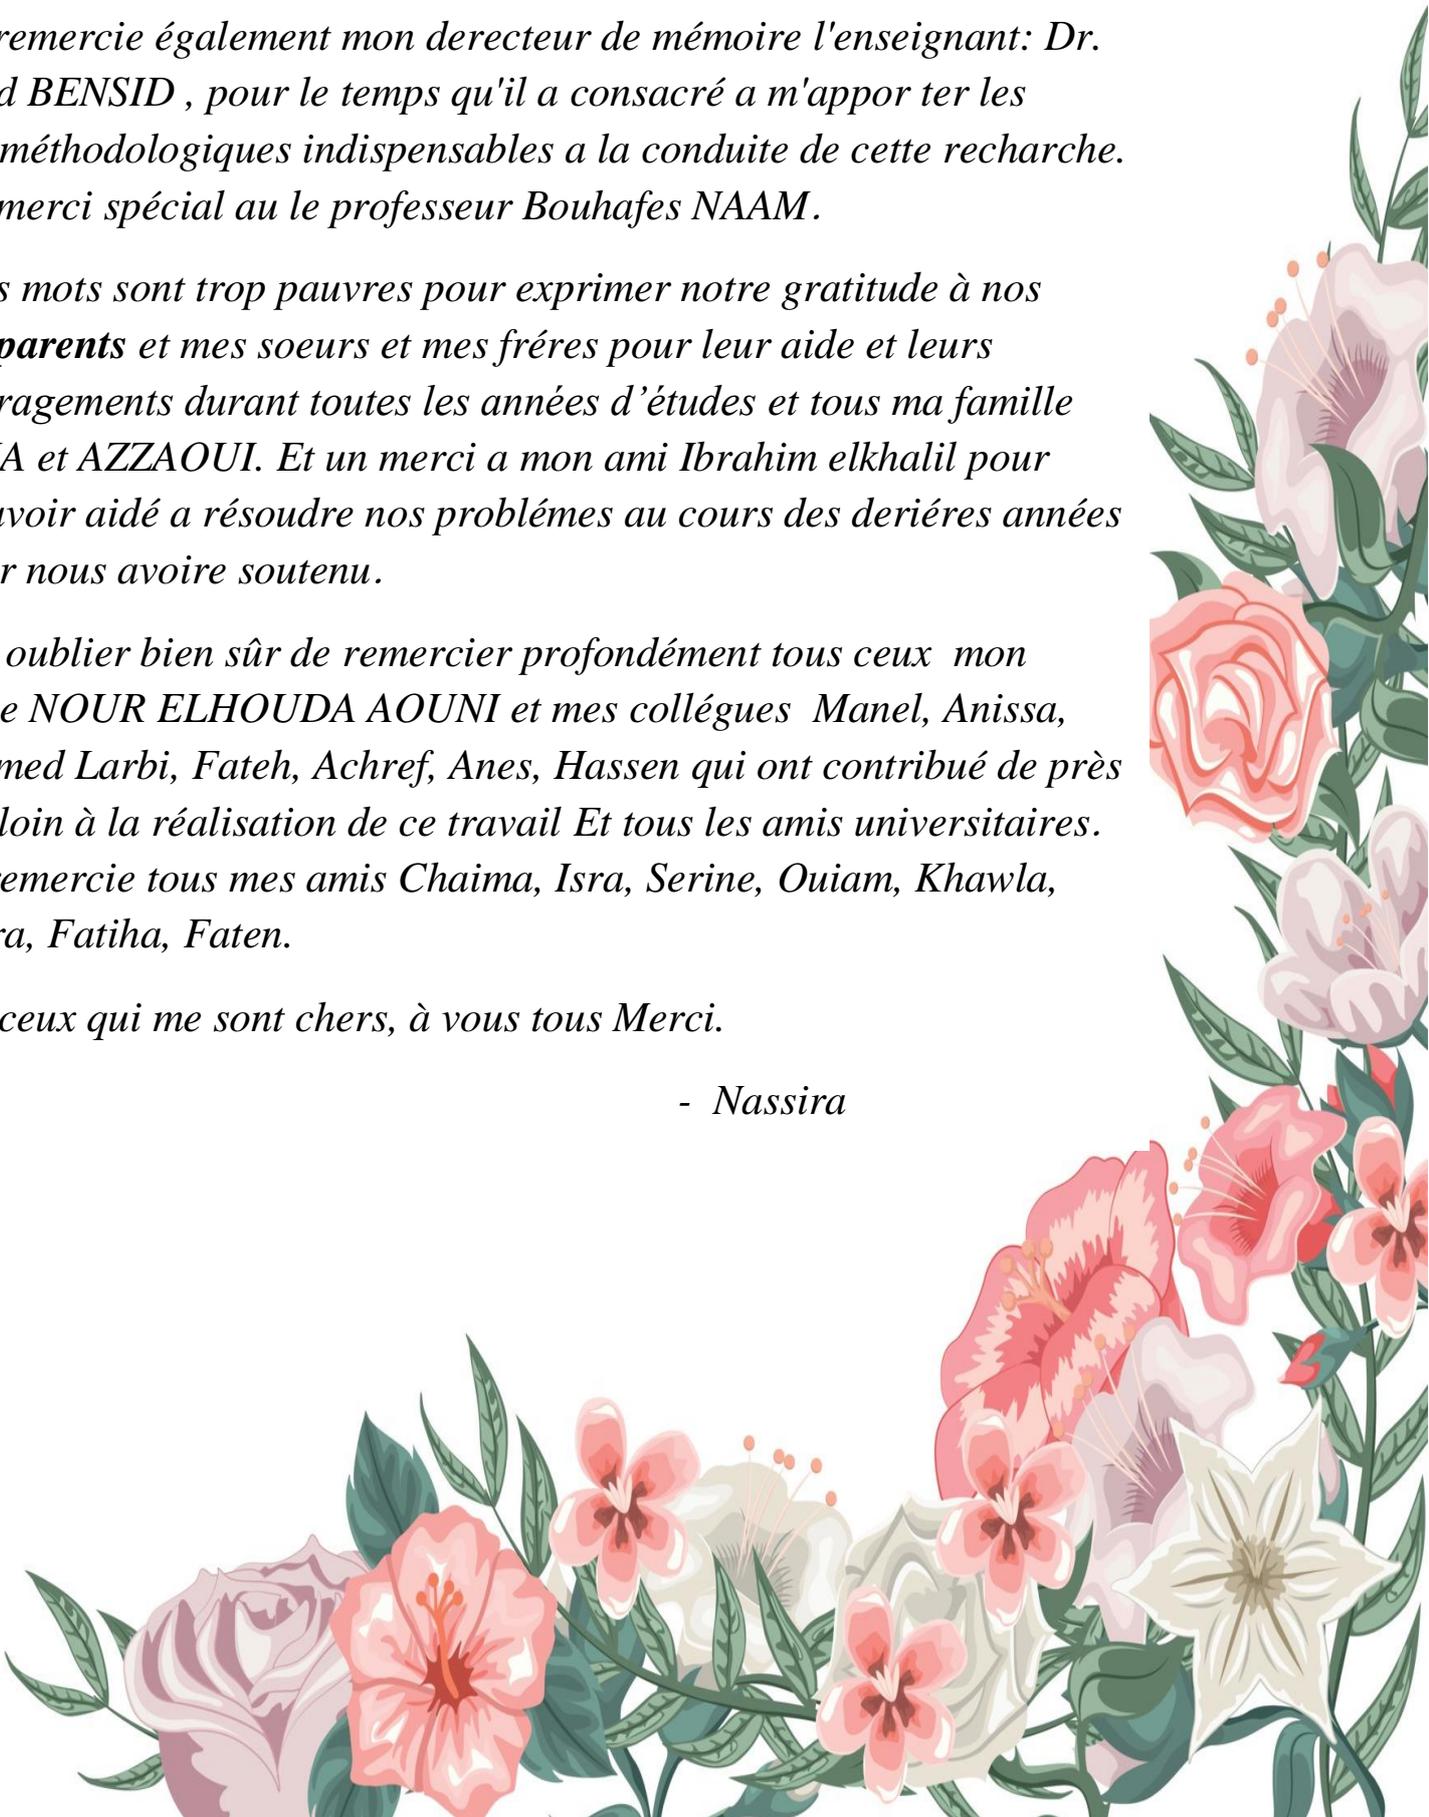
Nos remercie également mon directeur de mémoire l'enseignant: Dr. Khaled BENSID , pour le temps qu'il a consacré a m'apporter les outils méthodologiques indispensables a la conduite de cette recherche. Et un merci spécial au le professeur Bouhafes NAAM.

*Et les mots sont trop pauvres pour exprimer notre gratitude à nos chers **parents** et mes soeurs et mes frères pour leur aide et leurs encouragements durant toutes les années d'études et tous ma famille BARKA et AZZAOU. Et un merci a mon ami Ibrahim elkhalil pour nous avoir aidé a résoudre nos problèmes au cours des derrières années et pour nous avoir soutenu.*

Sans oublier bien sûr de remercier profondément tous ceux mon binome NOUR ELHOUDA AOUNI et mes collègues Manel, Anissa, Mohamed Larbi, Fateh, Achref, Anes, Hassen qui ont contribué de près ou de loin à la réalisation de ce travail Et tous les amis universitaires. Et je remercie tous mes amis Chaima, Isra, Serine, Ouïam, Khawla, Nassira, Fatiha, Faten.

Tous ceux qui me sont chers, à vous tous Merci.

- Nassira



Remerciement

Tout d'abord, je tiens à remercier Allah le Très Miséricordieux de m'avoir donné la patience, le courage et la volonté d'accomplir ce travail de recherche.

Je tiens à exprimer ma profonde gratitude à mon encadreur **M. Bensid Khaled** professeur à l'Université Kasdi-Merbah, Ouargla, pour avoir accepté de diriger et de superviser ce travail. C'est un honneur pour moi de travailler avec lui. Il a mis à ma disposition ses connaissances et sa riche expérience. Je le remercie également pour ses conseils, son orientation, sa documentation, sa disponibilité et sa modestie.

Je tiens également à remercier **Mme. Charif.F**, professeur à l'Université Kasdi-Merbah, Ouargla, pour l'honneur de présider le jury de cette thèse.

Mes remerciements vont également à **M. LATI.A** professeur à l'Université Kasdi-Merbah, Ouargla, pour avoir accepté de juger ce travail.

Ce travail n'aurait pas été possible sans la disponibilité de **M. BOUHAFES Naam** que je tiens à remercier du fond du cœur pour son aide et ses précieux conseils.

Je tiens également à remercier le **centre de recherche scientifique** de l'Université Kasdi-Merbah, Ouargla pour son soutien.

Je tiens à remercier les travailleurs d'**Algérie Télécom** de nous offrir une opportunité de stage.

Enfin, un grand merci à tous ceux qui, de près ou de loin, ont participé sur le terrain à la réalisation de cette thèse.

Résumé

Le monde entier fait face à une crise sanitaire unique en raison de la pandémie de COVID-19. Avec sa propagation continue, le nombre d'infections a atteint 528 millions de personnes dans le monde. Parmi les solutions visant à sauver des vies et à stopper l'éclosion de l'épidémie, l'intelligence artificielle (IA) a été adaptée pour relever les défis posés par cette épidémie. Dans cette étude, les techniques de tomodensitométrie (TDM) ont joué un rôle important dans le diagnostic et l'évaluation du traitement de la maladie. Pour classer COVID-19 comme positif ou négatif, 12 modèles de réseau à convolution profonde (CNN) pré-formés (ResNet18, ResNet50, ResNet101, VGG16, VGG19...etc) ont été utilisés. Les caractéristiques profondes ont également été classées à l'aide d'un classificateur SVM (Supportive Vector Machine).

Deux bases de données ont été formées, où la première base de données contenant 746 images et la seconde contenant 349 images a été utilisée dans l'expérience. La précision de la classification a été utilisée comme mesure de la performance de l'étude. Les travaux expérimentaux révèlent que l'apprentissage en profondeur montre le potentiel d'une détection plus rapide et plus précise du COVID-19 qu'auparavant. Il a produit les caractéristiques de profondeur extraites du modèle ResNet101 avec une précision de 97,85%, ce qui était le plus élevé parmi tous les résultats obtenus. Les résultats ont montré que les méthodes profondes sont très efficaces pour détecter le COVID-19 sur la base d'images de tomodensitométrie thoracique.

Mots clés : Covid-19, Intelligence Artificielle (IA), Techniques De Tomodensitométrie (TDM) Réseau de neurones convolutifs(CNN), Machine à vecteurs de support (SVM).

Abstract

The whole world is facing a unique health crisis due to the COVID-19 pandemic. With its continued spread, the number of infections has reached 528 million people worldwide. Among the solutions aimed at saving lives and stopping the outbreak of the epidemic, artificial intelligence (AI) has been adapted to meet the challenges posed by this epidemic. In this study, computed tomography (CT) techniques played an important role in the diagnosis and treatment evaluation of the disease. To classify COVID-19 as positive or negative 12 pre-trained deep convolutional network models (CNN) (ResNet18, ResNet50, ResNet101, VGG16, VGG19...etc) were used. Deep features were also classified using an SVM (Supportive Vector Machine) classifier.

Two databases were trained, where the first database containing 746 images and the second containing 349 images were used in the experiment. Classification accuracy were used as a measure of study performance. Experimental work reveals that deep learning shows the potential for faster and more accurate detection of COVID-19 than before. It produced the depth features extracted from the ResNet101 model with an accuracy of 97.85%, which were the highest among all the results obtained. The results showed that deep methods are highly effective in detecting COVID-19 based on chest CT images.

Keywords : Covid-19, Artificial Intelligence (AI), Computed Tomography (CT), Convolutional Neural Network (CNN), Support Vector Machine (SVM).

ملخص

يواجه العالم كله أزمة صحية فريدة من نوعها بسبب جائحة كوفيد-19. ومع استمرار انتشاره ، وصل عدد الإصابات به إلى 528 مليون شخص على مستوى العالم. من بين الحلول التي تهدف إلى إنقاذ الأرواح ووقف تفشي الوباء ، تم تكييف الذكاء الاصطناعي (AI) لمواجهة التحديات التي يفرضها هذا الوباء. في هذه الدراسة ، لعبت تقنيات التصوير المقطعي (CT) دوراً مهماً في تشخيص المرض وتقييم العلاج. لتصنيف كوفيد-19 على أنه إيجابي أو سلبي ، تم استخدام 12 نموذج شبكة تلافيفية عميقة مدربة مسبقاً (CNN) (ResNet18 ، ResNet50 ، ResNet101 ، VGG16 ، VGG19 ... إلخ). تم تصنيف الميزات العميقة أيضاً باستخدام مصنف SVM (آلة المتجه الداعمة).

وتم تدريب قاعدتي بيانات ، حيث تم استخدام قاعدة البيانات الأولى التي تحتوي على 746 صورة والثانية تحتوي على 349 صورة في التجربة. تم استخدام دقة التصنيف كمقياس لأداء الدراسة. يكشف العمل التجريبي أن التعلم العميق يُظهر إمكانية الكشف بشكل أسرع وأكثر دقة عن COVID-19 من ذي قبل. أنتج السمات العميقة المستخرجة من نموذج ResNet101 بدقة 97.85% ، والتي كانت الأعلى بين جميع النتائج التي تم الحصول عليها. أظهرت النتائج أن الطرق العميقة فعالة للغاية في اكتشاف COVID-19 بناءً على صور الصدر المقطعية.

كلمات مفتاحية : كوفيد-19, الذكاء الاصطناعي, التصوير المقطعي المحسوب, شبكة عصبية تلافيفية, آلة المتجه الداعمة

Table des matières

Remerciement	III
Résumé	IV
Abstract	V
VI	ملخص
Introduction générale	1
1 L'image Numérique et L'imagerie Médical	4
1.1 Introduction	5
1.2 Définition de l'image	5
1.3 Acquisition d'une image	6
1.3.1 Caractéristiques d'une image numérique	6
1.4 Domaine d'application du traitement d'images numériques	10
1.5 L'imagerie médicale	11
1.5.1 Les types d'image médicale	11
1.5.2 L'effet du le bruit a l'imagerie médicale	21
1.5.3 La segmentation d'images	21
1.6 Conclusion	22
2 Détection de covid-19	23
2.1 Introduction	24
2.2 Étiquette et forme covid 19	24
2.3 Les symptômes de la maladie Covid-19	25
2.4 La tomодensitométrie (TDM)	26
2.5 les méthodes de classification	26
2.5.1 Le réseaux de neurones convolutifs	27
2.5.2 La machine à vecteurs de support(SVM)	39
2.6 Conclusion	40
3 Expériences, Résultats et Discussions	41
3.1 Introduction	42
3.2 Détection COVID-19	43
3.3 Méthodologie proposée	43
3.3.1 Première méthode	44
3.3.2 Deuxième méthode	44

Table des matières

3.4	Matériel et méthodes	45
3.4.1	Base de données COVID-19	45
3.4.2	Les évaluation des performances	45
3.5	Analyse des résultats et discussions	47
3.5.1	UCSD base de données	47
3.5.2	CT covid base de données	57
3.6	Conclusion	62
	Conclusion et point de vue	63
	Bibliographie	65

Table des figures

1.1	Lettre 'A' affichée comme un groupe de pixel	7
1.2	Un histogramme	9
1.3	Image médicale	11
1.4	Scanner d'IRM	12
1.5	Rayon X de la main	13
1.6	L'échographie	16
1.7	L'imagerie nucléaire	18
1.8	La Scintigraphie	18
1.9	l'imagerie Dentisterie	20
2.1	Une image montrant la forme du coronavirus.	24
2.2	Les principaux symptômes du coronavirus.	25
2.3	Les réseaux de neurones convolutifs.	28
2.4	Les couches de CNN.	28
2.5	AlexNet architecture Design	30
2.6	MobileNetV2 architecture.	30
2.7	GoogLeNet architecture	31
2.8	Illustration of the network architecture of VGG19 model	31
2.9	VGG16 architecture	32
2.10	Nasnet Normal and Reduction Cell Architecture	32
2.11	Architecture of NASNetlarge.	33
2.12	deep residual network block that used in Resnet family	34
2.13	Xception architecture	35
2.14	Inception-ResNetV2 architecture	36
2.15	InceptionV3 Architecture.	36
2.16	SqueezeNet Architecture	37
2.17	The building unit of the ShuffleNet architecture	38
2.18	DenseNet network architecture	39
3.1	Schéma des modèles pour détecter le Covid-19.	43
3.2	Présentation de graphique à barres de la précision (accuracy%) du les mo- deles CNN.	48
3.3	Un processus de formation de ResNet-18.	49
3.4	Un processus de formation de ResNet-50.	50
3.5	Un processus de formation de SqueezeNet	50
3.6	Un processus de formation de NasNet Large.	51
3.7	Matrice de confusion de ResNet-18.	52
3.8	Matrice de confusion de ResNet-50.	52

3.9	Présentation de graphique à barres de Avg Acc(%) du les modeles CNN. . .	54
3.10	Matrice de confusion ResNet-50.	55
3.11	Matrice de confusion ResNet-101.	55
3.12	Matrice de confusion ResNet-18.	56
3.13	Présentation de graphique à barres de la précision (accuracy%) du les modeles CNN.	57
3.14	Un processus de formation de ResNet-101.	58
3.15	Un processus de formation de DenseNet.	59
3.16	Un processus de formation de ResNet-18.	59
3.17	Un processus de formation de AlexNet.	60

Liste des tableaux

3.1	Matrice de confusion.	46
3.2	Présentation de précision de différents modèles de classification utilisant les caractéristiques profondes de divers modèles CNN.	48
3.3	Classification de les modeles CNN par Extraction de caractéristique et la classification par SVM.	53
3.4	Précision de différents modèles de classification utilisant les caractéristiques profondes de divers modèles CNN.	57
3.5	les meilleur performance(Accuracy%) de les méthodes proposé.	61

Liste des sigles et acronymes

AemphAnalyse en Composantes Principales

PPP	<i>points par pouce</i>
DPI	<i>dots per inch</i>
IRM	<i>Imagerie par résonance magnétique</i>
TEP	<i>La tomographie par émission de positons</i>
NAS	<i>Neonatal abstinence syndrome</i>
RVB	<i>Rouge Vert Bleu</i>
FC	<i>Fréquence Cardiaque</i>
CNN	<i>Convolutional Neural Network</i>
IA	<i>L'intelligence artificielle</i>
CT	<i>Computed Tomography</i>
TDM	<i>Le scanner ou tomodensitométrie</i>

Introduction générale

Contexte

Le coronavirus est une maladie causée par un virus appelée COVID-19. La condition est maintenant une pandémie (ou propagation mondiale) et a tué de nombreuses personnes dans différents pays. Corona affecte souvent le système respiratoire, et l'agent causal de la maladie, le virus COVID-19, est partagé entre humains et animaux. Une nouvelle génération des coronavirus se sont propagés dans une région de La Chine qui a fait des milliers de morts jusqu'à présent. La dernière version des coronavirus se propager à des spécimens humains en décembre 2019 à Wuhan, en Chine. Le coronavirus est le cible du système respiratoire humain, donc il y a des récepteurs à la surface de notre les cellules du système respiratoire utilisées par le virus pour entrer dans les sections de cette zone. En général, la présence du coronavirus peut être dangereuse si une personne a une maladie chronique ou a poumons enflammés et maladies respiratoires telles comme l'asthme, ou si une personne a un système immunitaire affaibli. Symptômes importants de le virus chez l'homme comprend la fièvre, la toux, respiration rapide, essoufflement, douleur gorge et nez qui coule. Autres symptômes du coronavirus comprennent des frissons, des courbatures, maux de tête, diarrhée, nausées et vomissements. Selon des recherches antérieures, comparées aux personnes d'âge moyen et âgées avec COVID-19, il a été constaté que les enfants ou des jeunes présentant des symptômes modérés sont plus faciles à traiter, et ces les propriétés sont facilement prouvées. Selon à une mission conjointe de l'Organisation mondiale de la santé internationale (OMS) et la vérité chinoise Finder, le bilan des morts de 5,8% à Wuhan à 0,7% dans d'autres parties de la Chine. Plus des décès surviennent chez les patients âgés ou ceux avec une maladie sous-jacente (cardiovasculaire, diabète, maladie pulmonaire chronique, hypertension pression et cancer) [1].

