



HAL
open science

Détection de COVID-19 à partir des images radiographies thoraciques

Abdelbaki Souid, Hedi Sakli

► **To cite this version:**

Abdelbaki Souid, Hedi Sakli. Détection de COVID-19 à partir des images radiographies thoraciques. Colloque sur les Objets et systèmes Connectés - COC'2021, IUT d'Aix-Marseille, Mar 2021, MARSEILLE, France. ⟨hal-03593716⟩

HAL Id: hal-03593716

<https://hal.science/hal-03593716v1>

Submitted on 2 Mar 2022

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



HAL Authorization

Détection de COVID-19 à partir des images radiographies thoraciques

Abdelbaki Souid^{1*}, Hedi Sakli^{1,2}

¹ MACS Laboratory, RL16ES22, National Engineering School of Gabes, University of Gabes, 6029 Gabes, Tunisia; AbdelbakiSouid@gmail.com

² EITA Consulting, 5 Rue du Chant des Oiseaux, 78360 Montesson, France; hedi.s@eitaconsulting.fr

* Correspondence: SouidAbdelbaki@gmail.com

RESUME : La pandémie COVID-19 continue d'avoir un effet dévastateur sur la santé et le bien-être de la population mondiale. Une étape critique dans la lutte contre le COVID-19 est le dépistage efficace des patients infectés, l'une des principales approches de dépistage étant l'examen radiologique utilisant la radiographie thoracique. Il a été constaté dans les premières études que les patients présentaient des anomalies dans les images de radiographie thoracique qui sont caractéristiques des personnes infectées par COVID-19. Motivés par cela et inspirés par les efforts open source de la communauté de recherche, nous proposons une approche qui sert à détecter et classifier le COVID-19 à partir de trois classes, la base données, qui été une collection des petites bases due à la difficulté de la collection des données, contient plus de 6000 échantillons dépendant de l'un de ces classes. Notre approche a accompli un rapport d'exactitude dépasse 99%. Notre résultat est obtenu à partir de l'utilisation du Cloud qui joue un rôle critique et de l'importance de l'internet des objets dans le domaine médical et spécifiquement dans le traitement d'imagerie médicale.

Mots clés : Cloud, Internet des objets, CNN, Apprentissage profond, Imagerie médicale.

1 INTRODUCTION

La pandémie de la maladie du nouveau coronavirus 2019 (COVID-19) est une pandémie en cours causée par le coronavirus 2 du syndrome respiratoire aigu sévère (SRAS-CoV-2). Au 08 Jan 2021, plus de 119 millions de cas de COVID-19 ont été signalés dans 223 pays, régions et territoires, résultant plus de 2 millions décès [1]. Pour contrôler la propagation du COVID-19, un dépistage efficace des patients est essentiel. Jusqu'à présent, le procédé de criblage étalon-or est le test de réaction en chaîne de polymérase-transcription inverse (RT-PCR) qui a été conçu pour détecter SRAS-CoV-2 génétiquement. Mais il n'a qu'un taux positif compris entre 30% et 60% [2,3]. Pour les patients qui développent des maladies graves telles que la pneumonie et le SDRA, une bonne méthode de dépistage complémentaire est l'examen radiographique, où l'imagerie par radiographie thoracique (par exemple, radiographie ou tomodensitométrie (TDM)) est analysée pour le SRAS-CoV-2 viral ; Indicateurs d'infection, y compris les opacités bilatérales et périphériques en verre dépoli et les consolidations pulmonaires [4]. Cependant, les indicateurs d'infection virale peuvent être subtils et il est difficile pour les radiologues de distinguer la pneumonie Covid-19 des cas normaux ou autre pneumonie. Ainsi, les systèmes de diagnostics assistés par ordinateur qui peuvent aider à détecter la pneumonie COVID-19 dans les images de radiographie thoracique sont fortement souhaités.

