الجمهورية الجزائرية الديمقراطية الشعبية
République Algérienne Démocratique et Populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Département : Génie électrique Et Informatique Industrielle

Mémoire de fin d'étude en vue de l'obtention du diplôme de
Master en Génie électrique Et Informatique Industrielle

Spécialité
Systèmes de Télécommunications et Réseaux

- Thème -

L'utilisation de l'intelligence artificielle dans la lutte contre le COVID 19

Réalisé par :
Djamel LAKHDARI
Abderrahim MAHI

Les membres de Jury :

Mme BOUTERFAS Malika M.C.A	Président
M.KHOUMERI El hadi M.C.B	Promoteur
Mme BOUTOUTA Dalila M.A.A	Examinateur
Mme HABANI Lamia M.A.A	Examinateur

Alger, le 30/06/2022

Année universitaire 2021 –2022

L’utilisation de l’intelligence artificielle dans la lutte contre le COVID 19

Remerciements :

Nous souhaitons adresser nos remerciements les plus sincères aux personnes qui nous ont apporté leur aide et qui ont contribué à la réalisation de ce mémoire.

Nous tenons à remercier en premier, Monsieur KHOUMERI, notre encadrant, pour sa généreuse disponibilité, son aide précieuse ainsi que ses conseils et orientations qui nous ont été très utiles.

On remercie également Les membres de jury : Mme. HABANI, Mme. BOUTOUTA, et Mme. BOUTERFAS, pour L'intérêt qu'ils ont porté à mon travail.

Nous tenons à remercier, tout particulièrement, et à témoigner toute notre reconnaissance à nos professeurs du département génie électrique et informatique industrielle, pour la formation enrichissante qu'ils nous ont offerte durant ces cinq années au sein de l'Ecole Nationale Supérieure de Technologie.

Ce mémoire n'aurait jamais pu voir le jour sans le soutien actif des membres de nos familles, spécialement nos chers parents qu'ils nous ont toujours encouragés.

Table de matières :

Table de figures 1
Liste des abréviations: 2
Introduction générale 3
I. Théorie du deep learning 5
I.1 Introduction 5
I.2 Type d'approches du deeplearning 5
I.2.1 Apprentissage supervisé SL: 5
I.2.2 Apprentissage non supervisé UL: 6
I.2.3 Apprentissage semi-supervisé SSL: 6
I.2.4 Apprentissage par renforcement RL: 6
I.3 Deeplearning 7
I.3.1.1 Apprentissage profond et réseaux neuronaux NN 7
I.3.1.2 Perceptron 9
I.3.1.3 Réseau neuronal récurrent 10
I.3.1.4 Réseau convolutionel profond (Deep Convolutional Network) 10
I.3.1.5 L'apprentissage par transfert 13
I.4 Conclusion 15
II. Théorie du COVID 19 16
II.1 Introduction 16
II.2 Aspects microbiologiques des coronavirus 17
II.3 Épidémiologie 18
II.4 Diagnostic 18
II.5 Prévention 19
II.6 Conclusions 20
III. L'utilisation et les bienfaits du deeplearning contre le COVID 19 21
III.1 Introduction 21
III.2 Traitement du langage naturel 21
III.2.1 Détection de la mésinformation 22
III.3 Vision par ordinateur 23
III.3.1 Analyse des images médicales 23
III.4 Sciences de la vie 24
III.4.1 Prédiction de la structure protéique 24

III.5 Épidémiologie 25
III.5.1 Suivi des contacts 25
III.6 Conclusion 26
IV. Les limites et perspectives 27
IV.1 Introduction : 27
IV.2 Réunir l'éthique de l'IA et l'éthique de la santé 28
IV.2.1 Non-malfaisance 28
IV.2.2 Autonomie 29
IV.2.3 Justice 29
IV.3 Conclusion 30
Conclusion générale 30
Bibliographie 31
Résumé 34

Table de figures

Figure 1 : catégories de deep learning 5

Figure 2 : Composantes de l'apprentissage par renforcement 6

Figure 3 : Relation entre AI, ML et DL 7

Figure 4 : Illustration d'un modèle d'apprentissage profond (4) 8

Figure 5 : Représentation visuelle d'un perceptron (6) 10

Figure 6 : Configuration traditionnelle de l'apprentissage supervisé en ML (9) 14

Figure 7 : Configuration d'apprentissage par transfert (9) 15

Figure 8: Structure du coronavirus et chacun de ses protéines et leurs distributions (15) 17

Figure 9 : L'efficacité des vaccins contre le COVID-19 20

Liste des abréviations:

CT : Computed Tomography

DCN : Deep Convolutional Network

DL : Deep learning

FEVER : Fact Extraction and Verification

IA : IntelligenceArtificielle

MERS-CoV : CoV du Syndrome Respiratoire du Moyen-Orient

ML : Machine Learning

NLP : Natural Language Processing

NN : Neural network

RL : Reinforcement Learning

RNN : Réseau Neuronal Récurrent

SARS-CoV-2 : Severe Acute Respiratory Syndrome Coronavirus 2

SL : Supervised Learning

SSL : Semi-supervised Learning

TDM : Tomodensitométrie Thoracique

UL : Unsupervised Learning

NHS : National health service

Introduction générale

Le SARS-CoV-2 et la COVID-19 qui en découle constituent l'un des plus grands défis du XXIe siècle. Environ 460 millions de personnes avaient obtenu un résultat positif et 6 millions de personnes étaient mortes. La lutte contre ce virus nécessite l'héroïsme des professionnels de santé, l'organisation sociale et les solutions technologiques. Cette étude est axée sur l'avancement des solutions technologiques, en mettant l'accent sur l'intelligence artificielle et leDeep Learning. Nous soulignons également de nombreux cas où le Deep Learning peut faciliter l'organisation sociale, comme les prévisions de propagation et la détection de mésinformation.

Peu après l'annonce de la pandémie de COVID-19, l'OMS a souligné le rôle potentiellement important que l'intelligence artificielle et le DeepLearning pourraient jouer dans l'intervention de santé publique. Depuis le début de la pandémie, les applications novatrices de l'IA comprennent la détection des éclosions, la facilitation du diagnostic, l'identification des personnes atteintes de fièvres et l'accélération du séquençage génétique, ce qui démontre que l'intervention médicale est très prometteuse pour renforcer la réponse à la crise sanitaire mondiale et aux soins de santé futurs. Cependant, malgré son potentiel, le DLn'a pas eu d'impact à l'échelle mondiale. Il s'agit d'un moment important pour examiner les contraintes et les lacunes et tirer des leçons qui peuvent être apprises pour façonner un avenir durable.

Bon nombre de défis auxquels le DL fait face pour améliorer la santé existaient avant la pandémie. Alors que de nombreux problèmes graves sont devenus plus urgents dans la situation tandis que des décisions devaient être prises rapidement, d'autres nouveaux problèmes sont apparus, par exemple, l'absence d'expertise épidémiologique dans la conception et l'interprétation des résultats du DL, manque de données disponibles dans les contextes de crise et de mécanismes d'atténuation des risques. Ce que nous avons appris, c'est que de nouvelles normes doivent être établies pourque la technologie ait une incidence importante sur l'amélioration de la santé pendant la pandémie et au-delà.

Premièrement, l'intelligence et l'expertise humaines doivent être au centre de toutes les applications du DL. Cette compréhension est fondamentale pour dissiper le battage médiatique entourant le DL et c'est la première étape pour aborder la qualité et la responsabilisation des algorithmes du DL. Par exemple, la détection la plus précoce de l'éclosion à l'aide des données en ligne a suscité de l'intérêt pour le DL pour la prédiction et le suivi. Par la suite, de nombreuses entreprises ont adopté une approche de « mégadonnées » utilisant les données en ligne. Toutefois, ils n'ont pas été en mesure de reproduire les réussites précoces, car la quantité d'information sur la COVID-19 en ligne a augmenté les signaux de noyade dans les données. Fait crucial, l'expertise épidémiologique faisait souvent défaut dans la conception et l'interprétation des résultats du DL. Le rôle de l'expertise humaine deviendra encore plus important si les données sur la santé, qui n'ont pas été accessibles à de nombreuses entreprises jusqu'à présent, sont de plus en plus utilisées pour la prédiction et le suivi.

Deuxièmement, de nouvelles normes concernant la disponibilité des données dans les contextes de crise doivent être établies. Dans le domaine de la recherche et du développement en santé publique, la solidarité en matière de partage de données a été reconnue au début de la pandémie. Un certain nombre de mécanismes efficaces de partage de données ont été mis

en place, y compris la base de données de l'OMS sur la recherche mondiale sur les maladies à coronavirus. Ces approches évolutives pour les données ont fourni un bon soutien aux innovations en matière de DL pendant la pandémie, même si certains aspects des capacités de gestion des données doivent être développés davantage, comme l'élimination des inégalités dans l'accessibilité des données entre les pays.

L'utilisation de l'IA pendant la pandémie a également relancé un débat de longue date sur la tension entre la surveillance et la protection de la vie privée des données qui n'ont pas été recueillies dans le cadre de la recherche. Bien que la recherche des contacts et la surveillance des maladies grâce au DL aient contribué à l'intervention en cas de pandémie dans quelques pays, comme la Chine, la République de Corée et Singapour, ces approches ont fait l'objet de scepticisme dans bien d'autres. Il faut adopter des lois et des règlements qui peuvent équilibrer le bien-être de la collectivité et la protection des renseignements personnels pour veiller à ce que ces technologies d'IA, qui n'ont pas encore été déployées avec succès, puissent jouer leur rôle dans les prochaines phases de la pandémie. Le dépistage efficace des contacts et la surveillance des maladies seraient un élément utile pour ramener les sociétés à une nouvelle normalité, où la surveillance et les mesures de contrôle des maladies doivent être mises en œuvre de façon dynamique avec le moins de perturbations possible pour les sociétés.

Troisièmement, les nouvelles normes concernant les avantages et l'atténuation des risques doivent être établies. Les concepts de bienfaisance, de non-maîtrise et d'équité du DL ont attiré beaucoup d'attention avant la pandémie, mais surtout après. Les innovations en matière d'IA pour la réponse à la COVID-19 doivent inclure « l'éthique dès le départ ». L'intégration de considérations éthiques dans le processus d'élaboration de solutions d'IA assurera des avantages généraux tout en minimisant les préjudices. Pour ce faire, il est possible d'élaborer des lignes directrices et des normes plus claires, parallèlement à de solides systèmes d'essai et de vérification de préqualification. Ces mesures n'étaient pas en place avant la pandémie, mais des efforts ont été déployés pour combler cet écart.

Cette étude vise à illustrer l'utilisation du Deep Learning dans la lutte contre le COVID-19, et elle est diviséeenquatre chapitres.

Le premier chapitre traitera la théorie du deeplearning, les différents types d'apprentissage (supervisé, par transfert, par renforcement.), on explique aussi comment il fonctionne et sa relation avec les réseaux neuronaux.

Le deuxième chapitre traitera la théorie du covid 19, l'épidémiologie, lesaspects microbiologiques du virus et la prévention.

Le troisième est l'utilisation et les bienfaits du DL contre le COVID 19, dont on couvre les applications d'apprentissage profond dans le traitement du langage naturel, la vision par ordinateur, les sciences de la vie et l'épidémiologie, comme la détection de la désinformation et l'analyse des images médicales.

Le dernier chapitre comporte les limites et les perspectives.

Chapitre 1

Théorie du deep learning

I. Théorie du deep learning

I.1 Introduction

Il est difficile de trouver de nos jours quelqu'un qui n'a pas entendu parler d'une façon ou d'une autre de l'intelligence artificielle et n'a pas une idée de ce que c'est.
L'intelligence artificielle est le concept le plus large des machines capables d'effectuer des tâches d'une manière qui serait considérée comme intelligente.
Le deeplearning fait partie du machine learning, qui est une application actuelle de l'IA basée sur l'idée que les machines devraient pouvoir accéder aux données et apprendre par elles-mêmes.
Dans ce chapitre, on explique le concept dudeeplearning, comment il fonctionne réellement, et sa relation avec les réseaux neuronaux.

I.2 Type d'approches du deeplearning

Les approches d'apprentissage profond peuvent être classées comme suit : supervisées, semi-supervisées ou partiellement supervisé et non supervisé. En outre, il existe une autre catégorie d'approche d'apprentissage appelée Renforcement de l'apprentissage (RL) ou RL profond (DRL) qui est souvent discutée dans le cadre de semi-supervisé ou parfois dans le cadre d'approches d'apprentissage non supervisées.

