



République Algérienne Démocratique et Populaire

**Ministère d'Enseignement Supérieur et de la Recherche Scientifique
Université ABBAS LAGHROUR-Khenchela**

Département MI

Mémoire de fin d'études

Pour l'obtention du diplôme de Master (L.M.D)

Spécialité : Sécurité et technologie web

Thème:

***Apprentissage profond pour la détection
automatique de Covid19 sur des images
radiographies pulmonaires.***

Présenté par : BOUDRAA MEROUAN et LAHOUEL MAHIEDDINE

Encadreur : Dr. ABBAS FAYÇAL.

Membres de jury :

Président du jury :

Examineur :

Année universitaire 2020/2021

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

سورة الفاتحة



Remerciement

Nous tenons tout d'abord à remercier Dieu le tout puissant et miséricordieux, qui nous a donné la force et la patience d'accomplir ce modeste travail. En second lieu, nous tenons à remercier notre encadreur Dr. Abbas Faycal, pour son précieux conseil et son aide durant toute la période de notre travail. Nos vifs remerciements vont également aux membres du jury pour l'intérêt qu'ils ont porté à notre recherche en acceptant d'examiner notre travail et de l'enrichir par leurs propositions. A nos familles et nos amis qui par leurs prières et leurs encouragements, on a pu surmonter tous les obstacles. Enfin, nous tenons également à remercier toutes les personnes qui ont participé de près ou de loin à la réalisation de ce travail.



Résumé

La pandémie covid-19 a un impact dévastateur sur l'économie mondiale et la santé publique. L'un des principaux moyens de contrôler la propagation de cette maladie est l'identification au stade initial, de sorte que l'isolement et le traitement puissent être initiés. En raison du manque d'outils médicaux de diagnostic auxiliaires automatisés, de la disponibilité de kits de test de moindre sensibilité et de la disponibilité limitée des professionnels de la santé, la pandémie s'est propagée comme une traînée de poudre à travers le monde. Certaines découvertes récentes indiquent que les radiographies pulmonaires contiennent des informations importantes concernant l'apparition du virus, ces informations peuvent être analysées afin que le diagnostic et le traitement puissent être initiés à un stade plus précoce. C'est là que l'intelligence artificielle rencontre les capacités de diagnostic des cliniciens expérimentés. L'objectif de du travail proposé est de contribuer à la lutte contre la pandémie mondiale en développant une solution automatisée pour identifier les radiographies pulmonaires affectées par le covid-19 en utilisant un modèle de réseau neurones convolutif (CNN) optimisé.

Notre modèle s'opère en deux étapes : une étape de préparation de données, elle consiste à appliquer un entraînement sur les images composant la dataset afin d'extraire les caractéristiques. La seconde étape consiste à appliquer le concept de réseaux de neurone convolutif afin de classifier les images radiographiques pulmonaires affectées par le covid-19.

Mots Clés : classification, covid-19, CNN, Deep Learning, images CXR

ملخص

للوباء كوفيد-19 تأثير مدمر على الاقتصاد العالمي والصحة العامة. من الطرق الرئيسية للسيطرة على انتشار هذا المرض هو التحديد في المرحلة الأولية بحيث يمكن البدء في العزل والعلاج. نظرًا لعدم وجود أدوات طبية تشخيصية مساعدة آلية ، وتوافر مجموعات اختبار حساسية أقل ، ومحدودية توافر المتخصصين في الرعاية الصحية ، انتشر الوباء كالنار في الهشيم في جميع أنحاء العالم. تشير بعض النتائج الحديثة إلى أن صور الصدر بالأشعة السينية تحتوي على معلومات مهمة تتعلق بظهور الفيروس ، ويمكن تحليل هذه المعلومات حتى يمكن البدء في التشخيص والعلاج في مرحلة مبكرة. هذا هو المكان الذي يلتقي فيه الذكاء الاصطناعي بالقدرات التشخيصية للأطباء ذوي الخبرة. الهدف من العمل المقترح هو المساهمة في مكافحة الوباء العالمي من خلال تطوير طريقة آلية لتحديد صور الأشعة السينية للصدر المتأثرة بفيروس كورونا باستخدام نموذج الشبكة العصبية التلافيفية (CNN).

يعمل نموذجنا على مرحلتين: مرحلة إعداد البيانات ، وهي تتمثل في تطبيق تدريب على الصور المكونة لمجموعة البيانات من أجل استخراج الخصائص ، وتتكون المرحلة الثانية من تطبيق مفهوم الشبكات العصبية التلافيفية من أجل تصنيف أشعة الصدر. الصور المتأثرة بفيروس كوفيد-19.

الكلمات المفتاحية : تصنيف, كوفيد-19, CNN, والتعليم العميق, صور CXR

Abstract

The covid-19 pandemic is having a devastating impact on the global economy and public health. One of the main ways to control the spread of this disease is identification at the initial stage, so that isolation and treatment can be initiated. Due to the lack of automated ancillary diagnostic medical tools, the availability of lower sensitivity test kits, and the limited availability of healthcare professionals, the pandemic has spread like wildfire across the globe. Some recent findings indicate that chest x-rays contain important information regarding the onset of the virus, this information can be analyzed so that diagnosis and treatment can be initiated at an earlier stage. This is where artificial intelligence meets the diagnostic capabilities of experienced clinicians. The objective of the proposed work is to contribute to the fight against the global pandemic by developing an automated solution to identify chest x-rays affected by covid-19 using a convolutional neural network (CNN) model optimized.

Our model operates in two stages: a data preparation stage, it consists in applying training on the images composing the dataset in order to extract the characteristics, the second stage consists in applying the concept of convolutional neural networks in order to classify chest x-ray images affected by covid-19.

Keywords: classification, covid-19, CNN, Deep Learning, images CXR

TABLE DE MATIERES

INTRODUCTION GENERALE	I
CHAPITRE I.....	1
L'INTELLIGENCE ARTIFICIELLE	1
1. INTRODUCTION.....	2
1.1. Quelques Définitions.....	2
1.2. Grands domaines d'IA	3
2. L'apprentissage automatique.....	3
2.1. Quelques définitions :.....	3
3. La classification.....	4
3.1. Définition	4
3.2. L'objectif de la classification.....	4
3.3. Domaines d'application de la classification :.....	4
3.4. Les différentes méthodes de la classification et l'apprentissage	4
3.5. Présentation de certaines techniques de la classification :	6
iii. Machine à vecteurs de support :.....	7
4. Conclusion.....	8
CHAPITRE II.....	9
DEEP LEARNING.....	9
1. Introduction	10
2. Les réseaux de neurones.....	10
2.1. Définition	10
2.2. Domaines d'application de l'apprentissage profonde :	10
3. Les réseaux de neurone Convolutional CNN	11
3.1. Les Différents modules d'un réseau de neurones convolutif	11
3.2. La couche de convolution	12
3.3. La couche pooling	12
3.4. La couche Maxpooling.....	12
3.5. Les fonctions d'activation	13
3.6. Le dropout	15
3.7. Couche fully connected (FC)	16
4. Conclusion.....	17
CHAPITRE III.....	18
LE DEEP LEARNING POUR LA DETECTION DU COVID 19.....	18
1. INTRODUCTION.....	19
2. Deep Learning méthodes pour Covid-19	19
3. Réseau neuronal convolutif CNN.....	20
4. Recurrent neural network RNN.....	20

5.	long short term memory LSTM	21
6.	generative adversarial networks GAN	21
7.	Auto-encoder-decoder.....	22
8.	Types de problèmes Covid-19 résolus par DL.....	22
8.1.	Diagnostic.....	22
8.2.	Classification.....	23
8.3.	Forecasting	24
8.4.	Analyse des problèmes résolus et type d'entrées utilisées.....	25
9.	Conclusion.....	26
CHAPITRE IV		26
IMPLEMENTATION.....		26
1.	Introduction	27
2.	Environnement d'implémentation.....	27
2.1.	Google Colab.....	27
2.2.	Jupyter Notebook	27
2.3.	Python	27
2.4.	TensorFlow.....	28
2.5.	Keras	28
2.6.	Numpy.....	28
2.7.	Matplotlib.....	28
3.	Dataset.....	29
4.	Data Augmentation	31
5.	L'architecture de modèle.....	32
6.	Conclusion.....	34
CHAPITRE V		35
RESULTAT		35
1.	Introduction	36
2.	Compilation et entraînement	36
3.	Test de modèle	37
4.	Conclusion.....	39
CONCLUSION GENERALE		40
BIBLIOGRAPHIE.....		42
Bibliographie		43

TABLE DE FIGURES

Figure 1.1-L'apprentissage supervisé.....	5
Figure 1.2-Extrait de la classification taxinomique de Linné.....	6
Figure 2.1-Ensemble de neurones (cercles) créant la profondeur d'une couche de convolution (bleu). Ils sont liés à un même champ récepteur (rouge).....	12
Figure 2.2 Une illustration d'une couche de Maxpooling.....	13
Figure 2.3 Deux fonctions d'activation. (a) la sigmoïde, (b) la fonction ReLU.....	14
Figure 2.4 Une structure de réseau de neurones avant et après l'application de dropout.	16
Figure 2.5 Architecture de la couche fully connected.	16
figure 3.2 Analyse des niveaux d'utilisation des types de problèmes Covid-19 résolus par les méthodes DL.....	25
Figure 4.1 téléchargement des données depuis 'github'.....	29
Figure 4.2 la structure du dataset.....	29
Figure 4.3 exemple des images covid et non-covid du dataset.....	30
Figure 4.4 Effet des techniques d'augmentation sur une image radiographique. (a) Origine. (b) Renversé. (c) Rotation de 90°. (d) Rotation de 180°. (e) Tourné à 270°.	31
Figure 4.5 l'architecture de notre CNN.....	32
Figure 4.6 Configuration de modèle.	33
Figure 5.1 Exactitude du test.....	36
Figure 5.2 matrice de confusion.	37
Figure 5.3 La précision d'entraînement et de validation.....	38
Figure 5.4 L'erreur d'entraînement et de validation.....	38



INTRODUCTION GENERALE





Les systèmes de santé intelligents peuvent aider à améliorer les soins de santé dans le monde entier en utilisant l'intelligence artificielle (IA) et les techniques d'apprentissage automatique de différentes manières, L'IA permet aux médecins de diagnostiquer, découvrir et surveiller les maladies à un stade précoce. Ces applications dépendent de sources différentes et variées de données d'imagerie radiologique (radiographies, tomodensitométrie et IRM), d'imagerie pathologique et plus récemment, de séquences génomiques à utiliser lors de la mise en œuvre du ou des services.