Apprentissage automatique, apprentissage en profondeur et approches basées sur l'IA ont été utilisés pour la détection et la classification de diverses maladies. Ainsi, comme alternative, les solutions basées sur l'IA peut fournir des solutions efficaces qui peuvent aider à l'apprentissage de caractéristiques/modèles à partir d'images de tomodensitométrie, ce qui peut augmenter les capacités des radiologues dans une meilleure prise de décision et une gestion plus efficace de la situation. Les modèles de Deep Learning, basés sur CNN sont très efficace et ont montré des résultats prometteurs dans divers applications d'imagerie. CNN a rendu possible la développement d'architectures de réseaux de neurones profonds de plusieurs couches intermédiaires. Contrairement au traditionnel Algorithmes d'apprentissage automatique, où les caractéristiques d'entrée sont doit être alimenté en entrée de l'algorithme, CNN a automatique fonctionnalités d'apprentissage. Améliora-

tions technologiques en termes de traitement de données volumineuses et de haut débit. Les unités de traitement graphique (GPU) ont joué le rôle de catalyseur en augmentant les performances. L'apprentissage en profondeur basé sur CNN les modèles ont montré des résultats prometteurs dans divers domaines et sont fondamentales pour presque toutes les tâches de reconnaissance d'images. [2].

Problématique

Plusieurs tests sont disponibles pour détecter ce virus. Un test d'anticorps est effectué en prélevant un échantillon de sang. Cela peut généralement être fait avec une piqûre au doigt ou du sang prélevé dans une veine du bras. Le test PCR permet aussi de déterminer si l'on est porteur du Covid-19 au moment du prélèvement, et c'est le test de référence le plus sensible pour diagnostiquer l'infection mais les personnes qui le réussissent souffrent un peu. Tous ces tests et d'autres prennent du temps pour détecter la maladie et coûtent cher.

Objectifs

Les radiographies pulmonaires (CT scan) sont connues pour leur capacité à surveiller et à examiner diverses maladies pulmonaires, telles que l'épanchement, l'atélectasie et la pneumonie. Avec l'augmentation rapide de la propagation du virus Corona, une solution est nécessaire pour accélérer le processus de détection des personnes infectées par cette maladie.

Les méthodes d'apprentissage en profondeur ont été largement utilisées en imagerie médicale. En particulier, les réseaux de neurones convolutifs (CNN) ont été utilisés à la fois pour les problèmes de classification et de segmentation, ainsi que pour les images en coupe [3]. Cependant, les images CT des poumons appelées COVID-19 et pas COVID-19 peuvent être facilement classées, en particulier lorsqu'il y a des dommages causés par une pneumonie dus à différentes causes en même temps.

Dans la deuxième étape, une machine vectorielle (SVM) a été utilisée après avoir utilisé l'extraction de fonctionnalités (feature extraction) Covid-19 pour montrer d'autres caractéristiques dans les images CT. Pour la classification, l'extension SVM est utilisée pour le classificateur basé sur l'apprentissage en profondeur, ce dernier nécessitant un grand ensemble de données pour la formation et la validation. Ces étapes ont également contribué à la détection rapide du COVID-19. L'objectif principal de notre travail est de détecter COVID-19 sur des images CT utilisant les techniques de l'apprentissage profond.

Organisation du mémoire

Ce mémoire est organisé en trois chapitres :

Le premier chapitre, nous avons parlé du traitement d'images, l'image est une représentation d'une personne ou d'une chose avec des caractéristiques particulières. Nous utilisons des images dans plusieurs domaines, le numérique et la robotique, la télédétection, l'imagerie médicale, et cette dernière est connue comme un mélange de méthodes d'acquisition et de compensation, des images de le corps humain de différents phénomènes physiques, et il en existe plusieurs types.

Le deuxième chapitre, aborde la définition du covid comme un virus dangereux qui apparaît au microscope sous forme de peluches et présente de nombreux symptômes dont les plus dangereux sont ceux affectant le système respiratoire.

Le troisième chapitre, nous avons détaillé la détection rapide À propos de COVID-19 en utilisant l'intelligence artificielle et la tomographie. Nous avons expliqué la méthode approuvée. Les images modifiées ont été testées et classées de deux manières, la première avec cnns uniquement, et la seconde en ajoutant l'extraction featur et svm. Nous avons utilisé deux ensembles de données et déterminé un ensemble de normes de classification avec eux et analysé leurs résultats. C'est le meilleur dans le résultat de la notation.

Chapitre 1

L'image Numérique et L'imagerie Médical

1.1 Introduction

Le traitement d'image est un domaine très vaste qui a connu, et qui connaît encore, un développement important au cours des dernières décennies. Le traitement d'image est l'une des disciplines de l'informatique et des mathématiques appliquées qui extraient des informations d'images numériques et améliorent leur qualité. En fait, cette spécialisation est requise par tous les secteurs scientifiques (physique, biologie, médecine, astronomie, automatique,...).

Et par traitement d'image, nous entendons que toutes les opérations appliquées à une image numérique convertissent une image unique en une forme améliorée ou en extraient des informations utiles. Avec un ensemble d'informations organisées par une fonction (x,y) , une image s'est avérée représenter une personne ou une chose, par exemple, nous trouvons que l'imagerie médicale est la plus utile pour une personne, elle vise à améliorer son diagnostic de la maladie. C'est aussi considéré comme un moyen d'obtenir une image du corps humain et de la restituer à partir de phénomènes physiques.

Dans ce chapitre, nous avons consacré l'étude à l'imagerie médicale.

1.2 Définition de l'image

L'image est une représentation d'une personne ou d'un objet par la peinture, la sculpture, le dessin, la photographie, le film,...etc. C'est aussi un ensemble structuré d'informations qui, après affichage sur l'écran, ont une signification pour l'œil humain.

Elle peut être décrite sous la forme d'une fonction $I(x, y)$ de brillance analogique continue, définie dans un domaine borné, tel que x et y sont les coordonnées spatiales d'un point de l'image et I est une fonction d'intensité lumineuse et de couleur. Sous cet aspect, l'image est inexploitable par la machine, ce qui nécessite sa numérisation [4].

1.3 Acquisition d'une image

L'étude de cette étape passe inmanquablement par le système d'acquisition qui fait référence : l'œil. On utilise plus couramment des caméras vidéo, ou récemment pourquoi pas des appareils photos numériques. En médecine, on utilise des imageurs IRM, TEP, scanner X, écho doppler, échographie, scintigraphie,...etc.

Tous ces systèmes peuvent être comparés à des capteurs. Il ne faut pas oublier qu'il y a une étape de conversion analogique/numérique. C'est souvent cette étape qui limite la résolution de l'image.

L'une des caractéristiques intéressantes de ces capteurs est la taille du plus petit élément (pixel) [4].

1.3.1 Caractéristiques d'une image numérique

L'image est un ensemble structuré d'informations caractérisé par les paramètres suivants [4] :

1.3.1.1 Pixel

Contraction de l'expression anglaise « Picture éléments » : éléments d'image, le pixel est le plus petit point de l'image, c'est une entité calculable qui peut recevoir une structure et une quantification. Si le bit est la plus petite unité d'information que peut traiter un ordinateur, le pixel est le plus petit élément que peuvent manipuler les matériels et logiciels d'affichage ou D'impression. La lettre A, par exemple, peut A affichée comme un groupe de pixels dans la figure ci-dessous (Fig 1.1) [4] :

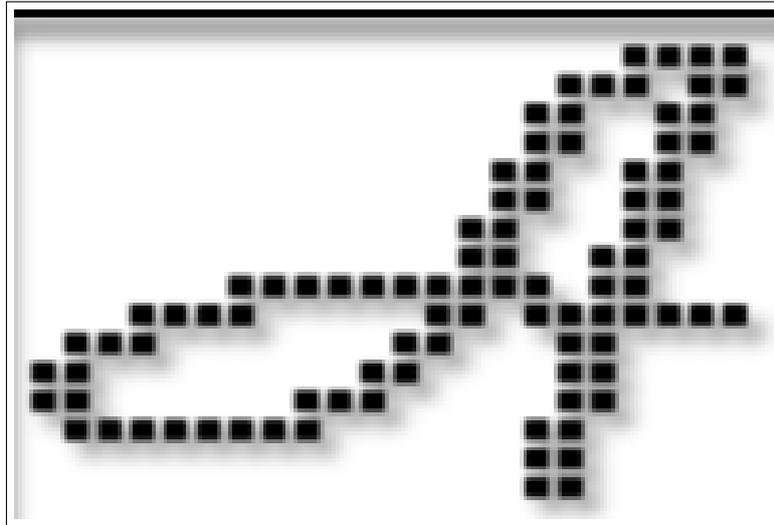


FIG. 1.1 : Lettre 'A' affichée comme un groupe de pixel

La quantité d'information que véhicule chaque pixel donne des nuances entre images Monochromes et images couleurs. Dans le cas d'une image monochrome, chaque pixel est codé sur un octet, et la taille mémoire nécessaire pour afficher une telle image est directement liée à la taille de l'image.

Dans une image couleur (R.V.B.), un pixel peut être représenté sur trois octets : un octet pour chacune des couleurs : rouge (R), vert (V) et bleu (B) [4].

1.3.1.2 Dimension

C'est la taille de l'image. Cette dernière se présente sous forme de matrice dont les éléments sont des valeurs numériques représentatives des intensités lumineuses (pixels). Le nombre de lignes de cette matrice multiplié par le nombre de colonnes nous donne le nombre total de pixels dans une image [4].

1.3.1.3 Résolution

C'est la clarté ou la finesse de détails atteinte par un moniteur ou une imprimante dans la Production d'images. Sur les moniteurs d'ordinateurs, la résolution est exprimée en nombre de pixels par unité de mesure (pouce ou centimètre), elle peut s'exprimer en DPI (« dots per inch » : points par pouce) ou en PPP (points par pouce). On utilise aussi le mot résolution

pour désigner le nombre total de pixels affichables horizontalement ou verticalement sur un moniteur ; plus grand est ce nombre, meilleure est la résolution.

Le choix de la résolution dépend de la destination finale de l'image : la résolution d'un écran informatique (moniteur) est de 72 DPI ; en conséquence, toute image destinée à l'affichage sur l'écran ne nécessite qu'une résolution de 72 voire 75 DPI. Dans le cas d'une numérisation, on peut calculer avec précision la résolution idéale. Pour affichage à écran, la formule de calcul est : Taille de destination (en points) / Taille d'origine (en pouces) [4].

1.3.1.4 Bruit

Le bruit est un terme issu du domaine de l'acoustique et désigne un signal parasite. Que ce soit pour le son ou pour l'image, le principe est identique : sur tout signal de base vient s'adjoindre un ensemble d'informations parasites aléatoires.

Un bruit (parasite) dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins. Sur une image, le bruit est particulièrement visible dans les zones sombres. Pourquoi ? Simplement car le capteur perçoit moins de lumière et dispose donc de moins d'informations électriques. Si le signal diminue, la proportion de bruit augmentera. La solution : éclairer. De la même manière, la sensibilité influe sur la qualité de l'image car le capteur n'est pas nativement apte à supporter de hautes sensibilités. Plus on augmente la sensibilité et plus la mesure de la lumière sera approximative, donc plus le signal sera amplifié, tout comme le bruit par la même occasion [4].

1.3.1.5 Histogramme

L'histogramme des niveaux de gris ou des couleurs d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (couleur) dans l'image. Pour diminuer l'erreur de quantification, pour comparer deux images obtenues sous des éclairages différents, ou encore pour mesurer certaines propriétés sur une image, on modifie souvent l'histogramme correspondant. L'histogramme est une courbe en deux dimensions pour laquelle l'axe vertical représente le nombre de pixel de l'image ou

encore la proportion de ces pixel dans l'image, tandis que l'axe horizontal représente l'ensemble des valeurs de luminosité potentielles de l'image comme se présente la figure ci-dessous (Fig 1.2) :

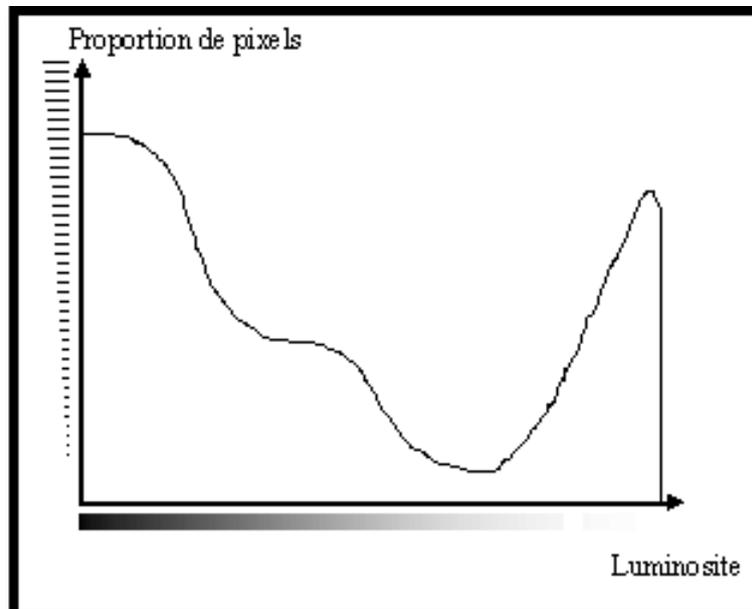


FIG. 1.2 : Un histogramme

Il permet de donner un grand nombre d'information sur la distribution des niveaux de gris (couleur) et de voir entre quelles bornes est répartie la majorité des niveaux de gris (couleur) dans les cas d'une image trop claire ou d'une image trop foncée. Il peut être utilisé pour améliorer la qualité d'une image (Rehaussement d'image) en introduisant quelques modifications, pour pouvoir extraire les informations utiles de celle-ci [4].

1.3.1.6 Contours

Les contours représentent la frontière entre les objets de l'image, ou la limite entre deux pixels dont les niveaux de gris représentent une différence significative. Les textures décrivent la structure de ceux-ci. L'extraction de contour consiste à identifier dans l'image les points qui séparent deux textures différentes [4].

1.3.1.7 Luminance

C'est le degré de luminosité des points de l'image. Elle est définie aussi comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface, pour un observateur lointain, le mot luminance est substitué au mot brillance, qui correspond à l'éclat d'un objet. Une bonne luminance se caractérise par :

- Des images lumineuses (brillantes).
- Un bon contraste : il faut éviter les images où la gamme de contraste tend vers le blanc ou le noir ; ces images entraînent des pertes de détails dans les zones sombres ou lumineuses. - L'absence de parasites [4].

1.3.1.8 Contraste

C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des luminances de deux zones d'images. Si L_1 et L_2 sont les degrés de luminosité respectivement de deux zones voisines A_1 et A_2 d'une image, le contraste C est défini par le rapport [4] :

$$C = \frac{L_1 - L_2}{L_1 + L_2} \quad (1.1)$$

1.4 Domaine d'application du traitement d'images numériques

Dès que l'on obtient une image et que l'on veut en extraire des informations, cela se fait par : Transmission numérique, robotique, automatisation de tâches, télédétection, imagerie médicale, assistance opérateur.

Selon l'évolution du traitement d'images à travers le domaine des techniques d'images croisées, il s'agit d'un domaine de recherche dans une activité complétée qui couvre un champ d'applications très large, dont l'imagerie médicale, qui a en elle-même opéré une mutation significative du médium. Qui a aidé dans le diagnostic précis des maladies internes de l'être humain.

1.5 L'imagerie médicale

L'imagerie médicale regroupe les moyens d'acquisition et de restitution d'images du corps humain à partir de différents phénomènes physiques tels que : l'absorption des rayons X, la résonance magnétique nucléaire, la réflexion d'ondes ultrasons ou la radioactivité. On associe parfois à l'imagerie médicale les techniques d'imagerie optique comme l'endoscopie. Les techniques de l'imagerie médicale sont considérées surtout comme outil diagnostique, elles sont aussi largement utilisées dans la recherche biomédicale [5].

1.5.1 Les types d'image médicale

Parmi les méthodes d'imagerie médicales les plus couramment employées en médecine, on peut citer d'une part les méthodes tomographiques basés soit sur les rayons X (radiologie conventionnelle, tomodynamomètre ou CT-scan, angiographie,...) soit sur la résonance magnétique (IRM), les méthodes échographiques utilisant les ultra-sons, et enfin les méthodes optiques utilisant les rayons lumineux [5].



FIG. 1.3 : Image médicale

À gauche, des poumons normaux ; à droite, les poumons d'une personne qui a la COVID-19.

1.5.1.1 Les champs magnétiques (Institut Royal Météorologique)

L'imagerie par résonance magnétique (IRM) permet de visualiser la structure anatomique de Tout volume du corps, en particulier des tissus mous tels que le cerveau, la moelle épinière, les viscères, les muscles ou les tendons. (IRM anatomique).

L'IRM permet aussi de suivre l'activité d'un organe tel le cerveau, à travers l'afflux de sang oxygéné e dans certaines de ses zones (IRM fonctionnelle) [5].



FIG. 1.4 : Scanner d'IRM

- [La radioactivité](#)

La radioactivité utilise les rayons X. Passant à travers une certaine partie du corps, ils impressionnent un film radiographique, plus ou moins noirci en fonction de l'organe traversé. La radio ressemble ainsi à une ombre chinoise, ou les os apparaissent en blanc et les structures moins denses (comme les poumons) en noir [5].

1.5.1.2 Les rayons X

Les rayons X ont été découverts par hasard en 1895 par Wilhelm Röntgen qui étudiait les rayons cathodiques dans un tube à décharge gazeuse sous haute tension. Bien que ce tube fût enchâssé dans un boîtier de carton noir, Röntgen nota qu'un écran de Platinocyanure de Baryum, placé par hasard à proximité, émettait une lumière fluorescente lorsque le tube fonctionnait. Après avoir effectué d'autres expériences, il conclut que cette fluorescence était causée par un rayonnement invisible d'une nature plus pénétrante que le rayonnement ultraviolet.

Comme il ne trouva pas de dénomination adéquate pour ces rayons, Röntgen les baptisa « Rayons X ». Notons au passage que ce rayonnement est encore souvent appelé en Allemagne Röntgenstrahlung. Peu après la découverte des rayons X, leur capacité à traverser le corps humain fut mise en évidence et donnèrent naissance aux premières images médicales.

Le premier cliché est celui de la main d'Anna Bertha Röntgen (22 décembre 1895); il s'agit de la première radiographie, la radiologie est née [5].



FIG. 1.5 : Rayon X de la main

Différents types d'examens utilisent les rayons X :

- [La Radiographie Conventioneelle](#)

Le terme « Radiographie » peut désigner l'ensemble des techniques permettant de réaliser les clichés des structures internes d'un patient ou d'un composant mécanique et ce, à l'aide de rayons X. L'application la plus courante est la radiographie médicale dans laquelle les clichés traduisent l'opacité plus ou moins marquée des tissus ou organes par une teinte plus ou moins claire. Sachant que le étudié par un faisceau de rayons X ; Ceux-ci viennent frapper et corps est composé de tissus dits "mous" c'est à dire peu opaques aux rayons X (comme la peau, la graisse, les muscles) et de tissus plus opaques (les os essentiellement), le procédé de radiographie consiste à faire traverser un corps imprimer une matrice de détecteurs photosensibles. L'image est créée par la différence d'opacité des tissus due aux rayons X. Les procédés d'acquisitions radiographiques mesurent la quantité de rayons X parvenant sur les détecteurs et donc, pour les tissus traversés, leur coefficient d'absorption de rayons X. La radiographie est encore le plus souvent réalisée sur film, celui-ci étant disposé dans une cassette protectrice derrière ou sous le corps exposé. Néanmoins, l'exclusivité de la radiographie sur film est généralement réservée aux « Tables d'Os » qui sont dédiées uniquement à l'examen osseux. La plupart des systèmes d'imagerie médicale proposent désormais une numérisation de l'image réalisée par une transformation des rayons X en électrons via une couche d'iodure de césium (CsI).

Cette radiologie numérique permet des applications de télé radiologie où le médecin qui interprète les images se trouve à distance, éloigné du lieu où s'effectue l'examen (parfois même dans un autre pays). Des applications de cette technologie sont effectives dans certains hôpitaux des Etats-Unis où des radiologues, situés en Inde font une première analyse des clichés [5].

- [La Tomodensitométrie \(Scanner\)](#)

Le scanner, également appelé tomographe axial assisté par ordinateur (TAO), est un dispositif de radiographie associant rayons X et traitement Informatique permettant d'obtenir, par des mesures de densité, une image des plans de coupe d'un objet, en particulier du corps humain. Inventé par le Britannique Godfrey Hounsfield dans les années 1970, le scanographe — appelé également scanner en raison de l'analyse par balayage qu'il effectue

(de l'anglais scanning) reconstitue l'image du corps en mesurant la densité des rayonnements X à travers le corps humain sous différents angles.

Le dispositif est constitué d'une source de rayons X, ou générateur, d'un couple émetteur-détecteur et d'un appareil de balayage, le tout étant relié à un système de traitement informatique et à une console permettant de visualiser et, éventuellement, d'archiver les images. Le détecteur est composé d'un scintillateur et d'un photomultiplicateur ; dans les premiers équipements, on employait des cristaux d'iodure de sodium, remplacés aujourd'hui par un gaz rare, comme le xénon, placé dans une chambre d'ionisation.

Il existe différents systèmes de balayage. Dans l'un d'eux, le couple émetteur-détecteur effectue un mouvement de translation, puis une rotation d'un angle α , ceci jusqu'à $n\alpha = 180^\circ$ (n étant le nombre de rotations). Les densités ensuite déterminées sont converties en « unités Hounsfield ».