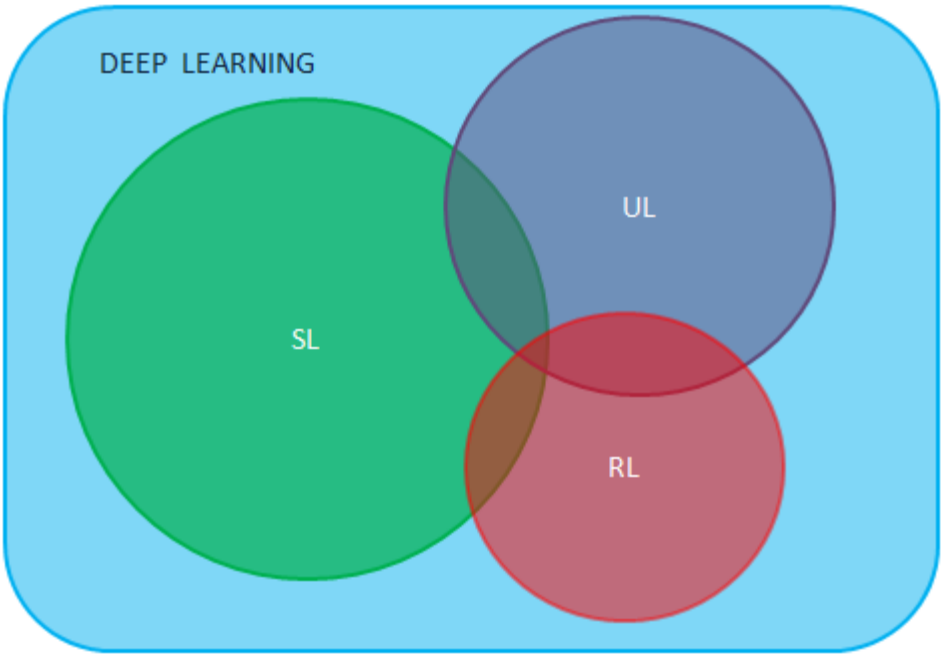


Figure 1 : catégories de deep learning.

I.2.1 Apprentissage supervisé SL:

L'apprentissage supervisé a mérité son nom parce que les scientifiques des données servent de guide pour enseigner à l'algorithme quelles conclusions qu'il devrait tirer. Il est similaire à

la façon dont un élève apprend l'arithmétique de base d'un enseignant. Ce type d'apprentissage nécessite des données étiquetées avec les bonnes réponses à attendre de la sortie de l'algorithme. (1)

I.2.2 Apprentissage non supervisé UL:

Inversement, l'apprentissage non supervisé est plus étroitement lié à ce qu'on appelle la véritable intelligence artificielle par certains experts, le concept selon lequel une machine peut apprendre à identifier des processus et des modèles complexes sans supervision humaine. Cette approche est particulièrement utile dans les cas où les experts ne savent pas quoi chercher dans les données et où les données elles-mêmes n'incluent pas les cibles.(1)

I.2.3 Apprentissage semi-supervisé SSL:

Jusqu'à présent, les données fournies sont toutes étiquetées avec la sortie désirée ou pas du tout étiquetées. L'apprentissage automatique semi-supervisé est une combinaison des deux. Dans de nombreuses situations pratiques, le coût de l'étiquetage est très élevé et dans le cas de grands ensembles de données, la tâche devient fastidieuse et prend beaucoup de temps. En outre, fournir trop de données étiquetées, peut forcer les biais humains sur le modèle. Même si les données non étiquetées sont inconnues pour le réseau, ces données apportent des informations utiles sur les paramètres du groupe cible. Ce qui mène à la conclusion qu'en incluant les données non étiquetées, la précision du modèle peut être améliorée tout en économisant du temps et de l'argent pour le construire. Par exemple, l'apprentissage automatique semi-supervisé pourrait être utilisé dans la classification des pages Web, la reconnaissance vocale ou le séquençage génétique. Dans ces cas, les scientifiques des données peuvent accéder à de grands volumes de données non étiquetées, et la tâche d'étiquetage tout cela prendrait un temps accablant.(2)

I.2.4 Apprentissage par renforcement RL :

L'apprentissage par renforcement est le troisième type principal d'apprentissage automatique avec l'apprentissage supervisé et non supervisé. Il se compose de cinq éléments importants qui sont : l'agent, l'environnement, l'état, l'action et la récompense. Le but de RL est de maximiser la récompense et minimiser le risque en exploitant son interaction avec l'environnement. L'algorithme RL (appelé agent) s'améliorera périodiquement en explorant l'environnement en passant par les différents états possibles. Pour maximiser les performances, le comportement idéal sera automatiquement déterminé par les agents. Une rétroaction (la récompense) est ce qui permet à l'agent d'améliorer son comportement. (3)

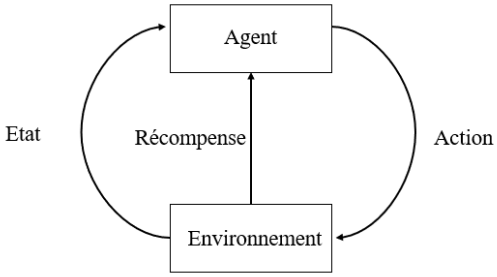


Figure 2 : Composantes de l'apprentissage par renforcement.

L'un des algorithmes les plus utilisés pour RL est Monte Carlo qui est basé sur la collecte des récompenses à la fin de l'épisode, puis le calcul de la future maximale récompense attendue. Un deuxième algorithme populaire est l'apprentissage de la différence temporelle qui utilise une approche différente de la première et qui consiste à estimer les récompenses à chaque état.

I.3 Deeplearning

Depuis l'arrivée de l'intelligence artificielle il y'a quelque temps, elle a un large éventail d'applications et elle est divisée en de nombreuses branches. L'apprentissage profond est un sous-ensemble de l'apprentissage automatique, qui est en soi un sous-domaine de l'IA. La figure ci-dessous est une représentation visuelle de la relation entre AI, ML et DL(4)

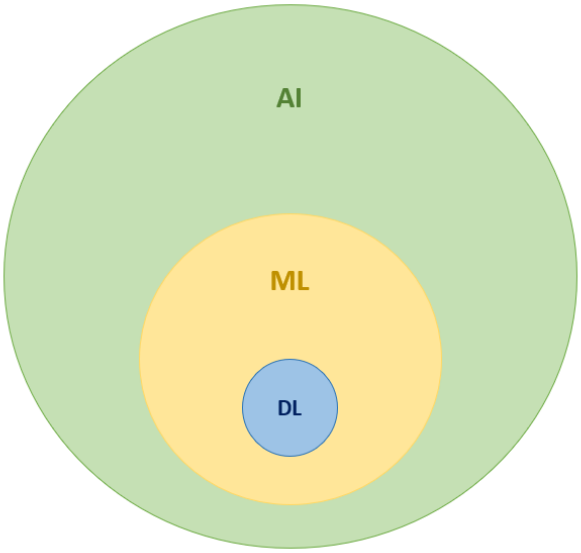


Figure 3 : Relation entre AI, ML et DL.

Alors, qu'est-ce que l'apprentissage profond et quel genre de problèmes qu'il résout? Nous répondrons à cette question en détail dans la prochaine section.

I.3.1.1 Apprentissage profond et réseaux neuronaux NN

L'IA a réussi depuis son existence à résoudre de nombreuses tâches qui signifiaient être intellectuellement difficiles pour les humains, pourtant, elle a lutté avec des problèmes qui semblent faciles et intuitifs pour les êtres humains tels que la reconnaissance du visage ou de la parole. La raison derrière cela, est que beaucoup de tâches difficiles peuvent être traduites en règles mathématiques faciles pour un ordinateur à comprendre. Par ailleurs, d'autres tâches qui semblent faciles sont difficiles à décrire officiellement.

Une bonne approche pour résoudre ces problèmes intuitifs est de donner la liberté aux ordinateurs d'apprendre des expériences antérieures et de comprendre le monde en interagissant avec lui en termes de hiérarchie des concepts. De cette façon, les humains n'auront plus besoin de spécifier toutes les connaissances aux ordinateurs. Ce concept permet à l'ordinateur de résoudre des concepts difficiles en les construisant à partir de concepts plus

simples. Si cette hiérarchie est représentée par un graphe, elle sera formée par de nombreuses couches et définie par profondeur. C'est pourquoi cette approche est appelée apprentissage profond.

Comme aucune caméra n'a la qualité de l'œil humain ou même qu'aucun ordinateur ne peut corréler l'information comme le cerveau humain, il est devenu difficile pour les applications d'intelligence artificielle du monde réel d'extraire de nouvelles caractéristiques abstraites des données brutes, en raison de la variation constante des données observées, telles que le changement de la vue d'angle dans différentes images et la variation des couleurs dans différentes circonstances. Étant donné que ces facteurs de variation ne sont identifiés que par une compréhension quasi humaine des données, il semble d'abord qu'une telle tâche est impossible par une simple représentation de l'apprentissage. Ici, où il vient le rôle de l'apprentissage profond, car il est basé sur la représentation des caractéristiques abstraites en termes d'autres représentations plus simples. Un exemple pratique de ce concept est démontré par la figure 4 où une image d'une personne (concept complexe) est détectée en recherchant différentes caractéristiques dans un format de couche, comme les coins, les contours et les bords (concepts simples).

Le réseau profond prédictif(The feedforward deep network) ou le perceptron multicouche est considéré comme un exemple typique d'un modèle d'apprentissage profond. C'est une fonction mathématique qui met en correspondance certains ensembles de valeurs d'entrée et de sortie. La fonction est formée en composant de nombreuses fonctions plus simples. Nous pouvons penser que chaque application d'une fonction mathématique différente fournit une nouvelle représentation de l'entrée.(4)

Le Deep Learning permet non seulement de représenter les données de la bonne manière, mais en ajoutant le concept de profondeur dans ses modèles, il permet à l'ordinateur d'apprendre le programme informatique à plusieurs étapes. Où chaque couche de la représentation peut être considérée comme l'état de la mémoire de l'ordinateur après.

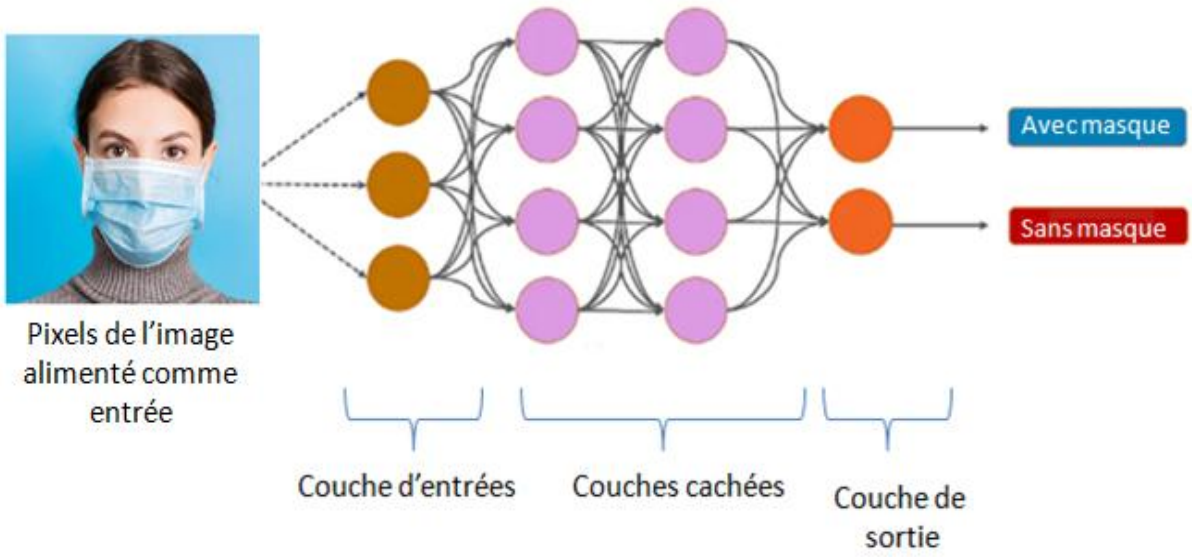


Figure 4 : Illustration d'un modèle d'apprentissage profond(4).

Les images qui représentent des scènes de notre réalité sont interprétées par les ordinateurs comme un ensemble de valeurs de pixels. La tâche d'identifier un objet ou de cartographier son identité à partir de ces valeurs est difficile pour les machines et peut être presque impossible lorsqu'on essaie d'apprendre cette cartographie directement.