Le 31 décembre 2019, une pneumonie de cause inconnue trouvée à Wuhan, en Chine, a été confirmée pour la première fois au bureau de pays de l'OMS en Chine, et la maladie a été nommée COVID-19 par l'OMS (Organisation mondiale de la santé). [1]

En raison de la récente pandémie, l'opportunité d'expansion des soins de santé intelligents augmente de façon exponentielle et attire de nombreux chercheurs pour trouver un remède ou un médicament au profit de milliards de personnes dans le monde. Par conséquent, la détection et la classification du COVID-19 est une application critique dans les systèmes de santé intelligents.

Dans ce mémoire, nous sommes motivés à proposer une approche basée sur la technologie d'apprentissage en profondeur (DL) en tant qu'outil potentiel pour aider les travailleurs de la santé à détecter en temps opportun la présence de COVID-19 à partir d'images CXR.

Ce document est divisé en 5 chapitres, il est organisé comme suit :

Chapitre1 : le premier chapitre introduit l'intelligence artificielle, l'histoire de l'intelligence artificielle et ses domaines, définition de l'apprentissage automatique notamment les approches de classifications.

Chapitre2 : le deuxième chapitre expose les réseaux de neurone en terme général et les réseaux de neurones convolutif (CNN) en spécifique.

Chapitre3 : Dans ce chapitre nous avons discuté les différentes recherches et statistiques effectuées par la communauté de DL sur le Covid-19, les méthodes et les algorithmes de DL pour le Covid-19 ensuite nous allons voir quelle sont les différents type



de problèmes de covid traités dans le DL ainsi nous exposons une analyse et des statistiques internationale.

Chapitre4 : le quatrième chapitre présente les détails d'implémentation. Ce chapitre définit la dataset ainsi que l'architecture de modèle qu'on a créé pour détecter et classifier les radiographies pulmonaires affectées par le covid-19.

Le Chapitre5 : conclut ce mémoire en présentant l'ensemble des résultats expérimentaux obtenus et des représentations graphiques pertinentes qui montre l'efficacité de notre méthode. Une conclusion synthétise notre travail et les résultats obtenus et nous proposerons quelques perspectives concernant notre travail.



CHAPITRE I

L'INTELLIGENCE ARTIFICIELLE



1. INTRODUCTION

L'intelligence artificielle est l'un des domaines les plus importants et passionnants de l'informatique. Ce dernier couvre les fondamentaux de l'informatique et des systèmes d'information afin de maximiser vos chances d'avoir des emplois futurs. Il offre également la possibilité de mener des recherches de pointe dans des domaines de haut niveau.

Dans ce chapitre nous allons présenter quelque définition d'IA et apprentissage automatique ainsi que l'approche de classification et ses différents algorithmes.

1.1. Quelques Définitions

Qu'est-ce que l'intelligence ?

« La faculté de connaître et comprendre, incluant la perception, l'apprentissage, l'intuition, le jugement et la conception. » (Petit Robert).

« La faculté de connaître et de raisonner. » (Dictionnaire American Heritage).

« Application de la connaissance à la résolution de problèmes. » (Newell et Simon).

L'intelligence artificielle (IA) c'est une science dont le but est de résoudre avec la machine les tâches qu'une personne effectue en utilisant son intelligence.

1.1 Un court historique d'IA

L'intelligence artificielle (IA) est un domaine qui a une longue histoire et qui est toujours en constante évolution.

- 1943 : McCulloch et Pitts créent le modèle du neurone formel.
- 1948 : Création de la cybernétique (science des systèmes) par Norbert Wiener.
- 1949 : Hebb établit la première règle d'apprentissage neuronal.
- 1950 Shannon, 1952 Samuel, 1953 Turing : machine pour jouer aux échecs.
- 1956 Workshop où est né le terme "intelligence artificielle".
- 1959 Rochester : Geometry Theorem Prover.
- 1958 McCarthy au MIT crée le LISP et le "time sharing". Créé DIGITAL.
- 1960 John McCarthy, Allen Bewell & Herbert Simon: L'ordinateur peut être utilisé pour autre chose que des calculs « manipuler des symboles »
- 1969 arrêt des RNs limitations des perceptrons.
- 1969-1979 : systèmes experts.
- Depuis 1986 : retour des réseaux de neurone. [2]



1.2.Grands domaines d'IA

L'intelligence artificielle apparaît dans une variété de domaines, c'est un principe universel. Il est utilisé dans des domaines où l'on ne le voit pas, comme dans la vie quotidienne (GPS, informatique, reconnaissance vocale, météo...), et nous le trouvons dans des domaines beaucoup plus impressionnants à la limite de la science-fiction, comme la robotique ou le jeu. Voici quelques exemples :

Apprentissage / Adaptation :

Exemples : construction de systèmes experts, classification automatique de galaxie, contrôleurs de robots....

Reconnaissance et synthèse de la parole :

Exemples : réservation d'hôtel, annuaire téléphone.

Reconnaissance et synthèse d'images :

Exemples : effets spéciaux au cinéma, vidéo surveillance.

Reconnaissance de l'écriture :

Exemples : reconnaissance chèques, codes postaux.

Langage naturel :

Exemples : interface, text mining, web mining.

Aide à la décision :

Exemple : contrôle de trajectoire du satellite voyagé, (Systèmes experts).

Aide à la programmation :

Exemple : agents d'interface.

2. L'apprentissage automatique

2.1.Quelques définitions :

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est modifié jusqu'à l'obtention du comportement désiré. L'apprentissage neuronal fait appel à des exemples de comportement [3].

- **Apprentissage Automatique** (Machine Learning) est une branche de l'intelligence artificielle d'éditée à l'étude de modèles et d'algorithmes capables d'apprendre automatiquement. Ceci implique résoudre une variété de tâches en se basant sur des données existantes, avec un minimum d'a priori humain [4]. Le but est double :

- Prédire un comportement face à une nouvelle donnée.
- Approximer une fonction ou une densité de probabilité.

Voici une définition un peu plus générale :



- **L'apprentissage automatique** c'est le domaine d'étude qui permet aux ordinateurs d'apprendre sans être explicitement programmés [5]

3. La classification

3.1.Définition

Classifier une image est une tâche ou une série de méthodes qu'une théorie unifiée pour pouvoir utiliser les images pour les analyses complémentaires ou pour la cartographie, il est souvent important de traduire l'information de fréquence contenue dans les images en information thématique portant sur l'occupation du sol ou la couverture végétale.

On a généralement le choix entre deux approches : la classification supervisée et non-supervisée.

3.2.L'objectif de la classification

L'objectif de la classification d'images est d'élaborer un système capable d'affecter un classement automatique d'images. Ainsi, ce système permet d'effectuer une tâche d'expertise qui peut s'avérer coûteuse à acquérir pour un être humain en raison notamment de contraintes physiques comme la concentration, la fatigue et le temps nécessaire pour un volume important de données images.

3.3.Domaines d'application de la classification :

La classification joue un rôle important dans toutes les sciences et techniques qui font appel à la statistique multidimensionnelle.


Citons tout d'abord les sciences biologiques : botanique, zoologie, écologie,...Ces sciences utilisent également le terme de "taxinomie" pour désigner l'art de la classification.

De même les sciences de la terre et des eaux : géologie, pédologie, géographie, étude des pollutions, font grand usage de classifications.

3.4.Les différentes méthodes de la classification et l'apprentissage

i. Méthodes supervisées :

Dans le cas de l'apprentissage supervisé, on dispose d'un ensemble de données étiquetées, ou d'exemples qui se sont vus associés une classe par un professeur ou un expert. Cet ensemble d'exemples constitue la base d'apprentissage.



Les méthodes d'apprentissage supervisé se donnent alors comme objectif général de construire à partir de la base d'apprentissage, ou fonctions de classement. Une telle fonction permet, à partir de la description d'un objet, de reconnaître un attribut particulier.




Figure 1.1-L'apprentissage supervisé.

Dans l'inférence inductive est définie comme un processus qui à partir d'une connaissance spécifique observée sur certains objets et d'une hypothèse inductive initiale, permet d'obtenir une assertion inductive impliquant ou rendant compte fortement ou faiblement des observations. Dans le cas de l'apprentissage inductif supervisé, qui est un sous domaine de l'inférence inductive, la connaissance spécifique consiste en un ensemble d'objets appartenant à des classes connues. L'assertion inductive est exprimée par une règle de classification qui assigne une classe à chaque objet. L'implication forte est satisfaite si la règle classe correctement tous les objets connus. [6]

Méthodes non-supervisées :

L'apprentissage non-supervisé, encore appelé apprentissage à partir d'observations ou découverte, consiste à déterminer une classification « sensée » à partir d'un ensemble d'objets ou de situations données (des exemples non étiquetés).

On dispose d'une masse de données indifférenciées, et l'on désire savoir si elles possèdent une quelconque structure de groupes. Il s'agit d'identifier une éventuelle tendance des données à être regroupées en classes. Ce type d'apprentissage, encore appelé Cluster ING ou Cluster Analysis, se trouve en classification automatique et en taxinomie numérique. Cette forme de classification existe depuis des temps immémoriaux. Elle concerne notamment les sciences de la nature les classifications des documents et des livres mais également la classification des sciences élaborées au cours des siècles par les philosophes. [7]




Figure 1.2-Extrait de la classification taxinomique de Linné.

L'automatisation de la construction de classification constitue aujourd'hui un véritable domaine de recherche. La notion clé utilisée pour créer des classes d'objets est une mesure de la similarité entre les objets. Les classes ou concepts sont construits de façon à maximiser la similarité intra-classes et à minimiser la similarité interclasses.

L'apprentissage non supervisé correspond également à la classification conceptuelle, où une collection d'objets forme une classe si cette classe peut être décrite par un concept, compte tenu d'un ensemble de concepts prédéfinis.

3.5.Présentation de certaines techniques de la classification :

i. k plus proches voisin :

L'algorithme KNN figure parmi les plus simples algorithmes d'apprentissage artificiel. Dans un contexte de classification d'une nouvelle observation x , l'idée fondatrice simple est de faire voter les plus proches voisins de cette observation. La classe de x est déterminée en fonction de la classe majoritaire parmi les k plus proches voisins de l'observation x .

