



Detecção de Covid-19 em Imagens de Raio-x Utilizando Redes Convolucionais

COVID-19 Detection in X-Ray Images Using Convolutional Neural Networks

Detección de Covid-19 en Imágenes de Rayos X Utilizando Redes Convolucionales

Pedro Paulo de Souza Leão¹, Natalia de Sousa Freire¹, Rafael Albuquerque Pinto², Kely Maciel Braule Pinto³, Rafael Giusti⁴, Eulanda Miranda dos Santos⁴

RESUMO

Descritores: Covid-19;
Aprendizado de Máquina

Objetivo: Este trabalho investiga diferentes abordagens de utilização de redes de convolução (CNNs) para diferenciar Pneumonia causada por Covid-19 de Pneumonia causada por outras doenças, e casos sem Pneumonia. Os dados utilizados são imagens de raio-x. **Método:** Duas abordagens de treinamento de CNNs são empregadas: CNN sem transferência de aprendizado e CNN treinada com transferência de aprendizado. Além disso, o problema de classificação é tratado em dois cenários: 1) duas classes e 2) três classes. **Resultados:** A abordagem sem transferência de aprendizado mostrou-se melhor no cenário com duas classes (acurácia 85,37% contra 82,11%), enquanto a segunda abordagem foi ligeiramente superior no cenário 2 (acurácia 87,91% vs 86,26%). **Conclusão:** Os resultados são interessantes e mostram que o desempenho dos métodos investigados pode variar ao modificarmos o cenário de avaliação, porém, ajustes dos parâmetros são necessários para que as conclusões sejam mais precisas.

ABSTRACT

Keywords: COVID-19;
Machine Learning

Objective: In this work we investigate different approaches to use Convolutional Neural Networks (CNN) to classify Pneumonia due to COVID-19, Pneumonia caused by other diseases, and no finding cases. The dataset used is composed of X-ray images. **Method:** Two different approaches for training CNN are employed: CNN with no transfer learning and CNN trained with transfer learning. In addition, the classification problem is dealt with in two scenarios: 1) two classes and 2) three classes. **Results:** The approach using no transfer learning was better in the first scenario (accuracy 85.37% versus 82.11%), while the second approach was slightly superior in the multi-class scenario (accuracy 87.91% versus 86.26%). **Conclusion:** The results are interesting and show that the performance of these methods may vary when we modify the classification scenario. However, a better process of tuning the parameters is necessary for more accurate conclusions.

RESUMEN

Descriptores: Covid-19;
Aprendizaje Automático

Objetivo: En este trabajo investigamos diferentes enfoques que utilizan redes neuronales de convolución (CNN) e imágenes de rayos X para diferenciar la neumonía causada por Covid-19 de la neumonía causada por otras enfermedades y casos sin neumonía. **Método:** Comparamos el ajuste del modelo CNN sin transferencia de aprendizaje y con transferencia de aprendizaje. También evaluamos el problema de clasificación con dos y tres clases. **Resultados:** El enfoque sin transferencia de aprendizaje es mejor en el escenario con dos clases (precisión 85,37% versus 82,11%), mientras que el segundo enfoque fue ligeramente superior en el escenario con 3 clases (precisión 85,37% versus 82,11%). **Conclusión:** Los resultados son interesantes y muestran que el desempeño de los métodos investigados varía cuando modificamos el escenario de evaluación, siendo necesarios ajustes más finos de los parámetros para alcanzar conclusiones más precisas.

¹ Aluno de Graduação do Instituto de Computação, Universidade Federal do Amazonas, Manaus (AM), Brasil.

² Aluno de Mestrado em Informática, Universidade Federal do Amazonas, Manaus (AM), Brasil.

³ Aluna de Doutorado em Informática, Universidade Federal do Amazonas, Manaus (AM), Brasil. Pesquisadora, Sidia Instituto de Ciência e Tecnologia, Manaus (AM), Brasil.

⁴ Professor do Instituto de Computação, Universidade Federal do Amazonas, Manaus (AM), Brasil.