Le Deep Learning aborde cet obstacle en introduisant le concept de couches où chaque couche représente des mappages simples, extraits de la cartographie complexe globale et imbriqués les uns avec les autres. Comme le montre la figure, il existe deux types de couches. La couche visible, qui représente l'entrée qui n'est observée que par les humains, et les couches cachées qui extraient les caractéristiques de l'image. La raison pour laquelle on appelle ce type de couches cachées est que leurs valeurs ne sont pas indiquées dans l'entrée et doivent être déterminées par le modèle en déterminant quels concepts sont utiles pour expliquer la relation dans les données observées.

Pour récapituler, le domaine de l'intelligence artificielle englobe de nombreux sous-domaines, tels que l'apprentissage automatique. Le Deep Learning est une technique de mise en œuvrequi donne aux machines une marge d'apprentissage lorsqu'il est fourni par les données nécessaires, ce qui est possible grâce à la représentation des différentes caractéristiques de données réelles comme des couches, où chaque caractéristique définie par rapport à des fonctionnalités plus simples, et des représentations plus abstraites calculées en termes de représentations moins abstraites.
Alors, quel est le lien entre l'apprentissage profond et les réseaux neuronaux ?En termes simples, le Deep Learning consiste à former des réseaux neuronaux multicouches avec de grands ensembles de données. Ainsi, l'apprentissage profond est fait par les réseaux neuronaux.
Les réseaux neuronaux sont l'un des systèmes informatiques les plus utilisés dans le domaine de l'apprentissage automatique. Ils sont capables de trouver des concepts et des modèles qui sont très difficiles à comprendre pour les humains. Cette puissante capacité est due à la façon dont cet outil imite le fonctionnement du système neuronal humain.
Depuis l'enfance, les humains rencontrent quotidiennement de nouvelles choses dans la vie qui les façonnent et les améliorent à mesure qu'ils grandissent malgré leurs erreurs. Le même concept s'applique aux réseaux neuronaux, car ils ont besoin de données pour en tirer des leçons. En alimentant plusde données au réseau, il se développera mieux en répétant la même tâche et en apprenant de ses erreurs précédentes. Brièvement expliqué, les données fournies pour le processus de formation sont généralement divisées en trois ensembles. Un ensemble de formation pour établir la connexion entre les nœuds du réseau en définissant les poids, un ensemble de validation pour améliorer les poids et un ensemble de tests pour évaluer le réseau après l'entrainement (5).

I.3.1.2 Perceptron

Perceptron est l'une des représentations les plus simples d'un neurone.Un perceptron est une unité de sortie unique d'entrée multiple. Le type de données qui circule dans le perceptron est binaire.(6)

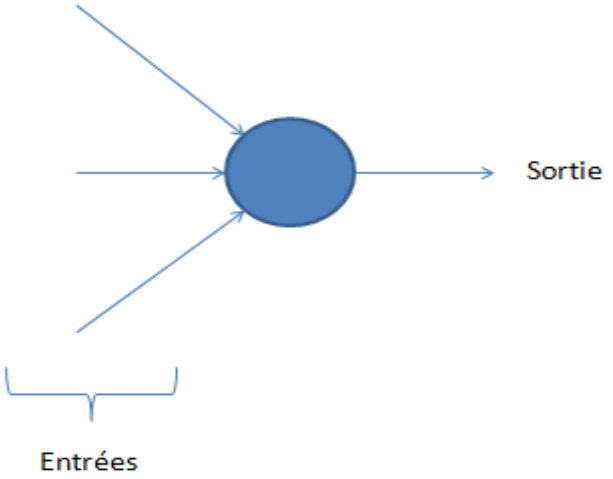


Figure 5 : Représentation visuelle d'un perceptron(6).

Les réseaux neuronaux sont l'un des plus anciens modèles de Neurone. Cette approche est apparue pour la première fois dans les années 50 et suit les règles suivantes :

- Tous les nœuds réseau sont entièrement connectés.
- Le flux est activé de l'entrée à la sortie sans boucles de retour
- Le réseau contient une couche cachée, qui se situe entre la couche de sortie et la couche d'entrée.

I.3.1.3 Réseau neuronal récurrent

Différents types de cellules ont été introduits par cette NN qui sont des cellules récurrentes. La principale différence entre le RNN et les autres réseaux est que chacune des cellules cachées reçoit sa propre sortie avec un délai fixe pour une ou plusieurs itérations. Les RNN sont utilisés dans une situation où la sortie dépend de l'ordre et du contexte des données transmises à être modélisé. Par exemple, l'auto-complétion de texte est un cas d'utilisation parfait pour ce type de réseaux.(7)

I.3.1.4 Réseau convolutionel profond (Deep Convolutional Network)

De nos jours, les DCN sont les NN les plus populaires. Ils comportent des cellules de convolution (ou couches de regroupement) et des noyaux qui servent à des fins différentes. Les noyaux de convolution traitent les données d'entrée tandis que les couches de mise en commun le simplifient en utilisant principalement des fonctions non linéaires, réduisant ainsi les fonctionnalités inutiles. (7)

Ce type de NN est utilisé pour les tâches de traitement d'image et ils fonctionnent sur des images avec une petite résolution comme suit :

L'image sera analysée en faisant glisser une fenêtre, pixel par pixel. Les données seront ensuite transmises aux couches de convolution où un entonnoir sera formé compressant les caractéristiques détectées. Du point de vue de la reconnaissance d'image, la première couche est responsable de la détection des gradients, la deuxième couche détecte les lignes et la troisième détecte les formes. Ce processus se poursuivra jusqu'à l'obtention d'objets particuliers.

Après avoir passé en revue les différents types de réseaux neuronaux, il est logique d'expliquer en profondeur le processus de formation et comment fonctionne exactement l'imitation des neurones humains.

L'ensemble du processus peut être résumé en sept étapes :

- **Initialisation du modèle :**

Le point de départ est la première étape du processus d'apprentissage. La formation des réseaux neuronaux peut être commencée de n'importe où. C'est pourquoi il est pratique de randomiser l'initialisation puisque, grâce à un processus d'apprentissage itératif, un modèle pseudo-idéal peut être atteint quel que soit le point de départ.

- **Propagation vers l'avant :**

Après avoir initialisé le modèle, l'étape suivante consiste à vérifier ses performances. Pourcommencer, l'entrée sera passée directement par la couche réseau pour calculer la sortie du modèle. Cette étape est appelée propagation vers l'avant, puisque le flux de calcul va vers l'avant de l'entrée par le réseau neuronal à la sortie.

- **Fonction de perte :**

À ce stade, il y a deux informations utiles à éliminer : la sortie réelle du réseau neuronal initialisé aléatoirement et la sortie souhaitée que le réseau devrait apprendre. Afin de généraliser à tout problème, une fonction de perte doit être définie. Il évalue la capacité du réseau neuronal de générer des sorties aussi près que possible des valeurs souhaitées. (8)

La fonction de perte la plus logique serait : **perte = (sortie souhaitée – sortie réelle)**. Néanmoins, cette fonction de perte renvoie des valeurs positives lorsque le réseau ne fonctionne pas (prédiction < rendement souhaité) et des valeurs négatives lorsque :

(prédiction > rendement souhaité). Pour éviter cette interprétation erronée, la fonction de perte devrait refléter une erreur absolue. Pour y parvenir, la fonction devrait être définie comme suit :**« Perte = valeur absolue de (sortie souhaitée – sortie réelle) ».**

- **Différenciation** :

Maintenant, le problème d'apprentissage automatique devrait être transformé en un processus d'optimisation qui vise à minimiser la fonction de perte totale. Pour ce faire, toute technique d'optimisation qui modifie les poids internes des réseaux neuronaux peut être utilisée. Ces techniques peuvent avoir différentes approches pour aborder le problème, comme la recherche avide ou la recherche par force brute.

Dans le cas d'un petit modèle qui a peu de paramètres à optimiser, il est possible de trouver quelpoids possède la plus petite somme de carrés d'erreurs sur l'ensemble de données. Cependant, dans le cas du traitement d'image où le NN s'est formé avec un tableau de 600x400 entrées, les modèles avec des millions de poids à optimiser peuvent facilement être atteints et la force brute ne sera pas la bonne solution, car il consomme beaucoup de ressources de calcul. Voici le rôle de la différenciation qui est un concept puissant en mathématiques qui peut aider à optimiser les poids. Essentiellement, il s'agit de la dérivée de

la fonction de perte. En mathématiques, le taux ou la vitesse dont une fonction change ses valeurs à un certain point peut être déduit en calculant la dérivée à ce moment.

Le concept du processus d'apprentissage est le suivant :

- Il faut d'abord vérifier la dérivée.
- Si elle est positive, le poids doit être diminué, car cela signifie que si les poids sont augmentés, l'erreur augmentera aussi.
- S'il est négatif, le poids doit être augmenté, car cela signifie que si les poids sont augmentés, l'erreur diminuera.
- Si c'est 0, rien ne doit être fait parce qu'un point stable est atteint.

- **Rétro propagation (back propagation):**

Dans la plupart des cas d'utilisation réels, les réseaux sont construits avec plus d'une couche pour obtenir le résultat désiré. Il est toujours possible de créer une fonction compliquée qui représente la composition sur l'ensemble des couches du réseau. La réduction de composition des fonctions pour chaque composition est que la dérivée dédiée de la composition doit être calculée, elle peut donner de faux résultats. La fonction de perte servira comme point de départ des erreurs et si on sait comment dériver chaque fonction de la composition comme la fonction de perte, il est possible de créer une chaîne et de propager les erreurs de la fin au début. Ce principe peut être représenté par l'exemple linéaire suivant : L'entrée passera par deux couches cachées, où elle sera multipliée d'abord 3 fois puis 2 fois pour finalement obtenir la sortie.

$$\text{Entrée} \rightarrow \quad 3.x \rightarrow \quad 2.x \rightarrow \quad \text{Sortie}$$

Si un changement delta 0.001 est appliqué à l'entrée, il évoluera vers un changement 0.003 au début et finalement vers un changement delta 0.006 sur la sortie. Si les deux fonctions sont réunies en une seule, le résultat sera le même.

$$\text{Entrée} \rightarrow \quad 6.x \rightarrow \quad \text{Sortie}$$

Par la même logique, l'erreur peut être rétro-propagé de la sortie à l'entrée passant par les calques du milieu pour donner quelque chose comme ceci :

$$\text{Entrée} \leftarrow \frac{x}{2} \leftarrow \frac{x}{3} \leftarrow \quad \text{Sortie}$$

En sachant comment transmettre-propager (en appliquant directement la fonction) et comment rétro-propager (en connaissant la dérivée de la fonction), une bibliothèque de fonctions ou de couches différenciables peut être créée pour composer n'importe quel réseau neuronal complexe. Pour créer le bon chemin de rétropropagation des erreurs, une pile des appels de fonction pendant le passage en avant et leurs paramètres doivent être sauvegardés et ensuite utiliser leurs dérivés. Ceci est réalisable par une technique appelée autodifférenciation. Cette approche n'a qu'une exigence qui est : toutes les fonctions doivent être fournies par la mise en œuvre de leurs dérivées, il est donc possible de les dé-empiler.

- **Mise à jour du poids :**

Pour les problèmes de la vie réelle les poids ne devraient pas être mis à jour avec de telles grandes étapes. Comme il y a beaucoup de non-linéarités, tout grand changement de poids conduira à un comportement instable. Étant donné que la dérivée n'est locale qu'au moment où elle est calculée, une règle générale de pondération delta met à jour les poids:

Nouveau poids = ancien poids – taux dérivé * taux d'apprentissage

- **Itérer jusqu'à la convergence :**

Comme les poids sont mis à jour avec un petit pas delta à la fois, le processus d'apprentissage sera lent. Ce processus peut être comparé aux algorithmes génétiques où de petites mutations sont appliquées à une génération après l'autre et les plus aptes survivront.

Dans le réseau neuronal, après chaque itération, pour obtenir une fonction de perte globale minimale, les mises à jour de poids sont forcées par la descente de gradient. La similitude se manifeste en voyant la fonction de perte comme une fonction d'aptitude à minimiser.

La mise à jour du poids dans NN est toutefois plus intelligente puisqu'elle est guidée par la force de gradient décroissante par rapport à l'erreur. Pour estimer le nombre d'itérations à appliquer, de nombreux facteurs doivent être pris en considération.

-Un taux d'apprentissage élevé appliqué au NN signifie un apprentissage plus rapide, il peut conduire à une performance instable par la suite.

-Il existe différentes techniques de mise à jour du poids avec des performances différentes, appliquer la méthode d'optimisation correcte aidera à déterminer le nombre d'itérations.

-La qualité de l'ensemble de données de formation joue un rôle important, parce que le réseau neuronal ne sera pas en mesure d'apprendre une corrélation aléatoire si l'entrée et la sortie n'ont pas de corrélation entre eux.