Donc la méthode du plus proche voisin est une méthode non paramétrique où une nouvelle observation est classée dans la classe d'appartenance de l'observation de l'échantillon d'apprentissage qui lui est la plus proche, au regard des covariables utilisées. La détermination de leur similarité est basée sur des mesures de distance. [8]

ii. k-means :

L'algorithme *k-means* est l'algorithme de regroupement le plus connu et le plus utilisé, du fait

de sa simplicité de mise en œuvre. Il partitionne les données d'une image en K clusters. Contrairement à d'autres méthodes dites hiérarchiques, qui créent une structure en « arbre de clusters » pour décrire les groupements, *k-means* ne crée qu'un seul niveau de clusters.



L'algorithme renvoie une partition des données, dans laquelle les objets à l'intérieur de chaque cluster sont aussi proches que possible les uns des autres et aussi loin que possible des objets des autres clusters. Chaque cluster de la partition est défini par ses objets et son centroïde. Le *k-means* est un algorithme itératif qui minimise la somme des distances entre chaque objet et le centroïde de son cluster.

La position initiale des centroïdes conditionne le résultat final, de sorte que les centroïdes doivent être initialement placés le plus loin possible les uns des autres de façon à optimiser l'algorithme. *K-means* change les objets de cluster jusqu'à ce que la somme ne puisse plus diminuer. Le résultat est un ensemble de clusters compacts et clairement séparés, sous réserve qu'on ait choisi la bonne valeur K du nombre de clusters. Les principales étapes de l'algorithme *k-means* sont :

1. Choix aléatoire de la position initiale des K clusters.
 2. (Ré-Affecter les objets à un cluster suivant un critère de minimisation des distances (généralement selon une mesure de distance euclidienne).
 3. Une fois tous les objets placés, recalculer les K centroïdes.
- Réitérer les étapes 2 et 3 jusqu'à ce que plus aucune réaffectation ne soit faite. [9]

iii. Machine à vecteurs de support :

Les machines à vecteurs de support ou séparateurs à vaste marge (en anglais Support Vector Machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de classification.

les SVM sont une généralisation des classifiées linéaires.les SVM ont été développés dans les années 1990 à partir des considérations théoriques de Vladimir Vapnik sur le développement d'une théorie statistique de l'apprentissage : la Théorie de Vapnik-Chervonenkis. Les SVM ont rapidement été adoptés pour leur capacité à travailler avec des données de grandes dimensions, le faible nombre d'hyper paramètres, leurs garanties théoriques, et leurs bons résultats en pratique.

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

[10]



4. Conclusion

Dans ce chapitre, nous avons représentées les concepts importants en IA quelques définitions, un historique. En suit,nous avons exposée quelques concepts fondamentaux, ses types et ses modèles. nous avons présenté aussi quelques algorithmes et méthodes de classification (kNN, Machine à Vecteur Support, , K-means,). Dans le chapitre suivant, nous expliquerons les réseaux de neurones artificiels et les réseaux de neurones convolutionnels.



CHAPITRE II

DEEP LEARNING



1. Introduction

L'intelligence artificielle est une discipline scientifique recherchant des solutions aux problèmes à forte complexité logique ou algorithmiques. L'apprentissage automatique est un champ d'étude de l'intelligence artificielle. Par conséquent, l'apprentissage profond (en anglais *deep learning*, *deep structured learning*, *hierarchical learning*) est un ensemble de méthodes d'apprentissage automatique tentant de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires.

Dans ce chapitre nous allons présenter les notions en relation avec l'apprentissage profond.

2. Les réseaux de neurones

2.1. Définition

L'apprentissage profond « *deep learning* » est un ensemble de techniques d'apprentissage automatique qui a permis des avancées importantes en intelligence artificielle dans les dernières années.

Dans l'apprentissage automatique, un programme analyse un ensemble de données afin de tirer des règles qui permettront de tirer des conclusions sur de nouvelles données.

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

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

Les progrès de l'apprentissage profond ont été possibles notamment grâce à l'augmentation de la puissance des ordinateurs et au développement de grandes bases de données « *big data* ».

2.2. Domaines d'application de l'apprentissage profond :

Ces techniques se développent dans le domaine de l'informatique appliquée aux Technologies de l'information et de la communication

- La reconnaissance visuelle — par exemple, d'un panneau de signalisation par un robot ou une voiture autonome — et vocale
- La robotique



- La bioinformatique, p. ex., pour l'étude de l'ADN et des segments non codants du génome, ou encore la Cryométrie
- La reconnaissance ou la comparaison de formes
- La sécurité
- La santé
- La pédagogie assistée par l'informatique
- L'art
- L'intelligence artificielle en général
- La traduction....

3. Les réseaux de neurone Convolutional CNN

Les réseaux de neurones convolutionnels ou CNN pour « Convolutional Neural Network » sont une extension des MLP (multilayer perceptron) permettant de répondre efficacement aux principaux défauts des MLP. Ils sont conçus pour extraire automatiquement les caractéristiques des images d'entrée, sont invariants à de légères distorsions de l'image, et implémentent la notion de partage des poids permettant de réduire considérablement le nombre de paramètres du réseau. Ce partage des poids permet en outre de prendre en compte de manière forte les corrélations locales contenues dans une image. Les réseaux de neurones convolutionnels ont initialement été inspirés par la découverte faite par Hubel et Wiesel de neurones sensibles aux aspects locaux et sélectifs en orientation dans le système visuel du chat. La première utilisation des réseaux de neurones convolutionnels a été réalisée par Fukushima. Les poids sont forcés à être égaux pour détecter des lignes, des points ou des coins à tous les endroits possibles de l'image, implémentant de fait l'idée du partage des poids.

Une avancée importante a été effectuée par Y. Lecun. Avec l'utilisation d'un réseau de neurones convolutionnels dont l'apprentissage a été réalisé par propagation arrière (backpropagation). Ce modèle a notamment été appliqué avec succès pour la reconnaissance de caractères manuscrits. Le premier réseau de neurones convolutif (CNN) a été introduit à la fin des années 80 par LeCun 1989. C'est le premier réseau de neurones pour la reconnaissance d'images. Ce réseau permettait la reconnaissance de chiffres manuscrits. [11]

3.1. Les Différents modules d'un réseau de neurones convolutif

Nous présentons dans cette partie les différents modules utilisés dans les CNN : les convolutions, l'agglomération (pooling), les fonctions d'activation, le dropout et la couche Fully Connected.



3.2. La couche de convolution

Trois hyper paramètres permettent de dimensionner le volume de la couche de convolution (aussi appelé volume de sortie) : la 'profondeur', le 'pas' et la 'marge'.

1. 'Profondeur' de la couche : nombre de noyaux de convolution (ou nombre de neurones associés à un même champ récepteur).
2. 'Le pas' contrôle le chevauchement des champs récepteurs. Plus le pas est petit, plus les champs récepteurs se chevauchent et plus le volume de sortie sera grand.
3. 'La marge (à 0)' ou 'zero padding' : parfois, il est commode de mettre des zéros à la frontière du volume d'entrée. La taille de ce 'zero-padding' est le troisième hyperparamètre. Cette marge permet de contrôler la dimension spatiale du volume de sortie. En particulier, il est parfois souhaitable de conserver la même surface que celle du volume d'entrée.




Figure 2.1-Ensemble de neurones (cercles) créant la profondeur d'une couche de convolution (bleu). Ils sont liés à un même champ récepteur (rouge).

3.3. La couche pooling

La couche pooling (ou agglomération) permet de rajouter de l'invariance spatiale lors de l'extraction de caractéristiques tout en réduisant la dimension des entrées. Elle peut être de différentes natures mais les types de *pooling* les plus utilisés sont le *Max Pooling* et l'*Average pooling*. Le *Max Pooling* renvoie l'élément maximum sur une fenêtre de calcul. L'*Average pooling* permet de renvoyer la moyenne des éléments sur une fenêtre de calcul.

3.4. La couche Maxpooling

La couche Maxpooling est généralement utilisée après la couche convolutionnel. Elle est utilisé pour réduire les dimensions d'une image afin de diminuer le temps de calcul et



minimiser l'espace mémoire occupé.

La couche maxpooling permet de construire une couche de regroupement bidimensionnelle en utilisant l'algorithme *max-pooling*. Prend la taille du filtre de *pooling* et avance comme arguments.

La formule ci-dessous illustre le calcul de la taille de Maxpooling. [12]

$$W2 = \frac{W1 - F}{S} + 1$$


$$H2 = \frac{H1 - F}{S} + 1$$

W1, H1 : La taille du volume d'entrée.

F : La taille spatiale du volume de sortie.

S : Le pas.

W2, H2 : La taille du volume de sortie.



3.5. Les fonctions d'activation

Il existe différentes fonctions d'activation. Parmi les plus connues

1.1.1 Fonction d'activation ReLU

La fonction d'activation (ReLU) est utilisée presque dans tous les réseaux de neurones convolutionnels et dans les méthodes d'apprentissage profond. C'est une fonction élémentaire qui est généralement s'exécutée selon deux cas : le premier cas ; la fonction est désactivée si les entrées sont négatives (la sortie est nulle), le deuxième cas où les entrées sont positives donc la sortie est la même que l'entrée. Elle est utilisée pour gagner la non-linéarité du réseau. [13] Comme illustré par la formule suivante :



$$f(x) = \left\{ \begin{array}{l} 0 \text{ pour } x < 0 \\ x \text{ pour } x \geq 0 \end{array} \right\}$$

Avec :

f : La fonction d'activation.

x : La valeur du neurone.

1.1.2 Fonction d'activation Sigmoide


La fonction d'activation Sigmoide est le choix le plus approprié, Elle est particulièrement utilisée pour les modèles, où il faut prévoir des possibilités en sortie. [14]

$$f(x) = \text{sigmoid}(x) = \frac{1}{1+e^{-x}}$$


Où :

f : La fonction d'activation

x : La valeur du neurone.



(a)



(b)

Figure 2.3 Deux fonctions d'activation. (a) la sigmoïde, (b) la fonction ReLU.



1.1.3 Fonction d'activation Softmax

Softmax est un autre type de fonction d'activation plutôt différent, ce qui normalise un ensemble de pré-activations de telle sorte que chacune puisse être interprétée comme une probabilité.

Habituellement, dans les problèmes de classification, s'il n'y a que deux classes, une seule unité Sigmoidale est utilisée. Cependant, s'il y a plus de deux classes, le Softmax est utilisé.

Considérant x comme un vecteur de pré-activations C , le Softmax sur ces classes C est défini comme suit : [15]

$$f(x) = \frac{e^x}{\sum_{i=1}^c e^i}$$


Où :

f : La fonction d'activation.

x : La valeur du neurone.