Dans le domaine de l'apprentissage en profondeur, les réseaux de neurones convolutionnels (CNN) sont généralement utilisés pour résoudre les problèmes de détection d'objets et de classification d'images en raison de leur capacité à préserver la structure spatiale et à reconnaître les caractéristiques de l'image. En 2016, le neural Xception réseau (XceptionNet) a été proposé

dans l'ILSVRC (ImageNet Large Scale Visual Recognition Challenge) avec 71 couches [5]. Il a atteint l'erreur top-5 à 3,6%, ce qui est inférieur à l'erreur humaine 5,1%. C'est la première fois qu'un modèle CNN surpasse l'humain dans les tâches de reconnaissance d'objets à grande échelle et il marque un avenir prometteur pour les modèles CNN.

Le but de cette recherche est d'évaluer l'efficacité de notre réseau de neurones convolutionnels proposé dans le diagnostic automatique de Covid-19 à partir de radiographies thoraciques. Pour ce faire, On a traité et utilisé une Dataset de 6432 CXR (Chest X-Ray) pour former et tester notre model. En raison du fait que la taille des échantillons liés à Covid-19 est petite (224 images), l'apprentissage par transfert est une stratégie préférable pour former des CNN profonds. Cela est dû au fait que les CNN sont des modèles sophistiqués nécessitant des ensembles de données à grande échelle pour effectuer une extraction et une classification précises des entités. Avec l'apprentissage par transfert, la rétention des connaissances extraites d'une tâche est la clé pour effectuer une tâche alternative.

Nos résultats sont de bon augure et démontrent l'efficacité du Deep Learning, et plus spécifiquement, le transfert de l'apprentissage avec les CNN à la détection automatique d'images radiographiques anormales liées à la maladie Covid-19.

2 METHODE

2.1 Ensemble de données de l'étude

Aux fins des expériences, plusieurs sources de rayons X ont été consultées. Tout d'abord, le référentiel Github a été analysé pour les ensembles de données connexes. Une collection d'images CXR de Cohen [6] a été sélectionnée, Aussi, Dataset collecté par Audrey Chung et al

[7]. Ensuite, une collection de radiographies de pneumonie commune a été ajoutée à l'ensemble de données, pour former les CNN à distinguer Covid-19 de la pneumonie commune. Cette collection est disponible sur Internet par Kermamy et al. [8].

Les données collectées comprennent 576 images avec Covid-19 confirmé, 4273 images avec pneumonie commune confirmée et 1583 images d'état normal. La figure 1 illustre les trois classes. Pour les images de différents rapports de pixels et pour éviter toute distorsion, un fond noir de rapport 1: 1,5 a été ajouté pour obtenir une remise à l'échelle parfaite à 200x266. On doit noter que les CNN sont capables d'ignorer une légère variance de position, c'est-à-dire qu'ils recherchent des motifs non seulement vers une position spécifique de l'image, mais également des motifs en mouvement.

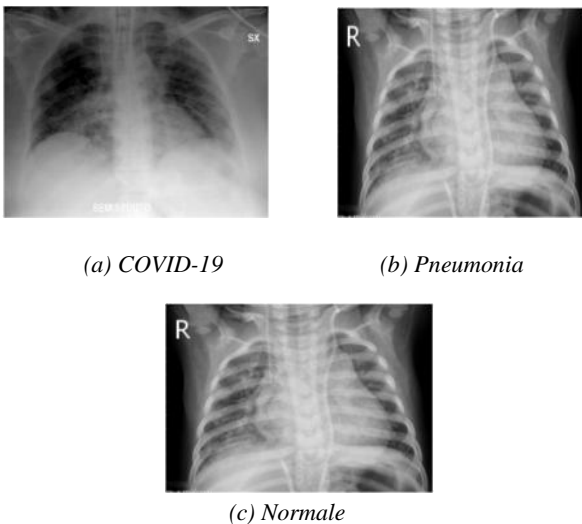


Figure 1 Classes des maladies incluse dans le Dataset

2.2 Modèle

Notre objectif est de créer un CNN pour reconnaître rapidement et efficacement les images radiographiques pulmonaires. Par rapport aux réseaux largement utilisés, ResNet50 [9] et DenseNet121 [10], nous adoptons le réseau léger Xception [5]. Le système de la reconnaissance des images radiographiques thoraciques est illustré à la figure 2. On a fait la préparation du Dataset (Ensemble du données). Ensuite, on divise le Dataset en deux parties, 80% pour l'apprentissage et 20% pour le test, puis télécharger le Dataset sur un Cloud Storage. Cette procédure sert à minimiser les temps d'apprentissage tant que nous faisons notre apprentissage sur instance du calcul IA sur le Cloud. Après avoir fini de la phase d'apprentissage, nous obtenons le nouveau poids. On test alors le model.