INTRODUÇÃO

O coronavírus pertence a uma família de vírus (CoV) que pode causar desde resfriados comuns a doenças mais graves, como a Síndrome Respiratória Aguda Severa (SARS, do inglês *Severe Acute Respiratory Syndrome*) e a Síndrome Respiratória do Oriente Médio (MERS, de *Middle-East Respiratory Syndrome*). O novo coronavírus recebeu a denominação SARS-CoV-2 pela Organização Mundial da Saúde (OMS) e a doença que ele provoca tem a denominação Covid-19⁽¹⁾.

Embora o vírus seja recente, é possível identificar um número significativo de trabalhos que propõem métodos que empregam técnicas de Aprendizagem de Máquina (AM) para diagnóstico automático da Covid-19 a partir de imagens. A literatura que envolve esse tipo de aplicação mostra que dados de Radiologia são muito utilizados no desenvolvimento de soluções baseadas em AM⁽²⁾.

A Radiologia é um braço da medicina responsável pelo diagnóstico por imagens e tratamento de doenças. Os tipos mais comuns de imagens radiográficas incluem tomografias computadorizadas, raio-x e imagens de ressonância magnética⁽³⁾. No caso de uso com algoritmos de AM, imagens de raio-x do tórax e de tomografia computadorizada são vitais para esse tipo de diagnóstico. Dentre essas duas fontes de informação, imagens de raio-x são interessantes porque possuem menor custo associado, têm aquisição mais rápida e são mais amplamente disponíveis⁽⁴⁾. Outro fator interessante a observar é a disponibilidade pública de dados anotados de raio-x que podem ser usados no desenvolvimento de soluções⁽²⁾.

Considerando esse contexto, dentre os trabalhos que utilizam imagens de raio-x, a maioria tem como objetivo realizar classificação binária, *i.e.*, entre os casos de Covid-19 detectados e os não detectados (equivalente em inglês a *No-Finding*). Entretanto, há também trabalhos que tentam identificar pneumonia causada por Covid-19 e diferenciá-la de outros tipos de pneumonia, além de também considerar a classe de casos não detectados (classe normal). Em termos de estratégias empregadas, observa-se o domínio de redes neurais profundas, mais precisamente Redes de Convolução (CNN, do inglês *Convolutional Neural Networks*), seja para segmentação e/ou para extração de características e classificação⁽²⁾. Em termos de métodos que não fazem segmentação, as soluções baseadas em CNN podem ser divididas em dois grupos: 1) métodos que empregam redes relativamente rasas com treinamento do zero⁽⁵⁻⁶⁾; e 2) métodos que usam modelos profundos com apoio de transferência de aprendizado⁽⁷⁻⁸⁾.

Dentre os trabalhos do primeiro grupo, Duran-Lopez et al.⁽⁵⁾ propõem um sistema denominado COVID-XNet, que classifica imagens de raio-x frontal do tórax em duas classes: Covid-19 e normal. Nesse trabalho, depois de aplicar a etapa de pré-processamento, as imagens obtidas são usadas como entrada para um modelo de CNN que foi treinado do zero para realizar a classificação bi-classe. O modelo proposto possui a seguinte arquitetura: cinco camadas de convolução, quatro de agrupamento máximo (*MaxPooling*), uma de agrupamento médio global (*GAP*) e uma camada *softmax* final. Os autores mostraram que o

COVID-XNet atingiu acurácia superior a 90% na base de dados investigada.

Outro trabalho do primeiro grupo é o DarkCovidNet, proposto por Ozturk et al.⁽⁶⁾ para o diagnóstico automático da Covid-19. O modelo é baseado na arquitetura Darknet-19⁽⁹⁾ e foi aplicado em imagens de raio-x de tórax para prover o diagnóstico da doença sem a necessidade de utilização de métodos de extração de características. Os experimentos foram executados em dois cenários diferentes. Primeiramente, o modelo foi utilizado para classificar as imagens em três categorias, que obteve acurácia de 87,02%: Covid-19, normal e Pneumonia. Posteriormente, o modelo foi treinado para detectar apenas duas classes, que teve acurácia de 98,08%: Covid-19 e normal. A arquitetura da rede consiste em 17 camadas de convolução, 5 camadas de agrupamento máximo, além da camada de saída. Os resultados dos experimentos mostraram que a taxa de acurácia obtida no problema de classificação binária é 10% superior à taxa obtida na classificação multiclasse.