3.6.Le dropout

La couche de dropout est introduite pour éviter le sur-apprentissage (*overfitting*), cette couche est utilisée pendant l'apprentissage. Elle permet de désactiver aléatoirement des neurones durant les différentes itérations de l'apprentissage. En d'autres termes, le dropout permet au réseau d'apprendre des sous-réseaux contenant moins de paramètres et donc moins sujets au sur-apprentissage. Cette manière de faire permet d'apprendre des paramètres plus génériques qui ne se focalisent pas sur des détails de la base d'apprentissage. Une fois l'apprentissage terminé, tous les neurones sont réactivés.



(a) Réseau neuronal standard. (b) Après l'application de dropout.

Figure2.4 Une structure de réseau de neurones avant et après l'application de dropout.

3.7.Couche fully connected (FC)

Après plusieurs couches de convolution et de Maxpooling, le raisonnement de haut niveau dans le réseau neuronal se fait via des couches entièrement connectées. Les neurones dans une couche entièrement connectée ont des connexions vers toutes les sorties de la couche précédente. Leurs fonctions d'activations peuvent donc être calculées avec une multiplication matricielle suivie d'un décalage de polarisation.




Figure2.5 Architecture de la couche fully connected.



4. Conclusion

Nous avons présenté dans ce chapitre un historique sur les réseaux de neurones, la définition des réseaux de neurone, aussi les réseaux de neurone convolutionnels et ses différents modules utilisés (la couche de convolution, les fonctions d'activation, la couche pooling, la couche dropout, et fully connected). Le prochain chapitre, nous allons voir l'état de l'art du deep learning pour la détection de COVID-19.



CHAPITRE III

LE DEEP LEARNING POUR LA DETECTION DU COVID 19





1. INTRODUCTION

Dans ce chapitre nous allons essayer de discuter les différentes recherches faites par la communauté de DL sur le Covid-19, commençant par les méthodes et les algorithmes de DL pour le Covid-19 ensuite nous allons voir les différents types de problèmes de Covid-19 traités par le deep Learning avec des analyses et des statistiques mondiales.

2. Deep Learning méthodes pour Covid-19

Dans cette section, diverses méthodes d'apprentissage en profondeur appliquées pour résoudre les problèmes de Covid-19 ont été mentionnées. Les types de méthodes d'apprentissage en profondeur utilisées sont le réseau neuronal récurrent (RNN), le réseau neuronal convolutif (CNN), le réseau antagoniste génératif GAN, la mémoire à long terme (LSTM) et l'auto-encodeur-décodeur. De nombreux types de CNN tels que les CNN multiples, les CNN résiduels de démarrage (IRCNN) et les CNN modifiés ont été utilisés avec succès pour résoudre les problèmes de Covid-19. En outre, diverses autres méthodes DL telles que DenseNet, Visual Geometry Group (VGG), MobileNet ResidualNet (ResNet) et SqueezeNet ont également été utilisés pour résoudre divers problèmes de Covid-19 comme le diagnostic et la classification, etc. [16] Ces méthodes ont été illustrées sur la figure 3.1.

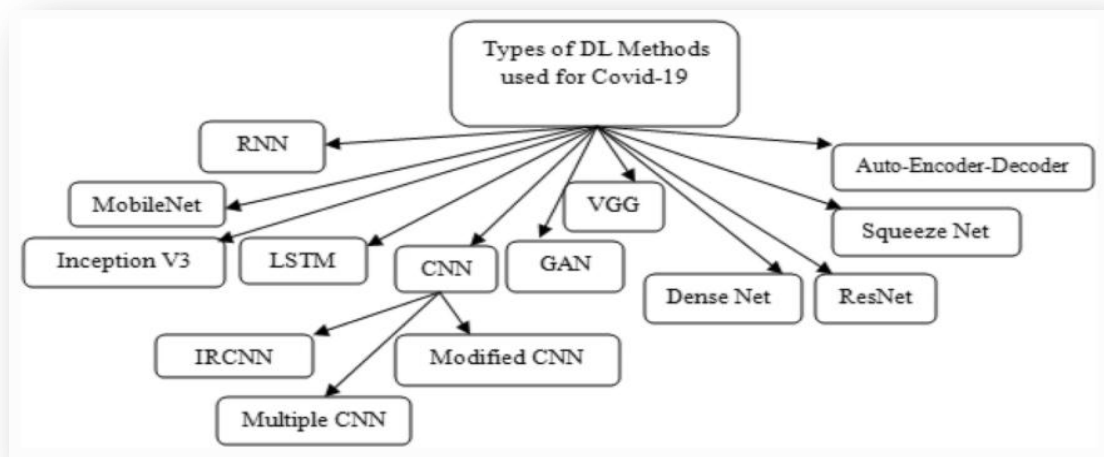


Figure 3.1 Plusieurs types de méthodes DL appliqués pour Covid-19.
[17]



3. Réseau neuronal convolutif CNN

Rajaraman et coll [18] ont introduit une méthode de détection du COV-19 dans les radiographies pulmonaires avec l'aide de CNN. Les auteurs ont examiné les ensembles de données tels que l'ensemble de données RSNA CXR, l'ensemble de données pédiatriques CXR [19], ainsi que l'ensemble de données Twitter Covid-19 CXR. La précision, la sensibilité, la précision, etc. sont utilisées comme mesures de performance. Sur la base de l'expérimentation, 99,01% du taux de précision a été obtenu en identifiant COV-19. Le risque de catégoriser automatiquement les maladies pulmonaires avec les images radiographiques du COV-19 émergé a été considéré par Apostolopoulos et al [20]. Les auteurs ont utilisé une variante efficace de CNN appelée MobileNetV2 et un ensemble de données avec 3905 images radiographiques. Ils ont envisagé plusieurs méthodes DL: AlexNet, VGGNet16, VGGNet19, GoogleNet et ResNet50. L'exactitude, la sensibilité et la précision sont considérées comme des mesures de performance pour catégoriser les images radiographiques présentant des maladies pulmonaires. Sur la base de l'expérimentation, 99,18% de précision de classification ont été obtenus. Rahimzadeh et Attar [21] ont proposé une technique de CNN profond pour identifier le NCOV-19 à partir d'images radiographiques, respectivement. Ils ont utilisé Xception, ResNet50V2 et un réseau concaténé qui sont des techniques DL avancées pour leur étude. Comme les CNN sont réciproques aux données d'image, les auteurs ont appliqué le modèle amélioré de CNN sur 42 radiographies de patients infectés ayant Covid-19 et 180 images radiographiques avec pneumonie. Le vrai positif (TP), le faux positif (FP), le vrai négatif (TN) et le faux négatif (FN) sont considérés comme les métriques d'évolution. Ils ont considéré que l'ensemble de données contenait 11 302 images. Sur la base de l'expérimentation, les auteurs ont conclu qu'une précision de 99,56% a été atteinte. De même, plusieurs recherches liées au Covid-19 sont lancées au jour le jour et des recherches pour résoudre les problèmes liés au Covid-19 ont déjà été mises en œuvre.

4. Recurrent neural network RNN

Zahangir Alom [22] a anticipé une nouvelle méthodologie pour l'identification du NCOV-19 en utilisant des NN récurrents (RNN) [23], ainsi que Covid-19 est le les ensembles de données des auteurs qui possèdent à la fois des images radiographiques et tomodensitométries, respectivement. Les auteurs ont pris en compte plusieurs paramètres



de performance tels que TP, FP et taux de précision. On a remarqué que la méthode proposée atteint des taux de précision de 84,67% et 98,78% pour les images CT et X, respectivement. Punn et coll. [24] ont introduit une méthode pour utiliser les techniques DL pour l'analyse pandémique. Les auteurs ont examiné les données du tableau de bord de l'Université Johns Hopkins. Le réseau neuronal profond (DNN), le RNN, la régression vectorielle de support (SVR) et la régression polynomiale (PR) sont les différentes techniques utilisées par les auteurs. Il faut des données de séries chronologiques comme entrée. Sur la base de l'expérimentation, les auteurs ont atteint le modèle PR comme le meilleur modèle parmi d'autres en termes d'erreur quadratique moyenne (RMSE).

5. long short term memory LSTM

Patankar [25] a développé une nouvelle méthode pour la découverte de médicaments pour résoudre le problème de Covid-19 en 2020. L'auteur a utilisé LSTM-RNN comme méthodologie proposée, et pour l'analyse des performances, ils ont utilisé les empreintes digitales Les données. Un bon taux de découverte de médicaments a été obtenu avec la méthode proposée. Ayyoubzadeh et coll.[26] ont développé une méthode moderne pour la prédiction de Covid-19 en 2020. Les auteurs ont développé LSTM comme méthodologie proposée et ont utilisé des données textuelles afin d'évaluer les performances. Un bon taux de prédiction a été obtenu avec la méthode proposée. Bandyopadhyay et Dutta [27] ont développé une méthode moderne pour la prédiction de Covid-19 à l'aide de données textuelles. Les auteurs ont proposé RNN basé sur LSTM, RNN basé sur GRU (unité récurrente gated), ainsi que LSTM-GRU-RNN pour prédire Covid-19. À partir de l'analyse expérimentale, il est observé que LSTM-GRU-RNN a surperformé entre autres. Pal et coll.[28] ont développé une méthode NN basée sur le LSTM pour la prédiction de Covid-19 à l'aide de données textuelles. Un bon taux de prédiction a été obtenu en utilisant la méthode proposée.

6. generative adversarial networks GAN

Pour identifier le COV-19 dans les images radiographiques pulmonaires, carence des ensembles de données standard, Loey et al. [29] ont introduit un modèle d'apprentissage par transfert profond lié au GAN. Les auteurs ont utilisé des technologies avancées comme AlexNet, VGGNet16, VGGNet19, GoogleNet et ResNet50. Ils ont pris des images de tomodensitométrie thoracique en entrée et ont trouvé le GAN comme la technique la plus utilisée. Ils ont considéré un ensemble de données contenant 307 images appartenant à quatre



types de classes: pneumonie bactérienne, Covid-19, et virus normal et pneumonie, respectivement. La robustesse de la technique projetée a été augmentée au fur et à mesure que les risques de sur-ajustement étaient résolus par le GAN. Sur la base de l'expérimentation, l'approche proposée a détecté efficacement le COV-19 même dans le manque d'ensembles de données et a obtenu une précision de 100% dans les tests. Zhavoronkov et coll. [30] ont développé le GAN et l'ont utilisé pour le dépistage de médicaments à l'aide de données textuelles. La précision, le rappel, etc. ont été utilisés comme mesures de performance, et des résultats fiables ont été observés sur la base d'expérimentations.