Actuellement, la plupart des grands hôpitaux sont équipés de scanners qui révèlent les tumeurs cancéreuses du foie, du cerveau, du poumon, des reins et qui décèlent les hernies discales. La scanographie permet de distinguer par exemple les kystes, les masses de sang, de graisse, de calcium. Elle a totalement révolutionné la radiologie, en particulier en neurologie. En outre, l'examen est indolore et presque sans danger pour le patient [5].

- [L'angiographie](#)

L'angiographie est une technique d'imagerie médicale dédiée à l'étude des vaisseaux sanguins qui ne sont pas visibles sur la radiographie standard. On parle d'artériographie pour l'exploration des artères et de phlébographie pour celle des veines. L'angiographie est un examen basé sur l'injection d'un produit de contraste lors d'une imagerie par rayons X. Sa signification littérale est « imagerie des vaisseaux ».

Cette technique utilise les rayons X et un produit de contraste « radio-opaque ». Celui-ci peut être constitué soit d'Iode (élimination par les reins) soit de dioxyde de carbone (CO_2). Son principe consiste à rendre visibles (ou opaques) les vaisseaux artériels ou veineux. Un cathéter est introduit dans le vaisseau pour injecter le produit de contraste qui se mélange au sang : le système vasculaire devient visible sur les clichés radiologiques grâce aux propriétés radio-opaques de l'iode. L'artériographie peut concerner n'importe quelle artère du corps. Pour une exploration cardiaque, on

parlera de coronarographie ; pour celle carotidienne et céphalée, on parlera de neuro-angiographie [5].

1.5.1.3 Les Images Ultrasonores

- L'échographie

L'échographie est une technique médicale consistant à visualiser certains organes à l'aide de sons à haute fréquence (les Ultrasons). Les sons réfléchis par les organes sont analysés par ordinateur de façon à produire une image sur un écran ou une photographie. Les sons sont émis par un cristal à oscillation rapide dont la fréquence se situe entre 18 et 20 kHz. Ces vibrations du cristal durent un millionième de seconde et se produisent 500 fois par seconde. On utilise une sonde, en contact étroit avec la peau, pour émettre les sons et recevoir les échos. La peau est également enduite de gel pour améliorer l'acoustique. L'air, les os et les tissus calcifiés absorbent la quasi-totalité des faisceaux d'ultrasons. Cet examen n'est donc pas utile pour diagnostiquer les atteintes osseuses ou pulmonaires. En revanche, les fluides sont de bons conducteurs d'ultrasons, si bien que cette technique est utilisée pour examiner les kystes et des organes tels que la vessie, le système biliaire ou visualiser le fœtus dans le sac amniotique.

L'échographie peut également servir aux examens du réseau artériel, du cœur, du pancréas, de la cavité péritonéale, de l'appareil urinaire, des ovaires, du système veineux, du cerveau et de la moelle épinière. L'examen du fœtus pendant la grossesse est pourtant son utilisation la plus courante [5].



FIG. 1.6 : L'échographie

- [L'échocardiographie](#)

Est l'application de la technique des ultrasons à l'examen du cœur. Elle est utilisée pour étudier les maladies cardiaques congénitales, les affections coronariennes, les tumeurs cardiaques et d'autres troubles du cœur. L'échographie est également utilisée pour guider les interventions chirurgicales comme l'amniocentèse ou au cours des biopsies délicates. À la différence des rayons X, l'échographie n'est pas contre-indiquée pendant la grossesse puisqu'elle ne présente aucun risque, ni pour la mère, ni pour l'enfant. Elle permet de suivre la croissance et le développement du fœtus, de s'assurer de sa bonne santé et de préciser le terme du bébé car il est possible de déterminer l'âge exact du fœtus en mesurant son tour de tête [5].

1.5.1.4 L'imagerie Nucléaire

La découverte de la radioactivité artificielle en 1934 par Irène et Frédéric Joliot-Curie a été à l'origine de l'émergence d'une discipline médicale nouvelle, la médecine nucléaire. Cette découverte a conduit à la production des isotopes radioactifs des éléments constituant de la matière vivante et à leur utilisation comme traceurs. L'élément radioactif est totalement indiscernable de son homologue stable naturel, sauf pour l'une de ses propriétés : il est capable de manifester sa présence dans l'ensemble des atomes par un rayonnement électromagnétique ou particulaire émis lors de sa désintégration.

La médecine nucléaire est l'ensemble des applications médicales des radios traceurs ou source radioactives. Cette technique se distingue de la plupart des autres modalités médicale par le fait qu'elle apporte des images physiologique plutôt qu'anatomique. Des molécules dont le comportement biologique est connu sont introduites dans le corps du patient de la façon appropriée au test en cours : injecté, avalé, inhalé etc. Leur comportement est alors étudié par le biais de l'imagerie par émission [5].

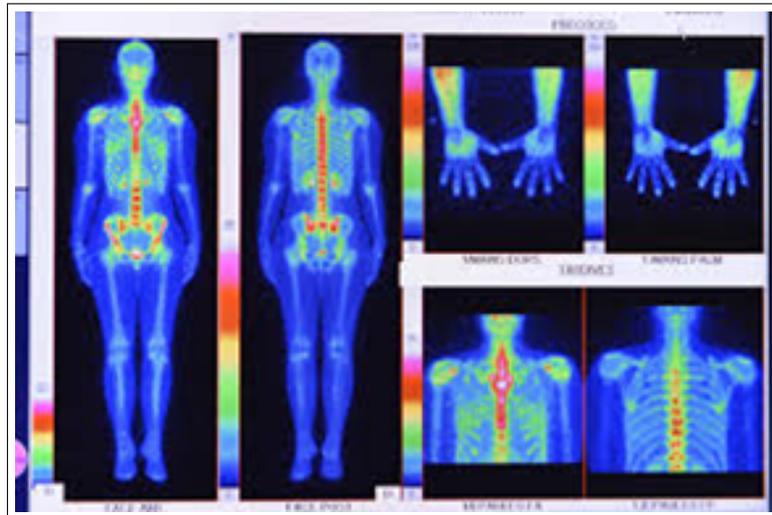


FIG. 1.7 : L'imagerie nucléaire

- [La Scintigraphie](#)

La scintigraphie est une méthode d'imagerie médicale qui procède par l'administration, dans l'organisme, d'isotopes radioactifs afin de produire une image médicale par la détection des rayonnements émis par ces isotopes après captation par les organes à examiner. Les différents traceurs utilisés sont spécifiques et capables de se fixer sélectivement sur l'organe que l'on désire étudier. Une caméra à scintillation, détectant la radioactivité, se déplace selon un axe longitudinal et transversal au-dessus de l'organe étudié. Les informations sont ensuite présentées sous la forme d'un document photographique, en noir et blanc, parfois artificiellement colorisé pour augmenter les contrastes [5].



FIG. 1.8 : La Scintigraphie

a- La Scintigraphie Thyroïdienne

La scintigraphie thyroïdienne repose sur l'utilisation d'un produit radioactif qui se fixe sélectivement sur la thyroïde pour une recherche d'une anomalie morphologique ou fonctionnelle. Deux radioéléments sont utilisés pour cet examen : l'iode-123 et le technétium-99m. A l'aide de la scintigraphie thyroïdienne, il est possible de visualiser des régions de la thyroïde qui captent moins le traceur (hypofixations appelées nodules froids) ou qui captent plus le traceur (hyperfixations appelées nodules chauds) [5].

b- La Scintigraphie Osseuse

La scintigraphie osseuse repose sur la fixation dans les structures osseuses de molécules phosphatées marquées au technétium-99m. Le radio pharmaceutique est injecté par voie intraveineuse et aucune préparation particulière du patient n'est nécessaire avant l'examen. Le traceur circule dans le sang et sa captation par le squelette est maximale au bout de trois heures, ce qui impose un temps d'attente équivalent entre l'injection et le début de l'examen [5].

c- La Scintigraphie Cardiaque

La scintigraphie cardiaque permet d'évaluer la circulation du sang au niveau du muscle cardiaque (évaluation de la perfusion) et donne des renseignements sur sa fonction et ses capacités de contraction. La comparaison de la fixation du radio traceur dans le muscle cardiaque pour deux examens, un d'effort et un de repos, permet de diagnostiquer ou d'exclure des maladies cardiaques. Les traceurs radioactifs couramment utilisés pour cet examen sont le Thallium-201 et le Technétium-99m.

1.5.1.5 La Tomographie par Emission de Positons

En médecine nucléaire, la tomographie par émission de positons¹ (TEP) est une méthode qui permet de mesurer l'activité métabolique d'un organe grâce aux émissions produites par les positons issus de la désintégration d'un produit radioactif injecté au préalable. La TEP repose sur le principe général de la scintigraphie qui consiste à injecter un traceur qui est généralement sous forme de glucose. Ce traceur est marqué par un atome radioactif qui émet des positons dont l'annihilation produit elle-même des photons. La détection de la trajectoire de ces photons par le collimateur de la caméra TEP permet de localiser le lieu de leur émission et donc la

concentration du traceur en chaque point de l'organe. Cette information quantitative est représentée sous la forme d'une image faisant apparaître les zones de forte concentration du traceur.

Ainsi la TEP permet de visualiser les activités du métabolisme des cellules : on parle d'imagerie fonctionnelle par opposition aux techniques d'imagerie dite structurale comme celles basées sur les rayons X (radiologie ou scanner) qui réalisent des images de l'anatomie. Par conséquent, la tomographie par émission de positons est un outil diagnostique qui permet de déceler certaines pathologies qui se traduisent par une altération de la physiologie normale comme les cancers ; en effet, Comme les cellules tumorales sont plus actives que les cellules normales, elles consomment davantage de glucose. La TEP permet ainsi d'obtenir des images précises de la répartition du glucose radioactif dans l'organisme et donc de localiser des cellules cancéreuses La TEP est aussi utilisée en recherche biomédicale, par exemple en imagerie cérébrale où elle permet de révéler les régions actives du cerveau lors de différentes activités cognitives [5].

1.5.1.6 Dentisterie

Les techniques d'imagerie médicale sont également utilisées en chirurgie dentaire. Grâce à elles, les dentistes peuvent déceler les pathologies à un stade précoce. Les deux principales techniques d'imagerie utilisées en dentaire sont la radiographie et la tomographie par ordinateur (CT) [5].



FIG. 1.9 : l'imagerie Dentisterie

1.5.2 L'effet du le bruit a l'imagerie médicale

Le bruit comme tout dispositif de mesure physique, les données sont entachées de bruit. Il provient à la fois du patient (agitation thermique des protons à l'origine d'émissions parasites) et de la chaîne de mesure (convertisseurs analogique-numérique, antenne,...etc.).

Le bruit est le signal aléatoire provenant du système de l'environnement, Il est toujours présent. A noter que le bruit dans l'imagerie médicale n'est pas un parasite. Il est généralement souhaitable pour la luminosité de l'image (ou la densité du film) d'être uniforme, sauf là où il passe à former une image. Il existe, cependant, les facteurs qui ont tendance à produire des variations de la luminance d'une image affichée même si aucun détail de l'image n'est présent. Cette variation est généralement aléatoire et n'a pas de modèle particulier. Dans de nombreux cas, il réduit la qualité de l'image qui est particulièrement importante lorsque les objets étant imagés, petites et de faible contraste. Cette variation aléatoire de luminosité de l'image est désigné comme bruit [6].

1.5.3 La segmentation d'images

La segmentation d'images est un domaine de recherche en pleine activité qui couvre un champ d'application très vaste (Imagerie médicale, Robotique, Imagerie Satellitaire...etc.).

En imagerie médicale la segmentation d'organe est si répandu qu'il serait difficile d'énumérer la liste des organes communément segmentés, mais en général la liste inclurait au moins ce qui suit : Le cerveau, le cœur, le foie et les vaisseaux sanguins.

La segmentation d'image médicale consiste à associer à chaque voxel de l'image médicale une étiquette ou un label indiquant ainsi le type de tissu ou la structure anatomique, la collection d'étiquettes produite à travers le processus de segmentation s'appelle la carte d'étiquettes(Labelmap) [5].

1.6 Conclusion

Dans ce chapitre, nous avons présenté le traitement d'image que est un l'ensemble des techniques permettant de modifier une image dans le but de l'améliorer ou d'en extraire des informations. Premièrement nous avons étudié l'image est une représentation d'une personne ou d'un objet, et ses caractéristiques. Puis L'imagerie médicale est certainement l'un des domaines de la médecine qui a progressé ces vingt dernières années, et un élément essentiel à l'étude des maladies. Ensuite nous avons mentionné les techniques d'imagerie médicale et leurs types qui sont d'une grande importance dans la détection des maladies humaines.

Chapitre 2

Détection de covid-19

2.1 Introduction

Les virus provoquent des infections respiratoires chez l'homme, y compris des rhumes légers et rarement mortels, dont le coronavirus 19.

Le virus Corona est apparu dans la ville chinoise de Wuhan en décembre 2019 et a provoqué la plus grande pandémie du millénaire. Il est également considéré comme une urgence sanitaire mondiale car il affecte gravement le système respiratoire et le corps humain. Cette maladie s'est largement propagée et a infecté des millions de personnes dans le monde, ce qui a incité les médecins à utiliser des radiographies pulmonaires pour détecter cette maladie, en particulier au niveau des poumons. Les avantages de l'imagerie thoracique peuvent être obtenus grâce à des méthodes d'imagerie médicale telles que les tomodensitogrammes et les rayons X, et les avantages des tomodensitogrammes à rayons X comprennent un examen approprié de la maladie et de son emplacement.

2.2 Étiquette et forme covid 19

Le nom « coronavirus » est dérivé de (latin : corona) et (« korōnē », qui signifie couronne ou couronne), et signifie également couronne ou halo. Le nom fait référence à l'apparence caractéristique des virions (la forme infectieuse du virus) qui apparaît au microscope électronique, car ils ont un feuillage / villosités de grandes saillies de surface bulbeuses, les montrant comme une couronne de roi ou une couronne solaire (Figure 2.1). Cette formation se produit via les fibrinogènes de l'épave virale (S), qui sont des protéines qui remplissent la surface du virus et déterminent le tropisme d'un hôte [7].



FIG. 2.1 : Une image montrant la forme du coronavirus.

2.3 Les symptômes de la maladie Covid-19

Les symptômes du COVID-19 sont similaires à ceux d'autres rhumes et grippes, et les principaux symptômes du coronavirus par rapport à d'autres maladies comprennent [7] :

- Fièvre.
- inflammation de la gorge.
- toux.
- Fatigué.
- Inflammation pulmonaire.

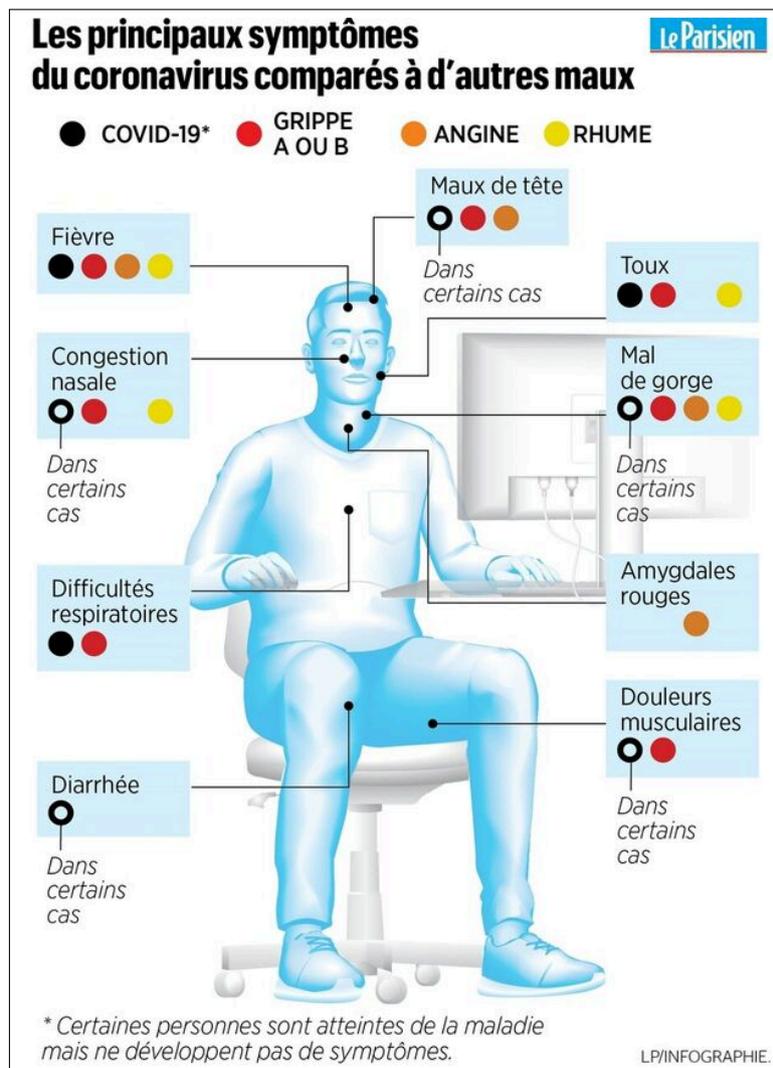


FIG. 2.2 : Les principaux symptômes du coronavirus.

Afin d'identifier les infections dans les poumons, en particulier de Covid, les médecins utilisent des radiographies pulmonaires médicales dans la détection rapide de COVID-19. Les caractéristiques d'imagerie thoracique peuvent être obtenues par des méthodes d'imagerie médicale telles que les tomodensitométries et les rayons X, et les avantages des tomodensitométries par rapport aux rayons X comprennent un examen approprié de la maladie et son emplacement.

2.4 La tomodensitométrie (TDM)

La tomodensitométrie (Eng : Computed tomography (CT)) est une approche d'imagerie non invasive pour aider au diagnostic précoce de la pneumonie. Cependant, la maladie à coronavirus 2019 (COVID-19) partage des caractéristiques d'imagerie similaires avec d'autres types de pneumonie, ce qui rend le diagnostic différentiel problématique. L'intelligence artificielle (IA) a fait ses preuves dans le domaine de l'imagerie médicale, ce qui a aidé à identifier les maladies. Cependant, la question de savoir si l'IA peut être utilisée pour identifier la gravité du COVID-19 est encore sous-déterminée.

Il est également connu que la tomodensitométrie est plus sensible et spécifique que la spectroscopie à rayons X et peut identifier l'implication interstitielle pulmonaire dans les premiers stades de COVID-19. Il est souvent utilisé chez les patients présentant une forte suspicion clinique de COVID-19 pour le dépistage et le diagnostic initial de pneumonie, bien qu'un scanner thoracique n'exclue pas le COVID-19 [8].

2.5 les méthodes de classification

Il y a deux méthodes différents de classification : les réseaux de neurones convolutifs (CNN) et les machines à vecteurs de support (SVM) ont été utilisés. Ces méthodes ont été largement rapportées et démontrées comme des méthodes efficaces de classification. La description de chacun de ces modèles de classification est donnée ci-dessous :

2.5.1 Le réseaux de neurones convolutifs

Un type particulier de perceptron multicouche est le réseau neuronal convolutif (Eng : Convolutional Neural Network, également connu sous le nom de CNN) , mais un simple réseau de neurones ne peut pas apprendre des fonctionnalités complexes, contrairement à une architecture d'apprentissage en profondeur. Les CNN ont montré d'excellentes performances dans de nombreuses applications, telles que la classification d'images, la détection d'objets et l'analyse d'images médicales. L'idée principale derrière un CNN est qu'il peut obtenir des caractéristiques locales à partir d'entrées de couche supérieure et les transférer vers des couches inférieures pour des caractéristiques plus complexes. Un CNN comprend des couches convolutionnelles, de mise en commun et entièrement connectées(FC) [7].

2.5.1.1 Architectures de réseaux de neurones profonds

La vision par ordinateur évolue rapidement de jour en jour. Une des raisons est le développement de l'apprentissage en profondeur. Lorsque nous parlons de vision par ordinateur, un terme réseau de neurones convolutionnel. Désignés par l'acronyme CNN de l'anglais Convolutional Neural Network, ils comportent deux parties bien distinctes :

La première partie d'un CNN est la partie convolutive à proprement parler. Elle fonctionne comme un extracteur de caractéristiques des images. Une image est passée à travers d'une succession de filtres, ou noyaux de convolution, créant de nouvelles images appelées cartes de convolutions .certains filtres intermédiaires réduisent la résolution de l'image par une opération de maximum local. En fin, les cartes de convolutions sont mises à plat et concaténées en un vecteur de caractéristiques, appelé code CNN. Ce code CNN en sortie de la partie convolutive est ensuite branché en entrée d'une deuxième partie, constituée de couches entièrement connectées. Le rôle de cette partie est de combiner les caractéristiques du code CNN pour classer l'image. La sortie est une dernière couche comportant un neurone par catégorie. Les valeurs une distribution de probabilité sur les catégories, Une architecture CNN typique à la Fig2.3 [7].

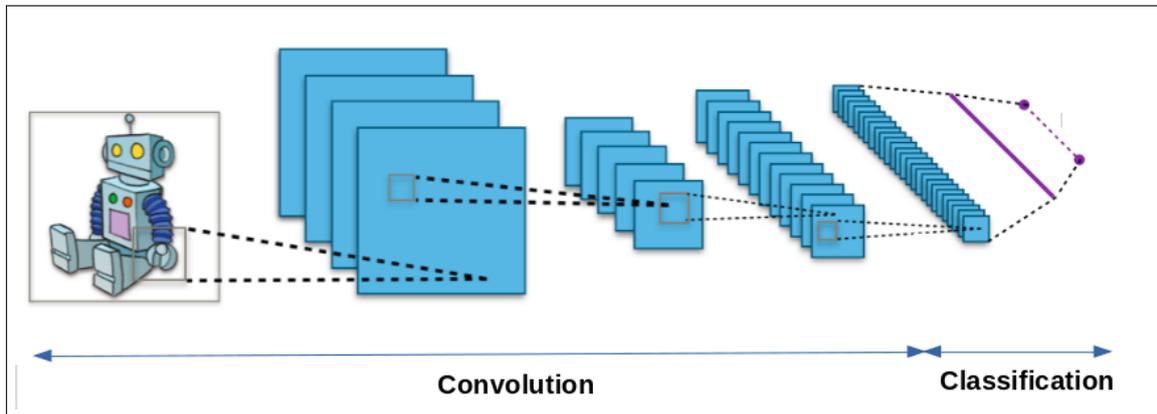


FIG. 2.3 : Les réseaux de neurones convolutifs.