I.3.1.5 L'apprentissage par transfert

Pour former un modèle suivant l'approche traditionnelle d'apprentissage supervisé pour effectuer une certaine tâche et domaine **A**, il est nécessaire de fournir des données étiquetées (labeled data) qui correspondent à la même tâche et domaine. La figure 6 est une représentation visuelle de la façon dont les données devraient respecter la tâche à accomplir. Brièvement expliqué, une tâche est le comportement attendu du modèle après que le processus de formation est terminé et un domaine est simplement l'environnement où les données ont été prises.(9)

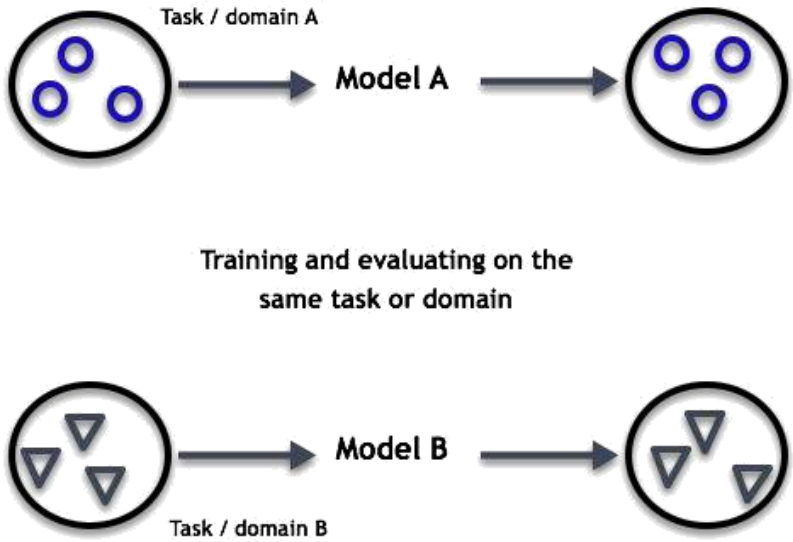


Figure 6 : Configuration traditionnelle de l'apprentissage supervisé en ML(9).

Après avoir formé le modèle **A** sur son ensemble de données, il fonctionnera correctement lors des tests sur les données de la même tâche et du même domaine. Par contre, et comme l'illustre la figure, un nouveau modèle **B** devrait être formé si de nouvelles données sont fournies pour une tâche ou un domaine différent.

Comme de nombreuses tâches se ressemblent, il est logique d'essayer de réutiliser les données pour des situations similaires. En cas d'utilisation de l'apprentissage supervisé traditionnel, un problème se pose, qui est la détérioration ou l'effondrement de la performance du modèle. Par exemple, un modèle qui a été formé pour détecter les piétons pendant la journée peut théoriquement être utilisé pour former un modèle pour détecter les piétons pendant la nuit. En pratique, cela causera des inexactitudes puisque le modèle est adapté à son ensemble de données et ne sait pas comment généraliser un nouveau domaine. Ce problème est plus problématique lorsqu'on essaie de former un modèle pour détecter les cyclistes, puisque le modèle existant ne peut même pas être réutilisé en raison de la différence d'étiquettes.

Pour surmonter ce problème, le concept d'apprentissage par transfert peut être utilisé en utilisant les données déjà existantes d'une tâche ou d'un domaine connexe. Il est alors possible de stocker ces connaissances acquises en résolvant la tâche source dans le domaine source et de les appliquer au problème d'intérêt, comme le montre la figure 7:

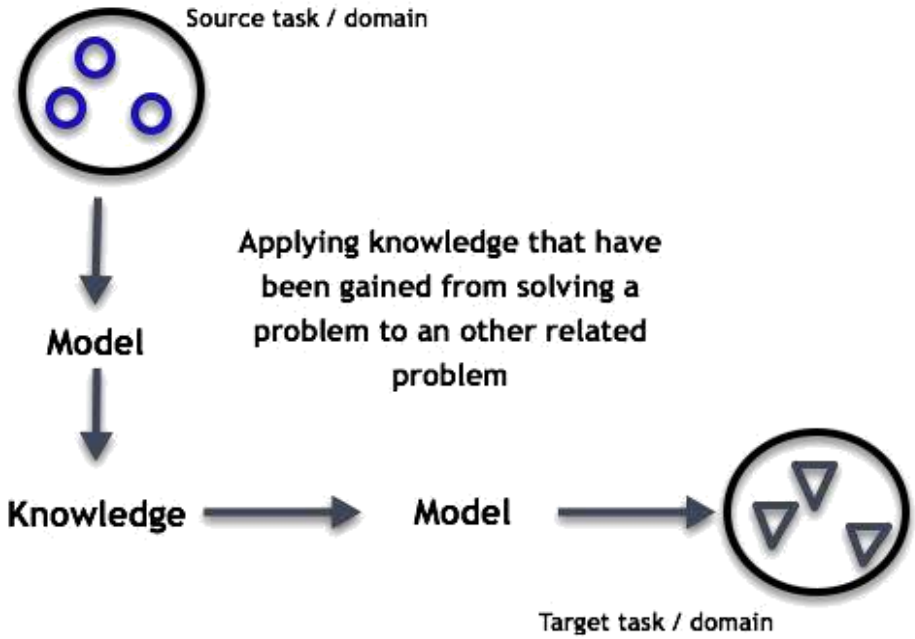


Figure 7 : Configuration d'apprentissage par transfert (9).

Les chercheurs essayent souvent de tirer des données existantes et des modèles formés autant que possible pour les transférer dans un nouveau domaine pour des tâches similaires. Il y a différents aspects qui peuvent être intéressants et pris en considération au moment du transfert de l'apprentissage. Par exemple, les recherches peuvent s'intéresser à la façon dont les objets sont façonnés dans les données, parce qu'ils ont une certaine forme qui aidera à définir les nouveaux objets, ou, en cas de reconnaissance de la parole, le contexte et les modèles de voix sont au centre de l'attention.

I.4 Conclusion

En résumé, ce chapitre présente une variété d'informations sur l'intelligence artificielle et l'apprentissage automatique, à partir des bases telles que le lien entre les deux et leurs objectifs, jusqu'à des informations plus détaillées telles que les différents types et techniques utilisés dans l'apprentissage automatique.

On a aussi traité dans ce chapitre l'apprentissage profond et les réseaux neuronaux, en particulier les réseaux de neurones convolutionnels.

Chapitre 2

Théorie du COVID 19

II. Théorie du COVID 19

II.1 Introduction

Fin décembre 2019, une épidémie d'une maladie inconnue appelée pneumonie, de cause inconnue est survenue à Wuhan, dans la province du Hubei, Chine. L'épidémie s'est propagée de manière substantielle pour infecter 9720 personnes en Chine avec 213 décès et pour infecter 106 personnes dans 19 autres pays, au 31 janvier 2020(10). Quelques jours plus tard, l'agent responsable de cette mystérieuse pneumonie a été identifié comme un nouveau coronavirus (nCoV) par plusieurs laboratoires indépendants.

Le virus responsable a été temporairement nommé « severe acute respiratory syndrome coronavirus 2 » (SARS-CoV-2) et la maladie infectée correspondante a été nommé coronavirus 2019 (COVID-19) par l'Organisation mondiale de la santé.

Selon le rapport quotidien de cette organisation, l'épidémie de SARS-CoV-2 s'est propagée dans tout le monde et a enregistré jusqu'à présent un total de 460 millions de cas et 6 millions morts au 29 avril 2022. L'épidémie de COVID-19 est devenue une menace sanitaire mondiale.

Les coronavirus (CoVs) sont un groupe de virus très diversifiés, enveloppés, à ARN monocaténaire. Ils causent plusieurs maladies touchant les systèmes respiratoire, entérique, hépatique et neurologique, avec une gravité variable chez les humains et les animaux. Les infections à CoV ont traditionnellement causé un faible pourcentage des infections respiratoires annuelles. Il existe des HCoV-OC43, HCoV-229E, HCoV-NL63 et HCoV-HKU1, qui provoquent des maladies respiratoires légères(11). Au cours des deux dernières décennies, deux nouveaux CoV ont été découverts. Le CoV du syndrome respiratoire aigu sévère (SARS-CoV) et le CoV du syndrome respiratoire du Moyen-Orient (MERS-CoV), sont apparus et provoquent des maladies humaines graves(12). Au cours de l'épidémie, le SARS-CoV a infecté plus de 8 000 personnes dans le monde entier avec près de 800 décès, ce qui représente un taux de mortalité d'environ 10 %. Alors que le MERS-CoV a infecté plus de 857 cas officiels et 334 décès, soit un taux de mortalité d'environ 35 %(13). Jusqu'à présent, le SARS-CoV-2 est le septième membre de la famille des CoVs qui infectent les humains.

Les principaux symptômes du COVID-19 étaient la fièvre, la fatigue et la toux, qui sont similaires à ceux des cas infectés par le SARS-CoV et le MERS-CoV. Il y a des chevauchements et des aspects distincts de la pathologie et de la pathogenèse de ces CoVs qui causent des maladies graves chez l'homme. (14)

De nombreuses publications ont fait état des caractéristiques cliniques, de la virologie, de la pathologie et de la radiologie du COVID-19, mais l'examen exhaustif est peu. L'objectif de ce chapitre est principalement d'examiner l'agent pathogène, les caractéristiques cliniques, le diagnostic, laprévention et le traitement du COVID-19, mais aussi de commenter brièvement l'épidémiologie et la pathologie sur la base des données et preuves actuelles.

II.2 Aspects microbiologiques des coronavirus

Les coronavirus sont une famille très diverse de virus à ARN monocaténaire, dont le diamètre est d'environ 125 nm, et appelés ainsi, en raison de l'apparence semblable à une couronne, vu par le microscope électronique.

Ils sont considérés comme ayant le plus grand génome des virus ARN avec une taille de 26-32 kilobases, qui code quatre protéines structurelles qui comprennent : la glycoprotéine épi (S), enveloppement (E), membrane (M) et nucléocapside (N), ainsi que l'hémagglutinine stéréos (HE) et 16 autres protéines non structurelles impliquées dans la transcription et la réplication virale, telles que l'héliothérapie et l'ARN polymérase à ARN (15)

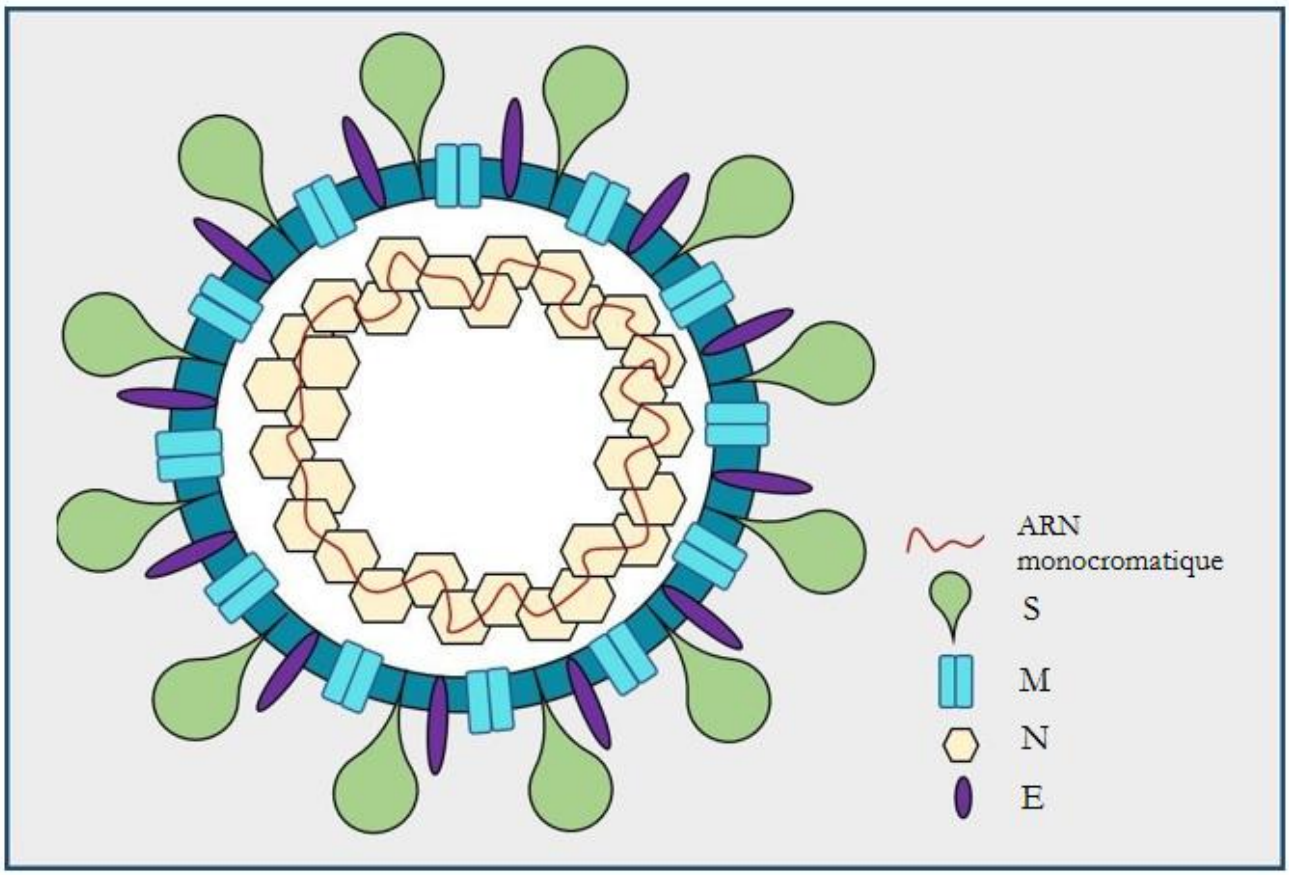


Figure 8: Structure du coronavirus et chacun de ses protéines et leurs distributions(15).