7. Auto-encoder-decoder

Les auto-codeurs sont des réseaux de neurones d'appropriation immédiate qui rétablissent la contribution au rendement [31]. À l'intérieur, ils ont un calque caché, qui peut être un code qui représente le modèle. Ils sont destinés à ne pas avoir la possibilité de dupliquer précisément la contribution au rendement. En règle générale, ils sont contraints à l'intérieur du composant du code ou condamnés à une amende pour adoption à l'intérieur du code. L'information est rétablie avec des erreurs dues à des malheurs de codage; Cependant, afin de les réduire, le réseau est obligé de rechercher les meilleurs faits saillants importants.

8. Types de problèmes Covid-19 résolus par DL

8.1.Diagnostic

Le diagnostic de COV-19 avec DL comprend les radiographies des poumons des patients et classe la radiographie comme COV-19 infecté ou non infecté. L'équipement d'examen des images DL peut être amélioré pour soutenir les radiologues dans la quantification, le triage et l'évaluation des tendances des données. Gozes et coll. [32] ont majoritairement porté l'étude de RADLogics. Le principal motif de leur étude est de créer un équipement de diagnostic d'image CT mécanique basé sur l'IA pour atteindre une précision élevée dans l'identification des patients COV-19-positifs et les observer pendant le traitement. Les auteurs ont fourni une enquête opportune des patients en distribuant les mesures quantitatives. Il a été constaté qu'il introduisait un score Corona qui mesure en permanence le développement de l'infection au fil du temps. Pour détecter l'infection, les auteurs ont initialement segmenté les sections pulmonaires des tomodensitogrammes avec une conception U-Net qui a été formée sur 6150 images. Les anomalies du NCOV-19 ont été identifiées à partir des images pulmonaires divisées avec le CNN 2D ResNet50 pré-formé sur l'ensemble



de données ImageNet. Sur la base de l'expérimentation, les auteurs ont rapporté deux points: soit une sensibilité élevée (98,2% de sensibilité et 92,2% de spécificité) soit une spécificité élevée (96,4% de sensibilité et 98% de spécificité). Le diagnostic de l'infection à Covid-19 comprend la détection, la prédiction de la gravité et le dépistage des médicaments.

L'Académie de recherche Alibaba (DAMO Academy) [33] s'est approchée début février avec une résolution basée sur l'IA capable d'identifier COV-19 avec une précision de 96% en 20 s. Le réseau acquiert la tomodensitométrie du patient en entrée et en sortie, que les symptômes du NCOV-19 aient été ou non visibles. Plus de 5000 échantillons formés ont été ajustés dans ce modèle et ont été disposés dans plus de 26 hôpitaux en Chine. Cette procédure a été utilisée pour diagnostiquer 30 000 cas à ce jour. Leur groupe a également urbanisé une solution PNL qui s'appuie sur des techniques pré-entraînées pour analyser les rapports de santé du NCOV-19 à la recherche d'un traitement [34]. Actuellement, ce modèle est largement utilisé et testé pour l'investigation textuelle des dossiers de santé et les études épidémiologiques par les centres de contrôle des maladies (CDC) dans plusieurs régions de Chine.

8.2.Classification

Selon la recherche médicale, il a été constaté que les personnes qui souffrent de COV-19 ont divers schémas respiratoires. Pour cette raison, les chercheurs de l'Université normale de Chine orientale se sont associés à des chercheurs organisationnels pour développer un algorithme basé sur DL qui peut aider au dépistage, à la prédiction et au diagnostic des patients affectés en fonction des problèmes respiratoires. La DL a été largement utilisée dans le domaine de la reconnaissance des formes respiratoires. Cho et coll. [35] ont exploité le CNN pour atteindre la classification de la respiration profonde. De même, Kim et al. [36] ont utilisé 1D CNN pour classer les signaux respiratoires projetés par les radars en quatre types. Ainsi, la catégorisation des signaux respiratoires extorqués par le schéma de mesure sans contact à l'aide de DL est une étude d'une grande importance. Wang et coll. [37] ont utilisé un GRU NN avec attention et des machines bidirectionnelles pour catégoriser six schémas respiratoires cliniquement majeurs (eupnée, tachypnée, bradypnée, biots, Cheyne-Stokes et apnée centrale) avec une caméra de profondeur. Les auteurs ont développé une technique de simulation respiratoire pour produire des informations simulées et ont atteint des informations mondiales actuelles avec une caméra de profondeur. Sur la base de l'expérimentation, les auteurs ont conclu que la technique prévue peut catégoriser les six schémas respiratoires



déclarés avec une précision de 94,5%, une précision de 94,4%, un rappel de 95,1% et un score F1 de 94,8%, respectivement. L'imagerie par tomодensitométrie est vitale pour l'évaluation, la stadification et le diagnostic de l'infection à Covid-19. Pour la quantification et pour réduire le temps de diagnostic par tomодensitométrie, les chercheurs ont construit un modèle avec des techniques DL pour mesurer l'infection pulmonaire causée par le COV-19. [38] La principale raison de leur étude est d'améliorer une technique basée sur la DL pour la quantification ainsi que la segmentation mécanique des zones infectées et de l'ensemble des poumons à partir de tomодensitogrammes. Les auteurs ont amélioré un réseau VB-NET [39]. Ils ont déclaré que leur modèle projeté était plus rapide que le vrai V-NET en raison de sa structure de goulot d'étranglement. Leur système a été formé sur 249 patients COV-19 et confirmé avec 300 derniers patients COV-19.

8.3.Forecasting

Le développement de systèmes de vigilance contre la maladie aide à contrôler la propagation de la maladie. Par conséquent, le développement de modèles de prévision précis aide le gouvernement et le système de santé à prendre les mesures nécessaires pour contrôler la propagation de la pandémie actuelle de Covid-19. Le problème de prévision a également été résolu avec des méthodes d'apprentissage en profondeur pour Covid-19. Huang et coll. [40] ont développé une méthode moderne pour la prévision de Covid-19 en Chine avec l'utilisation du modèle CNN. Pour l'évaluation des performances, un petit ensemble de données textuelles contenant des échantillons de patients Covid-19 a été pris en compte, et l'erreur absolue moyenne, l'erreur quadratique moyenne, etc. ont été utilisées comme facteurs d'évaluation. Une comparaison a été faite avec des algorithmes de référence dans la littérature tels que LSTM, MLP et GRU. Un bon taux de prévision a été observé avec la technique proposée.



8.4. Analyse des problèmes résolus et type d'entrées utilisées

À partir des seuls articles obtenus à partir de la recherche par mot-clé, il est observé que de nombreux problèmes de Covid-19 tels que le diagnostic, la classification et les prévisions ont été résolus. Dans cette section, nous avons fait une analyse sur les niveaux d'utilisation de ces problèmes, et cette analyse est mentionnée dans la figure 3.3

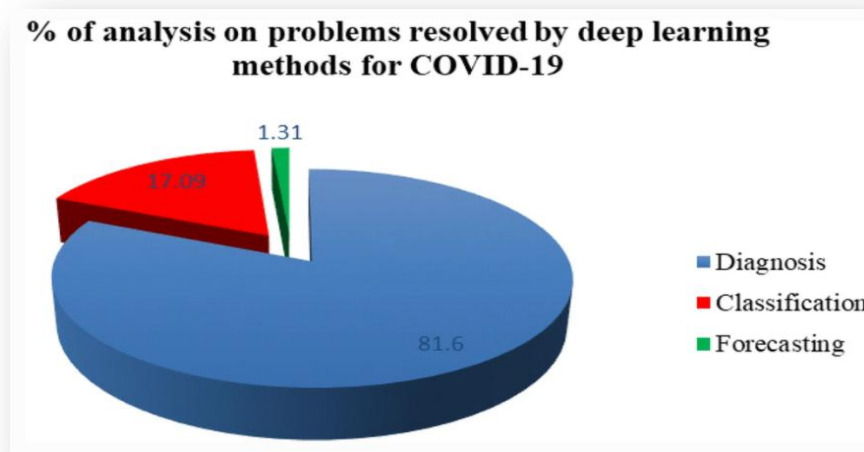


Figure 3.2 Analyse des niveaux d'utilisation des types de problèmes Covid-19 résolus par les méthodes DL. [41]



9. Conclusion

Dans ce chapitre nous avons présenté les différentes méthodes de deep Learning (CNN , RNN, LSTM, GAN...) utilisé pour traiter les différents problèmes de Covid-19 (Diagnostic, classification, forecasting). Nous montrerons dans le chapitre suivant l'implémentation de notre méthode que nous avons utilisé pour la classification et la détection du Covid-19, En effet notre méthode est basée sur les réseaux de neurones convolutionnels.



CHAPITRE IV

IMPLEMENTATION



1. Introduction

Dans ce chapitre, nous allons définir l'architecture de notre modèle qu'on a créé pour détecter et classifier le Covid-19, pour cela, on a utilisé le langage de programmation Python et ses bibliothèques : Tensorflow, Keras, Numpy, matploit pour développer notre modèle.

2. Environnement d'implémentation



2.1. Google Colab

Google Colab ou Colaboratory est un service cloud, offert par Google (gratuit), basé sur Jupyter Notebook et destiné à la formation et à la recherche dans l'apprentissage automatique. Cette plateforme permet d'entraîner des modèles de Machine Learning directement dans le cloud. Sans donc avoir besoin d'installer quoi que ce soit sur notre ordinateur à l'exception d'un navigateur. [42]

2.2. Jupyter Notebook



Jupyter Notebook est une application Web Open Source permettant de créer et de partager des documents contenant du code (exécutable directement dans le document), des équations, des images et du texte. Avec cette application il est possible de faire du traitement de données, de la modélisation statistique, de la visualisation de données, du Machine Learning, etc. [43]

2.3. Python



Python est un langage de programmation puissant de haut niveau, à la fois facile à apprendre, il prend en charge plusieurs modèles de programmation (procédural, fonctionnel et orienté objet). Les bibliothèques (packages) de python encouragent la modularité et la réutilisabilité des codes existants. Python et ses bibliothèques sont disponibles sans difficulté pour la majorité des plateformes et il peut être redistribué gratuitement. On estime que c'est l'un des langages de programmation les plus utilisés au monde [44].



