

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE Saad DAHLAB-BLIDA1



Faculté des Sciences
Département : informatique
Mémoire de fin d'étude
Pour l'obtention du Diplôme de :
Master Ingénierie de Logiciel
Thème :

UTILISATION DU DEEP LEARNING ET LES CT-SCAN THORACIQUES POUR DETECTER LE COVID 19

Réalisé par :

- **CHIRANE SOUNALLH ZAKARIA**

Encadré par :

- Dr.Mezian Abdelkrim ,
- Dr Kameche abdallah

Année universitaire 2020/2021

Remerciements

Je commence par remercier ma chère maman ma famille et amis pour m'avoir soutenu et encouragé durant la réalisation de ce projet.

J'adresse mes reconnaissances à mes promoteurs de projet Dr.Meziane et Mr.Kameche, je les remercie pour m'avoir guidé, pour leur pertinence, l'apport de leurs compétences et leur disponibilité.

Je tiens aussi à remercier Mme Bouzidi farah qui m'a aidé à terminer ce travail.

Je tiens à remercier les membres du jury pour avoir pris le temps d'examiner et évaluer ce travail.

Sans oublier les professeurs qui nous ont suivis tout au long de notre parcours universitaire, nous leur sommes reconnaissants pour leurs efforts et le savoir qu'ils nous ont transmis.

Je dédie ce travail :

Cher mère,

Permettez-moi de vous exprimer mon grand amour, mon attachement et ma plus haute considération pour votre personne. Je suis très fière d'être votre fils et de pouvoir enfin réaliser, ce que vous avez tant espéré et attendu de moi.

Vous n'avez jamais cessé de déployer tous vos efforts afin de m'encourager et m'aider à choisir le chemin de la Réussite.

Votre patience, votre bonne volonté, vos conseils précieux ainsi que votre confiance en moi ont été pour beaucoup dans ma réussite.

Cher mère, veuillez trouver, dans ce modeste travail, le fruit de

Vos sacrifices ainsi que l'expression de ma profonde

Affection et ma vive reconnaissance

Que Dieu vous protège

A mes deux frères

qui m'ont quitté à jamais Dr.Yagoub Hamza et Dr.Yagoub Mustapha qui ont toujours été un soutien très fort pour moi et ont toujours cru en moi dès mon jeune âge, ceux qui ont su m'éduquer et me donner les valeurs du respect, honnête et gratitude pour continuer ce chemin

Qu'Allah les bénisse dans son vaste paradis

Abstract

Owing to the COVID-19 pandemic and the imminent collapse of health care systems following the exhaustion of financial, hospital, and medicinal resources, the World Health Organization changed the alert level of the COVID-19 pandemic from high to very high. Meanwhile, more cost-effective and precise COVID-19 detection methods are being preferred worldwide.

Machine vision-based COVID-19 detection methods, especially deep learning as a diagnostic method in the early stages of the pandemic, have been assigned great importance during the pandemic. This study aimed to design a highly efficient computer-aided detection system for COVID-19 by using a neural search architecture network (NASNet)-based algorithm.

Résumé

En raison de la pandémie de COVID-19 et de l'effondrement imminent des systèmes de santé suite à l'épuisement des ressources financières, hospitalières et médicales, l'Organisation mondiale de la santé a fait passer le niveau d'alerte de la pandémie de COVID-19 d'élevé à très élevé. Pendant ce temps, des méthodes de détection COVID-19 plus rentables et plus précises sont préférées dans le monde entier.

Les méthodes de détection du COVID-19 basées sur la vision artificielle, en particulier l'apprentissage en profondeur en tant que méthode de diagnostic dans les premiers stades de la pandémie, ont reçu une grande importance pendant la pandémie. Cette étude visait à concevoir un système de détection assistée par ordinateur très efficace pour COVID-19 en utilisant un algorithme basé sur un réseau d'architecture de recherche neuronale (NASNet).

ملخص

نظراً لتفشي وباء كوفيد19 والانهيال الوشيك للأنظمة الصحية بعد استنفاد الموارد المالية والاستشفائية والطبية، رفعت منظمة الصحة العالمية مستوى التحذير من الجائحة كوفيد19 من مرتفع إلى مرتفع للغاية كما اصبح الطاقم الطبي يبحث عن طرق اكثر نجاعة للكشف عن الفيروس

حظيت طرق الكشف عن كوفيد19 القائمة على الرؤية الآلية ، وخاصة التعلم العميق كطريقة تشخيصية في المراحل المبكرة من الوباء بأهمية كبيرة. هدفت هذه الدراسة إلى تصميم نظام كشف عالي الكفاءة بمساعدة الكمبيوتر للكشف عن كوفيد19

Sommaire

Remerciements.....	I
Dédicace	II
Résumé.....	IV
Liste des figures	VIII
Introduction générale	1
Chapitre 01 : Corona virus.....	4
I. Qu'est-ce-que le Corona virus & covid-19	5
II. Les coronavirus humains	5
III. L'origine du coronavirus humain	5
IV. Coronavirus	6
V. Covid-19	6
Chapitre 02 : imagerie médicale.....	8
Introduction	9
Historique	9
I. Qu'est-ce qu'une image	10
II. Définition de l'imagerie médicale	10
III. Types d'imagerie médicale	11
IV. But de l'imagerie médicale	13
Chapitre 03: les Ct-scan et méthodes proposé.....	14
Introduction	15
I. Utilité des Ct-scan	16
II. Entre CT scan et la radiologie	18
III. But de cette étude.....	20
Chapitre 04: apprentissage automatique et apprentissage profond.....	22
Introduction	23
I. L'apprentissage automatique Machine Learning	23
A. Apprentissage supervisé	24
B. Classification non paramétrique.....	30
C. L'apprentissage par renforcement.....	31
II. De l'apprentissage automatique à l'apprentissage en profondeur.....	32
A. Apprentissage profond vs méthodes classique	33

B. Les architectures d'apprentissage en profondeur	35
III. Le problème de sur-apprentissage et sous-apprentissage	40
Chapitre 05 : implémentation et tests	43
Introduction	43
I. Notion importante sur le modèle	43
A. La normalisation des données.....	43
B. L'augmentation de donnée.....	43
C. L'apprentissage par transfert.....	44
D. Neural Architecture Search NASNet.....	47
E. ImageNet.....	47
F. Paramètre clé du modèle.....	48
II. Les outils et les détails d'implémentation.....	49
A. Langage de programmation et Framework.....	50
B. Corpusse et Dataset	54
C. Prétraitement des données	55
III. Evaluation des performances	63
IV. Conclusion	67

Liste des figures

Chapitre 01

Figure 1: origine du coronavirus.....	5
Figure 2: shema coronavirus.....	6
Figure3: cas covid dans le monde.....	7

Chapitre 02

Figure4, figure5: la radioactivité.....	9
Figure6: type d'imagerie médicale	11

Chapitre 03

Figure 7 : scanner image	19
--------------------------------	----

Chapitre 04

Figure 8 apprentissages supervisés	26
Figure 9 apprentissages par renforcement.....	33

Chapitre 05

Figure 10 : image net	50
Figure 11 : python.....	53
Figure 12 : anaconda	54
Figure13 : jupyter.....	54
Figure 14 : tensorflow	56
Figure 15 : keras	56
Figure 16 : données covid19 sous forme d'image	57
Figure 17 : représentation de données cas covid-19 et non-covid	60
Figure 18 : resultat du premier entrainement	64
Figure 19 : evaluation des performances.....	68

Introduction générale :

Depuis décembre 2019, un certain nombre de cas de « pneumonie virale inconnue » liés à un marché de gros de fruits de mer local ont été signalés dans la ville de Wuhan, province du Hubei, Chine. Un nouveau coronavirus (SARS-CoV-2) a été suspecté d'être l'étiologie avec la chauve-souris *Phinolophus* comme origine présumée. En seulement deux mois, le virus s'est propagé de Wuhan à toute la Chine et à 33 autres pays. Le 24 février à minuit, 77 658 cas confirmés cumulés avec 9 126 cas graves et 2 663 décès étaient documentés en Chine, et 2 309 cas confirmés avec 33 décès ont été signalés dans d'autres pays (dont le Japon, la Corée, l'Italie, Singapour, l'Iran comme les cinq premiers pays). Le 11 février à minuit, un total de 1 716 cas confirmés et 1 303 cas de personnel médical diagnostiqués cliniquement ont été signalés dans 422 établissements médicaux, dont 5 sont décédés, ce qui représente 0,4% des décès à l'échelle nationale au cours de la même période.

En l'absence de médicaments thérapeutiques ou de vaccins spécifiques pour la nouvelle maladie à coronavirus 2019 (COVID-19), il est essentiel de détecter les maladies à un stade précoce et d'isoler immédiatement la personne infectée de la population saine. Le diagnostic de COVID-19 doit être confirmé par la transcription inverse de l'amplification en chaîne par polymérase (RT-PCR) ou le séquençage de gènes pour des prélèvements respiratoires ou sanguins, comme indicateur clé d'hospitalisation. Cependant, compte tenu des limites de la collecte et du transport des échantillons et des performances du kit, le taux de positivité totale de la RT-PCR pour les échantillons de prélèvement de gorge était d'environ 30 à 60 % lors de la présentation initiale. Dans l'urgence actuelle, la faible sensibilité de la RT-PCR implique que de nombreux patients COVID-19 peuvent ne pas être identifiés et ne pas recevoir un traitement approprié à temps ; ces patients constituent un risque d'infection d'une population plus large étant donné la nature hautement contagieuse du virus.

Avec le niveau d'alerte le plus élevé au monde. Selon les statistiques de "WorldMeters", jusqu'au 5 janvier 2021, plus de 86 millions de personnes dans le monde ont contracté cette maladie, avec plus de 1 870 000 décès confirmés dus au COVID-19. La détection précoce du COVID-19 est essentielle non seulement pour les soins aux patients mais aussi pour la santé publique en assurant l'isolement des patients et en contrôlant la propagation de la maladie. La première et la plus importante étape pour contrôler cette pandémie est la détection rapide des patients infectés et le suivi des cas positifs. Diverses méthodes de diagnostic pour la détection rapide du COVID-19 ont été introduites par différentes études et par l'OMS, le test de transcription inverse-amplification en chaîne par polymérase (RT-PCR) étant la méthode de diagnostic la plus répandue. Bien que la RT-PCR soit l'étalon-or pour la détection du COVID-19, en raison de son temps et de son coût élevé, les personnes infectées, en tant que source de transmission, peuvent transmettre le virus à de nombreuses personnes en attendant de recevoir les résultats de leur Test RT-PCR. De plus, des études antérieures ont rapporté que le test RT-PCR a un taux élevé de faux négatifs ; ceci est une limitation majeure de ce test diagnostique et réduit sa sensibilité. De plus, cela entraîne un retard de détection, de traitement et, aux stades avancés de la maladie, une augmentation du taux de mortalité. Un afflux élevé de patients dans les centres de diagnostic pendant la pandémie a entraîné une utilisation excessive des ressources et une pénurie de kits de test RT-PCR. Indépendamment du besoin de tests RT-PCR pour les individus suspects, les multiples répétitions de ces tests pour les patients ont imposé un lourd fardeau aux sources de soins de santé. La nature chronophage des tests de laboratoire, associée à la nature moléculaire et non spécifique des tests sérologiques, a nécessité l'utilisation d'un test moins cher axé sur les résultats dans le tissu pulmonaire. En tant qu'outils majeurs de surveillance de la santé pulmonaire, les tests radiologiques ont attiré l'attention des cliniciens spécialistes. Pour l'évaluation COVID-19, la tomodensitométrie (CT) est une méthode de détection plus sensible et spécifique que l'imagerie par rayons X du thorax, et, dans de nombreux cas, l'atteinte pulmonaire et les opacités en verre dépoli (GGO) peuvent être visualisées sur CT avant même la l'apparition des symptômes cliniques et avant d'obtenir des résultats

positifs sur un test RT-PCR. Cela implique que, dans de nombreux cas, avant l'émergence des premiers symptômes cliniques et un résultat positif de RT-PCR, les complications de COVID-19 peuvent être détectées dans les poumons. Sur la base des rapports précédents et des recommandations de l'OMS, la tomodensitométrie thoracique est devenue un outil précieux pour la détection précoce et le triage des personnes suspectées de COVID-19 . Dans une étude portant sur des patients atteints de COVID-19, la TDM a permis une détection plus sensible que la RT-PCR . Malgré le succès de cette modalité radiologique dans la détection des lésions pulmonaires liées au COVID-19, certains problèmes sont associés à son utilisation. Malgré les recommandations de l'OMS, les résultats du scanner thoracique sont normaux chez certains patients au début de la maladie, ce qui confère une valeur prédictive négative au scanner seul. La faible spécificité de la TDM peut dissuader la détection de la maladie dans les cas non COVID-19. De plus, les rayonnements ionisants émis par le scanner peuvent causer des problèmes aux patients qui nécessitent plusieurs tomodensitogrammes au cours de leur maladie. Au cours de la dernière décennie, de nombreuses méthodes informatiques ont été utilisées pour améliorer l'efficacité des techniques d'imagerie médicale. L'une de ces méthodes est l'utilisation d'algorithmes d'apprentissage automatique, qui a connu un succès remarquable en imagerie médicale. Parmi les différents types de méthodes d'apprentissage automatique, les modèles d'apprentissage en profondeur ont atteint une haute précision dans les tâches de vision artificielle rapidement après l'émergence de COVID-19. Les réseaux de neurones convolutifs (CNN) ont un potentiel élevé pour l'extraction et l'analyse de caractéristiques. Lors de l'émergence de COVID-19, et en raison des limites des tests de diagnostic, de nombreuses techniques d'apprentissage automatique ont été adoptées pour améliorer la précision des méthodes de diagnostic.

CHAPITRE 01 :

CORONAVIRUS

I. Qu'est-ce que le Coronavirus & COVID-19 :

Les coronavirus sont une grande famille de virus, certains provoquent des maladies chez les humains et d'autres chez les animaux, comme les chauves-souris, les chameaux et les civettes.

II. Les coronavirus humains :

- Provoquent des maladies bénignes, comme le rhume.
- Le syndrome respiratoire aigu sévère (SRAS) est une maladie respiratoire virale causée par un coronavirus, appelé coronavirus associé au SRAS (SARS-CoV).
- Les coronavirus précédents ont inclus le SRAS-CoV et le MERS-CoV.
- Le coronavirus 2 du syndrome respiratoire aigu sévère (SARS-CoV-2) est une nouvelle souche de coronavirus qui n'a pas encore été identifiée chez l'homme.

III. Origines du coronavirus humain :

Les réservoirs écologiques les plus probables pour les coronavirus sont les chauves-souris, mais on pense que le virus a franchi la barrière des espèces pour l'homme à partir d'un autre hôte animal intermédiaire.

Cet animal hôte intermédiaire pourrait être un animal domestique pour alimentation humaine, un animal sauvage ou un animal sauvage domestiqué qui n'a pas encore été identifié (figure 1).