Selon le Comité International de Taxonomie du Virus, ils appartiennent à l'ordre : Nidovirales, subordonnés : Cornidovirinae, famille : Coronaviridae, sous-famille : Orthocoronavirinae, qui se compose de quatre genres : alfacoronavirus, betacoronavirus, gammacoronavirus et deltacoronavirus. (16)
Alors que les deux premiers infectent exclusivement l'homme et les mammifères, les deux derniers couvrent une plus large gamme d'hôtes, y compris certaines espèces d'oiseaux.
Les infections à coronavirus humaines et animales se traduisent principalement par des maladies respiratoires.

On sait depuis des années que les coronavirus humains, tels que HCoV-229E et HCoV-OC43, circulent dans la population; en outre, les plus récemment identifiés, HCoV-NL63 et

HCoV-HKU1, provoquent des infections respiratoires saisonnières, généralement légers, associés à des symptômes du rhume.
En revanche, le (SARS-CoV), (MERS-CoV) et le (SARS-CoV-2), apparus ces dernières années dans la population humaine, sont hautement pathogènes, étant donné qu'en infectant les cellules des voies respiratoires supérieures, de l'épithélium bronchique et des pneumocoques chez l'homme, les infections par le SRAS-CoV, le MERS-CoV et le SARS-CoV-2 peuvent se transformer en pathologies respiratoires graves potentiellement mortelles et provoquer des lésions pulmonaires pour lesquelles il n'existe pas de traitement prophylactique ou thérapeutique spécifique à ce jour (17).

II.3 Épidémiologie

En bref, les cas ont tendance à se trouver dans des groupes qui arrivent par vagues et se transforment en épidémies plus importantes partout dans le monde. L'éclosion s'est produite principalement à Wuhan. Selon le rapport quotidien de l'Organisation mondiale de la Santé, l'épidémie de SARS CoV 2 à ce jour a enregistré 460 000 000 cas et 6 000 000 décès au monde(10), le 27 février 2022. Il y a des preuves qui suggèrent que le mode de transmission est humain à humain et la principale voie de transmission de la COVID-19 est la gouttelette et le contact étroit. Si l'infection peut se produire par voie orale ou les voies conjonctivales sont inconnues, mais le SARS-CoV-2 a été détecté en larmes(18), qui ressemble au SARS CoV. Nombre reproducteur R0 a été estimé par certaines études. Sur la base des données cliniques de patients atteints de la COVID-19 au début de l'éclosion, le R0 moyen variait de 2,20 à 3,58, ce qui signifie que chaque patient a propagé une infection à deux ou trois autres personnes(19). Il est encore trop tôt pour développer une estimation R0 précise ou pour évaluer la dynamique de transmission. Plus la recherche est nécessaire à l'avenir.

La période d'incubation moyenne est d'environ 5 jours, allant de 1 à 14 jours et 95 % des patients sont susceptibles de présenter des symptômes après 12,5 jours de contact(20). Ces données suggèrent une période d'observation médicale de 14 jours ou une quarantaine pour les personnes exposées au contact étroit(21).

II.4 Diagnostic

Bien que l'historique des contacts soit vraie, des symptômes systémiques et des changements radiographiques de la pneumonie rendent le diagnostic probable, le diagnostic de laboratoire est plus fiable. La réaction en chaîne de la polymérase en temps réel (RT PCR) est couramment utilisée pour détecter les virus responsables des sécrétions respiratoires(22). La réussite de ces tests est très importante pour comprendre la cinétique virale et le tropisme tissulaire des cas de COVID-19. Plusieurs essais spécifiques et sensibles ciblant les gènes N et E du génome SARS-CoV-2 ont été conçus pour détecter l'ARN viral dans les échantillons cliniques. Les échantillons des voies respiratoires inférieures fournissent les charges virales. La source ou l'opération d'échantillonnage peut influer sur les résultats des tests RT PCR(23).
Le taux positif de RT PCR pour l'écouvillonnage de la gorge a signalé que les échantillons étaient à environ 60 % au début de la pandémie de COVID-19. Ces constatations suggèrent

que le résultat de la RT PCR devrait être interprété avec prudence. Une étude a examiné la valeur diagnostique et la cohérence de la tomodensitométrie thoracique (TDM) par rapport au test RT PCR dans 1014 patients chez qui on soupçonne une infection au SARS-CoV-2. Les résultats donnent à penser que la sensibilité de la TDM thoracique chez les patients soupçonnés était de 97 % selon le résultat positif de la RT PCR et de 75 % selon les résultats négatifs de la RT PCR. Ces résultats indiquent que la TDM thoracique est une modalité sensible pour détecter l'infection au SARS-CoV-2. (24)

II.5 Prévention

À l'heure actuelle, il n'existe pas de traitement préventif pour COVID-19. Les recommandations actuelles, établies par l'OMS pour prévenir la transmission par le virus SARS-CoV-2, sont les suivantes :

- Utilisation du masque facial.
- Maintenir une distance avec les personnes d'au moins 1,5 à 2 mètres.
- Se laver fréquemment les mains avec de l'eau et du savon ou utiliser de l'alcool.
- Éviter de se toucher les yeux, le nez et la bouche.
- Éviter les activités non essentielles.
- S'éloigner des lieux fermés et préférer les espaces ouverts.
- Éviter les lieux conglomérés, ainsi que des réunions sociales.
- En éternuant ou en toussant, se couvrir le visage avec le coude fléchi ou un mouchoir.
- Nettoyage et désinfection fréquents des surfaces, en particulier celles en contact fréquent.

La vaccination, en tant que mesure préventive, est encore en développement dans le monde entier. Il existe actuellement une grande variété de vaccins approuvés par l'OMS. Ci-dessus on trouve une figure qui estime le taux d'efficacité des vaccins contre la covid19 selon les résultats préliminaires des essais cliniques.

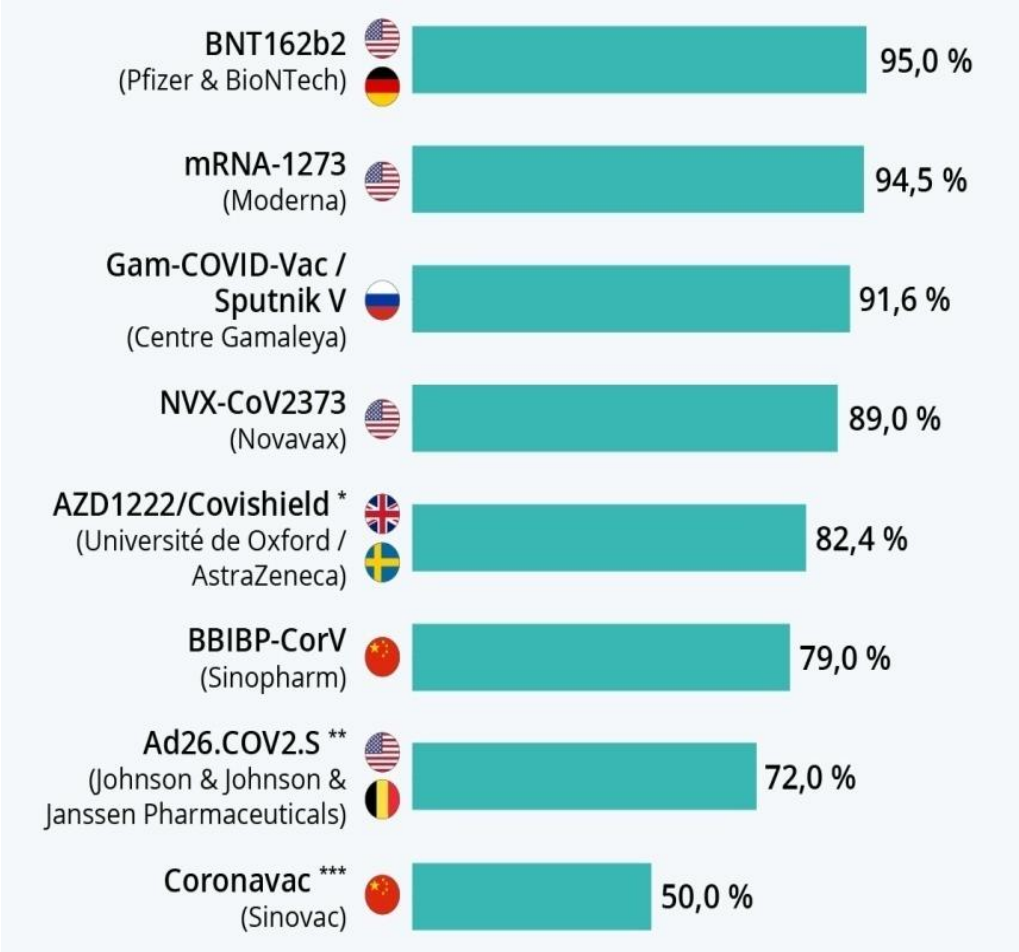


Figure 9 : L'efficacité des vaccins contre le COVID-19.

II.6 Conclusions

L'infection par le SRAS-CoV-2 et la maladie qu'il provoque, appelée COVID-19, est une situation de santé publique mondiale qui a entraîné un grand nombre de décès et de séquelles à long terme de la maladie. En Algérie, il a eu de graves conséquences, avec 6873 décès.

La COVID-19 est une maladie respiratoire d'origine virale répertoriée en fonction de ses stades de gravité et des dommages associés à de multiples organes et systèmes. Les manifestations cliniques sont variables d'une personne à l'autre; cependant, la surveillance des données d'alarme est importante pour la gestion en temps opportun des complications associées. Actuellement, il n'y a pas de traitement définitif pour le contrôle de la pandémie; celle-ci est réalisée en fonction de la symptomatologie et des états pathologiques subséquents. La vaccination comme moyen de prévention est déjà pratiquée dans le monde entier, mais il reste encore beaucoup à déterminer. Sa mise en œuvre actuelle prévoit la nécessité de réduire la mortalité et le nombre d'infections. Après récupération, une grande variété d'inconfort à long terme a été démontrée et la fatigue est la plus fréquente. Bien que l'infection par le SARS-CoV-2 ait été contractée auparavant, la probabilité de réinfection est possible dans un certain temps, d'où la nécessité de poursuivre les mesures préventives pour l'atténuer.

Chapitre 3

L’utilisation et les bienfaits du Deep Learning contre le COVID 19

III. L’utilisation et les bienfaits du deep learning contre le COVID 19

III.1 Introduction

Dans ce chapitre on explore la façon dont le deep Learning a permis de lutter contre la pandémie de COVID-19 et fournit des orientations pour les futures recherches sur la COVID-19. Nous couvrons les applications d’apprentissage profond dans le traitement du langage naturel NLP, la vision par ordinateur, les sciences de la vie et l’épidémiologie. Nous décrivons comment chacune de ces applications varie en fonction de la disponibilité des données et comment les tâches d’apprentissage sont construites. Les applications de traitement du langage naturel comprennent plusieurs programmes, on s'intéresse dans notre cas à la détection de la désinformation. L’application de vision par ordinateur couvre l’analyse d’images médicales. Au sein de Life Sciences, on montre comment l’apprentissage profond peut être appliqué à la prédiction de la structure des protéines. L’apprentissage profond a également été utilisé dans la prévision de la propagation de l’épidémie.