2.5.1.2 Les couches de réseaux de neurones convolutifs

Il y a plusieurs couches différentes dans CNN comme le montre la figure 2.4 [7].

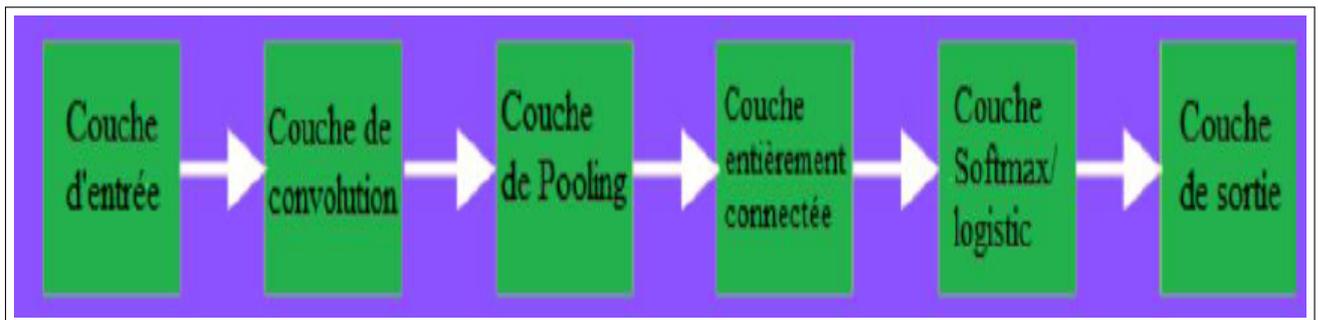


FIG. 2.4 : Les couches de CNN.

- **La couche de convolution (CONV)** c'est la couche la plus importante et le coeur des éléments constitutifs du réseau convolutif, et c'est aussi elle qui effectue le plus de calculs lourd, car les caractéristiques de l'image sont extraites dans cette couche [7].
- **La couche de Pooling** est utilisée pour réduire le volume spatial de l'image d'entrée après la convolution. Sa fonction est de réduire progressivement la taille spatiale de la représentation pour réduire le nombre de paramètres et de calculs dans le réseau, et donc de contrôler également le overfitting [7].
- **Couche entièrement connectée(FC)** après plusieurs couches de convolution et de max-pooling le raisonnement de haut niveau dans le réseau neuronal se fait via des couches entièrement connectées. Il connecte les

neurones d'une couche aux neurones d'une autre couche. Il est utilisé pour classer les images entre différentes catégories par formation [7].

- [Couche Logistique ou Softmax](#) est la fin de la couche entièrement connectée. La logistique est utilisée pour la classification binaire et Softmax est pour la multi-classification [7].
- [Couche de sortie \(output layer\)](#) la couche de sortie contient l'étiquette qui est sous forme codée [7].

2.5.1.3 Les modèles de réseaux de neurones convolutifs

Les modèles de réseaux neuronaux convolutifs et les méthodes d'intelligence artificielle ont souvent donné des résultats précis et fiables dans les applications utilisant des données basées sur des images. À l'aide de techniques d'apprentissage en profondeur, les chercheurs ont étudié et analysé des radiographies pulmonaires pour identifier le COVID-19 au cours des dernières années. Les formulaires se présentent comme suit :

- [AlexNet](#) est composé de 5 couches convolutives, 3 couches max-pooling, 2 couches de normalisation, 2 couches entièrement connectées (FC) et 1 couche softmax. Chaque couche convolutive est composée de filtres convolutifs et d'une fonction d'activation non linéaire ReLU. La mise en pool maximale est réalisée à l'aide des couches de mise en pool. En raison de l'existence de couches complètement liées, la taille d'entrée $224 \times 224 \times 3$ est fixe. Si l'image d'entrée est en niveaux de gris, elle est convertie en RVB en dupliquant le canal unique pour créer une image RVB à trois canaux. Le nombre total de paramètres d'AlexNet est de 60 millions, avec une taille de lot de 128 [9].

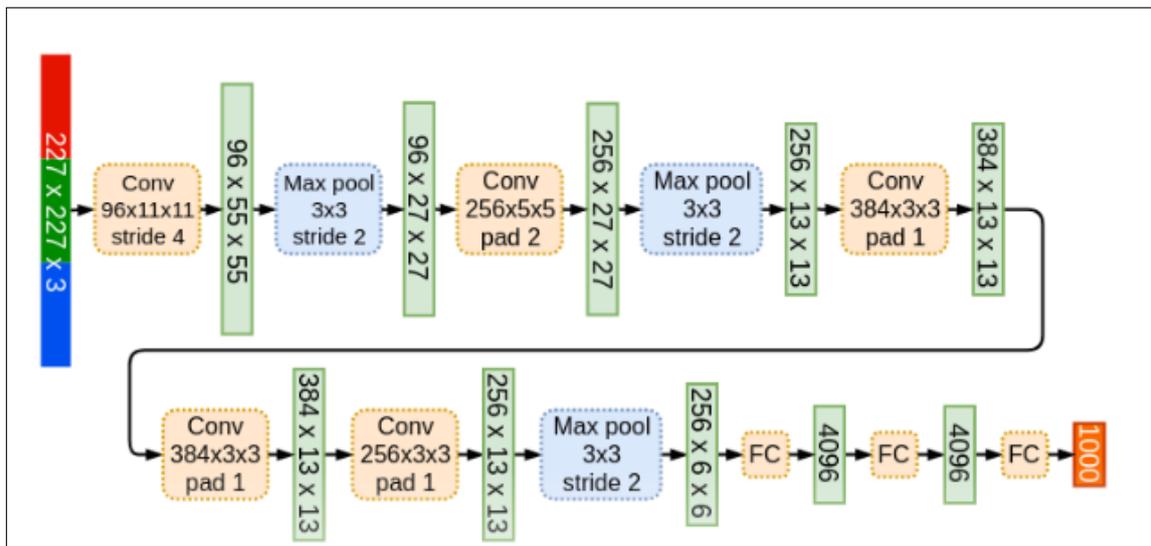


FIG. 2.5 : AlexNet architecture Design [10].

- [MobileNetV2](#) introduit un nouveau module avec une structure résiduelle inversée. Avec MobileNetV2, la reconnaissance d'objets et la segmentation sémantique de pointe sont réalisées. L'architecture de MobileNetV2 commence par une couche entièrement convolutive avec 32 filtres et 19 couches de goulot d'étranglement résiduel. En règle générale, le réseau nécessite 300 millions d'opérations de multiplication-addition et utilise 3,4 millions de paramètres. La précision est augmentée en supprimant ReLU6 de la sortie de chaque module de goulot d'étranglement [9].

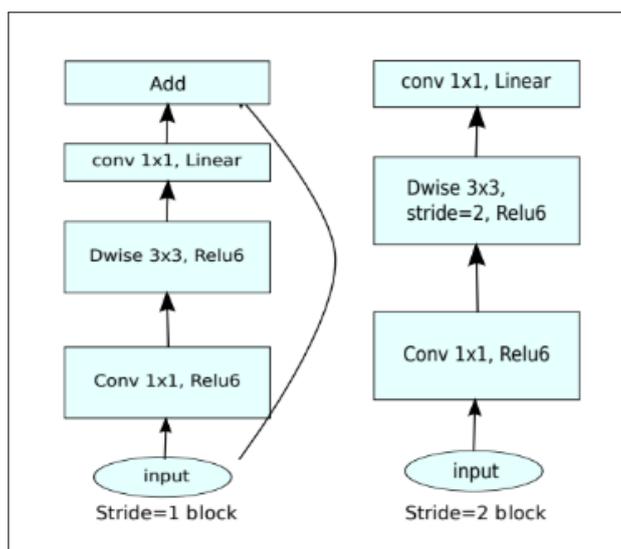


FIG. 2.6 : MobileNetV2 architecture.

- **GoogLeNet** est un CNN à 22 couches qui a montré de hautes performances sur la classification des images. Au bas de GoogLeNet, deux paires de couche de convolution et de couche de mise en commun maximale sont utilisées pour l'extraction et la réduction de caractéristiques [11].

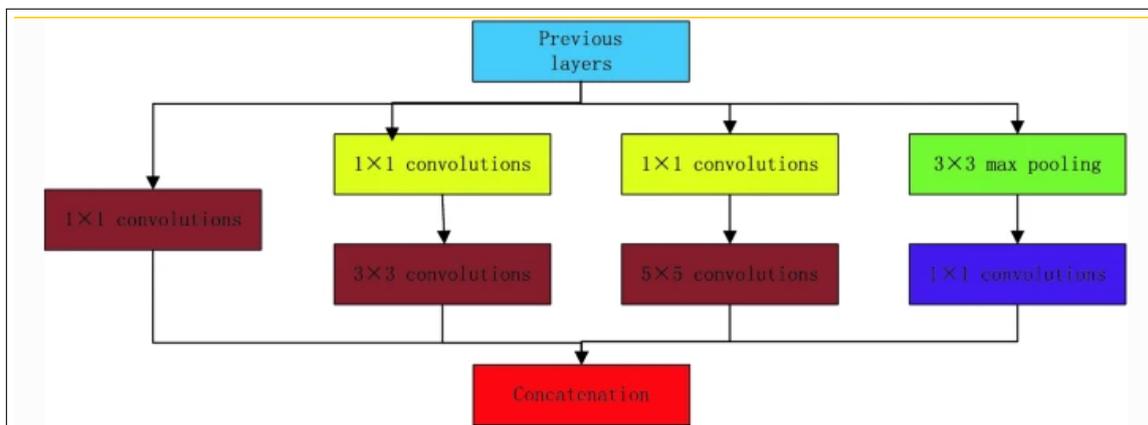


FIG. 2.7 : GoogLeNet architecture [11].

- **VGG19** L'entrée de VGG19 est une image RVB de taille fixe 224×224 . Il se compose de 19 couches dont 16 couches convolutives et 3 couches entièrement connectées, y compris la mise en commun maximale pour réduire la taille du volume et le classificateur softmax suivant la dernière couche entièrement connectée [12].

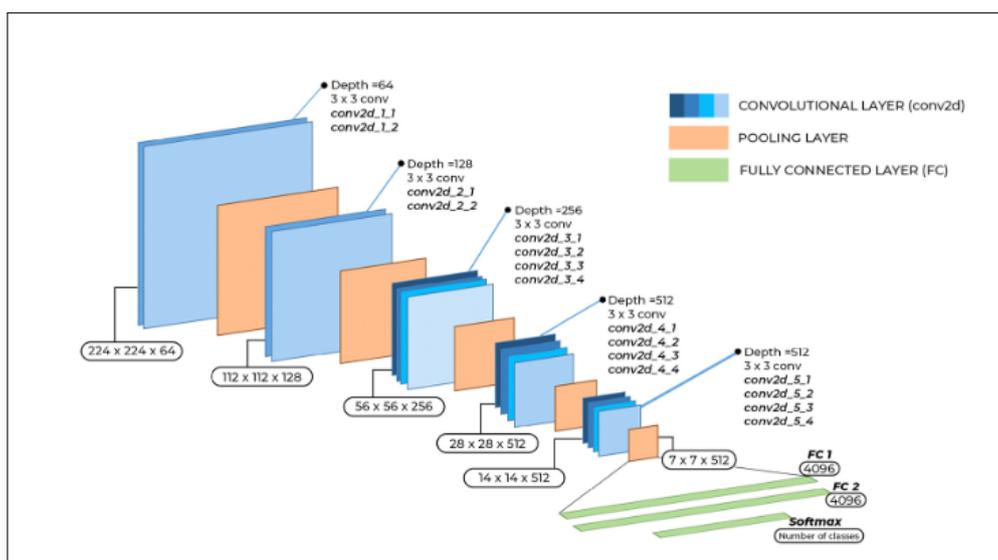


FIG. 2.8 : Illustration of the network architecture of VGG19 model

- **VGG16** L'entrée de VGG16 est une image RVB de taille fixe 224×224 . Il se compose de 16 couches dont 13 couches convolutives et 3 couches entièrement connectées, y compris la mise en commun maximale pour réduire la taille du volume et le classificateur softmax suivant la dernière couche entièrement connectée [12].

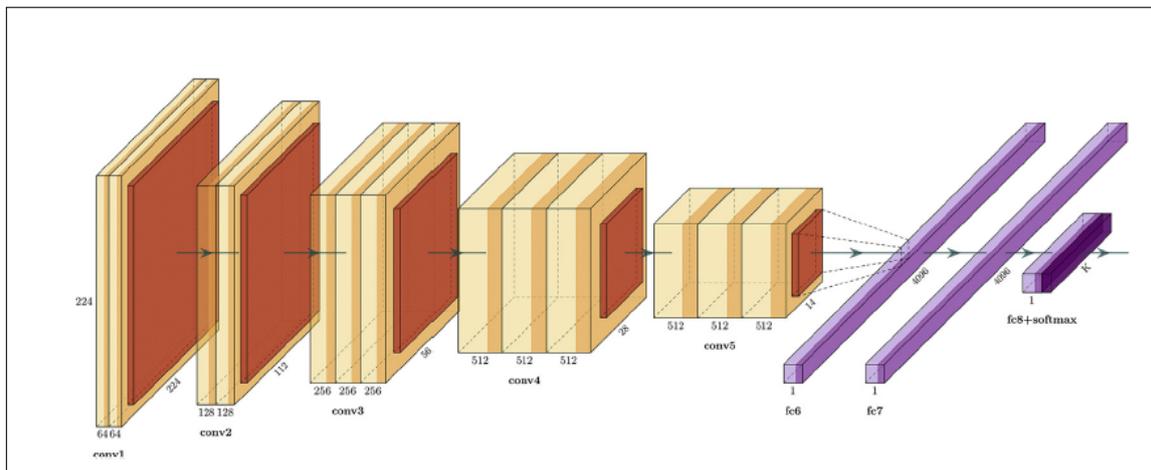


FIG. 2.9 : VGG16 architecture [13].

- **NasNet-Mobile** (NAS signifie Neural Architecture Search) et est une technique développée par Google Brain, elle a été entraînée sur deux types de jeux de données : "CIFAR10 et ImageNet". La recherche NASNet est l'un des meilleurs réseaux de neurones convolutifs qui optimisent les CNN pour différentes tailles. Il existe deux types de ce modèle où le plus petit modèle est appelé "NASNet-Mobile", que nous avons utilisé dans cette étude [12].

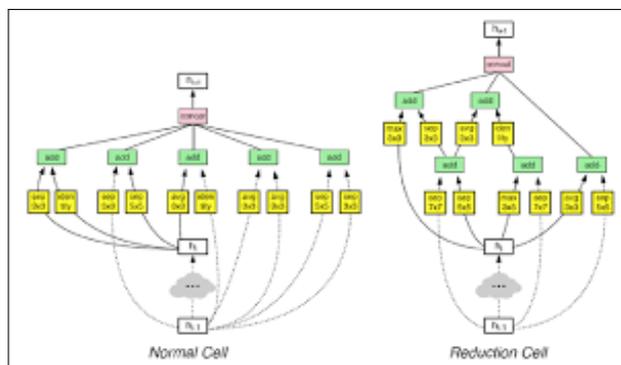


FIG. 2.10 : Nasnet Normal and Reduction Cell Architecture [14].

- [NASNet large](#) La recherche d'architecture neurale (NAS) est utilisée lors de la conception du NASetLarge, les cellules de démarrage sont également utilisées pour construire la couche du modèle, tout comme dans le cas d'InceptionNet-V3. Les deux types de cellules utilisées pour la conception de NASNet sont la cellule normale et la cellule de réduction [15].

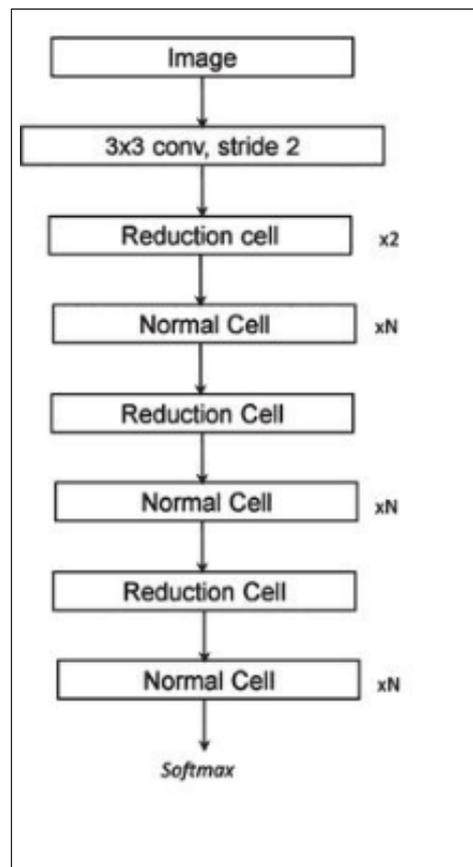


FIG. 2.11 : Architecture of NASNetlarge.

- [ResNet50 et ResNet101](#) L'architecture de ResNet50 est divisée en 4 étapes. Le réseau peut accepter une image d'entrée avec une hauteur, une largeur de multiples de 32 et une largeur de canal. Le réseau peut accepter une image d'entrée avec une hauteur, une largeur de multiples de 32 et une largeur de canal. Chaque architecture ResNet effectue une convolution initiale et une mise en commun maximale avec une taille de noyau de 7×7 et 3×3 , respectivement. Chaque bloc à 2 couches est remplacé par ce bloc de goulot d'étranglement à 3 couches dans le réseau à 34 couches, ce qui donne un ResNet à 50 couches. Un ResNet à 101 couches est créé en ajoutant des blocs supplémentaires à 3 couches [9].

- [ResNet18](#) est un réseau neuronal convolutif de 18 couches de profondeur. Vous pouvez charger une version pré-entraînée du réseau formée sur plus d'un million d'images à partir de la base de données ImageNet. Le réseau pré-entraîné peut classer les images en 1000 catégories d'objets, telles que le clavier, la souris, le crayon et de nombreux animaux. En conséquence, le réseau a appris des représentations de caractéristiques riches pour une large gamme d'images. Le réseau a une taille d'entrée d'image de 224 par 224 [16].

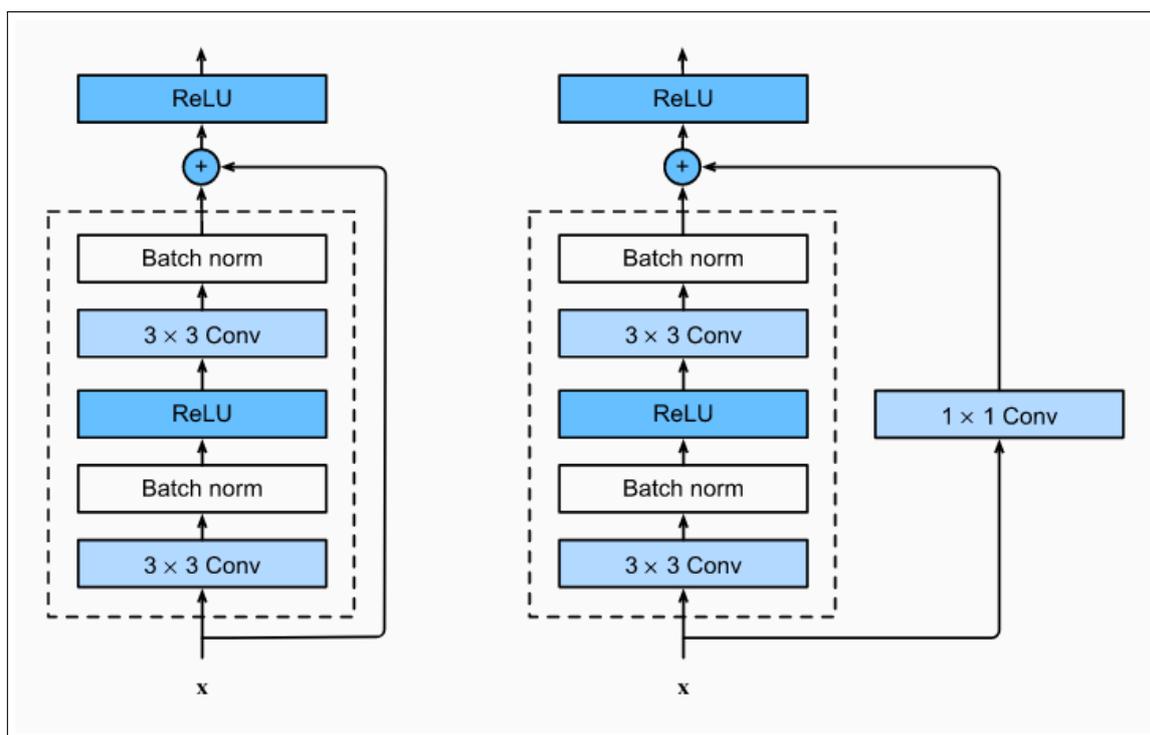


FIG. 2.12 : deep residual network block that used in Resnet family [17].

- [Xception](#) a été proposé par Chollet en 2016, le créateur de la bibliothèque Keras. Il s'agit d'une adaptation des architectures Inception dans lesquelles les modules Inception sont remplacés par des convolutions séparables en profondeur. Xception a surpassé le traditionnel InceptionV3 avec une précision Top-1 et Top-5 plus élevée sur l'ensemble de données ImageNet. Le nombre de paramètres de Xception est à peu près le même que celui d'InceptionV3 (environ 23 millions). La figure 7 explique notre modèle affiné de Xception pour la classification du COVID-19 et de la pneumonie [12].