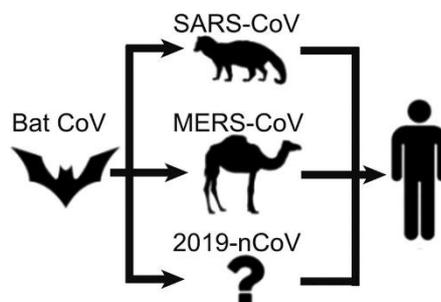


Figure 1

IV. Coronavirus :

- Les coronavirus appartiennent à la famille des Coronaviridae dans l'ordre des Nidovirales.
- Corona représente des pointes en forme de couronne sur la surface externe du virus; ainsi, il a été nommé coronavirus.
- Les coronavirus sont des virus enveloppés, de taille minuscule (65-125 nm de diamètre) et contiennent un ARN simple brin en tant que matériel nucléaire, d'une taille allant de 26 à 32 kb de longueur.

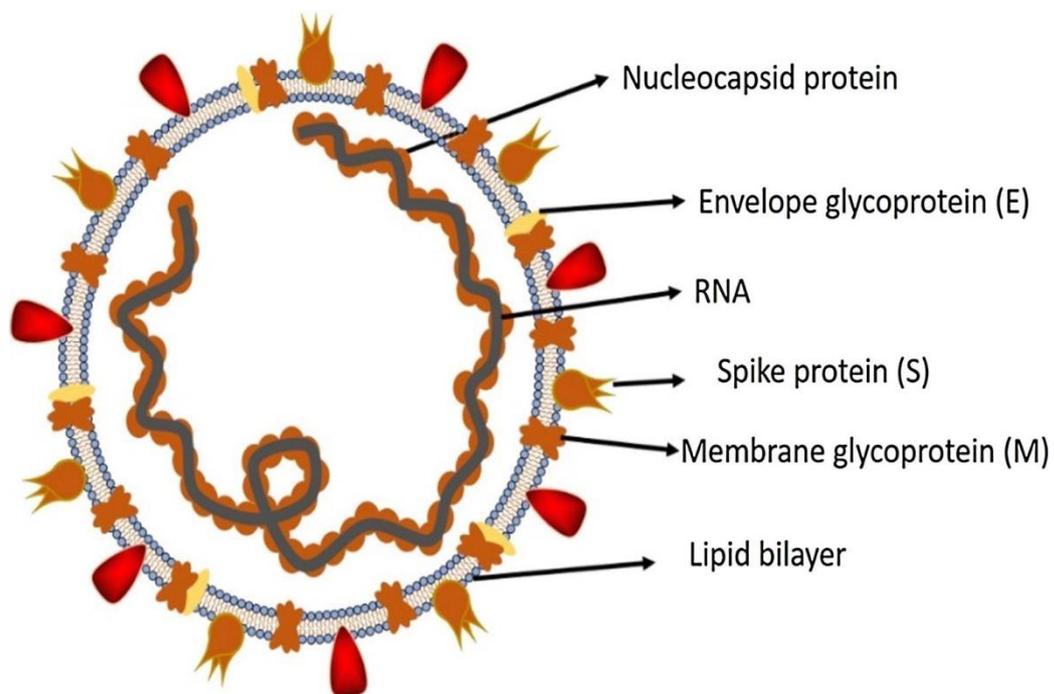


Figure 2

V. COVID 19 :

Le virus qui cause le COVID-19 est connu sous le nom de SARS-CoV-2. Il semble être apparu pour la première fois à Wuhan, en Chine, fin 2019.

L'épidémie s'est depuis propagée à travers la Chine à d'autres pays du monde. Fin janvier, le nouveau coronavirus avait été déclaré urgence de santé publique de portée internationale par l'OMS.

Les symptômes les plus fréquemment rapportés sont la fièvre, la toux sèche et la fatigue.

- Dans les cas bénins : les personnes peuvent avoir juste le nez qui coule ou un mal de gorge.
- Dans les cas les plus graves : les personnes atteintes du virus peuvent développer des difficultés respiratoires et peuvent finalement subir une défaillance organique. Certains cas sont mortels.

COVID-19 dans le monde 29 juin 2020

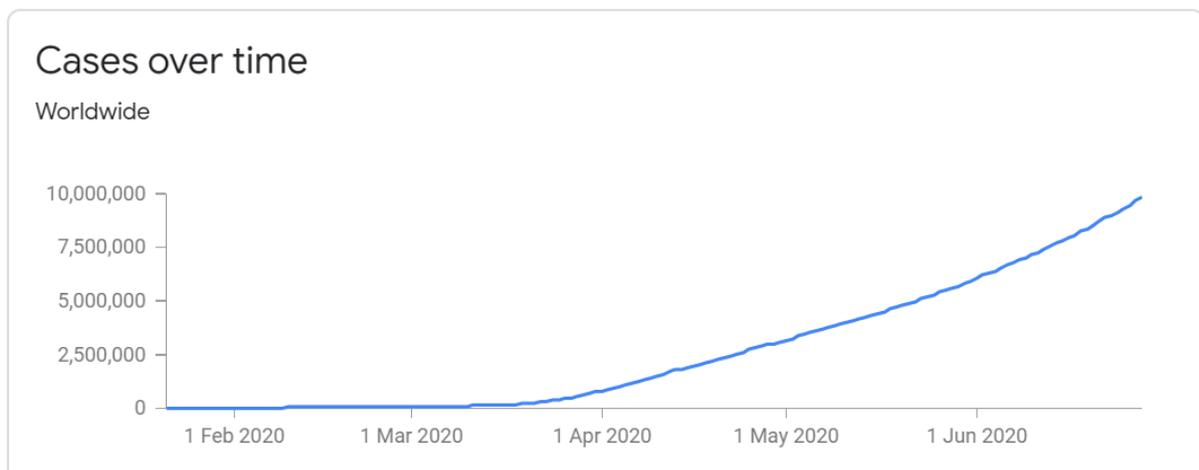


Figure 3

CHAPITRE 02 :

L'imagerie médicale

INTRODUCTION :

L'imagerie médicale a fait son apparition avec la découverte des rayons X. Depuis, l'imagerie médicale n'a cessé d'évoluer, de se perfectionner et de proposer des technologies de plus en plus précises, performantes et novatrices. La médecine moderne et la médecine de demain sont impensables sans l'imagerie biomédicale du fait de son rôle qui est central tant au niveau du diagnostic par les progrès continus des systèmes d'acquisition et d'interprétation que sur le plan thérapeutique.

La fabrication de l'image est le résultat d'un processus impliquant la physique, les mathématiques, la biologie et l'informatique.

Historique:

Une histoire qui a plus de cent ans

Le 8 novembre 1895 en fin d'après-midi Wilhelm Conrad Röntgen fait la découverte qui mènera à la description des rayons X.

La radioactivité Une autre découverte fondamentale qui aura des conséquences majeures en Imagerie Médicale (et en Radiothérapie) est celle de la radioactivité.

Pierre et Marie Curie ont décrit les effets de la radioactivité sur les organismes vivants; ces expériences ont rapidement mené à la description des effets nocifs mais aussi des possibilités d'utilisation thérapeutique.

Plusieurs pionniers de la radiologie (qui étaient également radiothérapeutes) furent, en particulier aux Etats-Unis, des ingénieurs ou photographes qui ont étudié la médecine dans un second temps afin d'acquérir les compétences nécessaires à l'exercice de la radiologie.

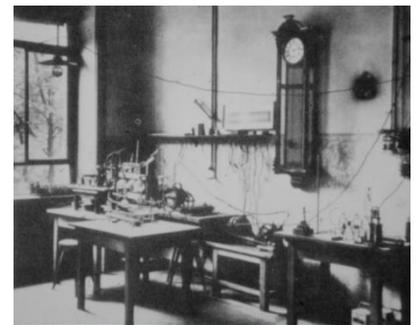


Figure 4

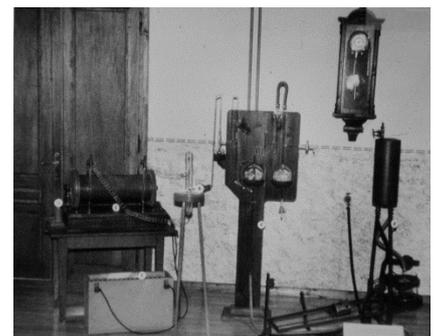


Figure 5

I. Qu'est-ce qu'une image?

Image = reflet de la réalité J'appelle image d'abord les ombres ensuite les reflets qu'on voit dans les eaux, ou à la surface des corps opaques, polis et brillants et toutes les représentations de ce genre (Platon) L'image abolit le temps et l'espace. Elle est lecture instantanée et présence immédiate du monde. À travers elle l'homme se reconnaît ; pourtant sa richesse est ambiguë et son pouvoir d'aliénation extrême. L'image sert de vérité. Elle s'offre à tous et se refuse à chacun.

Si nous regardons la définition de l'image et de l'imagerie dans le dictionnaire Larousse nous voyons: • Image: "représentation" (par une technique) "d'un être ou d'une chose..." • Imagerie: "ensemble d'images représentant des faits, des personnes, etc..."

II. Définition de l'imagerie médicale :

L'Imagerie Médicale est la discipline médicale mettant en oeuvre les moyens actuels pour observer sur le vivant les manifestations internes de la maladie en utilisant des sources de rayonnement (pas nécessairement ionisant), externes ou internalisées.

Les images produites par les techniques d'Imagerie Médicale doivent donner lieu à une double interprétation: elles doivent être décodées en fonction de la technique utilisée et interprétées ensuite en fonction de la situation clinique du malade pour finalement fournir un diagnostic, un élément du diagnostic, ou une évaluation de la situation actuelle de la maladie.

Le terme "imagerie médicale" remplace aujourd'hui les appellations "radiologie" ou "radiodiagnostic".

C'est l'ensemble des techniques et moyen qui permettant l'acquisition et la restitution des images interne du corps humain.

III. Types d'imagerie médicale :

Un service d'imagerie de nos jours est constitué d'une multitude de modalités allant de la radiologie conventionnelle au scanner IRM passant par les échographe et la mammographie et bien d'autre modalité produisant une quantité importante d'image médicale , ces dispositifs médicaux de plus en plus complexe permettant l'accès aux profondeurs du corps humain souvent d'une façon non invasive introduisant ainsi la possibilité de décrire une VEVO via les images du corps humain ce qui a permis des progrès éblouissant dans le domaine de la clinique depuis le diagnostic jusqu'au traitement :

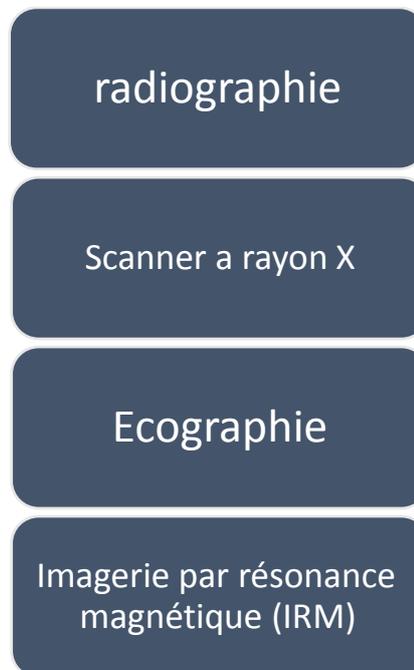


Figure 6

- **Radiographie** : La radiographie repose sur l'utilisation des rayons X. Le faisceau est émis à partir d'une source (un tube) fixe et non rotatif comme pour le scanner. Les rayons sont plus ou moins absorbés par les tissus – en fonction de la densité de ces derniers – avant d'être recueillis sur une pellicule

photosensible placée derrière le patient. Sur le cliché, les rayons X laissent une trace plus ou moins opaque, selon la densité des tissus traversés.

- **Scanner a rayon X** : Le scanner, mis au point en 1972, permet de visualiser les organes en 3D, sous forme de coupes. Il utilise lui aussi des rayons X émis pas un tube qui tourne autour du patient ; une succession d'images du corps sont prises à 360° grâce à des capteurs situés de part et d'autre du patient et qui mesurent l'absorption des tissus.

Le scanner permet par exemple de suivre l'évolution d'une hémorragie, d'une tumeur...

- **Ecographie** : échographie permet de visualiser les organes situés au niveau de l'abdomen, du petit bassin, du cou (thyroïde, ganglions, foie, rate, pancréas, reins, vessie, organes génitaux) mais aussi les vaisseaux (artères et veines), les ligaments et le cœur. Elle a pour objectif de détecter une infection, une malformation ou une tumeur.

- **Imagerie par résonance magnétique (IRM)** :

L'IRM (imagerie à résonance magnétique) utilise la propriété qu'ont les noyaux de certains atomes d'émettre des signaux quand ils sont soumis à un champ magnétique et une impulsion de radiofréquence particulière. Le patient est placé dans un tunnel, comme pour un scanner, mais l'IRM dure généralement plus longtemps. Les images sont présentées sous forme de coupes. L'IRM présente une très bonne résolution en contraste ; elle est utilisée pour visualiser de nombreux organes différents (cœur, foie...), en particulier le cerveau. L'IRM fonctionnelle est un outil pour étudier l'activité du cerveau.

Pour toutes ces techniques, des produits de contraste peuvent être employés pour mieux voir certains organes.

IV. But de l'imagerie médicale :

L'imagerie médicale a profondément influencé à la fois la recherche médicale et la pratique clinique. Elle est aujourd'hui incontournable aussi bien pour l'établissement du diagnostic que pour la mise en place et le suivi d'un traitement thérapeutique. Elle fournit un volume croissant de données tridimensionnelles provenant de modalités d'acquisition différentes (IRM, scanner-X, médecine nucléaire, échographie). Ce volume croissant de données rend délicate et laborieuse la tâche d'interprétation par un expert. Le traitement d'images est un outil permettant une automatisation des tâches et va assister l'expert aussi bien dans l'analyse qualitative que quantitative des images.

CHAPITRE 03 :
Les Ct-scan et méthode
proposé

INTRODUCTION :

En temps de pandémie, il est nécessaire d'offrir des outils pour aider les cliniciens à prendre des décisions pour un isolement rapide et un traitement approprié des patients. L'apprentissage en profondeur dans le domaine médical et du diagnostic automatique de différentes maladies et pathologies est une solution rapide pour soutenir le processus de gestion des patients dans des conditions critiques et immédiate.

De nombreuses études ont suggéré l'utilisation de techniques d'apprentissage automatique dans le diagnostic des maladies. Par exemple, certaines études ont utilisé des techniques d'apprentissage en profondeur pour diagnostiquer et différencier la pneumonie bactérienne et virale à l'aide d'images radiographiques pédiatriques thoraciques.