2.4. TensorFlow

Développé par les chercheurs de Google, TensorFlow est un outil open source d'apprentissage automatique (machine learning), d'apprentissage profond et d'analyses statistiques et prédictives. A l'instar de plateformes similaires, il vise à rationaliser le développement et l'exécution d'applications analytiques avancées destinées aux data-scientists, statisticiens et modélisateurs prédictifs. [45]

2.5. Keras




Keras est une API (interface de programmation applicative) de réseaux neuronaux de haut niveau, écrite en Python et capable de fonctionner sur TensorFlow ou Theano. Il a été développé et maintenu par François Chollet pour mettre en place des modèles d'apprentissage en profondeur aussi rapides et faciles que possible pour la recherche et le développement. Keras fonctionne sur Python 2.7 ou 3.5 et peut parfaitement s'exécuter sur les processeurs graphiques GPU et les processeurs (unité centrale de traitement CPU). [46]

2.6. Numpy



NumPy est une bibliothèque pour le langage de programmation Python qui permet plus de stockage de données avec moins de mémoire. Avec un tableau multidimensionnel et d'autres ressources, NumPy permet aux programmeurs Python de stocker des nombres efficacement. [47]

2.7. Matplotlib



Matplotlib est une bibliothèque du langage de programmation Python destinée à tracer et visualiser des données sous formes de graphiques⁵. Elle peut être combinée avec les bibliothèques python de calcul scientifique NumPy et SciPy⁶. Matplotlib est distribuée librement et gratuitement sous une licence de style BSD4. Sa version stable actuelle est compatible avec la version 3 de Python. [48]



3. Dataset

Le jeu de données Dataset est un facteur très important pour l'obtention d'un modèle performant, pour cela nous avons utilisé une dataset dont les images sont réelles github. [49]

. Nous avons redimensionné les images à celles d'une résolution de **150 × 150 pixels**. Le nombre d'images aux rayons X de chaque ensemble a été réparti dans la figure 4.3. La visualisation des images aux rayons X de chaque classe est illustrée à la figure 4.4.

```
! git clone https://github.com/education454/datasets.git

Cloning into 'datasets'...
remote: Enumerating objects: 2301, done.
remote: Total 2301 (delta 0), reused 0 (delta 0), pack-reused 2301
Receiving objects: 100% (2301/2301), 1.31 GiB | 31.52 MiB/s, done.
Checking out files: 100% (2295/2295), done.
```

Figure 4.1 téléchargement des données depuis 'github'.

La structure de notre dataset est montrée dans la figure ci-dessous.

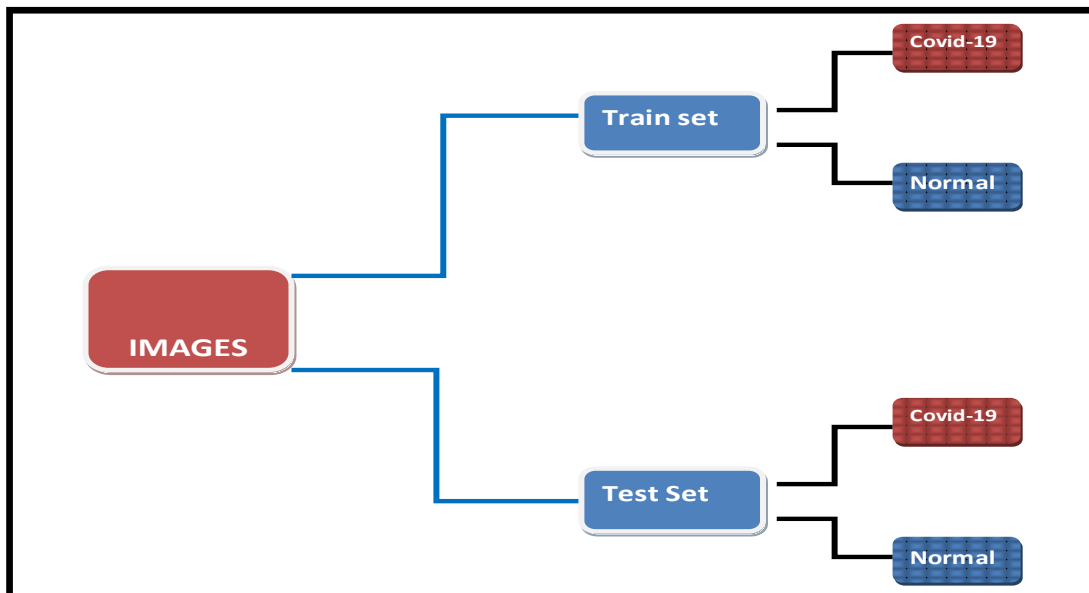


Figure 4.2 la structure du dataset.

Maintenant nous allons voir la composition et la taille de chaque directory



```
[ ] print("train dataset covid images :", len(train_covid_names))  
    print("train dataset normal images :", len(train_normal_names))  
    print("test dataset covid images :", len(test_covid_names))  
    print("test dataset normal images :", len(test_normal_names))
```

```
train dataset covid images : 545  
train dataset normal images : 1266  
test dataset covid images : 167  
test dataset normal images : 317
```

Figure 4.3 nombre d'images aux rayons X de chaque ensemble.

La figure ci-dessous présente quelques images des patients affecté et non affecté par la maladie COVID-19




Figure 4.3 exemple des images covid et non-covid du dataset.



4. Data Augmentation

L'augmentation de données est une technique qui peut augmenter considérablement les instances de données d'un ensemble de données pour entraîner un modèle [50]. Dans le cas d'ensembles de données d'image, la technique utilise les opérations de traitement d'image de base, telles que le retournement, la rotation, le recadrage ou le remplissage pour l'augmentation. L'ensemble de données est ensuite étendu par ces images transformées résultant de l'ensemble d'images existant, ce qui augmente la taille de l'ensemble de données pour entraîner les réseaux de neurones [51]. Pour résoudre le problème de la disponibilité d'un ensemble de données de petite taille qui affectait les performances du CNN proposé, la méthode d'augmentation des données a été utilisée dans cette étude. Cette technique a augmenté la taille de l'ensemble de données. Deux opérations de traitement d'image, le retournement et la rotation, ont été utilisées dans cette étude pour l'augmentation des données.

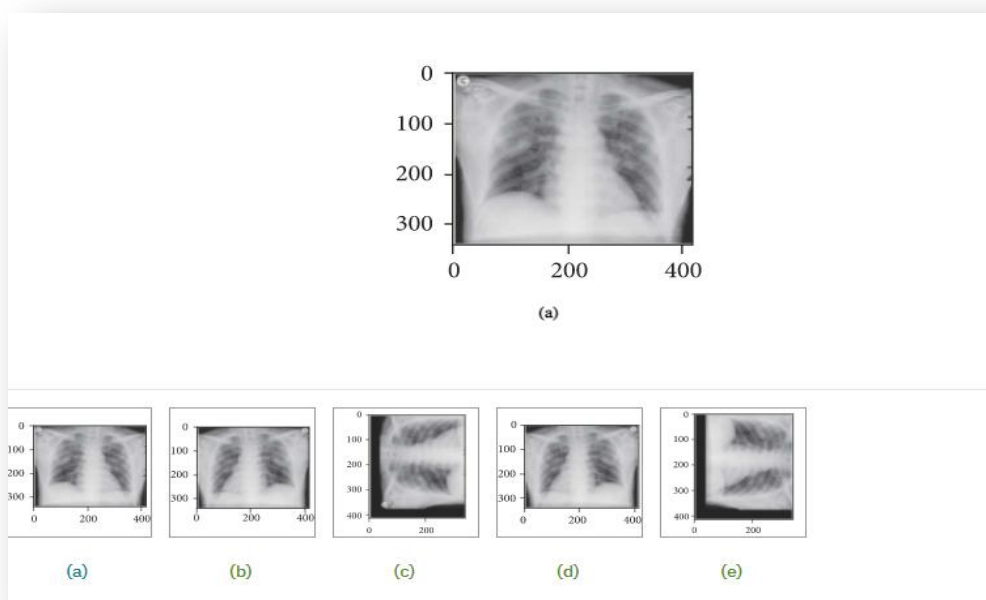


Figure 4.4 Effet des techniques d'augmentation sur une image radiographique. (a) Origine. (b) Renversé. (c) Rotation de 90°. (d) Rotation de 180°. (e) Tourné à 270°.



5. L'architecture de modèle

Un simple réseau de neurones multicouche 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 convolutives et une couche de neurones entièrement connectées (FC).

La figure ci-dessous montre l'architecture de notre modèle

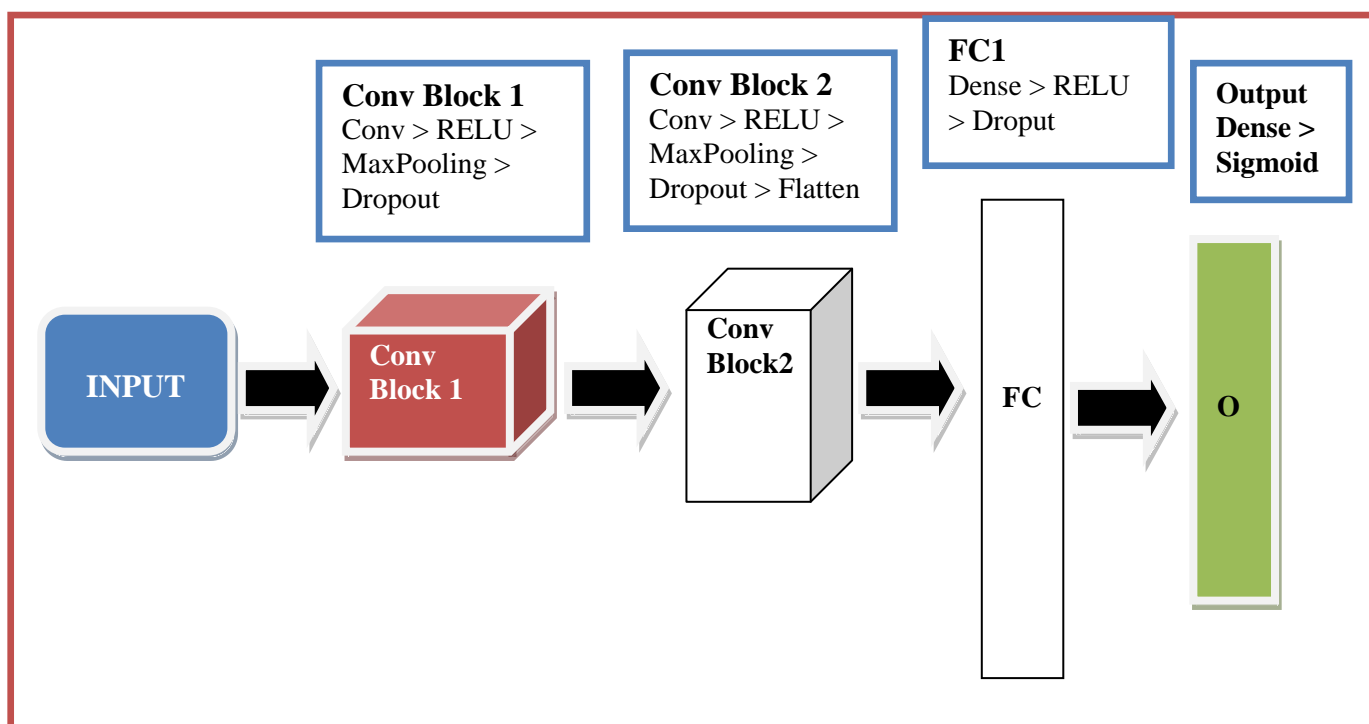


Figure 4.5 l'architecture de notre CNN.