III.2 Traitement du langage naturel

Le traitement du langage naturel (NLP) est la capacité d’un programme informatique de comprendre le langage humain tel qu’il est parlé et écrit. C’est une composante de l’intelligence artificielle.

Ça existe depuis plus de 50 ans et a des racines dans le domaine de la linguistique. Il a une variété d’applications du monde réel dans un certain nombre de domaines, y compris la recherche médicale, les moteurs de recherche.

NLP permet aux ordinateurs de comprendre le langage naturel comme le font les humains. Que la langue soit parlée ou écrite, le traitement du langage naturel utilise l’intelligence artificielle pour prendre les données du monde réel, les traiter et les comprendre d’une manière qu’un ordinateur peut comprendre. Tout comme les humains ont des capteurs différents, comme des oreilles pour entendre et des yeux pour voir, les ordinateurs ont des programmes pour lire et des microphones pour collecter l’audio. Et tout comme les humains ont un cerveau pour traiter cette entrée, les ordinateurs ont un programme pour traiter leurs entrées respectives. À un certain point du traitement, l’entrée est convertie en code que l’ordinateur peut comprendre.(25)
Le traitement du langage naturel comporte deux phases principales : le prétraitement des données et le développement d’algorithmes.

Le prétraitement des données implique la préparation et le "nettoyage" des données textuelles pour que les machines puissent les analyser. Il permet de mettre les données sous une forme pratique et de mettre en évidence les caractéristiques du texte avec lesquelles un algorithme peut travailler. Il y a plusieurs façons de le faire, notamment :

- Segmentation en jetons. C’est quand le texte est décomposé en plus petites unités à travailler avec.

- Arrêtez la suppression de mot. C'est quand les mots communs sont supprimés du texte de sorte que les mots uniques qui offrent le plus d'informations sur le texte restent.
- Étiquetage des parties de discours. C'est quand les mots sont marqués en fonction de types, comme les noms, les verbes et les adjectifs.

Une fois les données prétraitées, un algorithme est développé pour les traiter. Il existe de nombreux algorithmes de traitement du langage naturel, mais deux systèmes principaux sont couramment utilisés :

Un système fondé sur des règles qui utilise des règles linguistiques soigneusement conçues. Cette approche a été utilisée dès le début dans le développement du traitement du langage naturel, et est toujours utilisée.
Le deuxième est un système d'apprentissage automatique qui utilise des méthodes statistiques. Ils apprennent à effectuer des tâches basées sur les données de formation qu'ils sont nourris, et ajuster leurs méthodes à mesure que plus de données sont traitées. À l'aide d'une combinaison d'apprentissage automatique, d'apprentissage profond et de réseaux neuronaux, les algorithmes de traitement du langage naturel affinent leurs propres règles grâce au traitement et à l'apprentissage répétés.

III.2.1 Détection de la mésinformation

La propagation de l'information liée au SARS-CoV-2 et à la COVID-19 a été chaotique, désignée sous le nom d'infodémie(26). Des théories conspirationnistes allant de l'attribution causale des réseaux 5G aux faux traitements et à la communication d'informations scientifique, comment peut-on utiliser le Deep Learning pour lancer l'infodémie ?

La détection de la désinformation a été formulée comme un problème de classification de texte ou de similarité sémantique.
De nombreuses études ont construit des modèles de classification pour les tweets potentiellement contenant de la désinformation. Ces journaux sont pour la plupart plus différents dans la façon dont ils étiquettent ces tweets, et ça se fait selon sept étiquettes de questions; contiennent une allégation factuelle véridique, sont susceptibles de contenir de fausses informations, sont d'intérêt pour le grand public, sont potentiellement nuisibles à une personne, à une entreprise, à un produit ou à la société, exigent une vérification, qui cause un préjudice particulier à la société et qui nécessite l'attention d'une entité gouvernementale.
La détection de la désinformation et la vérification des faits ont été étudiées avant l'infodémie sur la COVID-19.
L'ensemble de données le plus notable est FEVER, Fact Extraction and Verifcation(27). Cet ensemble de données contient 185445 allégations générées par des annotateurs humains.
Construire un nouvel ensemble de données qui encadre correctement une nouvelle tâche est un thème commun dans le Deep Learning. SciFact est l'ensemble de données pour étendre les idées de FEVER aux applications liées à la COVID-19. Il est créatif dans la conception des tâches.
SciFact et FEVER introduisent de nouveaux ensembles de données qui montrent comment l'apprentissage supervisé peut lutter contre la détection de la désinformation.

SciFact non seulement classe une allégation comme vraie ou fausse, mais aussi fourni des éléments de preuve à l'appui et à l'encontre. Il utilise un astucieux système d'annotation consistant à utiliser des « citations », des phrases dans des documents scientifiques qui citent un autre document, comme exemples d'appui ou de réfutation d'une preuve pour une allégation.
Les auteurs de SciFACT et de FEVER basent leurs ensembles de données sur des systèmes de recherche d'informations neuronales. Leurs systèmes reposent sur des vecteurs de fonctionnalités éparses et des représentations distribuées des connaissances stockées implicitement dans les poids des réseaux neuronaux.

III.3 Vision par ordinateur

Computer Vision, propulsé par l'apprentissage profond, a un curriculum vitae très impressionnant. Il va transformer les soins de santé de plusieurs manières. L'application la plus importante et fréquemment discutée de la COVID-19 est le diagnostic par imagerie médicale. Le Deep Learning s'est très bien comporté lors du diagnostic de l'image médicale et a fait l'objet d'essais cliniques sur de nombreuses maladies(28). Les tâches relatives aux images médicales concernent principalement la classification et la segmentation, ainsi que la reconstruction à partir de coupes 2D d'un scanner pour constituer la vue 3D final.
Computer Vision aide également dans les opérations hospitalières subtiles, pour combattre la faiblesse acquise par les soins intensifs, assurent que les travailleurs et les patients se lavent les mains correctement et améliorent la formation chirurgicale, pour n'en nommer que quelques-uns. Computer Vision équipe les caméras pour qu'elles comprennent ce qu'elles enregistrent. Elles peuvent identifier les gens. Ils peuvent étiqueter chaque pixel d'une route pour les voitures autonomes. Ils peuvent cartographier des images satellites dans des cartes routières. Ils peuvent imaginer à quoi ressemblerait un croquis si c'était un objet photographié. Ici, nous utilisons le mot « comprendre » pour faire de l'hyperbole, c'est-à-dire qu'il peut répondre à des questions sémantiques sur les images ou les données vidéo. Ces applications décrivent le potentiel de la Computer Vision pour permettre un grand nombre d'applications subtiles en réponse à une pandémie, comme la détection des masques faciaux et la surveillance de la distanciation sociale ou de l'inventaire de l'équipement hospitalier.
Les dommages économiques sont l'une des plus grandes victimes de la COVID-19. Comment pouvons-nous concevoir des processus de fabrication et de chaîne d'approvisionnement sans contact qui ne mettent pas les travailleurs en danger ? La robotique axée sur la vision est une orientation prometteuse à cet égard. La robotique industrielle actuelle repose sur la résolution de différentes équations pour contrôler explicitement le mouvement souhaité. Cela fonctionne très bien lorsque l'entrée peut être extrêmement contrôlée, mais se décompose lorsque le robot doit généraliser à de nouvelles entrées. La robotique basée sur la vision offre une solution de contrôle plus générale qui peut s'adapter aux nouvelles orientations des objets ou aux distributions de poids des boîtes.

III.3.1 Analyse des images médicales

Automatiser l'analyse d'images médicales est l'une des applications les plus couramment discutées du Deep Learning. Ces systèmes s'améliorent rapidement et sont passés aux essais cliniques. Le diagnostic d'image médicale pour la COVID-19 est principalement axée sur la

classification de la pneumonie, de la pneumonie virale ou des radiographies thoraciques saines. De nombreux examens se concentrent sur la tâche de segmentation sémantique, où chaque pixel d'une image est classé. Les radios du thorax proviennent soit de radiographies, soit de haute résolution CT scan (computedtomography scan - tomodensitométrie) En examinent la corrélation entre les tests de tomodensitométrie thoracique et de RT-PCR pour 1014 patients et concluent que « la tomodensitométrie thoracique peut être considérée comme un outil principal pour la détection actuelle de la COVID-19 dans les zones épidémiques »(29). Il existe certaines raisons de préférer les radiographies pulmonaires aux CT scan, à savoir qu'elles sont moins coûteuses et plus disponibles et qu'elles ont un rayonnement ionisant plus faible.

La création de modèles d'apprentissage profond avec des ensembles de données relativement petits représente plusieurs défis. L'analyse des images médicales en est peut-être le meilleur exemple. Comparativement aux 1,4 million d'images dans ImageNet, nous avons rarement plus de 1 000 radiographies pulmonaires positives à la COVID-19. C'est particulièrement important dans une situation de pandémie, où nous devons recueillir des renseignements diagnostiques le plus rapidement possible. Les chercheurs se sont tournés vers des variantes de l'apprentissage supervisé comme solution à ce problème. Comprend l'apprentissage par transfert, auto-supervisé, faiblement supervisé ou apprentissage multitâche

III.4 Sciences de la vie

Cette section traitera d'une portée absolument massive, généralement appelée ici « Deep Learning for Life Sciences ». La science de la vie contient plusieurs branche, telle que l'amélioration des capacités de diagnostic de la COVID-19 des analyses sanguines à des applications révolutionnaires dans la modélisation des protéines et la réutilisation des médicaments, et dans notre cas on traitera la modélisation des protéines(30).

Les mégadonnées ne manquent pas à l'intersection de la biologie et du Deep Learning. Les humains contiennent 45000 gènes et le génome humain entier contient 3 milliards de paires de base. On estime qu'il y a 37,2 milliards de cellules dans un corps humain(31). Ces chiffres illustrent la « biologie à grande échelle »(32). Malgré une base solide d'information en biologie, nous n'avons pas un modèle exact de chaque voie physiologique dans le corps humain. Nous ne pouvons pas comprendre exactement ce qui arrivera avec l'introduction d'une nouvelle molécule. Cependant, nous pouvons toujours modéliser des protéines telles que les protéines membranaires avec lesquelles le virus se lie. Ces modèles de protéines nous permettent de concevoir des médicaments potentiellement inhibiteurs beaucoup mieux que par chance.

III.4.1 Prédiction de la structure protéique

L'une des clés pour comprendre la biologie du SARS-CoV-2 est la structure des protéines de la coquille externe. La structure détermine le rôle et la fonction d'une protéine (33). La compréhension de cette structure peut aider à déterminer les traitements potentiels. « Si un groupe de virus partage une structure protéique commune, les thérapies pour une infection virale peuvent être réutilisées pour de nouvelles maladies comme la COVID-19 » (34). La

vérification expérimentale de la structure est effectuée avec la cristallographie aux rayons X, l'imagerie par résonance magnétique nucléaire ou la microscopie Cryo-électronique. Cependant, cela coûte cher et prend du temps. Par conséquent, les chercheurs s'intéressent aux modèles qui peuvent prédire cette structure. Ces structures validées ont été placées dans la banque de données sur les protéines. Cet ensemble de données sur les séquences d'acides aminés 1-D et leurs structures en 3D est un excellent point de départ pour le Deep Learning.

La banque de données des protéines est un ensemble de données qui peut être utilisé avec l'apprentissage semi-supervisé. L'apprentissage semi-supervisé décrit le problème d'apprentissage lorsqu'il existe un petit ensemble de données étiqueté et un ensemble de données plus grand et non étiqueté. Ce ne sont que 158 milles structures expérimentalement déterminées disponibles dans la banque de données sur les protéines.
L'apprentissage de la représentation des protéines est un problème d'apprentissage semi-supervisé. Les Tâches d'évaluation des incorporations de protéines (TAPE) mettent à l'épreuve la force de l'apprentissage de la représentation protéique semi-supervisée et trouvent que l'auto-formation supervisée est efficace.
La modélisation des protéines recherche la séquence la plus similaire qui a une structure 3D vérifiée expérimentalement, en notant que des séquences d'acides aminés similaires ont probablement des structures 3D similaires. Du point de vue du Deep Learning, Nous recherchons la séquence la plus similaire dans laquelle nous avons une structure expérimentale réelle disponible.