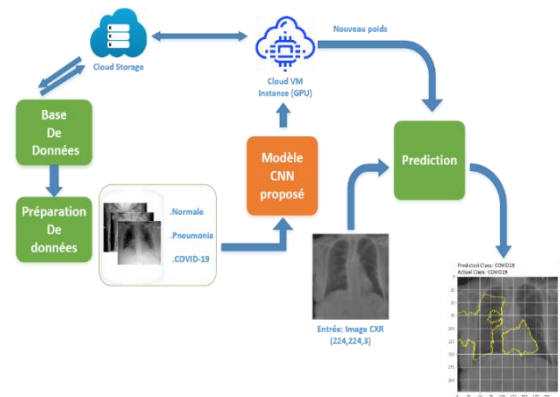


Figure 2 Architecture générale du Classificateur COVID-19.

Pour que le Dataset soit utilisable, nous faisons des modifications. Dans un premier temps, on a minimisé le nombre des échantillons de la classe Pneumonia de 4273 à 2565 échantillons, aussi pour la classe normale de 1583 à 1267 échantillons. Le Dataset est divisé en deux parties 80% d'apprentissage et 20% de test, dans la partie de données d'apprentissage. On a appliqué la méthode d'augmentation des données (cette dernière est essentielle pour éviter le sur-ajustement) et redimensionner à (224,224,3). L'augmentation de données est concentrée à faire des déformations et des répliques sur les échantillons d'apprentissage, qui sont : pivotement horizontale et verticale avec un taux de 0.3, retournement horizontale, redimensionnement et normalisation des échantillons.

Notre Modèle est constitué de trois blocs, le premier bloc est un poids du réseau de neurone Xception [5] préformé sur le Dataset ImageNet [11] (ImageNet c'est une très grande Dataset utilisé dans ILSVRC). Ce réseau est connu par son rapport d'exactitude et sa légère taille ainsi que sa période de latence. Il est connu aussi par son architecture et spécifiquement la structure de convolution séparable en profondeur, qui consiste en une convolution en profondeur (une convolution spatiale effectuée indépendamment pour chaque canal) suivie d'une convolution ponctuelle (une convolution 1x1 à travers les canaux). Le deuxième bloc est le bloc d'extraction de caractéristique, avec une couche de convolution d'un filtre de dimension 3x3 et stride de 3 puis, une couche GlobalAveragePool2D suivi par une couche BatchNormalization, comme illustré dans la figure 3. On a utilisé deux couches Dropout avec un taux de 0.5 but à minimiser le risque de sur-apprentissage, et une couche Fully Connected avec 512 unités qui connecte toutes les couches.

Nous avons entraîné le modèle pendant 120 époques avec un pas de 160 et nous avons utilisé l'optimiseur Adam avec un taux d'apprentissage de 0.0001. Pour l'erreur nous avons utilisé l'entropie croisée catégorique. Pour optimiser la phase d'apprentissage, nous

avons utilisé les méthodes suivantes : LearningRateScheduler, Au début de chaque époque, ce rappel obtient la valeur de taux d'apprentissage mise à jour de la fonction de planification fournie, avec l'époque actuelle et le taux d'apprentissage actuel, et applique le taux d'apprentissage mis à jour sur l'optimiseur. ReduceLROnPlateau est importante par ce que le modèle bénéficie souvent d'une réduction du taux d'apprentissage d'un facteur de 2 à 10 une fois que l'apprentissage stagne. Ce callback surveille une quantité et si aucune amélioration n'est observée pour un nombre d'époques «patience», le taux d'apprentissage est réduit.