Le modèle CNN proposé se compose de 10 couches dans lesquelles 2 sont convolutives (Conv2D), 2 couches 'MaxPooling', 3 couches 'Dropout', 1 couche 'Flatten' et 2 couches 'Dense'. La forme de l'image d'entrée du modèle CNN est (150, 150, 3), c'est-à-dire une image RVB de 150 x 150. Dans les deux couches Con2D. Après chaque couche Con2D, la couche de pooling maximale avec une taille de pooling de 2×2 a été utilisée, la couche d'activation a été utilisée avec la fonction ReLU et la couche dropout a été utilisé avec un taux



d'abandon de 50 %. Pour aplatir la matrice, une couche d'aplatissement a été utilisée qui les convertit en un vecteur qui sera entré pour 2 couches denses.

La valeur de sortie est donnée à une fonction d'activation sigmoïde. La sortie donnée par la fonction d'activation sigmoïde est comprise entre 0 et 1. Elle trouve l'erreur entre la classe prédite et la classe réelle. L'optimiseur « Adam » a été utilisé pour modifier le poids des attributs et le taux d'apprentissage afin de réduire la perte du modèle d'apprentissage. Les valeurs des paramètres du modèle et l'architecture du modèle sont données la figure 4.6.

```
Model: "sequential_1"
```

Layer (type)	Output Shape	Param #
conv2d_2 (Conv2D)	(None, 150, 150, 32)	2432
max_pooling2d_2 (MaxPooling2D)	(None, 75, 75, 32)	0
dropout_3 (Dropout)	(None, 75, 75, 32)	0
conv2d_3 (Conv2D)	(None, 75, 75, 64)	51264
max_pooling2d_3 (MaxPooling2D)	(None, 37, 37, 64)	0
dropout_4 (Dropout)	(None, 37, 37, 64)	0
flatten_1 (Flatten)	(None, 87616)	0
dense_2 (Dense)	(None, 56)	4906552
dropout_5 (Dropout)	(None, 56)	0
dense_3 (Dense)	(None, 1)	57

=====
Total params: 4,960,305
Trainable params: 4,960,305
Non-trainable params: 0

Figure 4.6 Configuration de modèle.



6. Conclusion

Nous avons présenté dans ce chapitre une méthode de classification et de détection de Covid-19 basée sur les réseaux de neurones convolutionnels, ainsi nous avons présenté l'architecture de notre CNN en détaillant les différentes couches. Dans le chapitre suivant nous allons exposer les résultats obtenus en termes de précision et d'erreur.



CHAPITRE V

RESULTAT





1. Introduction

Dans ce chapitre, nous allons présenter les résultats obtenus et les courbes de précision sur le jeu d'apprentissage et le jeu de validation afin de montrer l'efficacité de notre méthode.

2. Compilation et entraînement

Dans le domaine de l'apprentissage en profondeur, un algorithme Adam populaire est utilisé car il fournit rapidement de bons résultats, et il s'agit d'un algorithme d'optimisation pour mettre à jour les poids de réseau itératifs basés sur les données d'entraînement au lieu de la procédure classique de descente de gradient aléatoire.

La figure suivante présente l'entraînement du modèle pendant 30 epochs

```
Epoch 20/30
46/46 [=====] - 46s 997ms/step - loss: 0.0821 - accuracy: 0.9703 - val_loss: 0.0830 - val_accuracy: 0.9750
Epoch 21/30
46/46 [=====] - 45s 984ms/step - loss: 0.0793 - accuracy: 0.9726 - val_loss: 0.0676 - val_accuracy: 0.9781
Epoch 22/30
46/46 [=====] - 46s 990ms/step - loss: 0.0881 - accuracy: 0.9736 - val_loss: 0.0763 - val_accuracy: 0.9812
Epoch 23/30
46/46 [=====] - 45s 985ms/step - loss: 0.0679 - accuracy: 0.9746 - val_loss: 0.0812 - val_accuracy: 0.9750
Epoch 24/30
46/46 [=====] - 45s 979ms/step - loss: 0.0779 - accuracy: 0.9836 - val_loss: 0.0628 - val_accuracy: 0.9812
Epoch 25/30
46/46 [=====] - 45s 980ms/step - loss: 0.0564 - accuracy: 0.9830 - val_loss: 0.0699 - val_accuracy: 0.9781
Epoch 26/30
46/46 [=====] - 45s 976ms/step - loss: 0.0677 - accuracy: 0.9798 - val_loss: 0.1224 - val_accuracy: 0.9656
Epoch 27/30
46/46 [=====] - 45s 981ms/step - loss: 0.0916 - accuracy: 0.9611 - val_loss: 0.0770 - val_accuracy: 0.9719
Epoch 28/30
46/46 [=====] - 45s 986ms/step - loss: 0.0873 - accuracy: 0.9730 - val_loss: 0.0774 - val_accuracy: 0.9750
Epoch 29/30
46/46 [=====] - 48s 1s/step - loss: 0.0594 - accuracy: 0.9769 - val_loss: 0.0774 - val_accuracy: 0.9688
Epoch 30/30
46/46 [=====] - 46s 1s/step - loss: 0.0547 - accuracy: 0.9803 - val_loss: 0.0534 - val_accuracy: 0.9844
```

Figure 5.1 Exactitude du test.

Comme vous constater la figure 5.1 montre dans la dernière epoch que notre réseau atteint une valeur de 98% de précision et une valeur de l'erreur de 0.0534. En effet notre réseau de neurones produit de bons résultats en termes de précision.



3. Test de modèle

La matrice de confusion du modèle est illustrée à la figure 5.2. Les figures 5.3 et 5.4 montrent la courbe de précision et de perte entre l'entraînement et les tests, respectivement.

Selon la matrice de confusion, le test du modèle CNN utilise les 100 images radiographiques de l'ensemble de données, où 50 images appartiennent à la classe COVID-19 et 50 aux images normales. Le modèle CNN montre des performances significatives lors des tests et prédit correctement 97 images avec un taux d'erreur de 3%, comme indiqué dans la matrice de confusion.




Figure 5.2 matrice de confusion.

La figure 5.3 montre la précision du modèle pendant l'entraînement et la validation sous forme de graphique où la courbe en bleu montre la précision d'entraînement de CNN, tandis que la courbe de couleur orange montre la précision de validation. La précision d'apprentissage du CNN selon la figure 5.3 reste cohérente après les 5 époques et le CNN montre également une précision de validation cohérente après les 25 époques. Le graphique de la figure 5.4 montre la perte au cours de l'entraînement et la validation du CNN. La perte d'entraînement de CNN est minimale et cohérente à partir de la 1ère époque, tandis que la perte de validation devient minimale après 5 époques et reste cohérente jusqu'à la dernière époque. Les résultats ci-dessus montrent l'efficacité du modèle CNN proposé dans ce travail.

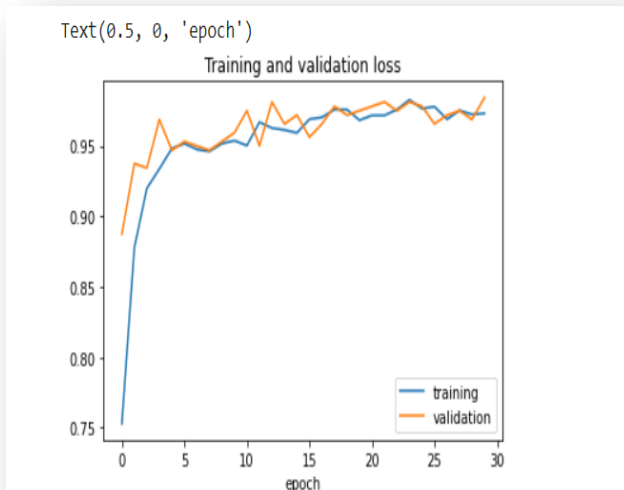


Figure 5.3 La précision d'entraînement validation.

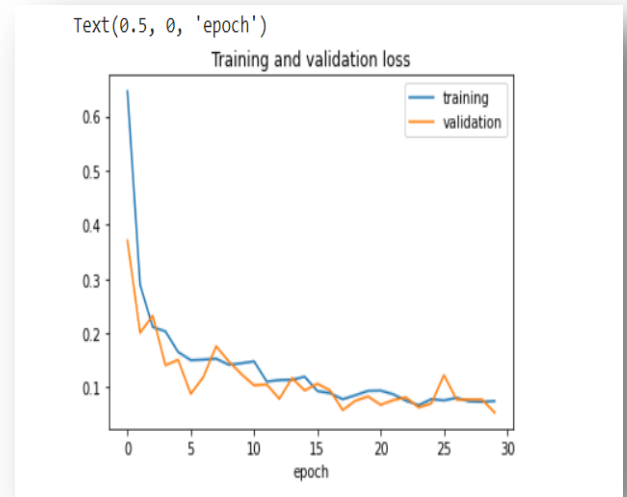


Figure 5.4 L'erreur d'entraînement et de validation.

Comme on peut le voir sur la figure 5.4, le CNN proposé ne met pas beaucoup de temps à converger, car à la première époque, la perte d'entraînement est de 0.7 et juste après 5 époques, elle diminue à 0,2, puis après 23 époques, elle diminue à 0,09, et à la dernière époque, la perte totale est de 0,075.

Les résultats fournis sont très efficaces car le score moyen de 30 itérations est de 97,5%.