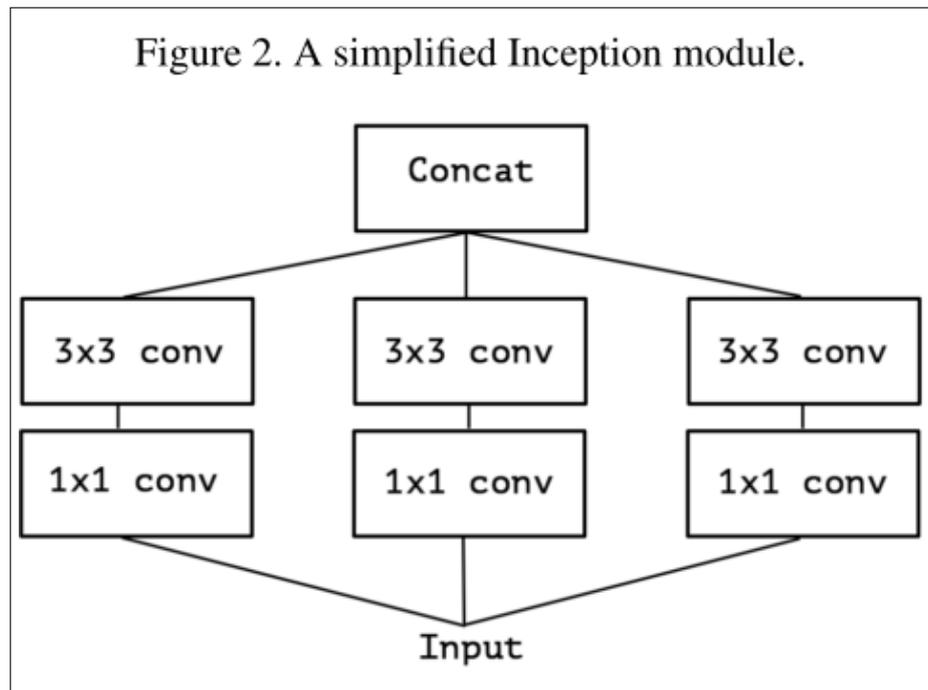


FIG. 2.13 : Xception architecture [18].

- [Inception-Resnet-v2](#) Les parties de base de l'architecture Inception-ResNetV2 représentées dans toutes les couches sont établies avant la couche fc. Le modèle Inception-ResNetV2 contient trois types de base de modules de démarrage, à savoir, Inception-ResNet-A, Inception-ResNet-B et Inception-ResNet-C, comme illustré à la Figure 3. Ces modules sont responsables à la fois de la réduction du nombre de paramètres petites couches Conv (par exemple, 1×7 , 7×1) et générer les caractéristiques discriminatoires. Chaque module possède lui-même plusieurs couches Conv et pool. Inception-ResNetV2 contient également deux types de modules de réduction, qui sont chargés de réduire la taille de l'image (voir Figure 4). Le modèle Inception-ResNetV2 a une taille d'entrée par défaut de 299×299 ; ainsi, nous l'avons redimensionné à 224×224 pendant la formation. [19].

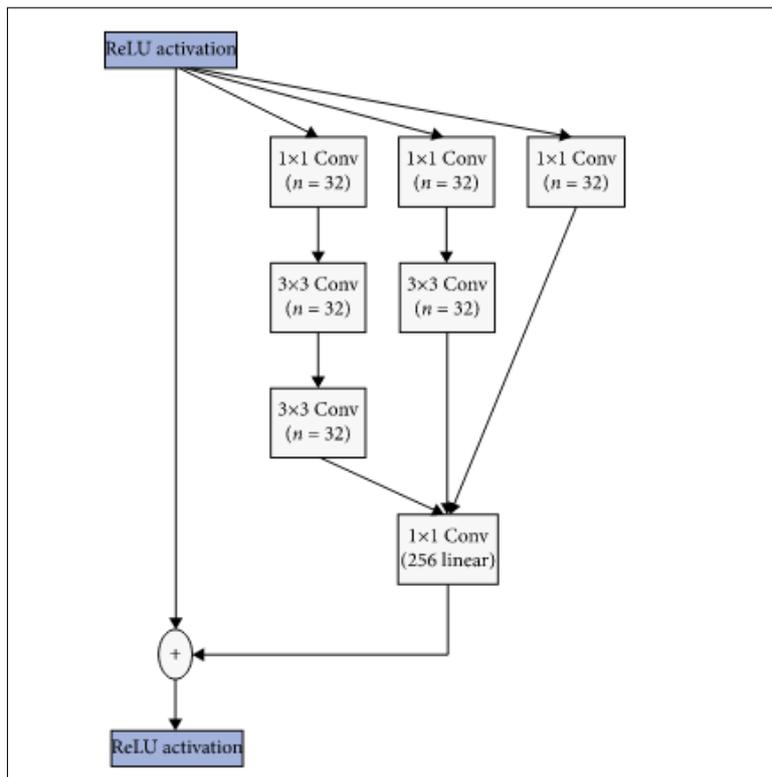


FIG. 2.14 : Inception-ResNetV2 architecture

- **Inception-v3** est une architecture de réseau neuronal convolutif de la famille Inception qui apporte plusieurs améliorations, notamment l'utilisation du lissage d'étiquettes, des convolutions factorisées 7 x 7 et l'utilisation d'un classificateur auxiliaire pour propager les informations d'étiquettes plus bas sur le réseau (avec l'utilisation de batch normalisation pour les couches dans le sidehead) [20].

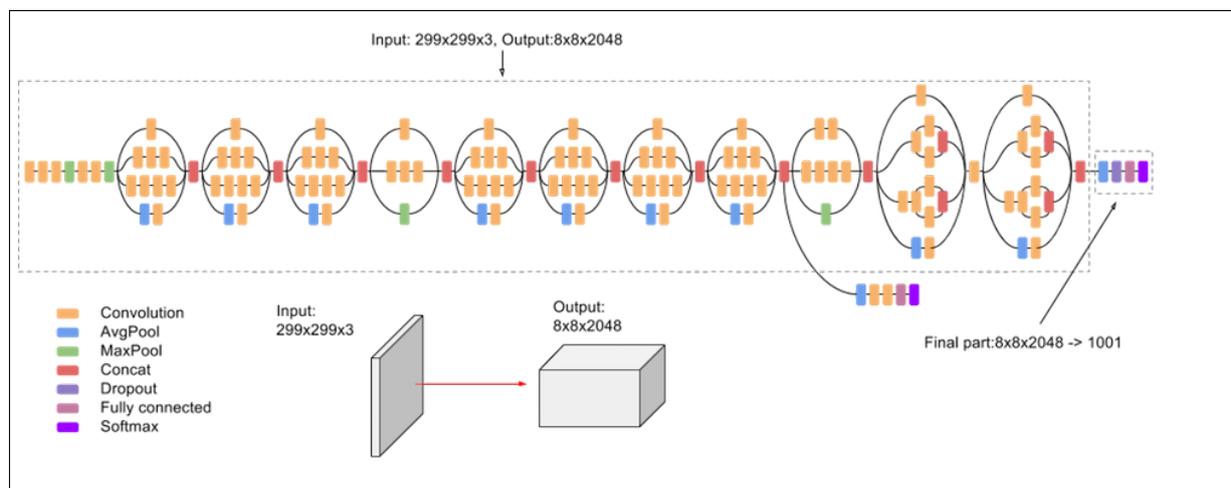


FIG. 2.15 : InceptionV3 Architecture.

- [SqueezeNet](#) dépend de la projection. La principale caractéristique de ce réseau est la réduction de l'espace des paramètres et de la complexité de calcul. Il donne moins de fonctionnalités avec des masques de convolution 3×3 . Des couches de compression et des connexions de raccourci de mappage d'identité sont utilisées pour obtenir une formation stable avec une structure de réseau plus profonde. Le regroupement moyen global est adopté dans la carte de convolution finale, puis la sortie est transmise à la couche FC. Le SqueezeNet est exploité pour donner une performance comparable à celle d'AlexNet (Pradeep et al.2018) [21].

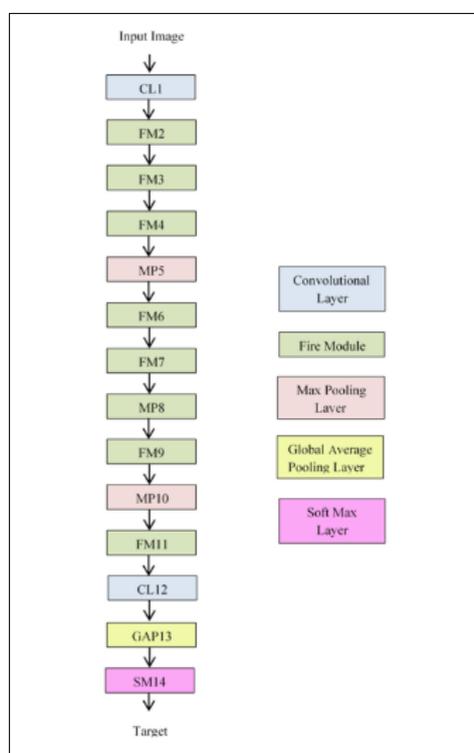


FIG. 2.16 : SqueezeNet Architecture [22].

- [ShuffleNet](#) est une architecture CNN très efficace en termes de calcul, principalement conçue pour les appareils mobiles dont la puissance de calcul est limitée. L'architecture introduit deux opérations importantes pour réduire considérablement le coût de calcul tout en maintenant la précision. La première opération consiste en des convolutions de groupe ponctuelles, ce qui peut réduire la complexité de calcul des convolutions 1×1 . La deuxième opération consiste à mélanger les canaux, ce qui facilite le flux d'informations sur les canaux de fonctionnalités [23].

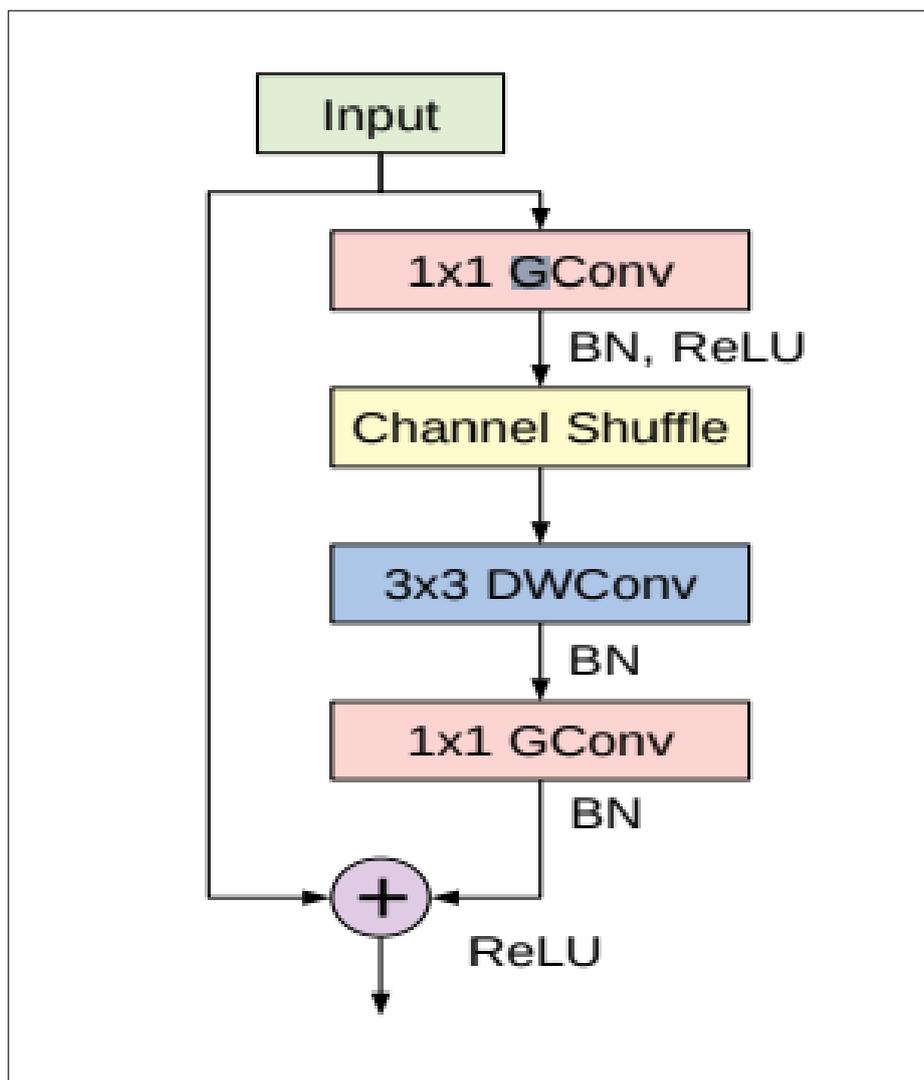


FIG. 2.17 : The building unit of the ShuffleNet architecture

- [DenseNet-201](#) est un réseau neuronal convolutif de 201 couches de profondeur. Vous pouvez charger une version pré-entraînée du réseau formée sur plus d'un million d'images à partir de la base de données ImageNet. Le réseau pré-entraîné peut classer les images en 1000 catégories d'objets, telles que le clavier, la souris, le crayon et de nombreux animaux. En conséquence, le réseau a appris des représentations de caractéristiques riches pour une large gamme d'images. Le réseau a une taille d'entrée d'image de 224 par 224 [16].

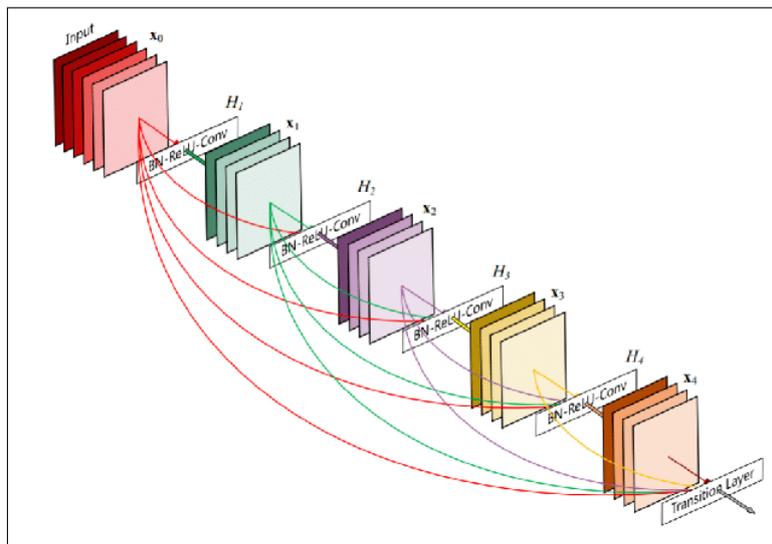


FIG. 2.18 : DenseNet network architecture [24].

2.5.2 La machine à vecteurs de support(SVM)

La machine à vecteurs de support (en anglais :Support Vector Machine) est une technique puissante d'algorithme général d'apprentissage automatique supervisé non linéaire qui convient aux problèmes linéaires et non linéaires et peut être utilisée à la fois pour la régression et la classification. Le but de SVM est de trouver un hyperplan dans un espace multidimensionnel qui divise l'espace des caractéristiques en deux groupes distincts. Un nouveau sujet est alors classé en fonction de quel côté de l'hyperplan il se trouve. SVM utilise la fonction noyau pour convertir les problèmes non séparables en problèmes séparables en mappant les données d'apprentissage dans un espace de caractéristiques de dimension supérieure, puis trouve l'hyperplan qui maximise la distance par rapport aux sujets les plus proches et atteint une séparation maximale. La fonction noyau peut être linéaire, polynomiale ou radiale, et le choix du noyau peut avoir un effet important sur les sorties du modèle. La méthode SVM a atteint avec succès des performances prédictives élevées dans les recherches sur les soins de santé [25].

2.6 Conclusion

Avec l'augmentation quotidienne des cas de la pandémie de COVID-19, un diagnostic précis et rapide de la COVID-19 est un défi pour tous les pays. Au cours de cette urgence sanitaire, le scanner thoracique s'est avéré très efficace pour identifier les patients atteints de COVID-19 à l'aide de modèles de réseau neuronal convolutif (CNN), contribuant ainsi à améliorer le diagnostic et le traitement de cette maladie.

Chapitre 3

Expériences, Résultats et Discussions

3.1 Introduction

La propagation rapide du COVID-19 a entraîné la mort de nombreuses personnes et sa propagation a dépassé la capacité des médecins et des hôpitaux dans de nombreuses régions du monde. Les douleurs musculaires, la toux et la fièvre sont tous des symptômes du virus et les patients atteints de pneumonie aiguë ont souvent des difficultés à respirer après plusieurs jours de symptômes.

L'apprentissage en profondeur est l'approche la plus réussie de l'apprentissage automatique, qui fournit une analyse utile pour étudier une grande quantité d'images de radiographie pulmonaire qui pourraient avoir un impact critique sur le dépistage du Covid-19.

Dans ce chapitre, afin de classer rapidement et avec précision les images de tomographie thoracique comme positives ou négatives pour COVID-19, nous avons utilisé des préformés modèles de réseau neuronal convolutif (CNN) pour classer les images de tomographie thoracique obtenues à partir de patients COVID-19. Nous avons également utilisé SVM au lieu d'un classificateur basé sur l'apprentissage en profondeur, car ce dernier a besoin d'un grand ensemble de données pour la formation et la validation.

3.2 Détection COVID-19

COVID-19 est une maladie dangereuse qui se propage rapidement parmi les gens. Il a balayé le monde ces dernières années, alors tout le monde a commencé à chercher des moyens rapides de diagnostiquer covid-19, donc la tomodensitométrie des poumons est la dernière solution. Les scans montrent une variété de signes causés par des infections virales. L'examen manuel par un médecin prend du temps, de sorte que les méthodes d'intelligence artificielle ont aidé à classer les patients atteints de Covid et d'autre Par CNN, qui a fourni des performances élevées par 12 CNNs qui diffèrent entre eux en termes de précision et d'équilibre entre sensibilité et qualité. En conséquence, il a été constaté que l'insertion directe de tranches d'image entières sans additifs a fourni une meilleure, plus rapide et moins de classification que les travaux précédents et élimine l'extraction manuelle des régions avec une signification sur les images fournies par la tomodensitométrie qui apparaissent grâce à la mise en œuvre automatisée de modèles d'apprentissage en profondeur pour la classification covid-19.

3.3 Méthodologie proposée

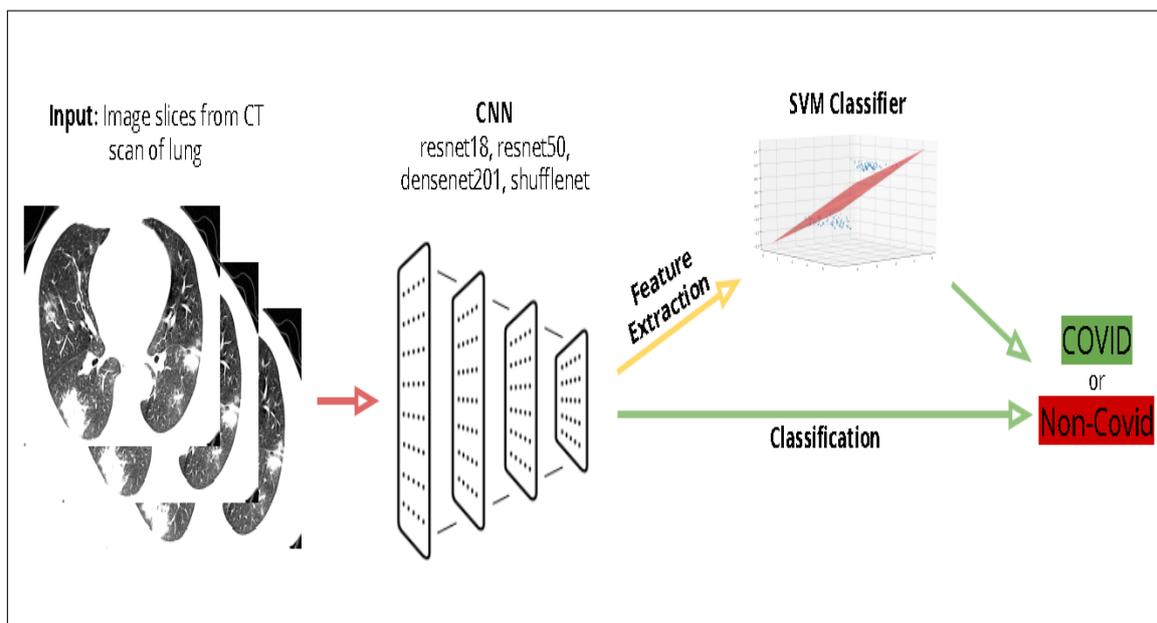


FIG. 3.1 : Schéma des modèles pour détecter le Covid-19.

Pour mener cette recherche, nous avons d'abord prélevé des échantillons de tomodensitométrie à partir de scanners pulmonaires de patients. Ensuite, testez les images classifié par CNN (12 modèles). Enfin, nous les avons classés de deux manières.

Matériel de développement

Notre système de détection est implémenté sous MATLAB R2021a dans une plateforme expérimentale en tant que station de travail (HP Z8 G4), avec un système d'exploitation Microsoft Windows 10 64 bits, équipé de :

- CPU : Intel Xeon Silver 4108 processor.
- RAM : 96 GB.
- GPU : (NVIDIA GeForce RTX 3090 '64', GeForce RTX 2080 Ti).

Le programme utilisé : MATLAB R2021a

MATLAB est un langage de haut niveau pour la programmation et la plate-forme de calcul numérique , Il facilite les opérations complexes.