Des efforts considérables ont également été investis dans le diagnostic de diverses caractéristiques d'imagerie par tomodensitométrie thoracique qui sont des caractéristiques de différentes maladies. Divers modèles allant des plus simples aux modèles plus avancés d'apprentissage automatique (apprentissage en profondeur)

Plusieurs techniques basées sur l'apprentissage profond pour la classification des patients, la segmentation ou la quantification des lésions du Covid-19 ont été réalisées. Les méthodes de classification sont souvent binaires. Les modèles sont principalement basés sur des images radiographiques, mais des études suggèrent que les Tomodensitogrammes sont plus fiables que les images radiographiques, pour le diagnostic de Covid-19 Des recherches récentes ont révélé que la sensibilité de la tomodensitométrie pour l'infection au COVID-19 était de 98%.

Les résultats indiquent que :

- la tomodensitométrie thoracique est sensible et spécifique dans le diagnostic de la COVID-19.
- La radiographie thoracique est modérément sensible et modérément spécifique dans le diagnostic de la COVID-19.

- L'échographie est sensible mais non spécifique dans le diagnostic de la COVID-19.

I. Utilité des Ct-scan :

La COVID-19 est une maladie respiratoire. Les cliniciens pourraient utiliser l'imagerie thoracique pour diagnostiquer les personnes qui présentent des symptômes de la COVID-19, en attendant les résultats d'un test RT-PCR ou lorsque les résultats d'un test RT-PCR sont négatifs et que la personne présente des symptômes de la COVID-19.

Avantages et inconvénients du Ct-scan et PCR :

- Le délai d'obtention des résultats PCR, la pénurie de tests disponibles et le nombre limité de laboratoires qualifiés sont autant d'éléments à prendre en considération pour les services d'urgence.
- Le test PCR détecte la présence d'ARN viral et nécessite des machines de traitement de laboratoire complexes pour obtenir des résultats.
- Le test PCR prend généralement un à plusieurs jours pour obtenir des résultats.
- Les personnes asymptomatiques pourraient transmettre le virus à d'autres en attendant les résultats.
- Le coût du test PCR élevé et les résultats lents empêchent l'utilisation du test PCR par une population de masse pour supprimer le taux d'infection.
- Des faux positifs peuvent survenir dans les tests basés sur la PCR.
- C'est dans ce contexte que le CT-scan thoracique (CT) a été proposé comme alternative diagnostique pour identifier les infections à SARS-CoV-2 .
- La tomodensitométrie (TDM) thoracique apporte le meilleur diagnostic pour la pneumonie COVID-19.
- L'analyse des données d'imagerie et de tests de laboratoire de plus de 1.000 patients montre que la TDM thoracique surpasse les tests biologiques dans le diagnostic de l'épidémie associée au nouveau coronavirus, COVID-19.

Une étude a donc regardé la valeur diagnostique et la cohérence de l'imagerie thoracique par rapport au test RT-PCR pour COVID-19.

Des participants ont subi à la fois une TDM thoracique et des tests RT-PCR entre le 6 janvier et le 6 février 2020. Les performances de la TDM thoracique dans le diagnostic de COVID-19 ont été évaluées en regard de la norme de référence actuelle :

la RT-PCR. Pour les participants ayant dû passer plusieurs tests RT-PCR, la conversion dynamique des résultats des tests RT-PCR (négatifs en positifs et positifs en négatifs, respectivement) a également été rapprochée des tomodensitogrammes thoraciques en série. L'analyse de ces données montre que :

- 59% des participants (601) ont obtenu des résultats positifs avec RT-PCR,
- 88% (888) avec la TDM.
- La sensibilité de la TDM thoracique à détecter COVID-19 atteint 97%, sur la base des résultats positifs par RT-PCR ;
- chez les patients « négatifs » via RT-PCR, 75% (308 des 413 patients) sont positifs via TDM thoracique : parmi ces 308 patients, 48% sont considérés comme des cas très probables, dont 33% comme des cas probables ;
- 81% des patients négatifs via RT-PCR mais positifs par TDM thoracique ont été déclassifiés comme cas positifs à COVID-19 très probables ou probables, après analyse complète des symptômes cliniques et des suivis dynamiques par scanner.

La faible sensibilité de la technique RT-PCR implique qu'un grand nombre de patients COVID-19 ne seront pas identifiés rapidement et pourraient ne pas recevoir à temps le traitement approprié. De plus, cette carence de détection -tout comme l'existence de cas asymptomatiques- accroît considérablement le risque de propagation du virus.

Note :

- Le diagnostic précoce de COVID-19 est crucial pour le traitement et le contrôle de la maladie.
- L'imagerie CT thoracique ou scan thoracique peut être une méthode plus fiable, pratique et rapide pour diagnostiquer et évaluer COVID-19, en particulier dans la zone épidémique.
- Cet outil d'imagerie de routine pour le diagnostic de la pneumonie, est rapide et relativement facile à réaliser.

II. Entre Ct scan et la radiologie :

X ray : les rayons X, une forme de rayonnement électromagnétique, traversent le corps humain pour être capturés sur un film spécial situé derrière l'humain. La quantité de pénétration dépend de la force des propriétés des vagues. C'est l'une des techniques d'imagerie les plus courantes. Il est facile à utiliser, relativement bon marché et nécessite moins d'expertise.

Le niveau de rayonnement est relativement faible pour un événement à usage unique.

Cependant les appareils à rayons X ne permettent pas de différencier considérablement la structure et ne donnent généralement pas de détails sur les tissus mous.

Pour observer les différences de densité osseuse, le déficit doit être relativement important. En radiographie, nous ne pouvons voir que l'imagerie antéro-postérieure et latérale ainsi que d'autres vues spécifiques pour des régions spécifiques, mais nous ne pouvons pas voir les coupes transversales du corps en série.

Ct scan :

Les tomodensitogrammes utilisent une version intensifiée des rayons X conjointement avec la technologie informatique. Ici, la force du scanner est environ 500 fois supérieure à celle d'une radiographie pulmonaire. La quantité de pouvoir pénétrant peut être contrôlée très facilement et est également améliorée avec les colorants radios opaques.

Il est très bon pour différencier les masses dures et

relativement bonnes pour discerner les modifications des tissus mous. Ce dispositif est rotatif, le rendant

capable de prendre des vues multi axiales. Cela comporte un risque très élevé de radiation, ainsi que le risque de colorants radio-opaques.

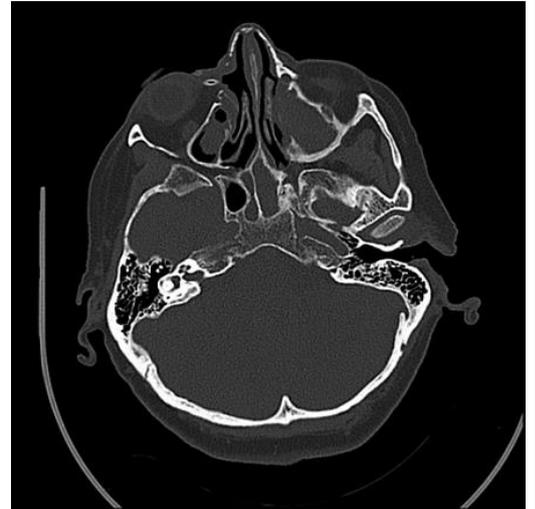


Figure 7

Quelle est la différence entre CT Scan et X-Ray?

La tomodensitométrie et les rayons X sont tous deux utilisés dans l'imagerie de l'intérieur du corps, nécessitant l'utilisation de films spéciaux pour obtenir les photographies. Ils sont également très efficaces pour séparer l'os des tissus mous.

La tomodensitométrie peut très bien différencier les modifications de deux types de masses osseuses et donner une description générale des modifications des tissus mous. Les appareils à rayons X ne peuvent donner qu'une faible différenciation de deux masses dures et n'ont aucune place dans l'élaboration des tissus mous.

Les images radiographiques sont en 2D, tandis que les images tomodensitométriques sont en 3D. La machine de tomodensitométrie tourne sur un axe et prend diverses images 2D du corps d'un individu sous plusieurs angles. Ensuite, l'ordinateur placera toutes les images transversales ensemble sur son

écran, ce qui donnera une image 3D de l'intérieur du corps, révélant la présence d'une blessure ou d'une maladie au médecin.

Tableau de comparaison entre les RAYON X et CT SCAN

RAYON X	CT SCAN
créer des images 2D	créer des images 3D
utilisé principalement pour voir les os et pour détecter les tumeurs et la pneumonie	utilisé principalement pour diagnostiquer les conditions dans les organes et les tissus mous
le plus courant et le plus largement disponible	plus puissant que les rayons X
utiliser radiation pour produire des images	prendre une image à 360 degrés

Sur la base du succès des 'Convolutional Neural Network CNN' dans les tâches de vision artificielle, nous avons conçu et mis en œuvre un modèle pour la classification des images CT d'individus avec et sans COVID-19 via un réseau de neurones profonds basé sur un réseau d'architecture de recherche neuronale (NASNet).

III. But de cette etude:

Pouvoir détecter le COVID-19 chez les patients à un stade précoce de la maladie à partir de plusieurs tomodensitogrammes pulmonaires, un modèle de pointe basé sur un extracteur de caractéristiques NASNet CNN a été proposé. Sur la base du modèle proposé, un système de détection assistée par ordinateur (CAD) a été conçu.

CHAPITRE 04 :

Apprentissage Automatique Et Apprentissage Profond

Introduction :

Actuellement l'informatique est presque présente dans tous les domaines : la santé, l'éducation, l'économie, et la cosmologie. Cette présence se reflète dans la vie quotidienne de l'individu et elle a permis des facilités d'utilisation et de compréhension de plusieurs complexes domaines. Un des domaines les plus importants qui a été touché par ce terrible développement de l'informatique est le domaine de la santé. Le développement de l'informatique et de la technologie continue à prendre une place de plus en plus importante dans le domaine de santé, ce qui a permis le développement du matériel médical, les logiciels de surveillance médicale, et les logiciels d'analyse médicale qui augmentent la précision des résultats. Ce dernier a donné une grande attention par les scientifiques, en particulier les spécialistes dans les domaines : de l'intelligence artificielle, les systèmes experts, l'apprentissage automatique « Machine Learning », et l'apprentissage en profondeur « Deep Learning ». Dans ce chapitre, nous allons d'abord présenter les techniques d'apprentissage automatique « Machine Learning ». Ensuite, nous décrivons comment l'apprentissage automatique a été déplacé vers l'apprentissage profond pour avoir des architectures plus prometteuses. Et enfin, nous discuterons quelques travaux basés sur l'apprentissage automatique « Machine Learning » et l'apprentissage en profondeur « Deep Learning », pour la prédiction du cancer du sein. Nous finissons le chapitre par une conclusion.

I. L'apprentissage automatique « Machine Learning » :

L'intérêt de l'apprentissage automatique a augmenté au cours de la dernière décennie, pour tout le discours sur l'apprentissage automatique, il y a beaucoup de conflits entre ce que la machine peut faire et ce que nous souhaitons. L'apprentissage automatique est un sous-ensemble de l'intelligence artificielle « IA », il est axé sur la création des systèmes qui apprennent et améliorent les performances, en se basant sur des données qu'ils traitent. Les algorithmes

d'apprentissage automatique entrent en jeu pour optimiser, fluidifier, et sécuriser cette dernière.

Définitions et types d'apprentissage automatique :

Définitions :

La définition de l'apprentissage automatique a connu une progression durant plusieurs années, cela est dû qu'à chaque fois il y avait de nouvelles découvertes dans ce domaine :

- Le terme « Apprentissage automatique » a été inventé par l'informaticien Américain « Arthur Samuel », dans le début de l'année 1959. Il a créé le premier programme qui permet aux ordinateurs de jouer et d'apprendre le jeu de dames sans être explicitement programmé.
- En 1997, l'informaticien américain « Tom Michael Mitchell » introduit une nouvelle définition de l'apprentissage automatique. Il a considéré qu'un programme apprend d'une expérience E , par rapport à une classe de tâches T , et avec une mesure de performance P .
- Avec le temps, la définition de l'apprentissage automatique a commencé à prendre une dimension mathématique et statistique. l'apprentissage automatique est essentiellement une forme de statistiques appliquées, mettant davantage l'accent sur l'utilisation d'ordinateurs pour estimer statistiquement les fonctions compliquées et un accent moindre sur la démonstration des intervalles de confiance autour de ces fonctions.
- Ces définitions peuvent varier en fonction de l'angle étudié, mais elles sont toutes orientées vers une seule direction, qui est définie comme suit : l'apprentissage automatique est la science ou l'art de la programmation des ordinateurs afin qu'ils puissent apprendre des données.

Types d'apprentissage automatique :

Il existe également de différents types d'apprentissage automatique. la définition du type d'apprentissage est basée sur la réponse à ces deux questions suivantes :

CHAPITRE 04 : APPRENTISSAGE AUTOMATIQUE ET APPRENTISSAGE PROFOND

- Est-ce que cet apprentissage compte sur la supervision humaine dans son entraînement et apprentissage ?
- Est-ce que ce type cet apprentissage utilise une base de données fournie par l'être humain ?
 - 1) Si la réponse est oui pour les deux questions, nous avons un apprentissage supervisé.
 - 2) Si la réponse est non pour la première question, et oui pour la deuxième question, nous parlons d'un apprentissage non supervisé.
 - 3) Si la réponse est non pour les deux questions, le type de l'apprentissage est l'apprentissage par renforcement.

Dans ce qui suit, nous définissons chacun de ces types : apprentissage supervisé, apprentissage non supervisé, et apprentissage par renforcement.

A. Apprentissage supervisé :

Dans l'apprentissage supervisé l'être humain aide l'algorithme pour apprendre, un data scientist sert de guide et il apprend l'algorithme les résultats qu'il doit trouver. Le même cas lorsqu'on apprend un enfant pour identifier les fruits, en les mémorisant dans sa mémoire. Dans l'apprentissage supervisé, l'algorithme apprend grâce à un jeu de données déjà étiqueté et dont le résultat est prédéfini.

Les algorithmes de l'apprentissage automatique supervisé sont les plus couramment utilisés, il y a deux types d'apprentissage supervisé :

- ✓ **La classification** : la classification consiste à trouver le lien entre une variable d'entrée (X) et une variable de sortie discrète (Y), en suivant une loi multinomiale.
- ✓ **La Régression** : la régression consiste à prédire une valeur continue pour la variable de sortie.