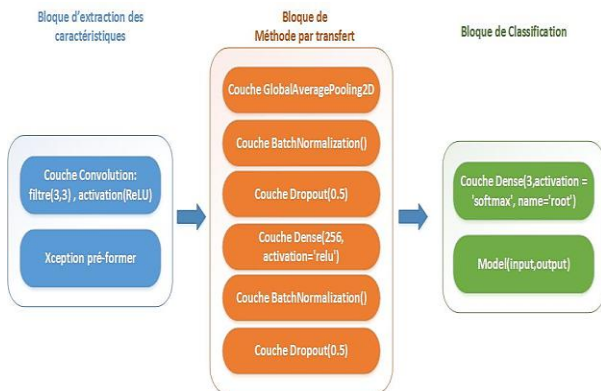


Figure 3 Architecture de notre modèle proposé

Pour tester la performance de notre approche, nous avons utilisés les métriques d'évaluation suivantes :

$$Exactitude = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Précision = \frac{TP}{TP + FP} \quad (2)$$

$$Rappel = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = \frac{2 \times précision \times rappel}{précision + rappel} \quad (4)$$

3 EVALUATION DE PERFORMANCE

Dans cette section, en vas discuter la performance de notre approche. Le tableau 1 présente les quatre métriques proposées dans la section précédente, qui sont le Rappel, Précision, Exactitude et F1-Score.

Tableau 1 Résultat de la performance du Modèle en fonction de : Précision, Rappel et F1-Score.

Classes	Précision	Rappel	F1-Score
COVID-19	0.60	0.68	0.60
NORMALE	0.21	0.24	0.23
PNEUMONIA	0.65	0.62	0.64
Moyen	0.48	0.51	0.49

Pour la classe COVID-19, on a un F1-score de 0.60. On peut dire que le système fait une prédiction exacte avec les échantillons COVID-19 ; au contraire le modèle fournit un résultat faible pour la classe Normale. Le résultat de la classe PNEUMONIA est le meilleur.

Le rapport d'exactitude fournit un bon résultat avec 99.55% en entrainement et 92,3% en validation et une différence de 4% entre l'entrainement et le test. Le résultat du rapport d'exactitude est illustré dans la figure 4. Le courbe d'exactitude de test fait des pics c'est un signe de sur ajustement provoquer par l'utilisation de la méthode par transfert.

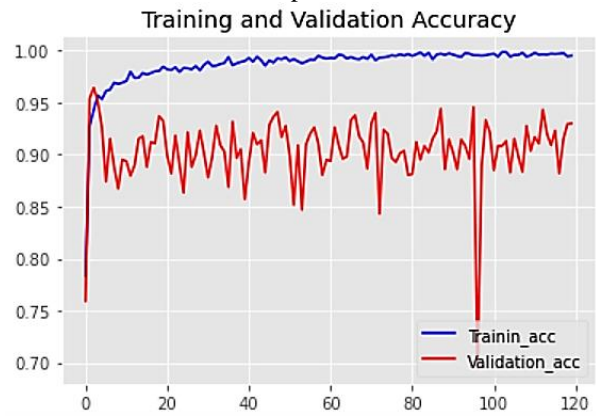


Figure 4 Courbe de métrique d'exactitude. En bleu entrainement et en rouge test.

Notre méthode fait l'état de l'art de la détection du COVID-19 à partir des image CRX.

4 CONCLUSION

D'après les résultats, il est démontré que la stratégie d'apprentissage de transfert avec CNNs peut avoir des effets significatifs sur la détection automatique et l'extraction automatique des caractéristiques essentielles à partir d'images à rayons X, liés au diagnostic de la Covid-19.

Certaines limites de l'étude particulière peuvent être surmontées dans des futures recherches. En particulier, une analyse plus approfondie nécessite beaucoup plus de données sur les patients, spécifiquement ceux qui souffrent de Covid-19. De plus, il est nécessaire de développer des modèles capables de distinguer les cas de Covid-19 d'autres cas viraux similaires, comme le SRAS, mais aussi d'une plus grande variété de pneumonies courantes ou même de radiographies physiologiques.