4. Conclusion

Nous avons montré dans ce chapitre que notre méthode basée sur l'utilisation d'un modèle de deep learning permet offrir une solution automatique pour la détection du COVID-19. En effet notre méthode améliore grandement le taux de précision (97.5%) et diminue le taux d'erreur. Nous avons prouvé à travers les courbes de précision et d'erreur que notre modèle CNN produit de bons résultats en termes de détection et de reconnaissance de COVID-19. A travers notre modeste expérience nous mentionnant que le nombre d'époque et la profondeur de réseaux sont des facteurs importants pour l'obtention de meilleurs résultats.



CONCLUSION GENERALE





Ce mémoire traite la classification radiographies pulmonaires affectées par le covid-19 en utilisant un algorithme de deep learning basé sur le réseau neuronal convolutif (CNN).

Nous avons atteint ce but en découpant la phase de classification et de reconnaissance en deux étapes, la première étape consiste à effectuer des prétraitements puis un entraînement sur le jeu de données. La deuxième étape consiste à effectuer une prédiction sur une image en alimentant notre CNN par celle-ci. En effet pour améliorer les performances de notre modèle et afin d'éviter un sur-apprentissage la technique de dropout est utilisée. Les résultats obtenus ont montré que notre méthode produit de bons résultats avec un taux de précision (97.5%) et diminue le taux d'erreur.

Nous avons rencontré quelques problèmes dans la phase d'implémentation, le manque de hardware puissant pour l'exécution du modèle, nous avons adopté la solution Google colab pour l'entraînement de modèle afin de lever ce problème.

Dans les travaux futurs, nous essaierons d'améliorer les performances de notre modèle en augmentant la valeur de précision par l'utilisation des différentes approches et technique du DL comme le transfert Learning et aussi on va jouer plus sur les hyperparametres pour essayer d'obtenir des excellents résultats.



BIBLIOGRAPHIE

**BIBLIOGRAPHIE**

- [1] Deng, S. Q., & Peng, H. J. (2020). Characteristics of and public health responses to the coronavirus disease 2019 outbreak in China. *Journal of clinical medicine*,
- [2] Russell, S. J., & Norvig, P. (2016). *Artificial intelligence: a modern approach*. Malaysia; Pearson Education Limited, « Meghyn. Bienvenu. Introduction à l'Intelligence Artificielle. Université Aix-Marseille 1. 2007-2008 et 2008-2009. ».
- [3] Touzet, C. (1992). *Les réseaux de neurones artificiels, introduction au connexionnisme*. EC2.
- [4] Thibodeau-Laufer, E. (2014). *Algorithmes d'apprentissage profonds supervisés et non supervisés : applications et résultats théoriques*, (maître ès sciences, Université de
- [5] Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3), 210-229.
- [6] R. S. Michalski, R.L. Chilausky. *Knowledge acquisition by encoding expert rules versus computer induction from examples : a case study involving*. 1981.
- [7] Parrochia. *Classifications, histoire et problèmes formels*. Cinquièmes Rencontres de la société.
- [8] Mathieu-Dupas, E. (2010). *Algorithme des k plus proches voisins pondérés et application en diagnostic*. In 42èmes Journées de Statistique.
- [9] Zerzaihi, H., & Zarour, F. (2020). *Reconnaissance d images par les réseaux de neurones convolutifs* (Doctoral dissertation, University of Jijel).
- [10] Agina, A., & Marrakchi, O. *Identification de textures hétérogènes d'images ASTER et ROS par les classifieurs SVM*.



- [11] Chabot, F. (2017). Analyse fine 2D/3D de véhicules par réseaux de neurones profonds (Doctoral dissertation, Université Clermont Auvergne).
- [12] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [13] Xiang, W., Tran, H. D., & Johnson, T. T. (2017). Reachable Set Computation and Safety Verification for Neural Networks with ReLU Activations. arXiv preprint arXiv:1712.08163.
- [14]]Kanestrøm, P. Ø. (2017). Traffic flow forecasting with deep learning (Master's thesis, NTNU).
- [15] Pezeshki, M. (2017). Towards deep semi supervised learning.
- [16] Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R., & Singh, V. (2020). Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet. *Chaos, Solitons & Fractals*, 138, 109944.
- [17] Nayak, J., Naik, B., Dinesh, P., Vakula, K., Dash, P. B., & Pelusi, D. (2021). Significance of deep learning for Covid-19: state-of-the-art review. *Research on Biomedical Engineering*, 1-24.
- [18] Rajaraman, S., Siegelman, J., Alderson, P. O., Folio, L. S., Folio, L. R., & Antani, S. K. (2020). Iteratively pruned deep learning ensembles for COVID-19 detection in chest x-rays. arXiv preprint arXiv:2004.08379.
- [19] Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., ... & Zhang, K. (2018). Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 172(5), 1122-1131.



- [20] Apostolopoulos ID, Aznaouridis SI, Tzani MA. Extracting possibly representative COVID-19 biomarkers from x-ray images with deep learning approach and image data related to pulmonary diseases. *Journal of Medical and Biological Engineering*.
- [21] Rahimzadeh M, Attar A. A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest x-ray images based on the concatenation of Xception and ResNet50V2
- [22] Zahangir Alom, M., Shaifur Rahman, M. M., Shamima Nasrin, M., Taha, T. M., & Asari, V. K. (2020). COVID_MNet: COVID-19 detection with multi-task deep learning approaches. *arXiv*, arXiv-2004.
- [23] Mooney, P. (2020). "Kaggle Chest x-ray Images (Pneumonia) Dataset.
- [24] Pun, N. S., Sonbhadra, S. K., & Agarwal, S. (2020). COVID-19 epidemic analysis using machine learning and deep learning algorithms. *medRxiv*.
- [25] Patankar, S. (2020). Deep learning-based computational drug discovery to inhibit the RNA dependent RNA polymerase: application to SARS-CoV and COVID-19.
- [26] Ayyoubzadeh SM, Ayyoubzadeh SM, Zahedi H, Ahmadi M, Kalhori SRN. Predicting COVID-19 incidence through analysis of Google trends data in Iran: data mining and deep learning pilot study. *JMIR Public Health Surveill*. 2020;6(2):e18828.
- [27] Bandyopadhyay, S. K., & Dutta, S. (2020). Machine learning approach for confirmation of COVID-19 cases: positive, negative, Death and Release. *medRxiv*.
- [28] Pal, R., Sekh, A. A., Kar, S., & Prasad, D. K. (2020). Neural network based country wise risk prediction of COVID-19. *arXiv preprint arXiv:2004.00959*.



- [29] Loey, M., Smarandache, F., & Khalifa, N. E. M. (2020a). A deep transfer learning model with classical data augmentation and CGAN to detect COVID-19 from chest CT radiography digital images.
- [30] Zhavoronkov A, Aladinskiy V, Zhebrak A, Zagribelnyy B, Terentiev V, Bezrukov DS, et al. Potential COVID-2019 3C-like protease inhibitors designed using generative deep learning approaches. *In silico Medicine Hong Kong Ltd A.* 2020;307:E1.
- [31] Zhou, Z., Huang, G., Chen, H., & Gao, J. (2018). Automatic radar waveform recognition based on deep convolutional denoising auto-encoders. *Circuits, Systems, and Signal Processing*, 37(9), 4034-4048.
- [32] Gozes, O., Frid-Adar, M., Greenspan, H., Browning, P. D., Zhang, H., Ji, W., ... & Siegel, E. (2020).
- [33] Alibaba. (2020) https://www.alibabacloud.com/blog/fighting-coronavirus-with-technology-another-breakthrough-for-alibaba-in-nlp-research_595973
- [34] Shan, F., Gao, Y., Wang, J., Shi, W., Shi, N., Han, M., ... & Shi, Y. (2020). Lung infection quantification of covid-19 in ct images with deep learning. *arXiv preprint arXiv:2003.04655*.
- [35] Cho, Y., Bianchi-Berthouze, N., & Julier, S. J. (2017, October). DeepBreath: Deep learning of breathing patterns for automatic stress recognition using low-cost thermal imaging in unconstrained settings. In *2017 Seventh International Conference on Affective Computing and Intelligent Interaction (ACII)* (pp. 456-463). IEEE.
- [36] Kim, S. H., & Han, G. T. (2019, February). 1D CNN based human respiration pattern recognition using ultra wideband radar. In *2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)* (pp. 411-414). IEEE.



- [37] Wang, Y., Hu, M., Li, Q., Zhang, X. P., Zhai, G., & Yao, N. (2020). Abnormal respiratory patterns classifier may contribute to large-scale screening of people infected with COVID-19 in an accurate and unobtrusive manner. arXiv preprint arXiv:2002.05534.
- [38] Shan, F., Gao, Y., Wang, J., Shi, W., Shi, N., Han, M., ... & Shi, Y. (2020). Lung infection quantification of covid-19 in ct images with deep learning. arXiv preprint arXiv:2003.04655.
- [39] Milletari, F., Navab, N., & Ahmadi, S. A. (2016, October). V-net: Fully convolutional neural networks for volumetric medical image segmentation. In 2016 fourth international conference on 3D vision (3DV) (pp. 565-571). IEEE.
- [40] Huang, C. J., Chen, Y. H., Ma, Y., & Kuo, P. H. (2020). Multiple-input deep convolutional neural network model for covid-19 forecasting in China. medRxiv.
- [41] Nayak, J., Naik, B., Dinesh, P., Vakula, K., Dash, P. B., & Pelusi, D. (2021). Significance of deep learning for Covid-19: state-of-the-art review. Research on Biomedical Engineering, 1-24.
- [42] <https://ledatascientist.com/google-colab-le-guide-ultime/>
- [43] <https://ledatascientist.com/google-colab-le-guide-ultime/>
- [44] Van Rossum, G. (1990). The python language. See <http://www.python.org>.
- [45] <https://www.lemagit.fr/definition/TensorFlow>
- [46] Chollet, F. (2017). Deep learning with python. Manning Publications Co.
- [47] <https://www.techopedia.com/definition/33858/numpy>
- [48] <https://www.journaldunet.fr/web-tech/developpement/1441179-a-quoi-sert-matplotlib-inline-en-python/>
- [49] <http://www.github.com/education454/datasets.git>



- [50] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1-48.
- [51] Ho, D., Liang, E., & Liaw, R. (2019). 1000x faster data augmentation. Berkeley Artificial Intelligence Research.
- [52] Reshi, A. A., Rustam, F., Mehmood, A., Alhossan, A., Alrabiah, Z., Ahmad, A., ... & Choi, G. S. (2021). An Efficient CNN Model for COVID-19 Disease Detection Based on X-Ray Image Classification. *Complexity*, 2021.