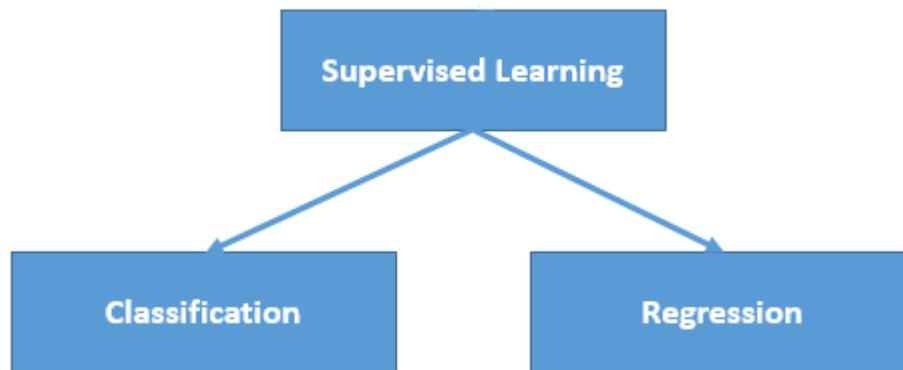


Figure 8

Les techniques de classification peuvent être catégorisées en deux catégories (paramétrique et non-paramétrique)

a) Classificateur paramétrique :

Les hypothèses peuvent grandement simplifier le processus d'apprentissage, mais peuvent également limiter ce qui peut être appris. Les algorithmes qui simplifient la fonction sous une forme connue sont appelés algorithmes d'apprentissage automatique paramétriques. Un modèle d'apprentissage qui résume les données avec un ensemble de paramètres de taille fixe (indépendamment du nombre d'exemples d'apprentissage) est appelé un modèle paramétrique. Quelle que soit la quantité de données que vous fournissez à un modèle paramétrique, il ne changera pas d'avis sur le nombre de paramètres dont il a besoin.

Les algorithmes impliquent deux étapes :

- 1) Sélectionner un formulaire pour la fonction.
- 2) Apprendre les coefficients de la fonction à partir des données d'entraînée.

Une forme fonctionnelle facile à comprendre pour la fonction de mappage est une ligne, comme elle est utilisée dans la régression linéaire :

$$b_0 + b_1 * x_1 + b_2 * x_2 = 0$$

Où b_0 , b_1 et b_2 sont les coefficients de la ligne qui contrôlent l'intersection et la pente, et x_1 et x_2 sont deux variables d'entrée.

Prendre la forme fonctionnelle d'une ligne simplifie grandement le processus d'apprentissage. Il ne nous reste plus qu'à estimer les coefficients de l'équation linéaire et nous avons un modèle prédictif du problème.

➤ **Avantages des algorithmes d'apprentissage automatique**

paramétriques :

- Plus simple : ces méthodes sont plus faciles à comprendre et à interpréter les résultats.
- Vitesse : les modèles paramétriques sont très rapides à apprendre à partir des données.
- Moins de données : ils ne nécessitent pas autant de données d'entraînement et peuvent bien fonctionner même si l'ajustement aux données n'est pas parfait.

➤ **Limitations des algorithmes d'apprentissage automatique**

paramétriques :

- Contrainte : en choisissant une forme fonctionnelle, ces méthodes sont fortement contraintes à la forme spécifiée.
- Complexité limitée : les méthodes sont plus adaptées à des problèmes plus simples.
- Mauvais ajustement : en pratique, il est peu probable que les méthodes correspondent à la fonction de mappage sous-jacente.

b) Classificateur non-paramétrique :

Les algorithmes qui ne font pas d'hypothèses solides sur la forme de la fonction de mappage sont appelés algorithmes d'apprentissage automatique non paramétriques. En ne faisant pas d'hypothèses, ils sont libres d'apprendre n'importe quelle forme fonctionnelle à partir des données d'entraînement. Les méthodes non paramétriques sont utiles lorsque l'on a beaucoup de données et aucune connaissance préalable, et que l'on ne voudrait pas trop se soucier de choisir les bonnes fonctionnalités.

CHAPITRE 04 : APPRENTISSAGE AUTOMATIQUE ET APPRENTISSAGE PROFOND

Les méthodes non paramétriques cherchent à mieux adapter les données d'apprentissage lors de la construction de la fonction de mappage, tout en conservant une certaine capacité à généraliser aux données invisibles.

En tant que tels, ils sont capables de s'adapter à un grand nombre de formes fonctionnelles.

Un modèle non paramétrique facile à comprendre est l'algorithme des k plus proches voisins qui effectue des prédictions basées sur les k modèles d'apprentissage les plus similaires pour une nouvelle instance de données. La méthode ne suppose rien sur la forme de la fonction de mappage autre que les modèles qui sont proches sont susceptibles d'avoir une variable de sortie similaire.

Voici quelques autres exemples d'algorithmes d'apprentissage automatique non paramétriques populaires :

- K-Voisins les plus proches
- Arbres de décision comme CART et C4.5
- SVM

➤ Avantages des algorithmes d'apprentissage automatique non paramétriques :

- Flexibilité : Capable de s'adapter à un grand nombre de formes fonctionnelles.
- Puissance : Aucune hypothèse (ou hypothèses faibles) sur la fonction sous-jacente.
- Performances : peut entraîner des modèles de prédiction plus performants.

➤ Limitations des algorithmes d'apprentissage automatique non paramétriques:

- Plus de données : nécessite beaucoup plus de données d'entraînement pour estimer la fonction de cartographie.
- Plus lent : beaucoup plus lent à s'entraîner car ils ont souvent beaucoup plus de paramètres à entraîner.

CHAPITRE 04 : APPRENTISSAGE AUTOMATIQUE ET APPRENTISSAGE PROFOND

- Sur-ajustement : il y a plus de risque de sur-ajustement des données d'entraînement et il est plus difficile d'expliquer pourquoi des prédictions spécifiques sont faites.
- **La régression logistique :**

Est un algorithme de classification utilisé pour affecter des observations à un ensemble discret de classes. Certains des exemples de problèmes de classification sont le spam par courrier électronique, la fraude ou non aux transactions en ligne, la tumeur maligne ou bénigne. La régression logistique transforme sa sortie à l'aide de la fonction logistique sigmoïde pour renvoyer une valeur de probabilité.

Nous pouvons appeler une régression logistique un modèle de régression linéaire mais la régression logistique utilise une fonction de coût plus complexe, cette fonction de coût peut être définie comme la « fonction sigmoïde » ou également connue sous le nom de « fonction logistique » au lieu d'une fonction linéaire. L'hypothèse de régression logistique tend à limiter la fonction de coût entre 0 et 1. Par conséquent, les fonctions linéaires ne parviennent pas à le représenter car il peut avoir une valeur supérieure à 1 ou inférieure à 0, ce qui n'est pas possible selon l'hypothèse de la régression logistique.

- **SVM**

(Machines à vecteurs de support) : est un apprentissage automatique très puissant et polyvalent modèle, capable d'effectuer la classification linéaire ou non linéaire, la régression, et même détection des valeurs aberrantes. C'est l'un des modèles les plus populaires de l'apprentissage automatique « Machine Learning », et n'importe qui intéressés par cette approche devraient l'avoir dans leur boîte à outils. Les SVM sont particulièrement bien adaptés à la classification d'ensembles de données complexes mais de petite ou moyenne taille. L'algorithme SVM consiste à chercher à la fois l'hyperplan optimal ainsi que de minimiser les erreurs de classification.

- **La méthode des k plus proches voisins :**

CHAPITRE 04 : APPRENTISSAGE AUTOMATIQUE ET APPRENTISSAGE PROFOND

Cet algorithme consiste à essayer différentes valeurs de K pour obtenir la séparation la plus satisfaisante.

- **Naïve Bayes :**

Est un classifieur assez intuitif à comprendre. Il se base sur le théorème de Bayes des probabilités conditionnelles, et il suppose que les variables sont indépendantes entre elles. Cela permet de simplifier le calcul des probabilités.

- **Les arbres de décision :**

Un arbre de décision sert à classer les futures observations, sachant qu'un corpus d'observations est déjà étiqueté.

- **Les Forêts Aléatoires :**

Cet algorithme fonde sur les arbres de décision, un modèle construit par de multiples arbres de décisions.

- **Régression Logistique :**

L'algorithme de régression logistique consiste à trouver les meilleurs coefficients pour minimiser l'erreur entre la prédiction faite pour des destinations visitées et la vraie étiquette donnée (e.g. bon, mauvais etc.).

- **Les réseaux de neurones :**

Les réseaux neuronaux sont un modèle informatique qui partage certaines propriétés avec le cerveau humain, dans lequel de nombreuses unités simples travaillent en parallèle sans centralisation, ils permettent de trouver des patterns complexes dans les données, il se compose de valeurs d'entrées, poids, fonction de transfert et une valeur de sortie.

B. Apprentissage non supervisé

Avec l'apprentissage non supervisé la machine n'a pas besoin de l'aide pour apprendre. L'apprentissage non supervisé est une approche plus indépendante, dans laquelle un ordinateur apprend à identifier des processus et des schémas

CHAPITRE 04 : APPRENTISSAGE AUTOMATIQUE ET APPRENTISSAGE PROFOND

complexes sans aucun guide, Il implique une formation basée sur des données sans étiquette, qui ne contiennent aucun résultat spécifique.

il y a deux types d'apprentissage non supervisé :

- **Regroupement (Clustering)** : c'est une méthode d'analyse statistique utilisée pour organiser des données brutes en silos homogènes, à l'intérieur de chaque grappe, les données sont regroupées selon une caractéristique commune.
- **Réduction de la dimension** : l'objectif est de simplifier les données sans perdre trop d'informations, à titre d'exemple, fusionner plusieurs caractéristiques en un seul caractère.

Les algorithmes les plus célèbres utilisés dans cette approche sont :

- **K-Moyenne** : est un algorithme de Regroupement (Clustering) il regroupe dans les même Cluster (Groupes) les données similaires (qui se ressemblent). Il utilise un raffinement itératif pour produire un résultat final.
- **Analyse de classification hiérarchique (HCA)** : la mise dans un cluster hiérarchique est similaire à la mise dans un cluster normal, sauf que dans ce cas nous souhaitons mettre en place une hiérarchie des clusters.
Cela peut s'avérer très important surtout quand nous désirons une flexibilité par rapport au nombre de clusters voulu.
- **PCA (Analyse des composants principaux)** : l'algorithme PCA consiste à transformer des variables liées entre elles, vers de nouvelles variables séparées les uns des autres. Ces nouvelles variables sont nommées les composantes principales, elles permettent au praticien de réduire le nombre de variables et de rendre l'information moins redondante.

C. L'apprentissage par renforcement :

Avec l'apprentissage par renforcement la machine n'a pas besoin de l'aide de l'être humain, ni en termes de supervision, ni en termes de fourniture de données.

CHAPITRE 04 : APPRENTISSAGE AUTOMATIQUE ET APPRENTISSAGE PROFOND

L'apprentissage par renforcement est une branche très différente. Le système d'apprentissage, appelé un agent dans ce contexte, peut observer l'environnement, sélectionner et effectuer des actions, et enfin obtenir des récompenses ou des pénalités (des récompenses négatives). La machine peut apprendre toute seule la meilleure stratégie à suivre, appelée une politique, pour obtenir plusieurs récompenses au fil du temps. Une politique définit l'action que l'agent devrait choisir lorsqu'il est dans une situation donnée

Parmi les premiers algorithmes d'apprentissage par renforcement, c'est l'algorithme « Temporal différence Learning », proposé par « Richard Sutton » en 1988 (Sutton, 1988). Aussi l'algorithme « Q-Learning » mis au point lors d'une thèse soutenue par « Chris Watkins » en 1989 et publié réellement en 1992 (Watkins & Dayan, 1992).

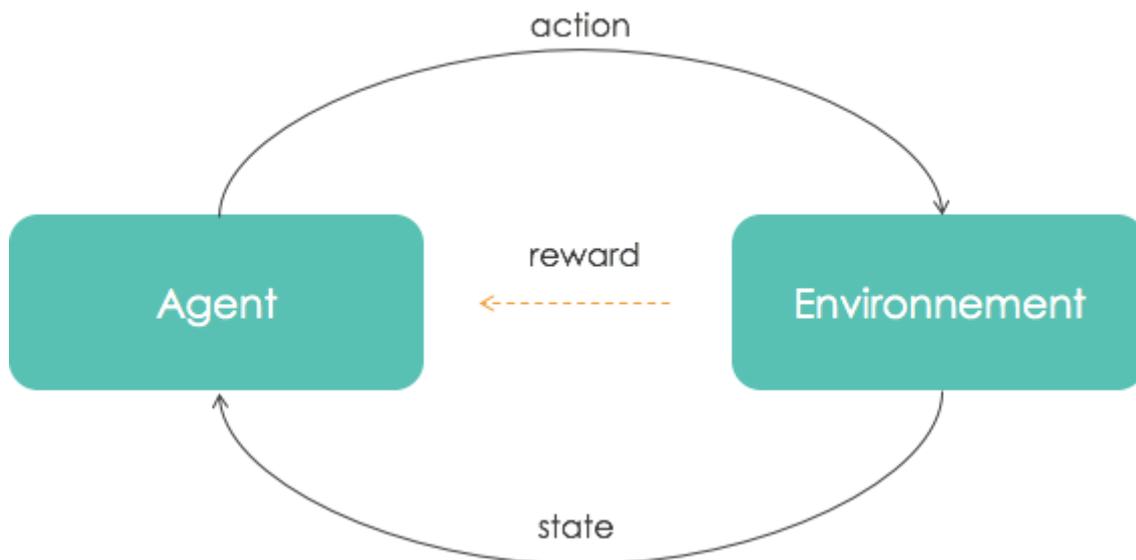


Figure 9

Le choix d'un type d'apprentissage automatique

Avec la présence de différents types de classifieurs pour l'apprentissage automatique, l'opération de choix d'un type est une question typique « Quel algorithme dois-je utiliser ? ». La réponse à cette question varie les facteurs suivants :

- ✓ La taille, la qualité et la nature des données.
- ✓ Le temps de calcul disponible.

- ✓ L'urgence de la tâche.
- ✓ Le but d'utilisation de ces données est fournir des indications sur les algorithmes à essayer en premier selon les facteurs mentionnés ci-dessus.

II. De l'apprentissage automatique à l'apprentissage en profondeur :

Nous ne pouvons pas différer sur l'efficacité de l'apprentissage automatique dans la résolution d'une variété de problèmes, mais il y a beaucoup de problèmes que ce type fait face, dont les plus importants sont le temps, la vitesse et l'efficacité, si un algorithme d'apprentissage automatique renvoie une prédiction inexacte, alors un ingénieur doit intervenir et faire des ajustements, dans ce cas, il y a un manque d'efficacité qui sera une perte de temps avec une prévision lente. Les algorithmes simples d'apprentissage automatique décrits dans ce chapitre fonctionnent très bien sur une grande variété de problèmes importants. Cependant, ils n'ont pas réussi à résoudre les problèmes centraux de l'intelligence artificielle, tels que la reconnaissance de la parole ou la reconnaissance d'objets. Le développement de l'apprentissage en profondeur a été motivé en partie par l'échec d'algorithmes traditionnels, lorsqu'on travaille avec des données de grande dimension, pour bien généraliser sur de telles tâches d'intelligence artificielle.