Notre approche contribue à la possibilité d'un diagnostic peu coûteux, rapide et automatique de la maladie et peuvent être cliniquement exploités dans un proche avenir. Elle présente de nombreux avantages, dont le plus important est de ne pas obliger le personnel infirmier et médical à contacter la flambée potentielle ; ce qui est particulièrement important pendant la période de propagation de la maladie.

Bibliographie

- [1] World Health Organization. "Coronavirus disease (COVID-19) outbreak situation." <https://www.who.int/emergencies/diseases/novel-coronavirus-2019>, 2020. [Online; accessed 08-January-2021].
- [2] Tao Ai, Zhenlu Yang, Hongyan Hou, Chenao Zhan, Chong Chen, Wenzhi Lv, Qian Tao, Ziyong Sun, and Liming Xia. "Correlation of chest CT and RT-PCR testing in coronavirus disease 2019 (COVID-19) in China: a report of 1014 cases." *Radiology*, p. 200642, 2020.
- [3] Y Yang, M Yang, C Shen, F Wang, J Yuan, J Li, M Zhang, Z Wang, L Xing, J Wei, et al. "Evaluating the accuracy of different respiratory specimens in the laboratory diagnosis and monitoring the viral shedding of 2019-nCoV infections. MedRxiv 2020: 2020.02.11.20021493." Sólo en caso de urgencia y si no se cuenta con otro donante podrá ser recolectado evaluando cuidadosamente los riesgos y beneficios. Podría volver a ser elegido si no tuvo historia de infección respiratoria severa, hayan transcurrido, 28.
- [4] Sana Salehi, Aidin Abedi, Sudheer Balakrishnan, and Ali Gholamrezanezhad. "Coronavirus disease 2019 (COVID-19): a systematic review of imaging findings in 919 patients." *American Journal of Roentgenology*, pp. 1–7, 2020.
- [5] Chollet, François. "Xception: Deep Learning with Depthwise Separable Convolutions". arXiv:1610.02357 [cs], avril 2017. arXiv.org, arxiv.org/abs/1610.02357.
- [6] Cohen JP (2020) COVID-19 image data collection. <https://github.com/ieee8023/covid-chestxray-dataset>
- [7] Audrey Chung (2020) Figure 1 COVID-19 Chest X-ray Dataset Initiative. <https://github.com/agchung/Figure1-COVID-chestxray-dataset>
- [8] Kermany, Daniel S., et al. "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning". *Cell*, vol. 172, no 5, février 2018, p. 1122-1131.e9. doi:10.1016/j.cell.2018.02.010.
- [9] He, Kaiming, et al. "Deep Residual Learning for Image Recognition". arXiv:1512.03385 [cs], décembre 2015. arXiv.org, <http://arxiv.org/abs/1512.03385>.
- [10] Huang, Gao, et al. « Densely Connected Convolutional Networks ». arXiv:1608.06993 [cs], janvier 2018. doi: [/abs/1608.06993](https://arxiv.org/abs/1608.06993).
- [11] J. Deng, W. Dong, R. Socher, L. Li, Kai Li and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database," 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, USA, 2009, pp. 248-255, doi: 10.1109/CVPR.2009.5206848.
- [12] JMartín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Ian Goodfellow, Andrew Harp, Geoffrey Irving, Michael Isard, Rafal Jozefowicz, Yangqing Jia, Lukasz Kaiser, Manjunath Kudlur, Josh Levenberg, Dan Mané, Mike Schuster, Rajat Monga, Sherry Moore, Derek Murray, Chris Olah, Jonathon Shlens, Benoit Steiner, Ilya Sutskever, Kunal Talwar, Paul Tucker, Vincent Vanhoucke, Vijay Vasudevan, Fernanda Viégas Oriol Vinyals, Pete Warden, Martin Wattenberg, Marti Wicke, Yuan Yu, and Xiaoqiang Zheng. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Software available from [tensorflow.org](https://www.tensorflow.org).
- [13] Abadi, M.; Agarwal, A.; Barham, P.; Brevdo, E.; Chen, Z.; Citro, C.; Corrado, G.S.; Davis, A.; Dean, J.; Devin, M.; et al. TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems. 2015. Available online: [tensorflow.org](https://www.tensorflow.org) (accessed on 31 May 2020).