III.5 Épidémiologie

La plus grande intervention pour contrer la propagation de la COVID-19 qui a été mise en œuvre est le confinement. La solution consistant à limiter les contacts entre les personnes réduit considérablement la propagation et la prévalence du SARS-CoV-2. Toutefois, le confinement entraîne un coût énorme sur le plan économique et de la santé mentale. Le champ de l'épidémiologie vise à répondre aux questions sur la propagation de maladies infectieuses comme la COVID-19. Les outils d'épidémiologie, tels que les équations différentielles, nous aident à comprendre de nombreuses questions importantes au sujet du virus. Combien de temps devrons-nous rester en quarantaine chez nous? Dans quelle mesure la quarantaine ralentira-t-elle la propagation du virus? Que savons-nous du taux d'infection? Il est extrêmement important de répondre à ces questions pour affecter des ressources limitées comme les ventilateurs, l'équipement de protection individuelle et les lits de soins intensifs, ainsi que pour informer le public. Cette partie on explorera comment le Deep Learning peut améliorer les prévisions de propagation. On prendra l'exemple de Suivi des contacts

III.5.1 Suivi des contacts

C'est un autre exemple d'application qui est lié à la confidentialité des données. L'idée de Contact Tracing, plus particulièrement « Digital Contact Tracing », est d'utiliser les données d'interaction de téléphone portable à travers des capteurs pour suivre le contact entre les individus. Les utilisateurs peuvent également s'inscrire à la recherche de contacts en

téléchargeant une application téléphonique. Cependant, cela nécessiterait que tout le monde télécharge l'application pour fonctionner de manière efficace. Ceci est particulièrement important en raison des phénomènes de contagiosité maximale précédant l'apparition des symptômes. Les données de recherche des contacts permettraient aux personnes de savoir si elles ont été exposées à une personne porteuse du virus, si elles ont visité un point chaud où le virus se trouvait et se trouve peut-être encore sur des surfaces, et ainsi de quantifier leur risque de contracter le virus elles-mêmes. Cette quantification s'améliorerait au fil du temps, car davantage de données sont recueillies sur la façon dont ces interactions mènent réellement à des infections. Il n'y a pas de tels ensembles de données publiques qui suivent les individus, mais les rapports de mobilité de Google (35) fournissent des renseignements sur les déplacements et les contacts entre les individus au niveau de la ville.

En imaginant que nous avions ce genre de données, ça existe une stratégie prometteuse pour contrôler la propagation en utilisant l'apprentissage par renforcement et les réseaux neuronaux graphiques.
Qui devrait être testé? Qui devrait se mettre en quarantaine? Les tests sont le genre de décisions que le modèle doit prendre pour les personnes en fonction de leur contact. La stratégie utilise des méthodes de construction de graphes de réseaux sociaux telles que l'attachement communautaire, l'attachement préférentiel et les statistiques dérivées du suivi cellulaire réel. Elle décri les techniques de construction d'une matrice de contiguïté avec différentes caractéristiques. Ils simulent les interactions et utilisent les réseaux neuronaux graphiques pour classer les candidats qui devraient être mis en priorité à l'essai. Dans les simulations, cela augmente le nombre de personnes en bonne santé de 25% et contient l'épidémie 30% plus souvent que les approches supervisées. Pour des ensembles de données de traçage de contacts réels, ces réseaux neuronaux graphiques deviendraient nécessaires pour traiter une grande population et de grandes données d'interaction.

III.6 Conclusion

Le Deep Learning a vraiment aidé à lutter contre la pandémie de COVID-19 avec ses diverses applications dans plusieurs domaines tel que le traitement du langage naturel et la vision par ordinateur.

Chapitre 4

Les limites et perspectives

IV. Les limites et perspectives

IV.1 Introduction :

Dans une crise comme la pandémie de COVID-19, les gouvernements et les services de santé doivent agir rapidement et de façon décisive pour arrêter la propagation de la maladie. L'intelligence artificielle (IA), qui dans ce contexte signifie en grande partie des algorithmes de données de plus en plus puissants, peut être une partie importante de cette action par exemple, en aidant à suivre l'évolution d'un virus ou en donnant la priorité aux ressources rares. Pour sauver des vies, il pourrait être tentant de déployer ces technologies à grande échelle. Le déploiement de l'IA peut toutefois toucher un large éventail de valeurs fondamentales, comme l'autonomie, la protection de la vie privée et l'équité. L'IA est beaucoup plus susceptible d'être bénéfique, même dans les situations urgentes, si ceux qui la mettent en service, la conçoivent et la déploient adoptent une approche éthique systématique dès le départ.

L'éthique consiste à examiner les préjudices et les avantages potentiels d'une action d'une manière fondée sur des principes. Pour une technologie largement déployée, cela jettera les bases de la fiabilité. Le déploiement éthique exige des consultations à grande échelle et ouvertement ; une réflexion approfondie et générale sur les répercussions potentielles; et la transparence au sujet des objectifs poursuivis, des compromis faits et des valeurs qui guident ces décisions. En cas de pandémie, ces processus devraient être accélérés, mais non abandonnés. Sinon, deux grands dangers se posent : premièrement, les avantages de la technologie pourraient être compensés par des effets secondaires néfastes et, deuxièmement, la confiance du public pourrait être perdue.

Le premier danger est que les avantages potentiels augmentent l'incitation à déployer les systèmes d'IA rapidement et à grande échelle, mais augmentent également l'importance d'une approche éthique. La vitesse de développement limite le temps disponible pour tester et évaluer une nouvelle technologie, tandis que l'ampleur du déploiement augmente les conséquences négatives. Sans réflexion préalable, cela peut entraîner des problèmes, comme une approche universelle qui nuit à des groupes déjà désavantagés.

Deuxièmement, la confiance du public dans l'IA est cruciale. Par exemple, les applications de suivi de contacts comptent sur une adoption généralisée pour leur succès. Les entreprises de technologie et les gouvernements, cependant, ont du mal à convaincre le public qu'ils utiliseront l'IA et les données de façon responsable. Les groupes de protection de la vie privée ont mis en garde contre les plans visant à permettre un accès accru aux données, des préoccupations ont été soulevées en Chine au sujet de la distribution des données et du contrôle par le système de codes QR de santé aux entreprises privées risque de miner la confiance à long terme dans la réputation de l'ensemble du secteur. Que les préjudices potentiels deviennent évidents immédiatement ou seulement beaucoup plus tard, l'adoption d'une approche éthique cohérente dès le départ nous placera dans une bien meilleure position pour récolter tous les avantages de l'IA, maintenant et à l'avenir.

IV.2 Réunir l'éthique de l'IA et l'éthique de la santé

L'IA peut être définie de manière générale comme des systèmes numériques qui peuvent prendre des décisions ou formuler des recommandations complexes sur la base d'entrées de données. Cette définition simple met en lumière trois raisons pour lesquelles de tels systèmes posent des défis éthiques.

Premièrement, les applications d'IA, en particulier dans le domaine de la santé, nécessitent souvent beaucoup de données personnelles et soulèvent donc toutes les préoccupations relatives à la gestion responsable des données, comme la protection de la vie privée, le consentement, la sécurité et la propriété(36).

Deuxièmement, les systèmes d'IA sont souvent utilisés pour automatiser les processus de prise de décision qui étaient auparavant effectués par les humains. Cette automatisation soulève des défis éthiques, comme qui doit être tenu responsable de ces décisions, ou comment les intervenants peuvent savoir quels jugements de valeur les guident. Par exemple, le système optimise une valeur commerciale, les intérêts d'un gouvernement, ou la santé de la personne ? Ces préoccupations peuvent survenir même lorsqu'un système d'IA ne recommande une ligne de conduite qu'en raison d'un biais d'automatisation, la propension des gens à suspendre leur propre jugement et à trop compter sur les systèmes automatisés(37).

Troisièmement, les opérations des systèmes d'IA sont souvent floues, en raison de la complexité des données ou de l'algorithme (en particulier de nombreux algorithmes de DL puissants et populaires utilisés dans l'apprentissage automatique). Ce manque de clarté, ainsi que les problèmes de responsabilisation qui s'y ajoutent, peuvent rendre difficile l'évaluation de facteurs pertinents sur le plan éthique, comme les biais non intentionnels dans le système ou la solidité des résultats dans différentes populations(38).

Bien entendu, la prise de décision éthique fait déjà partie intégrante de la pratique des soins de santé, où elle est souvent structurée en fonction depiliers de l'éthique biomédicale : la non-malfaisance, l'autonomie et la justice.

IV.2.1 Non-malfaisance

Pour éviter les préjudices imprévus découlant de l'utilisation de l'IA dans la gestion d'une pandémie, il est important d'examiner attentivement les conséquences potentielles des interventions proposées. Certaines interventions peuvent causer des problèmes de santé mentale à ceux qui sont déjà vulnérables ou entraîner des coûts économiques élevés. Les systèmes d'IA cherchent à optimiser une fonction objective particulière, c'est-à-dire une fonction mathématique qui représente les buts pour lesquels ils ont été conçus. Les préjudices potentiels non représentés par cette fonction ne seront pas pris en compte dans les prévisions du système. Par exemple, certains systèmes conçus pour éclairer la priorisation des ressources hospitalières sont optimisés pour prédire les décès dus à la COVID-19, mais pas d'autres préjudices possibles pour les patients(39). Si ces autres méfaits ne sont pas corrélés avec le risque de décès, le fait de décider comment prioriser les ressources de santé en se basant uniquement sur ce système pourrait considérablement regrouper les méfaits. De plus, comme ces systèmes seront déployés à grande échelle, ils doivent fonctionner de façon fiable, comme prévu, dans différentes populations et dans des conditions qui pourraient changer.

Essayer de développer rapidement les systèmes d'IA alors que notre compréhension du virus est encore limitée, et avec moins de temps que d'habitude pour assurer la qualité et la représentativité des données utilisées, risque de créer des systèmes fondés sur la simplification des hypothèses et des ensembles de données qui ne couvrent pas tous les cas réels. Par exemple, un examen systématique récent de 145 modèles de prédiction pour le diagnostic de la COVID-19 (dont 57 utilisant l'IA pour l'analyse d'images). Les diagnostics inexacts ou les interventions inappropriées découlant de ces modèles pourraient coûter plus de vies qu'ils n'en sauvent.

IV.2.2 Autonomie

Les avantages des nouvelles technologies dépendent presque toujours de la manière dont elles affectent le comportement et la prise de décision des gens, depuis les précautions qu'une personne choisit de prendre, jusqu'aux décisions de traitement prises par les professionnels de la santé, et la priorisation par les politiciens des différentes réponses politiques. Le respect de l'autonomie des peuples est donc crucial. Des données provenant de différentes cultures et de différents groupes d'âge montrent que les gens ressentent le besoin de contrôler et d'approuver l'utilisation de la technologie, ou que son influence sur leur comportement est susceptible d'être limitée(40). Un défi particulier pour les systèmes d'IA est qu'ils pourraient toucher les patients, les professionnels de la santé et d'autres intervenants de façon plus subtile et individualisée que, par exemple, un masque ou un vaccin, où les comportements souhaités sont évidents. Les concepteurs peuvent aider les utilisateurs à comprendre et à faire confiance aux systèmes d'IA afin qu'ils se sentent en mesure de les utiliser avec autonomie.

IV.2.3 Justice

Les systèmes d'IA axés sur les données peuvent affecter différemment les différents groupes, comme cela est bien documenté. Lorsque des données de qualité suffisante pour certains groupes font défaut, les systèmes d'IA peuvent devenir biaisés, souvent d'une manière qui discrimine les groupes déjà désavantagés, Par exemple, les applications pour téléphones intelligents sont de plus en plus présentées comme des outils de surveillance et de diagnostic, comme le modèle de diagnostic de la COVID-19 grâce au son de la toux. Mais l'accès aux smart phones est inégalement réparti entre les pays et la démographie, cela limite à la fois les personnes dont les données sont utilisées pour développer de telles applications et celles qui ont accès au service(41). Si l'on ne prend pas soin de détecter et de contrer tout biais, l'utilisation de l'IA pour la gestion des pandémies pourrait aggraver les inégalités en matière de santé. Encore une fois, la vitesse et l'échelle auxquelles les systèmes pourraient être déployés en réponse à la pandémie aggravent ces risques ce qui rends la prévoyance et la vigilance d'autant plus cruciales.

De façon plus générale, lorsque des systèmes d'IA sont proposés en réponse à une pandémie, des compromis difficiles entre les valeurs pourraient être introduits. Par exemple, les principaux responsables de la santé publique du Royaume-Uni ont plaidé pour une approche centralisée de la collecte de données dans la conception de l'application de traçage numérique des contacts du NHS, faisant valoir que l'apprentissage automatique pourrait être appliqué à l'ensemble de données résultantes pour aider à la prédiction des maladies. Les experts en droit et en sécurité ont toutefois plaidé en faveur d'une approche décentralisée, citant des préoccupations concernant la protection de la vie privée et la sécurité des données, le

Royaume-Uni a choisi d'utiliser une application décentralisée. Il s'agit de choix fondés sur la valeur, au sujet desquels des personnes raisonnables pourraient être en désaccord, et des groupes particuliers pourraient avoir des raisons beaucoup plus importantes de s'inquiéter. La participation de diverses communautés aux décisions et être ouvert à propos des valeurs et aux compromis aidera à réduire ces risques.