L'apprentissage en profondeur « Deep Learning »

L'apprentissage en profondeur « Deep Learning » a été un défi à définir pour beaucoup spécialiste dans le domaine car il a changé de forme lentement au cours de la dernière décennie. Une définition utile précise que l'apprentissage en profondeur est un réseau neuronal avec plus de deux couches. Le problème avec cette définition est qu'elle fait écho à l'existence de ce domaine depuis les années 80 du siècle dernier, formant ainsi une grande contradiction puisque beaucoup de gens pensent que ce domaine est relativement nouveau, pour réfuter cette contradiction, il

faut distinguer le moment où le domaine est apparu et celui où il a été cadré et exploité.

A. Apprentissage profond vs méthodes classiques :

L'apprentissage profond implique l'application de réseaux de neurones profonds avec plus de couches et plus de données que les algorithmes d'apprentissage automatique traditionnels, ce qui nécessite des modèles plus grands et plus de calculs. Ceci est également utile, car même si la quantité de données augmente, les performances des algorithmes d'apprentissage automatique traditionnels ne peuvent pas être améliorées après un certain temps, mais les performances des algorithmes d'apprentissage en profondeur sont proportionnelles à la quantité de données et à la diversité des données. Un réseau de neurones artificiels est un système qui apprend à agir sur la base d'exemples, sans avoir besoin de procédures spécifiques explicites.

Définitions :

Le terme « apprentissage profond » a été introduit dans le domaine de l'apprentissage automatique par « Rina Dechter » en 1986, et dans les réseaux de neurones artificiels par « Igor Aizenberg » et ses collègues en 2000, dans le contexte des neurones à seuil booléen (Schmidhuber, 2015), l'apprentissage profond désigne une technique d'apprentissage d'une machine, c'est une sous-branche de l'intelligence artificielle qui vise à construire automatiquement des connaissances à partir de grandes quantités d'information. Les caractéristiques essentielles du traitement ne seront plus identifiées par un traitement humain dans un algorithme préalable, mais directement par l'algorithme d'apprentissage profond.

L'apprentissage en profondeur permet donc implicitement de répondre à des questions du type « que peut-on déduire de ces données ? » et décrire des caractéristiques parfois cachées ou des relations entre des données souvent impossibles à identifier pour l'homme.

CHAPITRE 04 : APPRENTISSAGE AUTOMATIQUE ET APPRENTISSAGE PROFOND

D'après (Patterson & Gibson, 2017) l'apprentissage profond est un réseau neuronal avec un grand nombre de paramètres et de couches, l'exemple de base c'est le perceptron multicouche MLP « multi layer perceptron ».

Perceptrons a été inventé en 1958 au « Cornell Aviation Laboratory » par « Frank Rosenblat » financé par le bureau de recherche navale des États-Unis, Le mot vient de verbe latin « Percipio » qui signifie en Anglaise understand ; en Français comprendre, qui montre que Le robot ou l'appareil peut apprendre et comprendre le monde extérieur.

Un perceptron multicouche avec plusieurs couches cachées entre la couche d'entrée et la couche de sortie est un réseau de neurones profonds (DNN), le DNN est une fonction mathématique, qui mappe certains ensembles de valeurs d'entrée aux valeurs de sortie. La fonction est formée par la composition de nombreuses fonctions plus simples.

Certaines de ses caractéristiques :

✓ Plus de neurones.

✓ Des moyens plus complexes de connecter les couches neurones dans les réseaux.

✓ Puissance de calcul.

✓ Extraction automatique des fonctionnalités.

L'apprentissage profond s'applique dans divers domaines tel que :

✓ L'intelligence artificielle en général.

✓ La reconnaissance visuelle et la comparaison de forme.

✓ La robotique.

✓ La santé et la bio-informatique.

✓ La sécurité.

B. Les architectures d'apprentissage en profondeur :

Les trois grandes architectures de réseaux profonds selon :

- Réseaux de neurones pré-entraînés non supervisés.
- Réseaux neuronaux convolutionnels (CNN).
- Réseaux neuronaux récurrents (RNN) .

Habituellement, de nombreuses catégories considèrent les réseaux de neurones supervisés comme appartenant au domaine d'apprentissage automatique plutôt que d'apprentissage en profondeur.

a) Réseaux neuronaux convolutionnels (CNN) :

Les réseaux neuronaux convolutionnels CNNs « Convolutional neurone network » sont un type spécialisé de réseau neuronal pour le traitement de données qui a une topologie connue, ils sont des réseaux supervisés et non supervisés, cela dépend de l'exigence et l'utilisation, cependant, principalement sont supervisés. L'informaticien japonais « Kuniyuki Fukushima » a jeté les bases du lancement de cette structure par son travail sur Neocognitron en 1980 (Vázquez, 2018) Comme une grille, ils appartiennent aux réseaux de neurones artificiels acycliques, le nom convolutionnel indique que le réseau emploie une opération mathématique appelée convolution, et cela signifie un type spécialisé d'opération linéaire. L'architecture de ce réseau est inspirée à partir de l'arrangement des neurones situés dans la région du cortex visuel des animaux. Cet arrangement correspond au chevauchement des régions lors du pavage du champ visuel.

Le fonctionnement de CNNs est inspiré à partir du fonctionnement du processus biologique, ils consistent en un empilage multicouche de perceptrons, dont le but est le prétraitement de petites quantités d'informations.

1) L'architecture des réseaux neuronaux convolutés :

Les CNN se concentrent principalement sur l'idée que les données contiennent des images, ce qui permet de construire l'architecture de la manière la plus adaptée à la

CHAPITRE 04 : APPRENTISSAGE AUTOMATIQUE ET APPRENTISSAGE PROFOND

nécessité de traiter cette forme particulière d'information. Cependant, une des variations significatives est que les couches au milieu du CNN sont composées de neurones organisés en trois dimensions connues sous le nom de dimensionnalité spatiale de l'entrée (la hauteur, la largeur et la profondeur). L'architecture d'un CNN est modélisée de manière à tirer parti de la structure 2D d'une image d'entrée (ou de diverses entrées 2D similaires à un signal vocal). L'entrée et la sortie de chaque étape sont des ensembles de tableaux appelés cartes de caractéristiques

L'architecture des réseaux neuronaux convolutifs (CNNs) compose de trois majors couches :

- **Couche d'entrée** : la couche d'entrée accepte généralement l'entrée tridimensionnelle sous la forme (hauteur \times largeur) de l'image et a une profondeur représentant les canaux de couleur (généralement trois pour les canaux de couleur RGB).

- **Couche d'entraînement** : est construite de
 - ✓ Convolution couche .
 - ✓ Fonction d'activation : Linéaire rectifiée « Relu » .
 - ✓ Couche de mise en commun « pooling ».
 - ✓ Couche de classification : Couche de classification produire des probabilités ou des scores de classe.

Grâce à cette simple méthode de transformation, les CNN sont capables de transformer l'entrée originale couche par couche en utilisant des techniques de convolution et de sous-échantillonnage pour produire des scores de classe à des fins de classification et de régression

2) L'application des réseaux neuronaux convolutifs :

Les réseaux neuronaux convolutifs (CNNs) ont de larges applications, notamment :

- La reconnaissance d'image et vidéo.
- Les systèmes de recommandation.
- Le traitement du langage naturel.

L'efficacité des CNN dans la reconnaissance de l'image est l'une des principales raisons pour lesquelles le monde reconnaît le pouvoir de l'apprentissage profond.

3) Réseaux neuronaux récurrents (RNN) :

Les réseaux neuronaux récurrents RNNs « Recurrent Neural Networks » sont une famille de réseaux de neurones pour le traitement de données séquentielles inventé par l'informaticien américain « Michael Irwin Jordan » en 1986 (Vázquez, 2018).

Le chercheur allemand « Jürgen Schmidhuber » considère que les réseaux de neurones récurrents sont similaires au cerveau humain, qui est un grand réseau de rétroaction de neurones connectés. Ces derniers peuvent apprendre à traduire un flux d'entrée sensoriel tout au long de la vie dans une séquence de sorties motrices utiles.

Un réseau neuronal récurrent (RNN) est un type particulier de réseau neuronal artificiel qui permet de poursuivre des informations liées à des connaissances antérieures en utilisant un type particulier d'architecture en boucle. Ils sont employés dans de nombreux domaines concernant des données avec des séquences, comme la prédiction du prochain mot d'une phrase. Ces réseaux en boucle sont dits récurrents car ils effectuent les mêmes opérations et calculs pour chaque élément d'une séquence de données d'entrée. Les RNN possèdent une mémoire, qui les aide à prendre des informations à partir de séquences passées. Un réseau neuronal récurrent (RNN) est l'une des architectures de base. Nombre des architectures avancées actuelles s'inspirent des RNN. La principale caractéristique d'un RNN est que le réseau possède des connexions de rétroaction, contrairement à un réseau neuronal à anticipation traditionnel. Cette boucle de rétroaction permet au RNN de

modéliser les effets des premières parties de la séquence sur les dernières parties de la séquence, ce qui est une caractéristique très importante lorsqu'il s'agit de modéliser des séquences.

Un réseau neuronal récurrent (RNN) à une seule couche cachée dans sa forme de base. Il se compose d'un seul ensemble d'unités d'entrée, cachées et de sortie, les unités cachées s'alimentant elles-mêmes par le biais de boucles de rétroaction. En termes simples, comme le montre clairement sa version dépliée, un RNN peut être considéré comme de multiples copies (dans le temps) du même réseau, chacune transmettant un message à son successeur. Les paramètres entraînaables pour un RNN comprennent les poids et les biais qui sont partagés entre tous les pas de temps.

1) Types de réseaux de neurones récurrents (RNN)

Il existe quatre types de réseaux neuronaux récurrents :

➤ One to One RNN :

Ce type de réseau neuronal est connu sous le nom de réseau neuronal « Vanille » (standard). Il est utilisé pour les problèmes généraux d'apprentissage automatique, avec une seule entrée et une seule sortie.

➤ One to Many RNN :

Ce type de réseau neuronal possède une entrée unique et des sorties multiples

➤ Many to One RNN :

Ce RNN prend une séquence d'entrées et génère une sortie unique. L'analyse des sentiments est un bon exemple de ce type de réseau où une phrase donnée peut être classée comme exprimant des sentiments positifs ou négatifs

➤ Many to Many RNN :

Ce RNN prend une séquence d'entrées et génère une séquence de sorties. La traduction automatique est un des exemples où ce type de RNN est utilisé

2) L'application des réseaux neuronaux récurrents (RNN)

Les réseaux neuronaux récurrents peuvent être utilisés dans plusieurs applications (Patterson & Gibson, 2017) tel que :

- ➤ La transcription vocale au texte.
- ➤ Le traitement automatique du langage naturel.
- ➤ La traduction automatique.
- ➤ La génération de texte manuscrit.

4) Le réseau de neurones LSTM :

L'architecture mémoire court-terme étendue LSTM « Long Short-Term Memory » , est un type de RNN très utilisé en traitement du langage naturel, proposées par les informaticiens « Sepp Hochreiter » et « Jurgen Schmidhuber » en 1997.

L'idée principale de l'architecture LSTM est de diviser le signal entre ce qui est important à :

- Court terme à travers une couche de sortie LSTM, nommée « l'état caché ».
- Long terme, à travers un neurone qui conserve un état interne, nommé « cellule d'état », ce neurone n'est pas un neurone de sortie.

Le fonctionnement global d'un LSTM peut se résumer selon les trois étapes suivantes :

1. Détecter les informations pertinentes venant du passé, piochées dans une cellule d'état à travers la porte oublier « forget gate ».
2. Choisir, à partir de l'entrée courante, celles qui seront pertinentes à long terme, via « l'input gate ». Celles-ci seront ajoutées à la cellule d'état qui fait d'office d'une mémoire longue.
3. Piocher dans la nouvelle cellule d'état les informations importantes à court terme pour générer l'état caché suivant à travers la porte de sortie « output gate ».

III. Le problème de sur-apprentissage et sous-apprentissage :

Les facteurs déterminant le rendement d'un algorithme d'apprentissage automatique ou profond sont sa capacité à :

1. Réduire l'erreur dans la phase d'apprentissage.
2. Réduire l'écart entre le résultat d'apprentissage et l'erreur de test.

Ces deux facteurs correspondent aux deux enjeux centraux d'apprentissage automatique qui sont :

- ✓ Sur-apprentissage « overfitting ».
- ✓ Sous-apprentissage « underfitting ».

- Le sur-apprentissage :

A titre exemple, une équipe de football se comporte mal durant le passage des journées de la ligue. Par conséquent, tous les joueurs de l'équipe seront jugés par l'échec ; bien qu'il y ait des joueurs compétents et même le buteur de la ligue. Cette situation s'appelle « la généralisation ». Le problème de la généralisation est très connu chez les êtres humains, et même les machines peuvent se tomber dans ce problème. Au niveau de la Machine Learning, ce problème s'appelle le surapprentissage « overfitting ». Cela signifie que le modèle fonctionne sur les données d'apprentissage, mais il ne peut pas se généraliser sur d'autres données.

- Le sous-apprentissage :

Si nous prenons le même exemple cité dans la section précédente. Mais cette fois on ne connaît pas les joueurs de l'équipe aussi les supporters ne connaît même pas les résultats de l'équipe dans des nombreuses journées. Par conséquent, l'équipe est jugée qu'elle est faible et même tous ses joueurs, donc nous avons une mauvaise pensée sur l'équipe malgré le manque d'informations. Cette situation s'appelle « le sous-apprentissage ; underfitting », cela signifie que le modèle développé est faible pour apprendre la structure sous-jacente des données, vu le manque d'informations

CHAPITRE 04 : APPRENTISSAGE AUTOMATIQUE ET APPRENTISSAGE PROFOND

Pour éviter ces deux problèmes, cités ci-dessus, plusieurs solutions ont été proposées dans la littérature. Concernant la résolution du problème de sur-apprentissage, nous pouvons :

- Utiliser plus des données durant la phase d'apprentissage.
- Réduire le bruit dans les données d'apprentissage (fixer les erreurs dans la base de données). Pour résoudre le problème de sous-ajustement, nous pouvons :
- Fournir une meilleure base de données à l'algorithme d'apprentissage.
- 2- Réduire les contraintes sur le modèle.

Comparaison entre l'apprentissage automatique et l'apprentissage en profondeur.

Chapitre 5 :

Implémentation et tests

Introduction :

La construction d'un modèle de réseau de neurones efficace nécessite un examen attentif de l'architecture du réseau ainsi que du format des données d'entrée, pour notre cas un traitement d'image. Les paramètres d'entrée de données d'image les plus courants sont le nombre d'images, la hauteur d'image, la largeur d'image, le nombre de canaux et le nombre de niveaux par pixel. Typiquement, nous avons 3 canaux de données correspondant aux couleurs Rouge, Vert, Bleu (RVB). Les niveaux de pixels sont généralement $[0,255]$.

Il existe un certain nombre d'étapes de prétraitement que nous pourrions souhaiter effectuer avant de l'utiliser dans un projet de « Deep Learning ».