3.3.1 Première méthode

- Classification CNN.
- Déterminer la performance (Accuracy) dans chaque module pour connaître la meilleure façon d'utiliser ses résultats dans l'étude.

3.3.2 Deuxième méthode

- Nous appliquons l'extraction des caractéristiques par le modele CNN pour extrait des caractéristiques discriminantes dans les images entrante.
- Nous effectuons la classification par SVM (Support Vector Machine).

3.4 Matériel et méthodes

3.4.1 Base de données COVID-19

-Nous avons utilisé deux bases de données :

- [UCSD](#)

La base de données COVID-19 CT se compose des images de patients prises à partir de divers documents de recherche. Tel qu'utilisé pour former plusieurs réseaux et faire des tests préliminaires. Un ensemble de données COVID-CT contenant des images de tomodensitométrie a été utilisé pour classifier le COVID-19. L'ensemble de données se compose de deux classes, Non-COVID-19 et COVID-19 pour 384 Patients (213 Covid, 171 Non covid) et 746 images au total. Les données ont été partitionnées en deux parties (training and test dataset), la première partie (80%) a été utilisée pour formation tandis que la deuxième partie (20%) pour tester les performances des algorithmes [26].

- [CT Covid](#)

L'ensemble de données COVID-CT contient 349 images CT contenant les résultats cliniques de COVID-19 de 216 patients. Les données ont été divisées au hasard les données en formation et validation ensembles de données. Utilisez 80% des images pour la formation et 20% pour la validation [26].

3.4.2 Les évaluations des performances

L'évaluation des performances du modèle est un élément essentiel de la construction d'un modèle d'apprentissage automatique efficace. L'évaluation peut être effectuée avec un ensemble de mesures de performance, dont la plupart sont dérivées de la matrice de confusion. La matrice de confusion compare la classe d'origine (observée) à la classe prédite. Il se compose de quatre résultats possibles : TP ; TN ; FP ; FN.. Le tableau 3.1 montre la disposition de la matrice de confusion. Avec :

TP (True Positives) : représentent une situation dans laquelle le classificateur a correctement classé le positif.

TN (True Negatives) : représentent une situation dans laquelle le classificateur a correctement classé le négatif.

FP (false positives) : indique le nombre de cas où le modèle a mal classé positif comme négatif.

FN (false negatives) : représente les patients négatifs incorrectement classés comme positifs.

TAB. 3.1 : Matrice de confusion.

	Predicted	
Observed	P	N
P	TP	FN
N	FP	TN

Dans cette étude, nous utilisons l'évaluation des performances les plus courantes à savoir : Accuracy, Precision, Sensitivity/Recall, F-score, Specificity [25].

- **Accuracy** : est une métrique largement utilisée pour surveiller les performances des modèles d'apprentissage automatique et se définit comme le rapport entre les instances correctement classées et le nombre total d'instances. Pour les données déséquilibrées, cette métrique peut être trompeuse.

$$Accuracy = \frac{TP + TN}{TN + FP + FN + TP} \quad (3.1)$$

- **Precision** : est le vrai positif divisé par la somme de toutes les prédictions positives.

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

- **Sensitivity/Recall** : est défini comme la proportion d'instances positives qui sont correctement classées comme positives, par rapport à tous les ensembles positifs.

$$Recall = \frac{TP}{TP + FN} \quad (3.3)$$

- **F-score** : est une mesure à valeur unique basée sur deux paramètres. Il s'agit de la moyenne pondérée des valeurs de précision et de rappel. En d'autres termes, est la moyenne harmonique de la précision et du rappel. La plage du F-score est comprise entre 0 et 1 (1 signifie parfait).

$$F - score = \frac{2 * Recall * Precision}{Recall + Precision} = \frac{2.TP}{2.TP + FP + FN} \quad (3.4)$$

- **Specificity** : est la proportion d'instances négatives correctement identifiées comme négatives par rapport au nombre total d'instances négatives observées.

$$Specificity = \frac{TN}{TN + FP} \quad (3.5)$$

3.5 Analyse des résultats et discussions

Nous avons proposé un modèle profond basé sur l'architecture des modèles CNN pour détecter les cas de COVID-19 à partir d'images radiographiques thoraciques. Le modèle proposé a été testé sur deux base de données :

3.5.1 UCSD base de données

3.5.1.1 Classification après l'application du modèle CNN

À l'aide de couches CNN, nous avons effectué des tests sur douze CNN qui validaient les CNN précédemment testés dans cette étude pour classer les images CT complètes afin de distinguer le COVID-19 des non-COVID-19. Ces réseaux sont : (1) SqueezeNet, (2) GoogLeNet, (3) DenseNet-201, (4) ResNet-18, (5) ResNet-50, (6) ResNet-101, (7) Xception, (8) ShuffleNet, (9) NasNet-Large, (10) AlexNet, (11) VGG-16 et (12) VGG-19.

CNN models	Accuracy%	precision%	Specificity	Sensitivity%	F1-Score
NasNet-Large	65.52	59.2	65.2	65.89	62.3
AlexNet	71.43	63.3	69.7	73.8	68.1
ResNet-50	75.86	60.2	70.9	85.5	70.6
ResNet-101	75.86	76.5	77.5	74.3	75.3
ResNet-18	79.31	77.6	79.4	79.2	78.3
VGG-16	68.97	57.1	66.7	72.7	63.9
VGG-19	66.01	60.2	65.8	66.3	63.1
DenseNet201	79.31	78.6	80	78.6	78.6
GoogleNet	71.43	67.3	71.2	71.75	69.4
SqueezeNet	74.88	70.4	74.1	75.8	73
Xception	72.91	68.4	72.1	72.8	70.5
ShuffleNet	75.86	78.6	78.6	73.3	75.8

TAB. 3.2 : Présentation de précision de différents modèles de classification utilisant les caractéristiques profondes de divers modèles CNN.

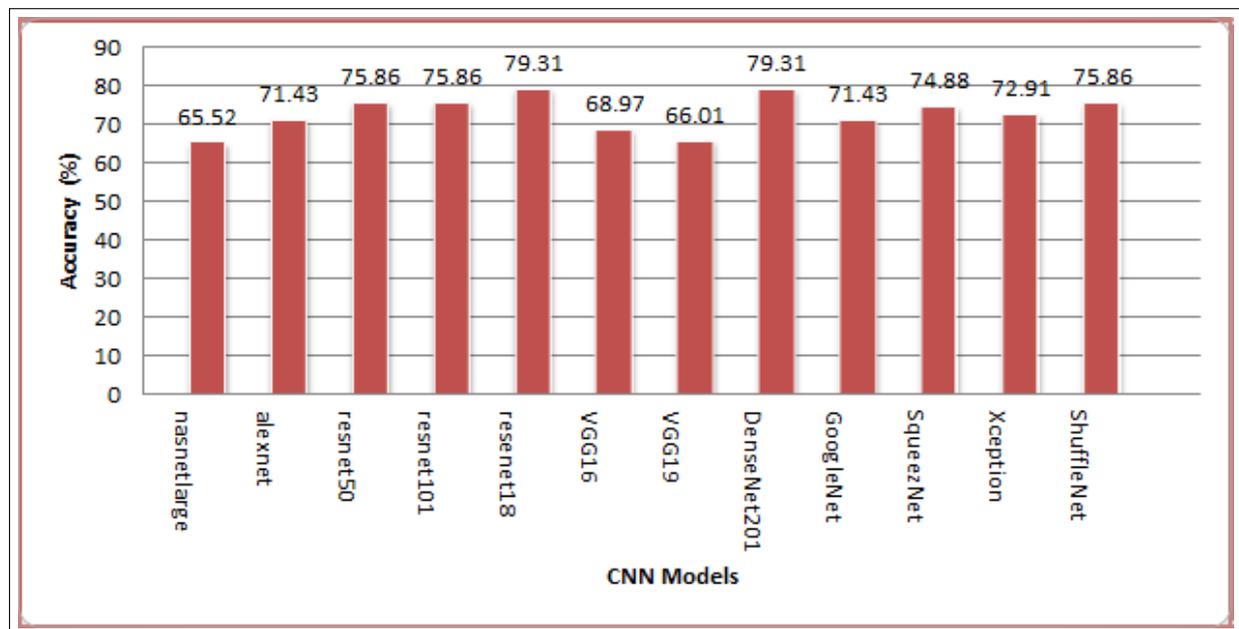


FIG. 3.2 : Présentation de graphique à barres de la précision (accuracy%) du les modeles CNN.

Le tableau 3.2 détaille les résultats des modèles CNN sur la classification COVID-19. Dans ce tableau, les deux meilleurs modèles proposés Resnet-18 et DenseNet-201 ont atteint la performance (accuracy) de 79,31%, tandis que la précision, la spécificité, la sensibilité et la mesure F (F1-Score) pour la classe COVID-19 sont de 77,6%, 79,4%, 79,2% et 78,3% respectivement pour Resnet-18 et 78,6%, 80%, 78,6% et 78,6% respectivement pour DenseNet-201. tandis que le deuxième meilleur score de précision de 75,86% a été obtenu à partir des modèles Resnet-50, Resnet-101 et ShuffleNet, mais les valeurs d'évaluation de la classification étaient différentes, et le modèle SqueezeNet a atteint la troisième meilleure performance (accuracy) de 74.88%. Le modèle le plus faible en termes de la performance (accuracy) est NasNet-Large qui obtient 65,52%.

Le graphique à barres représente la performance (Accuracy) des modèles CNN présentés dans le tableau 3.2 ci-dessus.

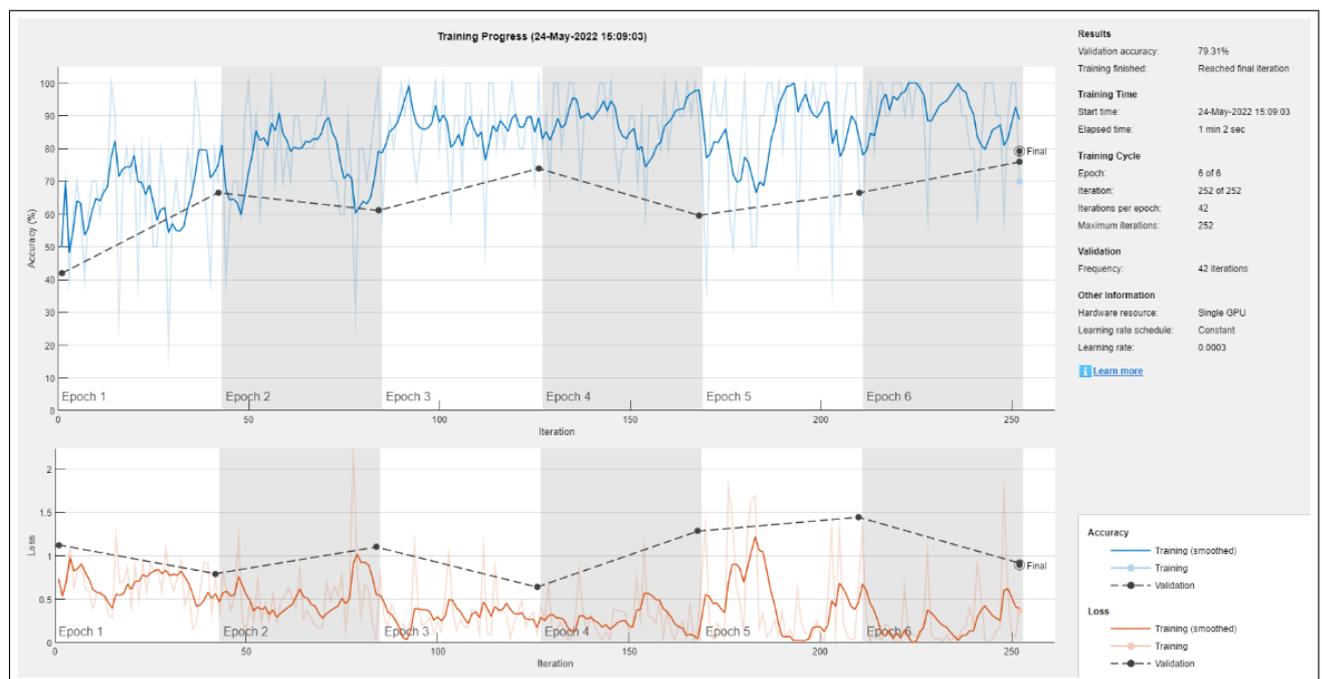


FIG. 3.3 : Un processus de formation de ResNet-18.

Chapitre 3. Expériences, Résultats et Discussions

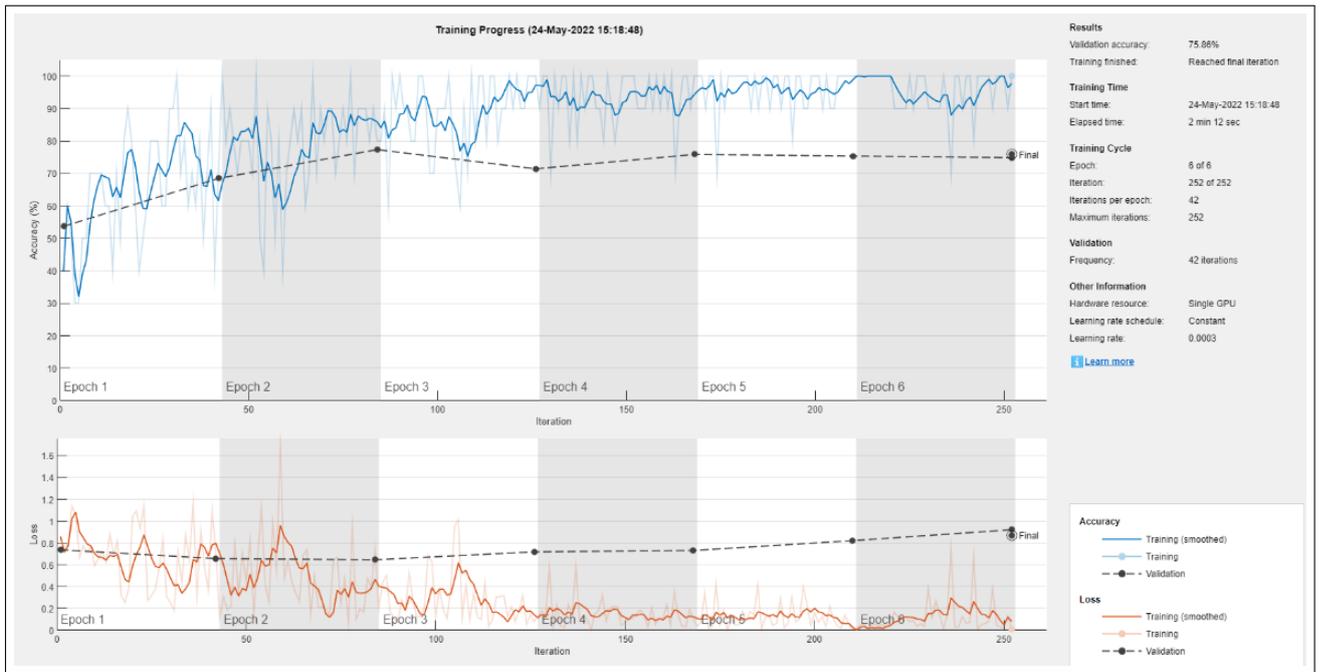


FIG. 3.4 : Un processus de formation de ResNet-50.

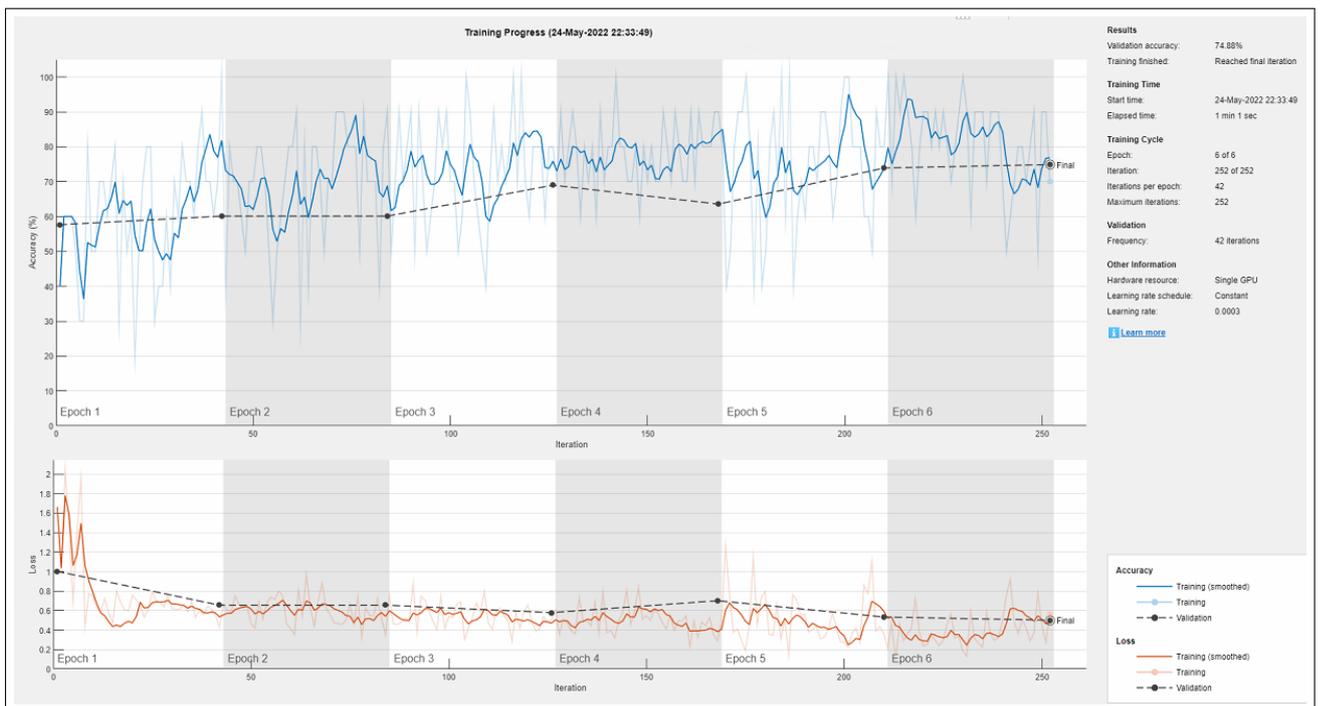


FIG. 3.5 : Un processus de formation de SqueezeNet

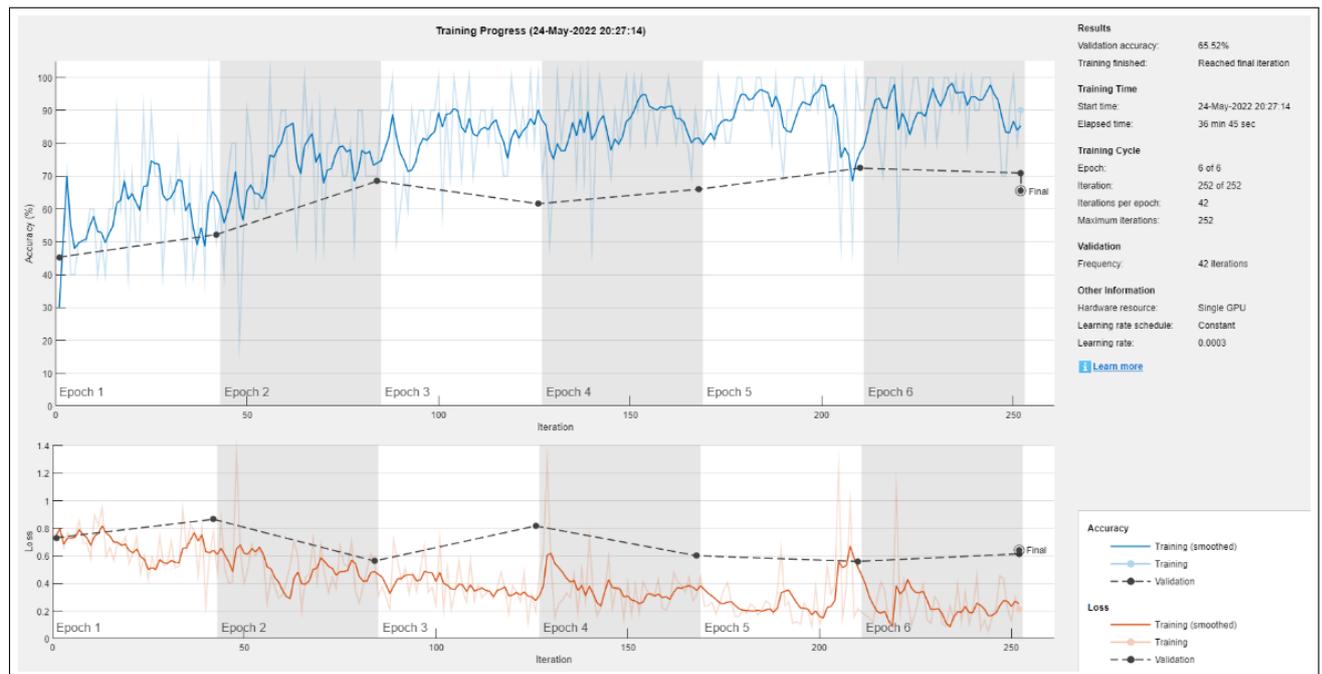


FIG. 3.6 : Un processus de formation de NasNet Large.

La procédure de formation de bout en bout du modèle CNN proposé est illustrée à les quatre figures(Fig 3.3, fig3.4, fig3.5 et fig3.6). L'augmentation des données a été effectuée à la fois pour le réglage fin et pour la formation de bout en bout, et a été réalisée en faisant pivoter, déplacer et retourner de manière aléatoire les images de formation. Le graphique supérieur montre les précisions de formation et de formation moyenne (with light blue = training [smoothed] and blue = training), tandis que le graphique inférieur de la fig3.3. montre la valeur de perte pour les échantillons de formation (orange = training[smoothed], and light orange = training), et la ligne pointillée noire est la validation . Le score de performance(accuracy) obtenu était de 79.31% de Resnet-18 et la procédure de formation a été complétée en 252 itérations.