IV.3 Conclusion

Les technologies fondées sur l'IA promettent des avantages pour lutter contre une pandémie comme la COVID-19, mais soulèvent également des défis éthiques pour les développeurs et les décideurs. Si une approche éthique n'est pas adoptée, les risques de conséquences néfastes imprévues et de perte de confiance des intervenants augmentent.

Une communication ouverte et transparente avec divers groupes d'intervenants pendant l'élaboration des systèmes d'IA est la meilleure façon de relever ces défis.

Conclusion générale

La pandémie de COVID-19 a mis en épreuve nos systèmes de santé d'une manière sans précédent. Presque partout dans le monde, des réseaux de laboratoires de lutte contre la COVID-19 ont été mis en place pour répondre aux besoins particuliers des citoyens et des patients, et ils continueront d'être fondamentaux lors du redémarrage des activités sociales et professionnelles.

La pandémie de COVID-19 a révélé les faiblesses de nos systèmes de santé qui n'étaient pas préparés pour faire face à un très grand nombre de patients qui ont besoin d'un traitement de soutien respiratoire en peu de temps. Cette urgence a forcé les autorités sanitaires à arrêter toutes les procédures médicales non urgentes et à convertir les salles en unités de soins intensifs ou sous-unités de soins intensifs. D'autre part, la pandémie a incité la communauté scientifique à unir ses efforts pour lutter contre ce nouvel agent pathogène. Les scientifiques ont fait appel a l'intelligence artificielle et au deep learning

Nous avons présenté de nombreuses applications du deep learning pour lutter contre la COVID-19. Le SARS-CoV-2 et la COVID-19 ont engendré de nombreux nouveaux problèmes que l'humanité doit résoudre. Notre étude décrit comment certains de ces problèmes peuvent être résolus avec le deep learning et l'intelligence artificielle. Nous avons décrit comment différents types de données sont entrés dans les réseaux neuronaux et comment les tâches sont construites comme des problèmes d'apprentissage. Ces applications sont explorées à travers les domaines de données dans le traitement du langage naturel, la vision par ordinateur, les sciences de la vie et l'épidémiologie.

Nous avons également couvert certaines des limitations les plus urgentes du Deep Learning. Cela comprend les défis liés aux mesures de rendement et à l'apprentissage à partir de données limitées. Le déploiement de l'IA peut toutefois toucher un large éventail de valeurs fondamentales, comme l'autonomie et la protection de la vie privée.

Bibliographie

1. **Castle Nikki (2017): Supervised vs. Unsupervised Machine Learning.**

2. **Castle Nikki (2018): What is Semi-Supervised Learning?**

3. **David Fumo (2017): Types of Machine Learning Algorithms You Should Know.** [En ligne] https://towardsdatascience.com/types-of-machine-learning-algorithms-you-should-know-953a08248861.

4. **Goodfellow et al. (2016): Deep Learning, MIT Press,.**[En ligne] https://www.deeplearningbook.org/.

5. **Dormehl Luke (2018): What is an artificial neural network? Here‘s everything you need to know,.**[En ligne] https://www.digitaltrends.com/cool-tech/what-is-an-artificialneural-network/.

6. **A. Nielsen Michael (2017): Neural Networks and Deep Learning, Determination.** http://neuralnetworksanddeeplearning.com/. [En ligne]

7. **Tchircoff Andrew (2017): The mostly complete chart of Neural Networks, explained.**[En ligne] https://towardsdatascience.com/the-mostly-complete-chart-of-neuralnetworks-explained-3fb6f2367464.

8. **Moawad Assad (2018): Neural networks and back-propagation explained in a simple.**[En ligne] https://medium.com/datathings/neural-networks-and-backpropagation-explained-in-a-simple-way-f540a3611f5e.

9. **Ruder Sebastian (2017): Transfer Learning – Machine Learning‘s NextFrontier.**[En ligne] http://ruder.io/transfer-learning/index.html#applicationsoftransferlearning.

10. **World Health Organization Coronavirus Disease 2019.**[En ligne] https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200131-sitrep-11-ncov.pdf.

11. **Zumla A, Chan JF, Azhar EI, Hui DS, Yuen KY. Coronaviruses—drug discovery and therapeutic options. Nat Rev Drug Discov. 2016.**

12. **Cheng VC, Lau SK, Woo PC, Yuen KY. Severe acute respiratory syndrome coronavirus as an agent of emerging and reemerging infection. Clin Microbiol Rev. 2007; 20(4):660-694.**

13. **Gretebeck LM, Subbarao K. Animal models for SARS and MERS coronaviruses. Curr Opin Virol. 2015.**

14. **Liu J, Zheng X, Tong Q, et al. Overlapping and discrete aspects of the pathology and pathogenesis of the emerging human pathogenic coronaviruses SARS-CoV, MERS-CoV, and 2019-nCoV. J Med Virol. 2020.** https://doi.org/10.1002/jmv.25709. [En ligne]

15. **V'kovski P, Kratzel A, Steiner S, Tiel V. Coronavirus biology and replication: implications for SARS-CoV-2. Nat Rev Microbiol. 2020; 19:155-70.** [En ligne] https://doi.org/10.1038/s41579-020-00468-6.

16. **International Committee on Taxonomy of Viruses (ICTV),.** [En ligne] https://talk.ictvonline.org/ictv-reports/ictv_9th_report/positive-sense-rna-viruses-2011/w/posrna_viruses/222/coronaviridae.

17. **Cevik M, Tate M, Lloyd O, et al. SARS-CoV-2, SARS-CoV, and MERS-CoV viral load dynamics, duration of viral shedding, and infectiousness: a systematic review and meta-analysis. Lancet Microbe.** [En ligne] https://doi.org/10.1016/S2666-5247(20)30172-5.

18. **Xia J, Tong J, Liu M, Shen Y, Guo D. Evaluation of coronavirus in tears and conjunctival secretions of patients with SARS-CoV-2 infection.J Med Virol. 2020.** [En ligne] https://doi.org/10.1002/jmv.25725..

19. **Li Q, Guan X, Wu P, et al. Early transmission dynamics in Wuhan,China, of novel coronavirus-infected pneumonia. N Engl J Med. 2020.** [En ligne] https://doi.org/10.1002/jmv.25725..

20. **Wang D, Hu B, Hu C, et al. Clinical characteristics of 138 hospitalized patients with 2019 novel coronavirus-infected pneumonia in Wuhan.**[En ligne] https://doi.org/10.1001/jama.2020.1585.

21. **Bai Y, Yao L, Wei T, et al. Presumed asymptomatic carrier transmission of COVID-19. JAMA. 2020.** [En ligne] https://doi.org/10.1001/jama.2020..

22. **Binnicker MJ. Emergence of a novel coronavirus disease (COVID-19) and the importance of diagnostic testing.**[En ligne] https://doi.org/10.1093/clinchem/hvaa071.

23. **Zou L, Ruan F, Huang M, et al. SARS-CoV-2 viral load in upper rerespiratory.**[En ligne] https://doi.org/10.1056/NEJMc2001737.

24. **Yang Y, Yang M, Shen C, et al. Evaluating the accuracy of different respiratory specimens in the laboratory diagnosis.** [En ligne] https://doi.org/10.1101/2020.02.11.20021493.

25. **Haque A, Milstein A, Fei-Fei L. Illuminating the dark spaces of healthcare with ambient intelligence.** [En ligne] https://doi.org/10.1038/s41586-020-2669-y.

26. **Management., WHO Infodemic.** [En ligne] https://www.who.int/teams/risk-communicat ion/infodemic-management .

27. **Thorne J, Vlachos A, Christodoulopoulos C, Mittal A. Fever: a large-scale dataset for fact extraction and verification;.** [En ligne]

28. **Raghu M, Zhang C, Kleinberg J, Bengio S. Transfusion: understanding transfer learning for medical imaging; 2019.** [En ligne]

29. **Topol E. Welcoming new guidelines for ai clinical research. Nat Med. 2020;.** [En ligne] https://doi.org/10.1038/s41591-020-1042-x.

30. **Brinati D, Campagner A, Ferrari D, Locatelli M, Banfi G, Cabitza F. Detection of covid-19 infection.** [En ligne] https ://doi.org/10.1101/2020.04.22.20075143.

31. **S, Strippoli P, Canaider S. An estimation of the number of cells in the human body.** [En ligne] https ://doi.org/10.3109/03014460.2013.807878.

32. **Collins FS, Morgan M, Patrinos A. The human genome project: Lessons from large-scale biology.**[En ligne] https://doi.org/10.1126/scien ce.1084564.

33. **D, Silver D, Kavukcuoglu K, Hassabis D. Improved protein structure prediction using potentials from deep learning.** [En ligne] https://doi.org/10.1038/s41586-019-1923-7.

34. **Barabasi A-L, Gulbahce N, Loscalzo J. Network medicine: a network-based approach to human disease.**[En ligne] https://doi.org/10.1038/nrg2918.

35. **Google Mobility Reports.** [En ligne] https://www.googl e.com/covid19/mobility/.

36. **Kroll JA. Data science data governance.**[En ligne] https://ieeexplore.ieee.org/abstract/document/8636447/.

37. **Strauch B. Ironies of automation: still unresolved after all these years.**[En ligne] https://ieeexplore.ieee.org/abstract/document/8013079/.

38. **Wynants L, Van Calster B, Collins GS, et al. Prediction models for diagnosis and prognosis of covid-19 infection.**[En ligne] https://www.bmj.com/content/369/bmj.m1328.long

39. **Li Y, Horowitz MA, Liu J, et al. Individual-level fatality prediction of covid-19 patients using AI methods.**[En ligne] https://www.bmj.com/content/369/bmj.m1328.long

40. **Ryan RM, Deci EL. Self-determination theory: basic psychological needs in motivation, development, and wellness.**[En ligne] https://www.google.com/books/edition/Self_Determination_Theory/th5rDwAAQBAJ?hl=en&gbpv=0

41. **Statista. Global smartphone penetration rate as share of population 2020.**[En ligne] https://www.statista.com/statistics/203734/global-smartphone-penetration-per-capita-since-2005/.

Résumé

L'épidémie actuelle du coronavirus a semé la peur partout dans le monde, ce qui a incité les professionnels de la santé à se mobiliser pour en faire face.

L'intelligence artificielle était le moyen le plus efficient, grâce à son aptitude à reproduire l'intelligence humaine dans ses capacités d'apprentissage, en utilisant des algorithmes d'apprentissage profond qui marquent l'aube de la recherche sur cette dernière, ce qui aide à analyser les images médicales, prévoir la propagation et détecter la mésinformation ainsi que d'autres bienfaits.

Cependant, ses avantages évidents s'accompagnent non seulement de limitations générales de l'application des systèmes d'IA, mais aussi de défis qui caractérisent spécifiquement l'opérationnalisation des concepts de maladie et de santé.

Mots clés : Covid, intelligence artificielle, apprentissage profond, réseau neuronal.

Abstract

The current coronavirus outbreak has sown fear all over the world, promoting medical professionals to step up to deal with it.

Artificial intelligence was the most effective way, thanks to its ability to replicate human intelligence in its learning capabilities, using deep learning algorithms that mark the dawn of AI research. Which helps to analyze medical images, predict the spread and detect misinformation along with other benefits.

However, its obvious advantages come not only with general limitations of the application of AI systems, but also with challenges that characterize the operationalization of the concepts of disease and health.

Key words: Covid, artificial intelligence, deep learning, neural network.

ملخص

أثار وباء فيروس كورونا الحالي الخوف في جميع أنحاء العالم،مما شجع المهنيين الصحيين على التصعيد لمواجهته.

كان الذكاء الاصطناعي الوسيلة الأكثر كفاءة، بفضل قدرته على تقليد الذكاء البشري في قدراته التعلمية، باستخدام خوارزميات التعلم العميق التي تميز فجر البحث عن هذا الأخير. مما يساعد في تحليل الصور الطبية، التنبؤ بالانتشار، اكتشاف المعلومات الخاطئة، بالإضافةللفوائد الأخرى.

ومع ذلك، فإن فوائده الجليّ لا تقترن فقط بالقيود العامة في تطبيق أنظمة الذكاء الاصطناعي، ولكن أيضًا بالتحديات التي تميز تفعيل مفاهيم المرض والصحة.

الكلمات المفتاحية:كوفيد، ذكاء اصطناعي، تعلم عميق، شبكة عصبية.