I. Notion importante sur le modèle :

A. La normalisation des données :

Les pixels d'entrée de tout algorithme d'IA doivent avoir une distribution de données normalisée pour améliorer la convergence de la phase d'apprentissage. La normalisation est l'action de soustraire la moyenne de la distribution de chaque pixel et de diviser par l'écart type. Pour obtenir des valeurs positives, la mise à l'échelle des données normalisées est prise en compte à la fin de cette étape.

B. L'augmentation de donnée :

Est une méthode utilisée pour générer des données supplémentaires à partir de l'ensemble de données actuel. Il crée des copies perturbées des images existantes, dans ce cas. L'objectif principal est de renforcer le réseau de neurones avec diverses diversités, ce qui conduit à un réseau qui distingue les caractéristiques pertinentes des caractéristiques non pertinentes dans l'ensemble de données. L'augmentation d'image peut être effectuée en utilisant plusieurs techniques. Les techniques d'augmentation sont utilisées efficacement lorsque cela est nécessaire en fonction de la disponibilité et de la qualité des données. Notre proposition intègre plusieurs techniques, pour

prendre en charge un grand nombre d'ensembles de données pour différentes conditions, comme suit :

- **Rotation** : l'image est tournée dans un intervalle compris entre -10° et 10° .
- **Zoom** : la mise à l'échelle de l'image en effectuant un zoom avant ou arrière augmenterait également l'ensemble.
- **Cisaillement** : le cisaillement de l'image peut être effectué à l'aide d'une rotation avec le facteur d'imitation de troisième dimension.
- **Flou gaussien** : à l'aide d'un filtre gaussien, les facteurs de haute fréquence peuvent être éliminés, provoquant une version floue d'une image. En utilisant ces méthodes, l'ensemble de données a été élargi et utilisé dans la phase d'apprentissage. Néanmoins, pendant la phase de test, l'ensemble de test ne sera pas augmenté. Cela permettrait d'affirmer la robustesse de l'architecture et d'éviter le sur-ajustement.

C. L'apprentissage par transfert :

L'apprentissage par transfert est une méthode d'apprentissage automatique dans laquelle un modèle développé pour une tâche est réutilisé comme point de départ d'un modèle sur une deuxième tâche.

C'est une approche populaire dans l'apprentissage en profondeur où des modèles pré-entraînés sont utilisés comme point de départ pour les tâches de vision par ordinateur et de traitement du langage naturel étant donné les vastes ressources de calcul et de temps nécessaires pour développer des modèles de réseau neuronal sur ces problèmes et des énormes sauts de compétences qu'ils fournissent sur des problèmes connexes.

Il est courant d'effectuer un apprentissage par transfert avec des problèmes de modélisation prédictive qui utilisent des données d'image comme entrée.

Il peut s'agir d'une tâche de prédiction qui prend des photos ou des données vidéo en entrée.

Pour ces types de problèmes, il est courant d'utiliser un modèle d'apprentissage en profondeur pré-entraîné pour une tâche de classification d'images importante et difficile, telle que le concours de classification de photographies « ImageNet » de classe 1000.

Les organismes de recherche qui développent des modèles pour cette compétition et réussissent souvent à publier leur modèle final sous une licence permissive pour la réutilisation. Ces modèles peuvent prendre des jours ou des semaines pour s'entraîner sur du matériel moderne.

En vision par ordinateur, par exemple, les réseaux de neurones essaient généralement de détecter les contours dans les couches précédentes, les formes dans la couche intermédiaire et certaines caractéristiques spécifiques à la tâche dans les couches ultérieures. Dans l'apprentissage par transfert, les couches initiales et intermédiaires sont utilisées et nous ne recyclons que les dernières couches. Il permet d'exploiter les données étiquetées de la tâche sur laquelle il a été initialement formé

Dans l'apprentissage par transfert, nous essayons de transférer autant de connaissances que possible de la tâche précédente sur laquelle le modèle a été formé à la nouvelle tâche à accomplir. Cette connaissance peut prendre diverses formes selon le problème et les données. Par exemple, cela pourrait être la façon dont les modèles sont composés, ce qui nous permet d'identifier plus facilement de nouveaux objets.

L'apprentissage par transfert présente plusieurs avantages, mais les principaux avantages sont le gain de temps de formation, les meilleures performances des réseaux de neurones (dans la plupart des cas) et le fait de ne pas avoir besoin de beaucoup de données.

Habituellement, beaucoup de données sont nécessaires pour former un réseau de neurones à partir de zéro, mais l'accès à ces données n'est pas toujours disponible - c'est là que l'apprentissage par transfert entre en jeu. Avec l'apprentissage par transfert, un modèle d'apprentissage automatique solide peut

être construit avec relativement peu de données d'entraînement, car le modèle est déjà pré-entraîné. Ceci est particulièrement utile dans le traitement du langage naturel, car la plupart des connaissances d'experts sont nécessaires pour créer de grands ensembles de données étiquetés. De plus, le temps de formation est réduit car cela peut parfois prendre des jours, voire des semaines, pour former un réseau de neurones profonds à partir de zéro sur une tâche complexe.

➤ **Approches de l'apprentissage par transfert :**

- **DEVELOPPER UN MODÈLE POUR LE RÉUTILISER :**

Si vous avez la même entrée dans les deux tâches, vous pouvez éventuellement réutiliser le modèle et faire des prédictions pour votre nouvelle entrée. Alternativement, changer et recycler différentes couches spécifiques à une tâche et la couche de sortie est une méthode à explorer.

- **UTILISER UN MODÈLE PRETRAINER :**

La deuxième approche consiste à utiliser un modèle déjà pré-entraîné. Le nombre de couches à réutiliser et à recycler dépend du problème. Keras, par exemple, fournit neuf modèles pré-entraînés qui peuvent être utilisés pour l'apprentissage par transfert, la prédiction, l'extraction de caractéristiques et le réglage fin.

Il existe également de nombreux instituts de recherche qui publient des modèles entraînés.

Ce type d'apprentissage par transfert est le plus couramment utilisé tout au long de l'apprentissage en profondeur.

Il existe des modèles d'apprentissage automatique pré-entraînés qui sont très populaires. L'un d'eux est le modèle Inception-v3, qui a été formé pour le « Large Visual Recognition Challenge » d'ImageNet.

Microsoft propose également des modèles pré-entraînés, disponibles pour le développement R et Python, via le package MicrosoftML R et le package MicrosoftML Python.

D. Neural Architecture Search NASNet :

Neural Architecture Search vise à découvrir la meilleure architecture pour un réseau de neurones pour un besoin spécifique. Le NAS prend essentiellement le processus d'un humain qui affine manuellement un réseau de neurones et apprend ce qui fonctionne bien, et automatise cette tâche pour découvrir des architectures plus complexes. Ce domaine représente un ensemble d'outils et de méthodes qui testeront et évalueront un grand nombre d'architectures dans un espace de recherche à l'aide d'une stratégie de recherche et sélectionneront celle qui répond le mieux aux objectifs d'un problème donné en maximisant une fonction.

NAS est un sous-domaine d'AutoML, qui encapsule tous les processus qui automatisent les problèmes de Machine Learning et donc ceux de Deep Learning. 2016 marque le début de NAS avec les travaux de Zoph et Le ou Baker et al, qui ont réalisé des architectures de pointe pour la reconnaissance d'images et la modélisation du langage avec des algorithmes d'apprentissage par renforcement. Ces travaux ont donné une impulsion considérable à ce domaine.

La recherche d'architecture neuronale (NAS) est l'un des domaines de l'apprentissage automatique qui se développe le plus rapidement. Un grand nombre de travaux de recherche concernent l'automatisation de la recherche d'architectures de réseaux de neurones, dans différentes industries et différents problèmes.

E. ImageNet :

C'est une ontologie à grande échelle d'images construite sur la structure WordNet. ImageNet vise à remplir chacun de la majorité des 80 000 synsets (noms concrets et dénombrables et leurs ensembles de synonymes) de WordNet avec une moyenne de 500 à 1 000 images propres. Cela se traduira par des

dizaines de millions d'images annotées organisées par la hiérarchie sémantique de WordNet.

Pour construire ImageNet, nous collectons d'abord un grand ensemble d'images candidates (environ 10 000) à partir des moteurs de recherche d'images Internet pour chaque synset, qui contient généralement environ 10 % d'images appropriées. Nous déployons ensuite une tâche d'annotation d'images. Pour obtenir une évaluation fiable, chaque image est évaluée par un nombre déterminé dynamiquement de travailleurs en ligne. A ce moment nous avons six sous-ImageNets terminés avec plus de 2500 synsets et environ 2 millions d'images au total (Mammal-Net, Vehicle-Net, MusicalInstrument-Net, Tool-Net, Furniture-Net et GeologicalFormation -Rapporter).

ImageNet est beaucoup plus vaste en termes d'échelle et de diversité et beaucoup plus précis que les ensembles de données d'images existants.



Figure 10

F. Paramètre clé du modèle :

- **La fonction de perte :**

La fonction de perte est un moyen de calculer les performances de l'algorithme lors de son apprentissage avec l'ensemble de données utilisé. Il estime à quel point les prédictions sont éloignées de la réalité. Ce facteur est utilisé plus tard dans l'optimisation de l'algorithme en minimisant la perte subie. En fait, la fonction de perte est un indicateur si le réglage de l'algorithme d'une certaine manière est bénéfique.

- **Taux d'apprentissage :**

Ce taux est une valeur critique lors de la mise à jour de la formule de pondération. Sa valeur optimale est parfois inaccessible. Les valeurs faibles et élevées des taux d'apprentissage entraînent plusieurs problèmes. Des valeurs faibles diminuent la vitesse du processus d'entraînement, provoquant un retard dans l'ensemble de la procédure. En revanche, des valeurs élevées augmentent la vitesse de convergence et réduisent les poids définis, et par conséquent, aucun poids sous-optimal n'est atteint

- **Régularisation :**

L'un des principaux problèmes à éviter dans les algorithmes d'IA est le sur-ajustement, qui pourrait être interprété en soumettant explicitement l'architecture de l'algorithme à l'ensemble d'apprentissage. La sortie du réseau est limitée uniquement à la sortie spécifique obtenue précédemment par l'ensemble d'apprentissage, quelle que soit l'entrée. La régularisation est un mécanisme qui ajuste la cartographie et atténue le sur-ajustement. L'augmentation des données est connue pour être utilisée pour augmenter l'ensemble de données d'entraînement, réduisant ainsi le sur-ajustement, mais un coût de mémoire important pourrait être une grande préoccupation dans cette méthode. Les méthodes de régularisation peuvent être utilisées quelle que soit la taille de l'ensemble de données d'apprentissage. Dropout et drop-connecte sont les techniques de régularisation les plus connues. Les réseaux entièrement connectés sont généralement soumis à des mécanismes de décrochage basés sur les distributions de probabilité des connexions dans chaque couche. Dans ce processus, les connexions sont supprimées et les nœuds seraient supprimés en conséquence.

II. Les outils et les détails d'implémentation :

Pour évaluer et tester les performances de l'approche proposée, nous devons d'abord passer par l'étape de l'implémentation. Dans cette section, nous décrivons les différents outils, et les langages de programmation utilisés

De nos jours, il existe plusieurs langages de programmation et chaque langage possède ses propres caractéristiques. Parmi ses langages, notre choix s'est focalisé sur Python.

A. Langage de programmation et Framework :

- **Python**

Il est l'un des langages de programmation les plus intéressants du moment, il est inventé par « Guido van Rossum », la première version de python est sortie en 1991. C'est un langage de programmation interprété, multi paradigme et multiplateformes. Il favorise la programmation impérative structurée, fonctionnelle et orientée objet

Python est à la fois simple et puissant, il permet d'écrire des scripts très simples, et grâce à ses nombreuses bibliothèques, nous pouvons travailler sur des projets plus ambitieux.

➤ **Pour quoi Python ?**

Python est un langage stable, flexible et il fournit divers outils pour les développeurs. Ce qui permet de le classer en premier choix pour l'apprentissage automatique, à partir du développement, la mise en œuvre, et la maintenance. Python aide les développeurs de développer des produits confiants (Gupta, 2019). Selon (Gupta, 2019), Python possède de nombreux avantages:

✓ ***Simple et cohérent*** : la simplicité de Python aide les développeurs à gérer l'algorithme complexe de l'apprentissage automatique.

✓ ***La flexibilité*** : Le facteur de flexibilité réduit la possibilité d'erreurs, il a laissé les programmeurs prendre le contrôle complètement, et de travailler sur elle confortablement

✓ ***Bibliothèques et Framework*** : Les algorithmes de l'apprentissage automatique sont très complexes, mais Python

est le secours avec une large gamme de bibliothèques comme Scikit-learn, Keras et de Framework, à titre d'exemple TensorFlow.

✓ *Lisibilité* : Python est facile à lire, de sorte que les développeurs peuvent facilement comprendre le code.

✓ *Indépendance de la plateforme* : Python est un langage indépendant de la plate-forme. Il est supporté par de nombreuses plateformes, y compris Windows, LINUX et macOS.



Figure 11

- **Anaconda :**

Anaconda est une distribution libre et open source des langages de programmation Python et R appliqué au développement d'applications dédiées à la science des données et à l'apprentissage automatique (traitement de données à grande échelle, analyse prédictive, calcul scientifique), qui vise à simplifier la gestion des paquets et de déploiement



Figure 12

- **Jupyter**

Jupyter Notebook (anciennement IPython Notebooks) est un environnement de programmation interactif basé sur le Web permettant de créer des

documents Jupyter Notebook. Le terme "notebook" peut faire référence à de nombreuses entités différentes, adaptées au contexte, telles que l'application web Jupyter, le serveur web Jupyter Python ou le format de document Jupyter.

Un document Jupyter Notebook est un document JSON. Il suit un schéma contenant une liste ordonnée de cellules d'entrée/sortie. Celles-ci peuvent contenir du code, du texte (à l'aide de Markdown), des formules mathématiques, des graphiques et des médias interactifs. Ce document se termine généralement par l'extension ".ipynb".

Jupyter s'appuie sur un noyau IPython pour Python 2, un noyau IPython pour Python 3, IRkernel, un noyau pour le langage R, ainsi que le langage Scala basé sur R et IJulia, un noyau pour le langage Julia, maintenus par les principaux développeurs du projet. Un grand nombre de noyaux sont développés et maintenus par la communauté des développeurs. Cela inclut IPyLua, noyau pour le langage Lua (il existe plusieurs noyaux Lua), IRuby, noyau pour le langage Ruby, Calysto Processing pour Processing



Figure 13

- **TensorFlow**

TensorFlow est une plate-forme open source de bout en bout pour l'apprentissage automatique. Il dispose d'un écosystème complet et flexible d'outils, de bibliothèques et de ressources communautaires qui permet aux chercheurs de pousser l'état de l'art en matière de ML et aux développeurs de créer et de déployer facilement des applications basées sur le ML.