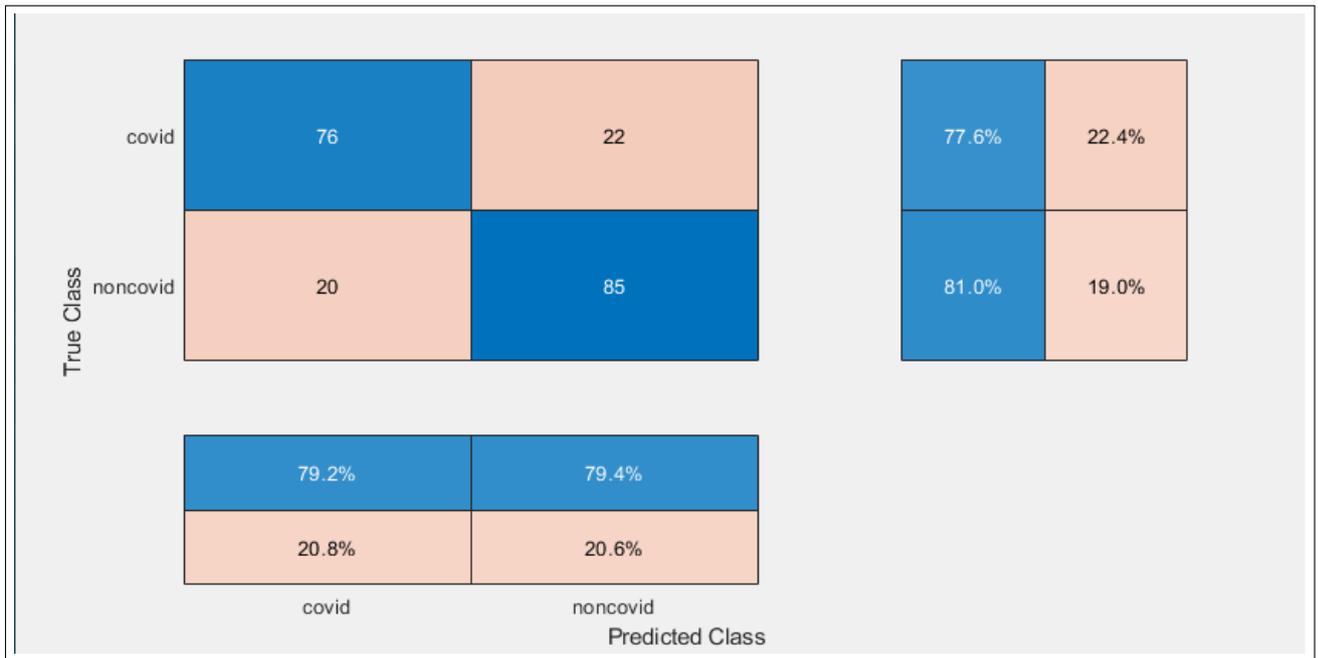


FIG. 3.7 : Matrice de confusion de ResNet-18.

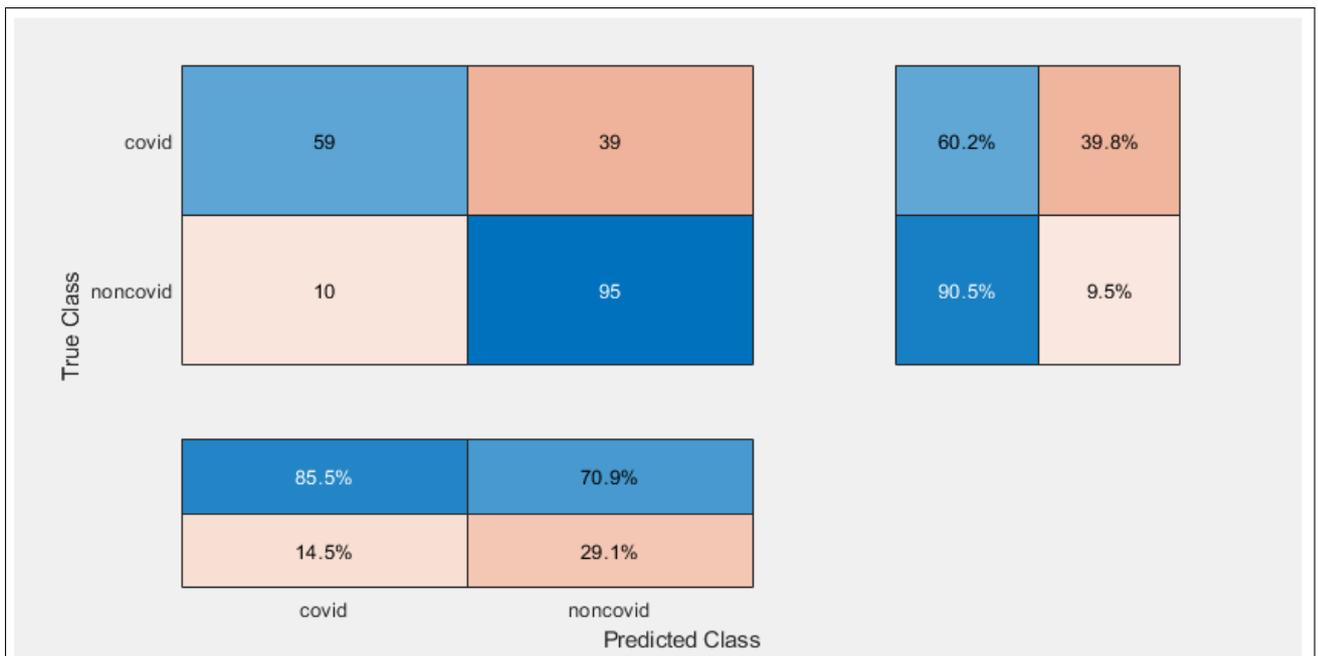


FIG. 3.8 : Matrice de confusion de ResNet-50.

La figure 3.7 montre la matrice de confusion pour ResNet18. nous pouvons observer que 76 images sont classées comme COVID-positives (TP) et 85 images (TN) sont correctement classées comme COVID-négatives par le modèle ResNet18. Ainsi, notre modèle a correctement classé 161 images alors que 42 images ne sont pas correctement classées. Sur ces 42 images mal classées, 20 images sont prédites comme

COVID-positives (FP) même si elles étaient COVID-négatives, souffrant donc d'une erreur de type I. Enfin, 22 images ont souffert d'une erreur de type II, où les images réellement COVID-positives sont prédites comme COVID-négatives (FN).

3.5.1.2 l'extraction de caractéristiques par CNN et la classification par SVM

Modèle CNN	Avg Accuracy%	F1-score
NasNet-Large	75.23	71.45
AlexNet	77.68	74.79
ResNet-50	79.24	77.73
ResNet-101	80.04	76.1
ResNet-18	79.65	76.06
VGG-16	78	74.32
DenseNet-201	79.65	76.06
GoogleNet	78.45	74.05
SqueezeNet	78.97	73.41
VGG-19	77.97	74.29
Xception	77.52	74.28
ShuffleNet	82.06	77.25

TAB. 3.3 : Classification de les modeles CNN par Extraction de caractéristiques et la classification par SVM.

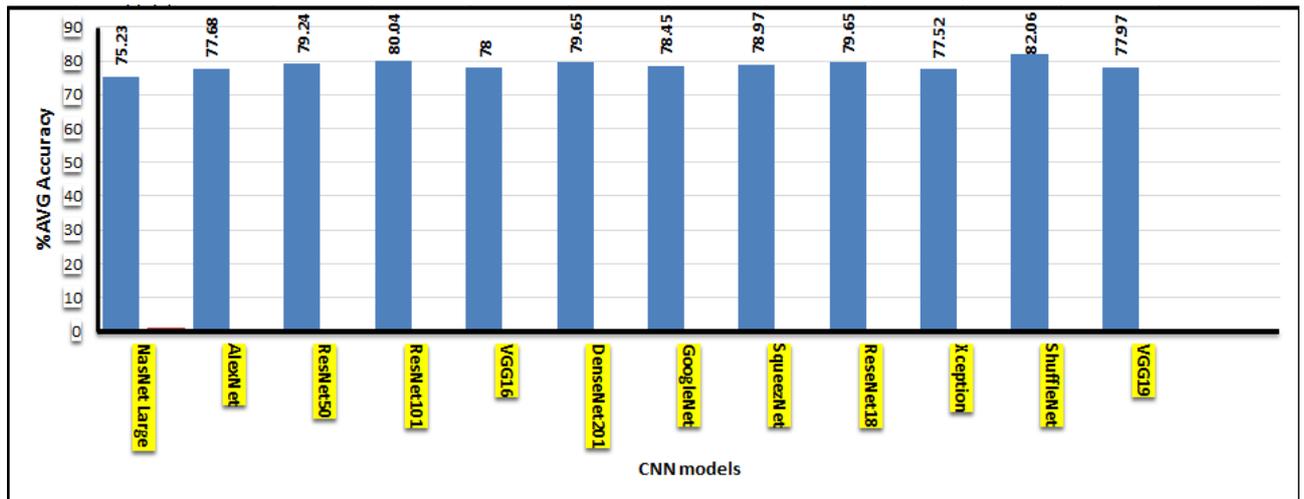


FIG. 3.9 : Présentation de graphique à barres de Avg Acc(%) du les modeles CNN.

Tous les modèles CNN approfondis ont obtenu des scores de précision moyenne(Avg accuracy) de classification supérieurs à 70%. D'après le tableau 3.3, on peut voir que le modèle ShuffleNet a produit le score de précision moyen(average accuracy) le plus élevé, avec un score de précision moyen de 82,06%, F1-score = 77.25%, tandis que le modèle ResNet-101 a produit un score de précision moyen de 80,04%, F1-score = 76.1% , comme deuxième meilleur score. tandis que les modèles ReseNet-18 et DenseNet-201 ont produit le même score de précision moyen de 79,65%, F- score = 76.06% . Le modèle ResNet-50 a produit un score de précision moyen de 79,24%, F1-score = 77.73% , tandis que les modèles SqueezeNet et GoogleNet ont produit des scores de précision moyens de 78,97, F1-score = 73.41% et 78,45%, F1-score = 74.05%, respectivement, tandis que le modèle NasNet-Large produit le score de précision moyen le plus bas de 75,23%, F1-score = 71.45%.

Le graphique à barres représenté toutes les valeurs de précision moyenne(Avg Accuracy) du les modèles CNN présentés dans le tableau 3.3 ci-dessus.

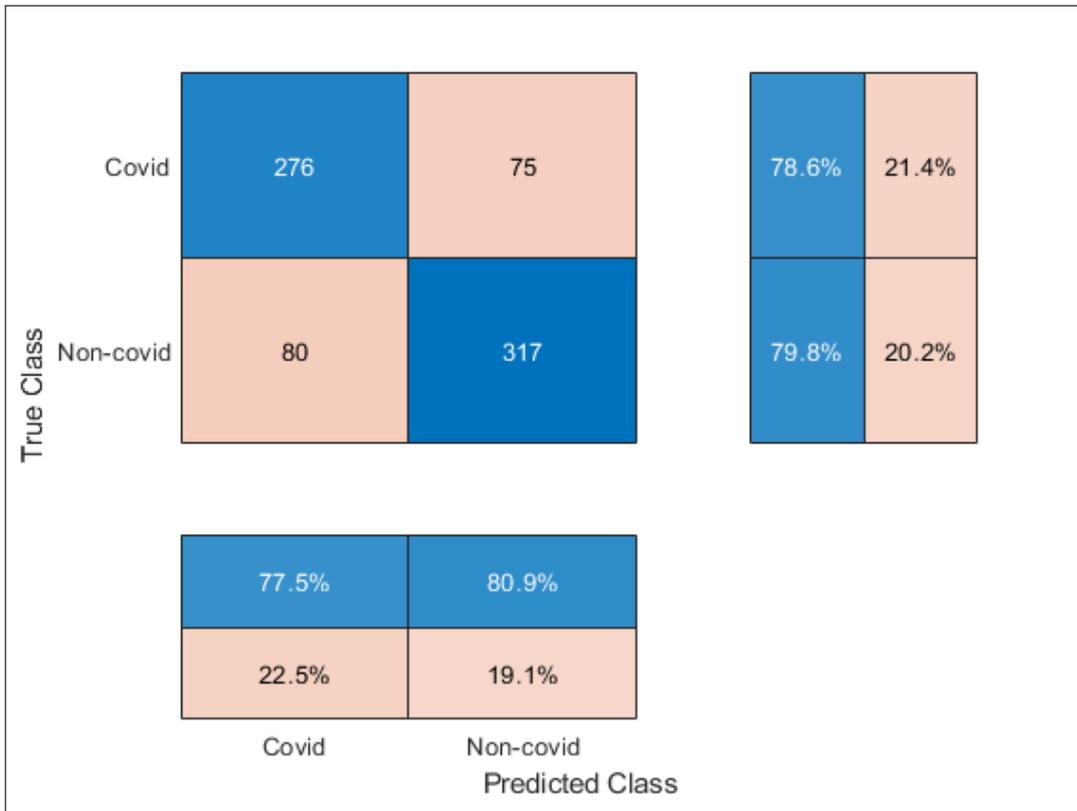


FIG. 3.10 : Matrice de confusion ResNet-50.

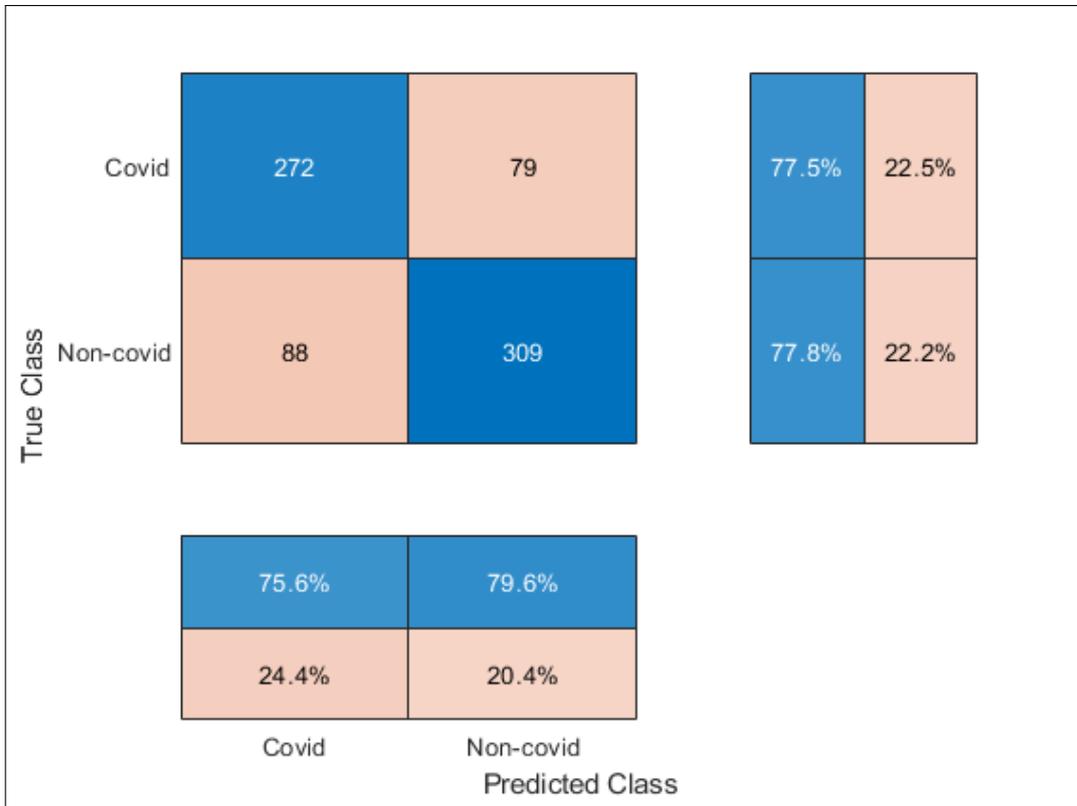


FIG. 3.11 : Matrice de confusion ResNet-101.

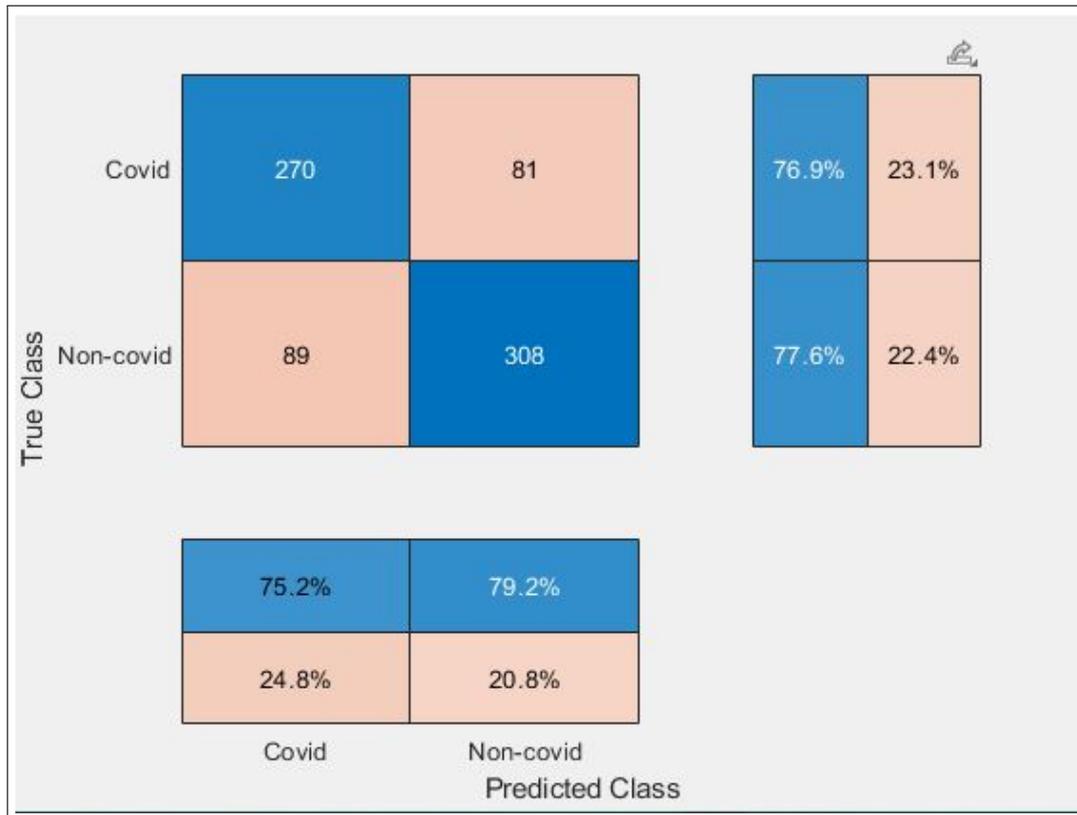


FIG. 3.12 : Matrice de confusion ResNet-18.

Par exemple Fig 3.12 présente la matrice de confusion pour les fonctionnalités Resnet-18 avec le classificateur linéaire SVM. Les étiquettes représentent respectivement les cas normaux (sains) "COVID-19" et "Non covid". De la Fig3.13, on peut également observer que si 270 échantillons COVID-19 et 308 échantillons normaux (sains) ont été correctement classés, 89 échantillons COVID-19 et 81 échantillons normaux (sains) ont été mal classés. Par conséquent, le taux de classification correcte des échantillons COVID-19 était de 76,2%(Sensitivité), alors qu'il était de 79,2%(Precision) pour les échantillons normaux (sains).

3.5.2 CT covid base de données

3.5.2.1 Classification après l'application du modèle CNN

Modèle CNN	MACC%	MSEN%	MSPE%	mF1%
NasNetlarge	92.8859	92.9114	92.8571	93.21
AlexNet	86.7114	82.2785	91.7143	85.2
ResNet-50	95.4362	97.2152	93.4286	95.95
ResNet-101	97.8523	98.481	97.1429	98
ReseNet-18	95.5705	95.1899	96	95.79
VGG-16	95.0336	96.962	96.962	95.67
VGG-19	95.9732	99.1772	98	95.75
DenseNet-201	96.1074	97.2152	94.8571	96.38
GoogleNet	95.4362	97.2152	93.4286	95.95
Squeezenet	87.9195	95.1899	79.7143	89.77
Xception	92.2148	90.3797	94.2857	92.35
ShuffleNet	93.4228	94.1772	92.5714	93.98

TAB. 3.4 : Précision de différents modèles de classification utilisant les caractéristiques profondes de divers modèles CNN.