TensorFlow a été développé à l'origine par des chercheurs et des ingénieurs travaillant au sein de l'équipe Google Brain au sein de l'organisation Machine Intelligence Research de Google pour mener des recherches sur l'apprentissage automatique et les réseaux de neurones profonds. Le système est suffisamment général pour être également applicable dans une grande variété d'autres domaines.

TensorFlow dans des Applications Médicales

GE Healthcare a utilisé TensorFlow pour augmenter la vitesse et la précision des IRM dans l'identification de parties spécifiques du corps. Google a utilisé TensorFlow pour créer DermAssist, une application mobile gratuite qui permet aux utilisateurs de prendre des photos de leur peau et d'identifier les complications potentielles pour la santé. Sinovation Ventures a utilisé TensorFlow pour identifier et classer les maladies oculaires à partir de tomographies par cohérence optique (OCT).



Figure 14

- **Keras :**

Keras est une API de réseau de neurones écrite en langage Python. Il s'agit d'une bibliothèque Open Source, exécutée par-dessus des frameworks tels que Theano et TensorFlow.

Conçue pour être modulaire, rapide et simple d'utilisation, Elle offre une façon simple et intuitive de créer des modèles de Deep Learning.

Aujourd'hui, Keras est l'une des APIs de réseaux de neurones les plus utilisées pour le développement et le testing de réseaux de neurones. Elle permet de créer très facilement des " layers " pour les Neural Networks ou de

mettre en place des architectures complexes. Il existe plusieurs modules entièrement configurables et pouvant être combinés pour créer de nouveaux modèles.

L'un des avantages de cette modularité est qu'il est très facile d'ajouter de nouvelles fonctionnalités sous forme de modules séparés. Keras est donc très flexible, et adapté à la recherche et à l'innovation.

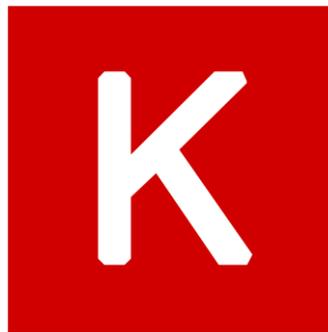


Figure 15

B. Corpusse et Dataset :

Ensemble de données de tomodensitométrie pulmonaire COVID-19 (SARS-CoV-2), contenant un total de 8 439 tomodensitogrammes, dont 7 495 cas positifs (infection COVID-19) et 944 négatifs (normaux et non COVID-19). Les données sont disponibles sous forme d'images PNG de 512 × 512 pixels et ont été collectées auprès de vrais patients dans les centres de radiologie des hôpitaux universitaires. L'objectif de cet ensemble de données est d'encourager la recherche et le développement de méthodes efficaces et innovantes telles que les CNN profonds qui sont capables d'identifier si une personne est infectée par COVID-19 grâce à l'analyse de ses tomodensitogrammes.

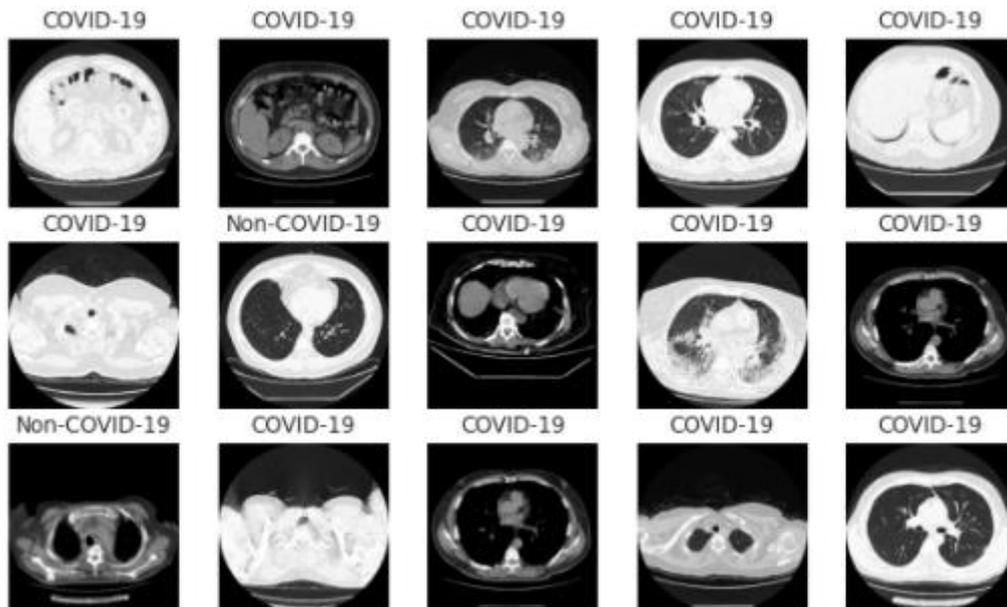


Figure 16

C. Prétraitement des données

1) Importation des modules

La première étape consiste à importer les modules nécessaires

```
import tensorflow as tf
tf.random.set_seed(SEED)
import tensorflow.keras
from tensorflow.keras import layers, models, optimizers
from tensorflow.keras.layers import Dense, BatchNormalization, Dropout, Activation, GlobalAveragePooling2D, Input
from tensorflow.keras.models import Sequential, load_model, Model
from tensorflow.keras import regularizers
from tensorflow.keras.utils import to_categorical
from tensorflow.keras.callbacks import ModelCheckpoint, ReduceLROnPlateau, EarlyStopping
from tensorflow.keras.preprocessing import image
from tensorflow.keras.layers.experimental import preprocessing
import tensorflow.keras.backend as K

from tensorflow.keras.applications import NASNetLarge
NETWORK = NASNetLarge

from sklearn.model_selection import train_test_split
from sklearn import metrics
from sklearn.metrics import confusion_matrix, mean_squared_error, classification_report
```

2) Importer le dataset :

On utilisera « tf.io.gfile.globe » qui Renvoie une liste de fichiers qui correspondent au lien donné(s) comme c'est montre ci dessus.

```
dataset_id1 = 'covid19-lung-ct-scans'  
GCS_PATH1 = '/content/COVID-19_Lung_CT_Scans'  
BATCH_SIZE = 128 * strategy.num_replicas_in_sync
```

3) Paramètre d'entrée du model :

Dans ces lignes de code ont spécifie les classes utiliser ainsi que le codage e d image qu'on vas utiliser Les dimensions des images d'entrée ont été modifiées en 224×224×3.

```
CLASSES = ['COVID-19', 'Non-COVID-19']  
NUM_CLASSES = len(CLASSES)  
IMAGE_SIZE = [224, 224]  
input_shape = (224, 224, 3)
```

Pour construire notre modèle d'apprentissage, nous avons d'abord défini la fonction loss utilisée, Nous avons effectué 50 itérations « epochs » pour entrainer le modèle ainsi que « adam optimizer » qui est un algorithme d'optimisation qui peut être utilisé à la place de la procédure classique de descente de gradient stochastique pour mettre à jour les poids du réseau de manière itérative en fonction des données d'apprentissage.

```
LOSS = tf.keras.losses.CategoricalCrossentropy(label_smoothing=0.2)  
METRICS = ['accuracy']  
Epochs = 50  
Early_Stop = 15  
OPTIMIZER = tensorflow.keras.optimizers.Adam(lr = 1e-2, decay = 1e-5)
```

4) Représentation des données :

La représentation des données est une partie importante exploration des données et pour tirer des conclusions, donc dans le « dataset » utilisé on trouve deux classes de label covid/non-covid19.

Les résultats sont montre ci-dessus :

```
data = {'Cases':['COVID-19', 'non-COVID'],
        'Cases_count':[COUNT_COVID, COUNT_Non_COVID]
        }

df = pd.DataFrame(data)

sns.set(style="darkgrid")
plt.figure(figsize=(10,8))
sns.barplot(x=df.index, y= df['Cases_count'].values)
plt.title('Number of All the Data', fontsize=14)
plt.xlabel('Case type', fontsize=12)
plt.ylabel('Count', fontsize=12)
plt.xticks(range(len(df.index)), ['COVID-19', 'non-COVID'])
plt.show()

print(df)
```

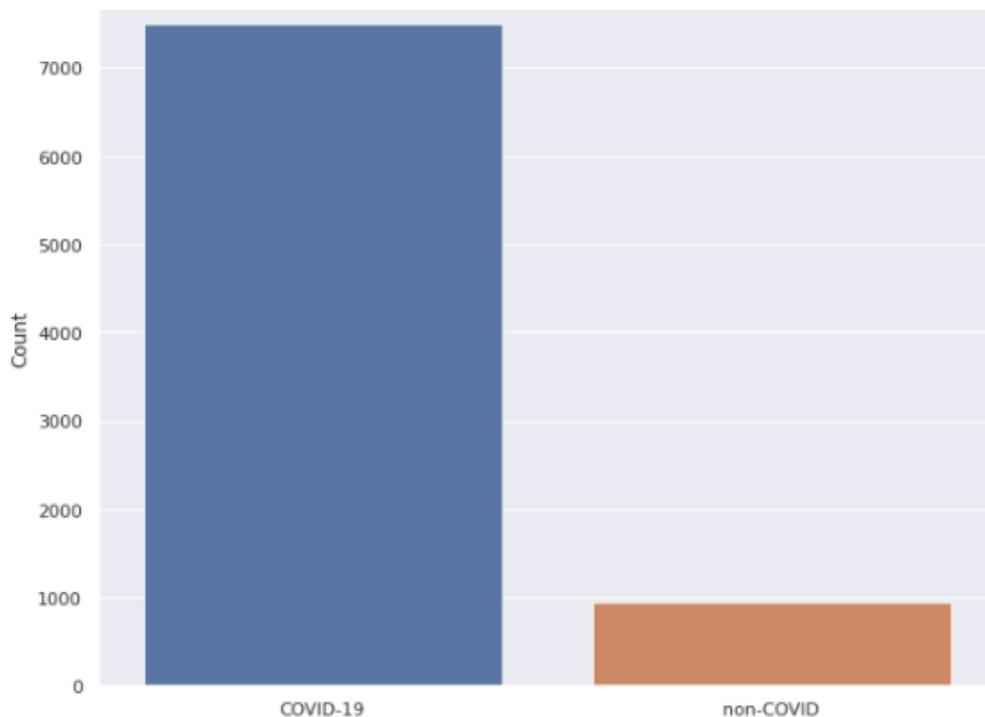


Figure 17

5) Division du dataset :

Dans cette étape Le ratio a été réparti au hasard entre les ensembles d'apprentissage, de validation et de test, respectivement, de sorte que 20 % des données ont été attribuées à l'ensemble de test, les 80 % restants à l'ensemble d'entraînement et 20 % de l'ensemble d'entraînement ont été attribués à la validation ensemble.

```
train_filenames, test_filenames = train_test_split(fileNames, test_size=0.2)
train_filenames, val_filenames = train_test_split(train_filenames, test_size=0.2)
```

```
train_list_ds = tf.data.Dataset.from_tensor_slices(train_filenames)
val_list_ds = tf.data.Dataset.from_tensor_slices(val_filenames)
test_list_ds = tf.data.Dataset.from_tensor_slices(test_filenames)
```

```
TRAIN_IMG_COUNT = tf.data.experimental.cardinality(train_list_ds).numpy()
print("Training images count: " + str(TRAIN_IMG_COUNT))
```

```
VAL_IMG_COUNT = tf.data.experimental.cardinality(val_list_ds).numpy()
print("Validating images count: " + str(VAL_IMG_COUNT))
```

```
Test_IMG_COUNT = tf.data.experimental.cardinality(test_list_ds).numpy()
print("Testing images count: " + str(Test_IMG_COUNT))
```

```
Training images count: 5400
Validating images count: 1351
Testing images count: 1688
```

Ce qui nous donnera 5400 exemple d'entraînement 1351 exemple de validation et 1688 pour les données de test

6) Encodage des images :

Étant donné que les données proviennent généralement de diverses origines, une stratégie pour guider la complexité et l'exactitude est essentielle. Le prétraitement des images garantit une réduction de la complexité et une meilleure précision. Cette méthode standardise les données en plusieurs étapes afin d'alimenter le réseau avec un jeu de données propre.

Les réseaux de neurones qui traitent les images ont besoin d'images au format d'image unifié. Par conséquent, la première étape consiste à redimensionner les images dans des dimensions uniques et une forme carrée, qui est la forme typique utilisée dans les réseaux de neurones.

Toutes les images des ensembles ont été mélangées de telle sorte que le réseau ne verrait pas nécessairement les données d'une certaine classe uniquement pendant la formation, et chaque lot inclurait des images avec des étiquettes différentes appartenant à la fois aux classes COVID-19 et non COVID-19.

```
def get_label(file_path):
    parts = tf.strings.split(file_path, os.path.sep)
    return int(parts[-2] == CLASSES)

def decode_img(img):
    img = tf.image.decode_png(img, channels=3)
    img = tf.image.convert_image_dtype(img, tf.float32)
    return tf.image.resize(img, IMAGE_SIZE)

def process_path(file_path):
    label = get_label(file_path)
    img = tf.io.read_file(file_path)
    img = decode_img(img)
    return img, label
```

7) Images augmentation :

Étant donné que les CNN dépendent d'un grand nombre de données pour améliorer leur efficacité et éviter le sur-ajustement des modèles.

On spécifier des propriétés : un flip horizontal et le « contrast » (figure suivante)

```
img_augmentation = Sequential([
    preprocessing.RandomFlip("horizontal"),
    preprocessing.RandomContrast(factor=0.20)
], name="Augmentation")
```

D. Construction du modèle :

Inspirés par l'approche d'apprentissage par transfert, pour une meilleure extraction des caractéristiques, les blocs préliminaires du réseau « NASNetLarge » pré-

entraîné ont été utilisés. NASNet a une architecture évolutive pour la classification des images et se compose de 2 motifs répétés appelés la cellule normale et la cellule de réduction

Tous les paramètres ont été initialisés à l'aide des poids obtenus en ajustant NASNetLarge sur l'ensemble de données ImageNet. Après le bloc d'extraction de caractéristiques, les poids ont été transférés vers 3 couches denses ou entièrement connectées

La première couche dense utilisait une fonction d'activation ReLU, la couche suivante utilisait une aussi ReLU et la dernière couche qui est en fait la couche de classificateur, utilisait une fonction d'activation Softmax.

Au cours du processus d'apprentissage, dans la première phase, le bloc d'extraction de caractéristiques a été gelé et contenait des paramètres non entraînés, et Adam a été utilisé comme optimiseur. Dans cette phase, le taux d'apprentissage initial de $1e-3$ et la fonction de perte ont été utilisés

Pour éviter le sur ajustement du modèle, en plus de la normalisation des lots, des méthodes de régularisation du poids et d'abandon ont également été appliquées. Pour la régularisation, la norme euclidienne (L2) a été utilisée avec différentes valeurs de coefficient dans l'intervalle (0,001-0,01) après activation à l'aide de la fonction d'activation ReLU et abandon de 20 à 30 % des poids

```

def build_model(OPTIMIZER, LOSS, METRICS):
    model = None
    inputs = layers.Input(shape=input_shape)
    x = img_augmentation(inputs)
    baseModel = NETWORK(include_top=False, input_tensor=x, weights="imagenet", pooling='avg')

    baseModel.trainable = False

    x = BatchNormalization(axis = -1, name="Batch-Normalization-1")(baseModel.output)
    x = Dense(512, activation='relu', kernel_regularizer=regularizers.L1L2(l1=1e-5, l2=1e-4))(x)
    x = BatchNormalization(axis = -1, name="Batch-Normalization-2")(x)
    x = Dropout(.2, name="Dropout-1")(x)

    x = Dense(256, activation='relu')(x)
    x = BatchNormalization(axis = -1, name="Batch-Normalization-3")(x)

    outputs = Dense(NUM_CLASSES, activation="softmax", name="Classifier")(x)
    model = tf.keras.Model(inputs=baseModel.input, outputs=outputs, name="Deep-COVID")

    model.compile(optimizer = OPTIMIZER, loss = LOSS, metrics = METRICS)

    return model

with strategy.scope():
    model = build_model(OPTIMIZER, LOSS, METRICS)

```

- **Résultat du premier entraînement :**

Graphes de fonction de perte et de précision :

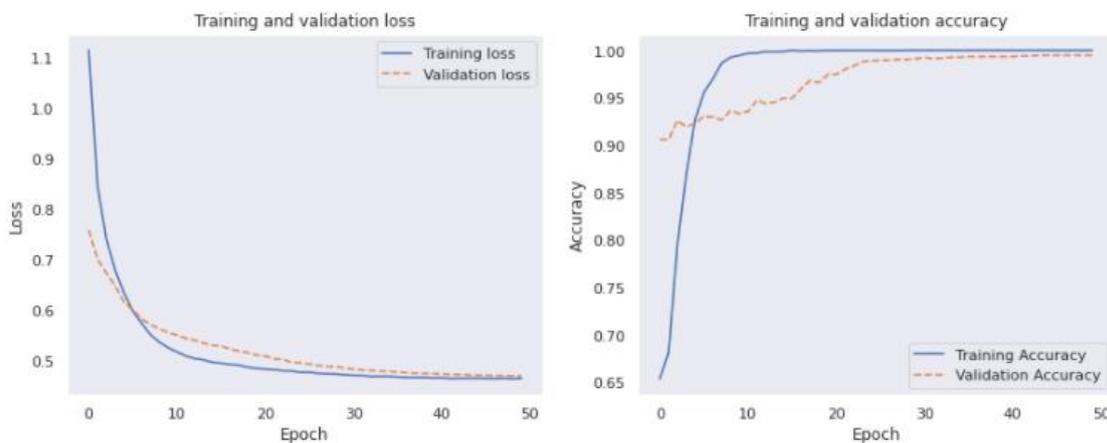


Figure 18

- ✓ Le modèle est arrivé à une précision de « 99.64 ».
- **Deuxième entraînement :**

cette fois le modèle est entièrement entraînable et a été ajusté une fois de plus sur les mêmes données, dans cette phase, l'optimiseur de descente de gradient stochastique avec un taux d'apprentissage initial de $1e-4$.

Le nombre d'époques dans la première phase a été de 50, 100 itérations ont été considérées dans la deuxième phase.

Comme c'est montré dans la figure suivante :

```
def fine_tune(OPTIMIZER, LOSS, METRICS):
    for layer in model.layers[-54:]:
        if not isinstance(layer, BatchNormalization):
            layer.trainable = True

    model.compile(optimizer = Fine_Tune_OPTIMIZER, loss = LOSS, metrics = METRICS)
    return model

with strategy.scope():
    model = fine_tune(Fine_Tune_OPTIMIZER, LOSS, METRICS)
```

- **Résultat du deuxième entraînement**

Après la fin d'entraînement on arrive aux résultats suivant :

```
model = load_model(Fine_Tune_filepath)

results = model.evaluate(test_ds, return_dict=True)
print ('\nModel Evaluation:')
print(results['accuracy']*100)

2/2 [=====] - 57s 8s/step - loss: 0.3617 - accuracy: 0.9994

Model Evaluation:
99.94075894355774
```

La fonction de perte est minimisée a 0.36 ainsi que Le modèle est arrivé à une précision de 99.94.

III. Evaluation des performances :

Nous avons utilisé les mesures de performances suivantes pour évaluer et montrer l'efficacité de notre modèle :

- la justesse (accuracy) : La justesse ou (the accuracy en Anglais) est l'un des critères permettant d'évaluer les modèles de classification.

Elle désigne la proportion des prédictions correctes effectuées par le modèle, l'équation représente la formule de calcul de cette mesure :

Tel que :

$$\textit{Accuracy} = \frac{\textit{TruePositive} + \textit{TrueNegative}}{\textit{TruePositive} + \textit{FalsePositive} + \textit{FalseNegative} + \textit{TrueNegative}}$$

TruePositive Le résultat où le modèle prédit correctement ; c'est la classe positive (valeur 1), la prédiction est effectuée sur la base de données de test.

TrueNegative Le résultat où le modèle prédit correctement ; la classe négative (valeur 0), la prédiction est effectuée sur la base de données de test.

FalsePositive Le résultat où le modèle prédit incorrectement la classe positive (valeur 1), la prédiction est effectuée sur la base de données de test.

FalseNegative Le résultat où le modèle prédit incorrectement la classe négative (valeur 0), la prédiction est effectuée sur la base de données de test.

- La précision : Elle mesure le pourcentage de valeurs positives ***TruePositive*** qui sont réellement correctes. Autrement dit, on vérifie si le modèle obtient des valeurs positives par rapport au nombre total des valeurs positives dans la base de données de test, elle est calculée en utilisant l'équation

$$\textit{Précision} = \frac{\textit{True_Positive}}{(\textit{True_Positive} + \textit{False_Positive})}$$

- ✓ La Sensibilité : Elle mesure le pourcentage de valeurs positives correctement identifiées (*TruePositive*) par le modèle (e.g. le pourcentage de patients correctement identifiés comme atteints par la maladie). Elle représente également le rappel (the recall) du modèle ou la sensibilité du modèle. Elle est calculée en utilisant l'équation :

$$\text{Sensibilité} = \text{Recall} = \frac{\text{True_Positive}}{(\text{True_Positive} + \text{False_Negative})}$$

- ✓ La Spécificité: Elle mesure le pourcentage de valeurs négatives correctement identifiées (*TrueNegative*) par le modèle (e.g. le pourcentage de patients correctement identifiés qu'ils ne sont pas atteints par la maladie), elle est calculée en utilisant l'équation

$$\text{Spécificité} = \frac{\text{True_Negative}}{(\text{True_Negative} + \text{False_Positive})}$$

- ✓ F1-mesure : Le F1-mesure (également F-score ou score F1) il mesure la similarité de deux échantillons, il calculé à partir de la précision et le rappel du modèle, l'équation calcule le F1-mesure:

$$\text{F1 - mesure} = 2 \cdot \frac{\text{précision} \times \text{Sensibilité}}{\text{précision} + \text{Sensibilité}}$$

Nous avons utilisé des mesures pour évaluer la performance du modèle proposé, en utilisant une matrice de confusion. Sur la base de cette matrice de confusion, la spécificité et la sensibilité dans la mesure et l'analyse des performances du modèle proposé ont été calculées, où la spécificité a été définie comme la capacité du classificateur à identifier correctement les individus sans COVID-19 (taux vrai-négatif). La sensibilité a été définie comme la capacité du classificateur à identifier correctement les individus atteints de COVID-19 (taux de vrais positifs). Ces évaluations ont été effectuées en les utilisant.

Ci-dessous représente la matrice de confusion figure 19).

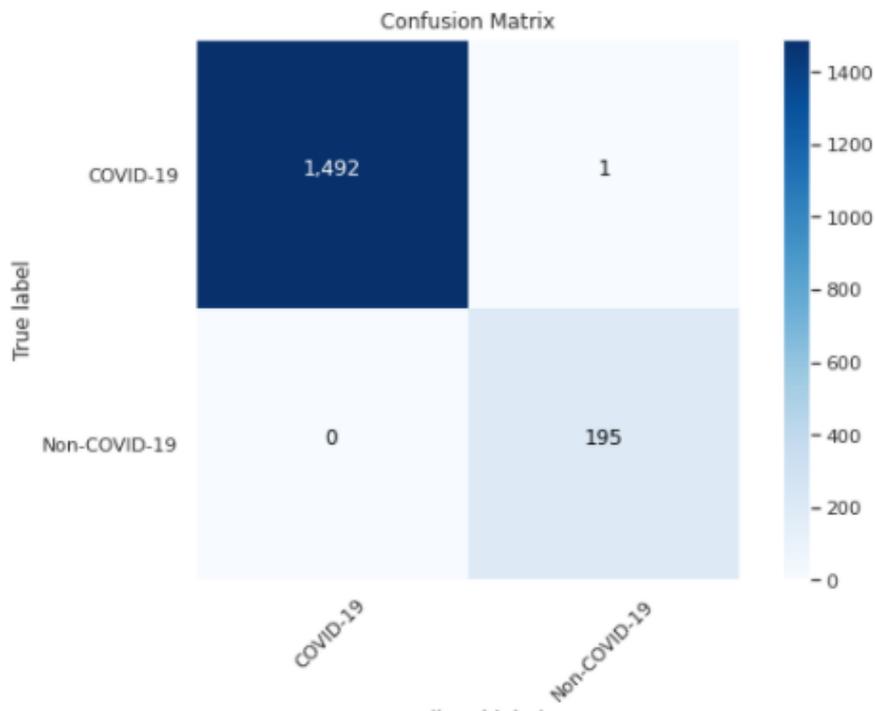


Figure 19

On voit sur les donne de test qu'on a 1492 covid19 le modèle les a bien classée comme cas covid 19 et 195 cas non covid les a classer non covid alors qu'un seul cas covid19 il l'a classer non covid.

Pour des mesures de performances en détaille voici les résultats dans la figure ci-dessus:

Other Metrics:

MSE: 0.0005924170616113745

Accuracy: [0.99940758 0.99940758]

Precision (positive predictive value): [1. 0.99489796]

Recall (Sensitivity, hit rate, true positive rate): [0.99933021 1.]

Specificity (true negative rate): [1. 0.99933021]

➤ **Observation**

Nous avons observé qu'avec l'augmentation des époques, le modèle avait un taux d'erreur plus faible, et donc une précision accrue pour les données inconnues, ce qui suggère que le modèle a un potentiel élevé pour détecter de nouveaux cas de COVID-19 à partir des tomodensitogrammes. Le modèle détecte tous les cas de COVID-19 et non COVID-19 parmi les images de l'ensemble de tests étaient de 0,003938, ce qui était significativement inférieur à celui rapporté dans les études précédentes.

IV. Conclusion :

La RT-PCR est la méthode définitive pour diagnostiquer le COVID-19. Cependant, le test d'acide nucléique prend beaucoup de temps et l'analyse des expectorations peut prendre plusieurs jours. Le coût élevé et la faible sensibilité de ce test ont causé des problèmes majeurs aux systèmes de santé pendant la pandémie.

Par conséquent, les personnes présentant des résultats faussement négatifs à la RT-PCR ont été une source de transmission du virus et ont propagé le virus à d'autres. Lorsque l'OMS a souligné la nécessité d'augmenter les tests de diagnostic et d'évaluer de manière exhaustive les individus suspects, les médecins et les systèmes de santé ont été encouragés à utiliser des tests moins chers et plus rapides.

Lors de la tentative de détection de COVID-19 à ses stades initiaux, un scanner pulmonaire ne montre pas toujours les zones de consolidation pulmonaire, et dans de nombreux cas. Les modèles d'apprentissage automatique peuvent améliorer l'efficacité des méthodes de diagnostic radiologique et constituer une alternative appropriée au test « RT-PCR ». Le cœur du système de « SAD » conçu dans cette étude est basé sur une architecture CNN profonde

NASNet a été utilisé ici car il pourrait déterminer la meilleure architecture pour le modèle.

Le système proposé peut être utilisé dans les centres de diagnostic comme méthode fiable pour détecter les personnes atteintes de COVID-19 avec une grande précision dans les premiers stades de la maladie.

Bibliographie

- 1) Ni Q, Sun ZY, Qi L, Chen W, Yang Y, Wang L, et al. A deep learning approach to characterize 2019 coronavirus disease (COVID-19) pneumonia in chest CT images. Eur Radiol 2020 Dec;30(12):6517-6527
- 2) Hasan AM, Al-Jawad MM, Jalab HA, Shaiba H, Ibrahim RW, Al-Shamasneh AR. Classification of Covid-19 Coronavirus, Pneumonia and Healthy Lungs in CT Scans Using Q-Deformed Entropy and Deep Learning Features. Entropy (Basel) 2020 May
- 3) Nishiura H, Jung S, Linton NM, Kinoshita R, Yang Y, Hayashi K, et al. The Extent of Transmission of Novel Coronavirus in Wuhan, China, 2020. J Clin Med 2020 Jan 24
- 4) Wang L, Lin Z, Wong A. COVID-Net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images. Sci Rep 2020 Nov
- 5) WHO Coronavirus Disease (COVID-19) Dashboard. World Health Organization. URL: <https://covid19.who.int/>
- 6) Chung M, Bernheim A, Mei X, Zhang N, Huang M, Zeng X, et al. CT Imaging Features of 2019 Novel Coronavirus (2019-nCoV). Radiology 2020
- 7) R. N. Keiron O'Shea, «An Introduction to Convolutional Neural Networks»
- 8) A. Mathew, «Deep Learning Techniques: An Overview,» chez Advanced Machine Learning Technologies and Applications , springer, january 2021
- 9) N. Bostrom, «Machine intelligence is the last invention that humanity will ever need to make,» TED, march 2015.
- 10) A. Subasi, Practical Machine Learning for Data Analysis Using Python, Academic Press, June 21, 2020.
- 11) J. Alzubi, «Machine Learning from Theory to Algorithms: An Overview,» Journal of Physics
- 12) V. Nasteski, «An overview of the supervised machine learning methods,» 2017

- 13) A. Ng, « Linear regression with one variable – Cost Function,» 2014. [En ligne]
- 14) N. A. J. K. A. Shadman Sakib, «An Overview of Convolutional Neural Network: Its Architecture and Applications,» november 2018
- 15) R. N. Keiron O'Shea, «An Introduction to Convolutional Neural Networks».
- 16) A. Pant, «Introduction to Logistic Regression,» 22 january 2019
- 17) S. Shetty, «Deep Learning Algorithms and Applications in Computer Vision,»
INTERNATIONAL JOURNAL OF COMPUTER SCIENCES AND ENGINEERING