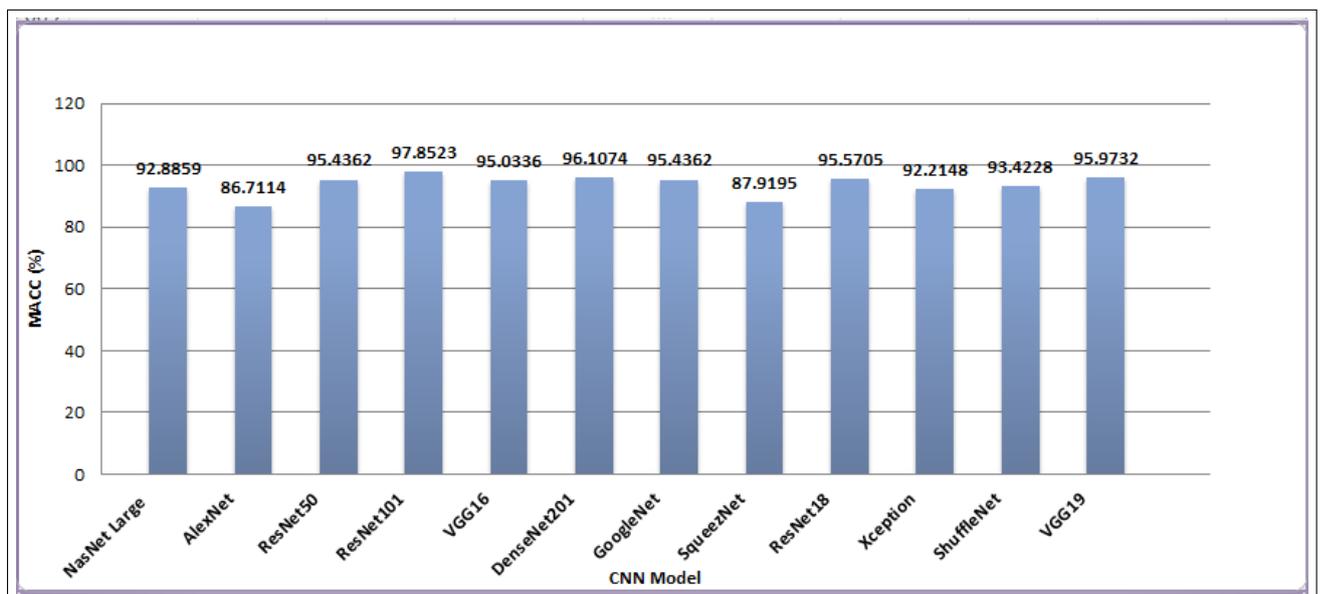


FIG. 3.13 : Présentation de graphique à barres de la précision (accuracy%) du les modeles CNN.

D'après le tableau 3.4, ResNet-101 était le meilleur modèle de classification. ResNet-101 a atteint $MACC = 97,85\%$, $MSEN = 98,48\%$, $MSPE=97,14\%$ et $mF1 = 98\%$. Le modèle proposé DenseNet-201 a atteint deuxième mieux classification de $MACC= 96,10\%$, $MSEN$, $MSPE$ et $mF1$ pour la classe COVID-19 sont respectivement de $97,21\%$, $94,85\%$ et 96% . Le reste des modèles a également atteint des valeurs très similaires, et le plus faible modèle en terme moyenne de accuracy est AlexNet qui obtient l'évaluation de classification suivante $MACC = 86.71\%$, $MSEN = 82.27\%$, $MSPE=91.71\%$ et $mF1 = 85.2\%$.

Le graphique à barres représenté toutes le valeurs la précision du les modèles CNN présentés dans le tableau 3.4 ci-dessus.

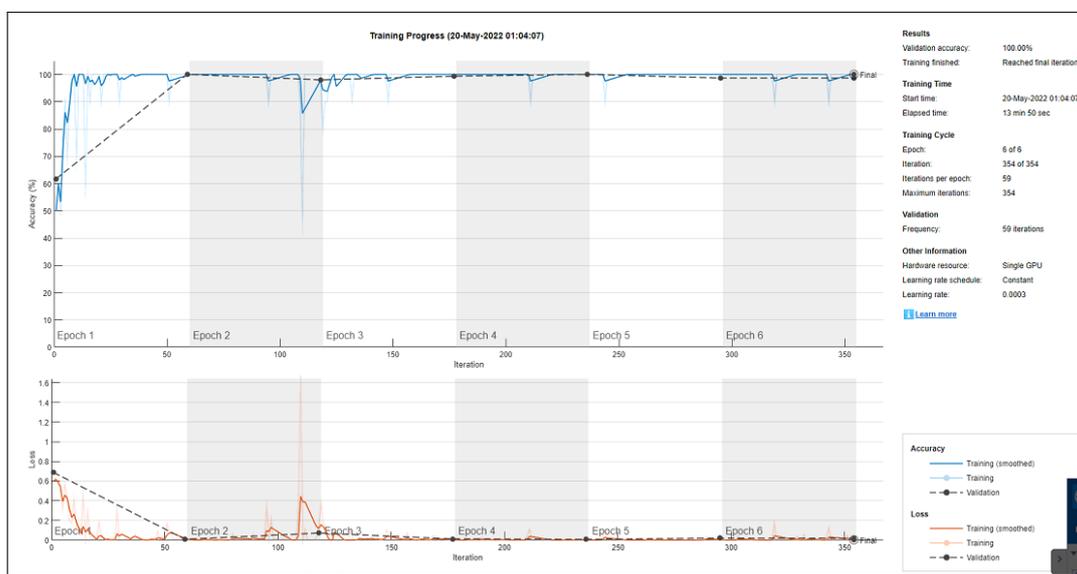


FIG. 3.14 : Un processus de formation de ResNet-101.

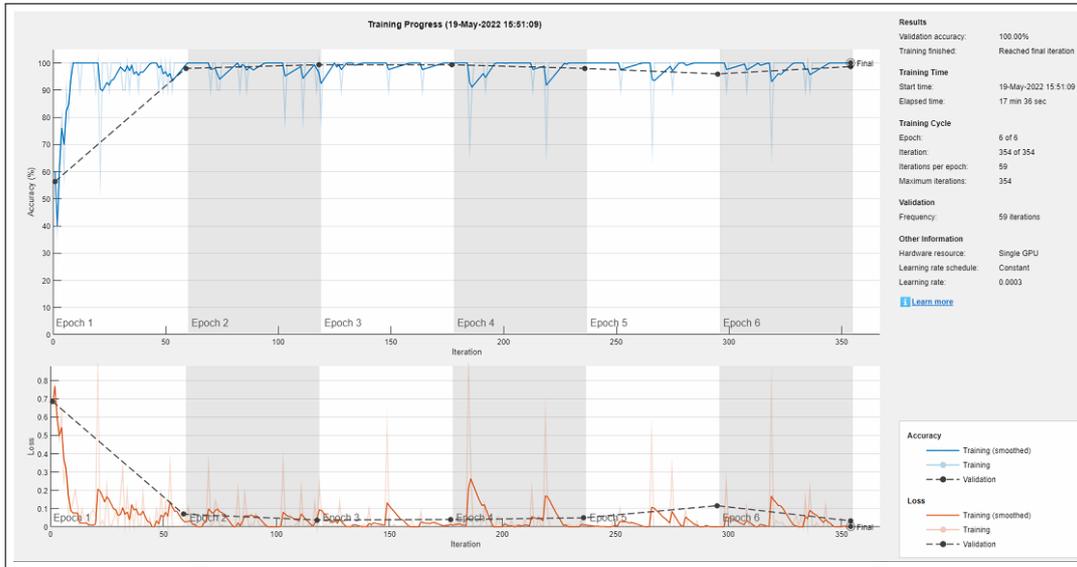


FIG. 3.15 : Un processus de formation de DenseNet.

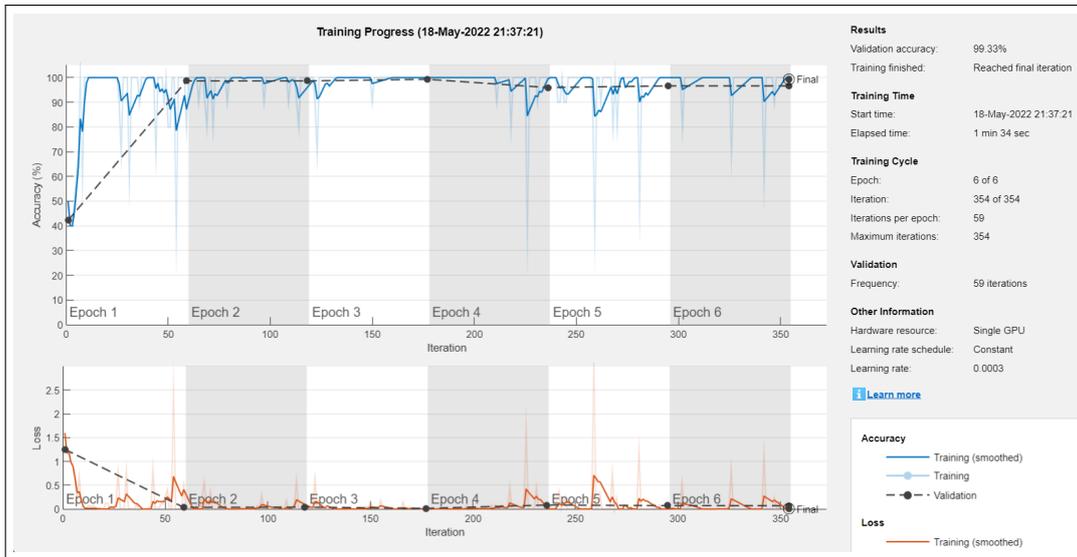


FIG. 3.16 : Un processus de formation de ResNet-18.

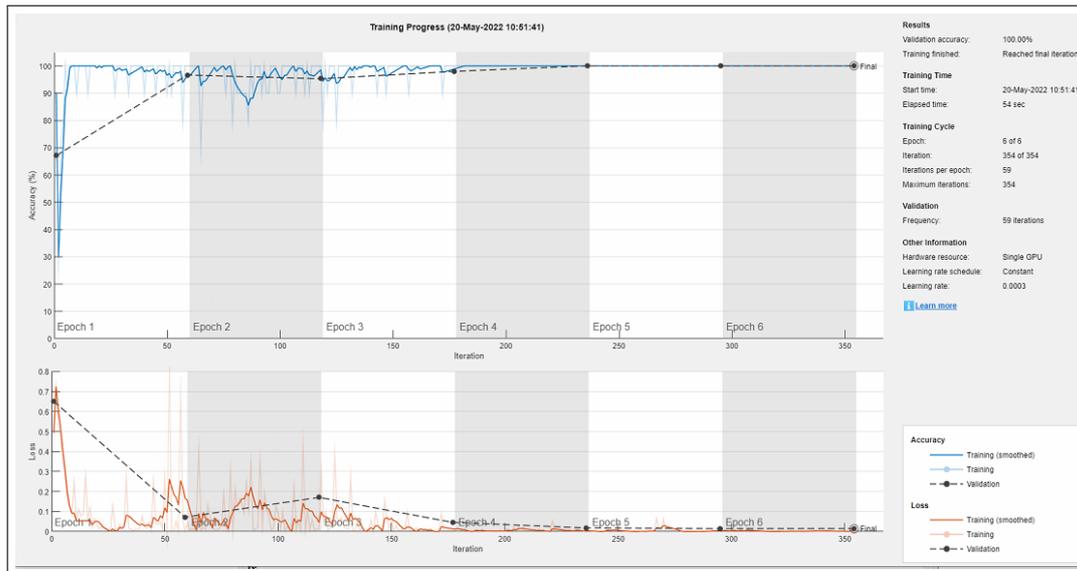


FIG. 3.17 : Un processus de formation de AlexNet.

Douze CNN modèles ont été étudiés à l'aide d'une base de données COVID-19 différente. Le graphique supérieur de la figure montre la procédure de formation des trois meilleurs CNNs (Fig 3.14, fig 3.15 et fig 3.16) et le modèle le plus faible (fig 3.17). Le tableau 3.4 présente les indicateurs d'évaluation de la classification. Moyenne de précision (MAcc), moyenne de sensibilité (MSEN), moyenne de spécificité (MSPE) et moyenne de F1-Score (mF1), respectivement.

- [La comparaison](#)

Notre étude était basée sur la détection du COVID-19 par des images radiographiques thoraciques. Dans la première base de données (UCSD), nous avons utilisé deux méthodes : la classification instantanée par les modèles CNN, et la seconde basée sur l'extraction de caractéristiques par les modèles CNN + classifieur SVM. Ensuite, dans la deuxième base de données (CT COVID), nous catégorisons simplement par modèles CNN. Les résultats obtenus dans le tableau 3.5 ont montré les conclusions suivantes :

La méthode	Model CNN	Accuracy(%)
CNN	ResNet-18; DenseNet-201	79.31
SVM	ShuffleNet	82.06
CNN	ResNet-101	97.85

TAB. 3.5 : les meilleur performance(Accuracy%) de les méthodes proposé.

- Dans la première base de données (UCSD) utilisant la première méthode (CNN), il est apparu que densenet201 est le meilleur en termes de performances (précision) par rapport aux douze modèles entraînés, et lors de l'application de la deuxième méthode (SVM), il a montré que ShuffleNet est le meilleur parmi les douze modèles, et en comparant la première méthode avec la deuxième méthode, SVM est meilleur en classification et donne de meilleurs résultats en termes de performances (Accuracy) car l'extraction de caractéristiques a été utilisée avant, ce qui extrait des fonctionnalités supplémentaires et réduit les informations redondantes, ce qui conduit à une meilleure classification et moins d'erreurs, et le résultat était une meilleure performance (Accuracy) que CNN.
- Dans la deuxième base de données, nous avons utilisé la première méthode (CNN) uniquement. Resenet101 semblait être le mieux classé car le score de performance (Accuracy) était élevé par rapport aux douze modèles entraînés utilisés. Il se caractérise par plusieurs avantages, comme le temps d'entraînement court et le nombre de ses nombreuses couches.

3.6 Conclusion

La prédiction précoce des patients atteints de COVID-19 est essentielle pour empêcher la propagation de la maladie à d'autres personnes. Dans ce chapitre, nous avons proposé une approche basée sur l'apprentissage par transfert profond utilisant des images radiographiques pulmonaires obtenues à partir de patients normaux COVID-19 pour prédire automatiquement les patients COVID-19.

Comme nous l'avons expliqué dans ce chapitre l'architecture de l'application, les résultats obtenus. Les résultats de performance montrent que les modèles pré-entraînés Resnet-18 et DenseNet-201 ont donné la performance (accuracy) de 79,31% la plus élevée pour UCSD base de données, et ResNet-101 a donné la moyenne de précision (MACC) 97,85% la plus élevée et surpasse les autres modèles d'apprentissage par transfert, pour CT covid base de données, car le modèle ResNet101 comprend une couche convolutive, une couche de regroupement, une couche entièrement connectée et une couche Softmax. Grâce à l'introduction de méthodes d'apprentissage par transfert, le modèle converge plus rapidement et prend moins de temps à s'entraîner. De plus, le réseau restant résout le problème difficile de la formation approfondie du réseau et de l'amélioration des performances.

Conclusion générale et Points de vue

Conclusion générale

La classification des images est une tâche importante dans les domaines de la vision par ordinateur, de la reconnaissance d'objets et de l'apprentissage automatique. Grâce au deep learning, l'avenir de l'IA réside dans le développement d'applications très volumineuses et rapides.

En raison du manque d'installations médicales auquel sont confrontés presque tous les pays du monde, une détection précoce et précise du COVID-19 est devenue essentielle. À cette fin, après avoir terminé notre étude, il a été démontré que le réseau d'apprentissage en profondeur amélioré détecte le COVID-19 sur des images prises à partir de tomodensitogrammes thoraciques et la classification des cas non COVID-19. Le modèle proposé n'a pas besoin d'extraire la fonctionnalité manuellement, il est automatisé avec précision et rapidité dans les résultats expérimentaux qui ont été très convaincants et sont apparus comme une application utile pour le dépistage du COVID-19 sur les tomodensitogrammes d'individus suspectés d'avoir un coronavirus.

Points de vue

Sur la base de nos découvertes, on pense qu'il aide les radiologues à prendre des décisions dans la pratique clinique en raison de ses performances supérieures. Pour détecter le COVID-19 à un stade précoce, cette étude fournit des informations sur la manière dont les méthodes d'apprentissage en profondeur peuvent être utilisées pour la transmission. Dans d'autres études, les performances de classification de différents modèles CNN peuvent être testées en augmentant le nombre d'images de radiographie pulmonaire COVID-19 dans l'ensemble de données.

À l'avenir, nous visons à expérimenter d'autres modèles CNN ainsi que diverses stratégies de fusion pour améliorer les performances. Nous visons également à valider la méthode proposée dans d'autres bases de données, et ainsi démontrer la robustesse des modèles proposés. Les travaux futurs pourraient également inclure le dépistage de multiples affections telles que la pneumonie, la bronchite et la tuberculose ainsi que le COVID-19 pour les personnes suspectées de maladies respiratoires.

Bibliographie

- [1] N. Safdarian and N. J. Dabanloo, “Detection and classification of covid-19 by lungs computed tomography scan image processing using intelligence algorithm,” *Journal of Medical Signals and Sensors*, vol. 11, no. 4, p. 274, 2021.
- [2] “Détection automatisée du covid-19 à partir d’un scanner à l’aide d’un réseau de neurones convolutionnels,” *Biocybernétique et génie biomédical*, vol. 41, pp. 572–588.
- [3] X. Xu, F. Zhou, B. Liu, D. Fu, and X. Bai, “Efficient multiple organ localization in ct image using 3d region proposal network,” *IEEE transactions on medical imaging*, vol. 38, no. 8, pp. 1885–1898, 2019.
- [4] H. M. Boucetta youcef, “détection poursuite et comptage d’objet par la vision artificielle,” in *Memoire master*. universite de Blida, 2017.
- [5] R. BENTATA, “Segmentation d’images tomographiques par émission de positons,” Ph.D. dissertation, Université d’Oran1-Ahmed Ben Bella, 2012.
- [6] R. BOUCHOUAREB, “Réduction de bruit dans l’imagerie médicale en utilisant les réseaux de neurones cellulaires et les ondelettes,” Ph.D. dissertation, Université de Batna 2, 2015.
- [7] A. MHAMMEDI, I. YAKOUB, A. OUAHAB *et al.*, “La détection de covid-19 par l’apprentissage profonde (deep learning),” Ph.D. dissertation, UNIVERSITE AHMED DRAIA-ADRAR, 2021.
- [8] Y. Han, S.-c. Mu, H.-d. Zhang, W. Wei, X.-y. Wu, C.-y. Jin, G.-r. Gu, B.-j. Xie, and C.-y. Tong, “Artificial intelligence computed tomography helps evaluate the severity of covid-19 patients : A retrospective study,” *World Journal of Emergency Medicine*, vol. 13, no. 2, p. 91, 2022.

- [9] S. Akter, F. Shamrat, S. Chakraborty, A. Karim, and S. Azam, “Covid-19 detection using deep learning algorithm on chest x-ray images,” *Biology*, vol. 10, no. 11, p. 1174, 2021.
- [10] S. Q. Salih, H. K. Abdulla, Z. S. Ahmed, N. M. S. Surameery, and R. D. Rashid, “Modified alexnet convolution neural network for covid-19 detection using chest x-ray images,” *Kurdistan Journal of Applied Research*, pp. 119–130, 2020.
- [11] X. Yu, S.-H. Wang, X. Zhang, and Y.-D. Zhang, “Detection of covid-19 by googlenet-cod,” in *International Conference on Intelligent Computing*. Springer, 2020, pp. 499–509.
- [12] S. Al-Jumaili, A. D. Duru, and O. N. Uçan, “Covid-19 ultrasound image classification using svm based on kernels deduced from convolutional neural network,” in *2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, 2021, pp. 429–433.
- [13] K. Sahinbas and F. O. Catak, “Transfer learning-based convolutional neural network for covid-19 detection with x-ray images,” in *Data Science for COVID-19*. Elsevier, 2021, pp. 451–466.
- [14] A. Setyanto, K. Kusriani, T. B. Sasongko, A. B. Permana, and A. P. Saputra, “Efficient deep learning architecture for facemask detection,” in *2021 4th International Conference on Information and Communications Technology (ICOIACT)*. IEEE, 2021, pp. 119–124.
- [15] S. Albahli and W. Albattah, “Detection of coronavirus disease from x-ray images using deep learning and transfer learning algorithms,” *Journal of X-ray Science and Technology*, vol. 28, no. 5, pp. 841–850, 2020.
- [16] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [17] S. Al-Jumaili, A. D. Duru, and O. N. Uçan, “Covid-19 ultrasound image classification using svm based on kernels deduced from convolutional neural network,” in *2021 5th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*. IEEE, 2021, pp. 429–433.

- [18] S. Kogilavani, J. Prabhu, R. Sandhiya, M. S. Kumar, U. Subramaniam, A. Karthick, M. Muhibullah, and S. B. S. Imam, “Covid-19 detection based on lung ct scan using deep learning techniques,” *Computational and Mathematical Methods in Medicine*, vol. 2022, 2022.
- [19] M. Alruwaili, A. Shehab, A. El-Ghany *et al.*, “Covid-19 diagnosis using an enhanced inception-resnetv2 deep learning model in cxr images,” *Journal of Healthcare Engineering*, vol. 2021, 2021.
- [20] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 2818–2826.
- [21] H. M. Emar, M. R. Shoaib, M. Elwekeil, W. El-Shafai, T. E. Taha, A. S. El-Fishawy, E.-S. M. El-Rabaie, S. A. Alshebeili, M. I. Dessouky, and F. E. Abd El-Samie, “Deep convolutional neural networks for covid-19 automatic diagnosis,” *Microscopy Research and Technique*, vol. 84, no. 11, pp. 2504–2516, 2021.
- [22] M. e. H. G. e. J. M. e. M. M. Prakash, NB et Murugappan, “Deep transfer learning for covid-19 detection and infection localisation with superpixel based segmentation,” *Villes et société durables*, vol. 75.
- [23] H. Alshazly, C. Linse, E. Barth, and T. Martinetz, “Explainable covid-19 detection using chest ct scans and deep learning,” *Sensors*, vol. 21, no. 2, p. 455, 2021.
- [24] A. M. Rafi, U. Kamal, R. Hoque, A. Abrar, S. Das, R. Laganier, M. K. Hasan *et al.*, “Application of densenet in camera model identification and post-processing detection.” in *CVPR workshops*, 2019, pp. 19–28.
- [25] A. A. Osi, M. Abdu, U. Muhammad, A. Ibrahim, L. A. Isma’il, A. A. Suleiman, H. S. Abdulkadir, S. S. Sada, H. G. Dikko, and M. Z. Ringim, “A classification approach for predicting covid-19 patient’s survival outcome with machine learning techniques,” *medRxiv*, 2020.
- [26] J. Zhao, Y. Zhang, X. He, and P. Xie, “Covid-ct-dataset : a ct scan dataset about covid-19,” 2020.