Conforme ocorre em diversas aplicações práticas de visão computacional que empregam soluções baseadas em CNN, o uso de transferência de aprendizado é amplamente difundido. Por exemplo, Hemdan et al.⁽⁷⁾ compararam sete CNNs pré-treinadas, as quais foram aplicadas em imagens de raio-x no intuito de realizar o diagnóstico automático da Covid-19. Os autores consideraram apenas o problema de classificação binária em: Covid-19 e normal. Dentre os sete classificadores testados, os modelos VGG19 e DenseNet201 produziram os melhores desempenhos nos resultados experimentais, com acurácia de 90% obtida por ambos os classificadores.

Narin et al.⁽⁸⁾ também desenvolveram um método de predição automática de Covid-19 em imagens de raio-x de tórax usando modelos de CNN pré-treinados. Os autores compararam três arquiteturas de rede: ResNet50, InceptionV3 e Inception-ResNetV2. Eles também empregaram os classificadores para resolver um problema bi-classe, isto é, Covid-19 vs normal. Ao comparar os resultados obtidos por cada modelo de CNN, o melhor desempenho médio em todas as categorias foi obtido pela ResNet50, alcançando acurácia de 98% na base de dados testada.

Há muitos outros trabalhos que utilizam CNN com transferência de aprendizado no contexto de detecção de Covid-19 por imagens de raio-x, *e.g.*, os trabalhos de Ouchicha et al.⁽¹⁰⁾, Apostolopoulos e Mpesiana⁽¹¹⁾, Rahimzadeh e Attar⁽¹²⁾, Wang e Wong⁽¹³⁾, Kumar et al.⁽¹⁴⁾, Ahsan et al.⁽¹⁵⁾ e Cohen et al.⁽¹⁶⁾. Apesar das diferentes arquiteturas testadas, VGG e ResNet são tipos de arquiteturas bastante utilizados. Além disso, é possível observar que não há um padrão quanto à forma de classificar as instâncias: problema binário vs problema de múltiplas classes.

Com base no contexto apresentado, o objetivo deste trabalho foi investigar alguns dos pontos ainda sem consenso na literatura sobre a aplicação de CNNs na tarefa de diagnóstico de Pneumonia por Covid-19 a partir de imagens de raio-x. O primeiro ponto investigado foi: qual a melhor abordagem - treinamento do zero ou uso de transferência de aprendizado? O problema também foi

investigado nas versões de classificação binária e classificação com múltiplas classes. Por fim, dois modelos pré-treinados empregados com frequência nos trabalhos relacionados são testados em nossos experimentos na abordagem de uso de transferência de aprendizado.

MÉTODOS

Dois abordagens empregando CNN foram investigadas neste trabalho: 1) CNN composta por poucas camadas de convolução treinada sem transferência de aprendizado; e 2) modelos mais profundos pré-treinados em problema de classificação de imagens genéricas. Essas duas abordagens são descritas nas seções seguintes.

Antes, porém, é importante destacar que os mesmos valores de diversos parâmetros foram empregados nos diferentes modelos de CNN testados para facilitar a comparação entre as duas abordagens. Esses parâmetros são os seguintes. As imagens de raio-x foram redimensionadas para 224 x 224 e foi empregada a técnica de aumento de dados nas duas abordagens, por meio de operações aleatórias de rotação até 20°, deslocamento vertical até 20% e deslocamento horizontal até 20%, com inversão horizontal aleatória e cisalhamento até 15%. Exceto pelo cisalhamento, essas são deformações potenciais de imagens radiográficas. Foi feito o preenchimento por proximidade nas imagens, considerando o redimensionamento das imagens. Também foram definidos: número de épocas como 200, tamanho dos lotes como 32, conjunto de funções *callbacks* como o *checkpoint* e a parada antecipada (com espera de 30 épocas) — a parada antecipada é utilizada para evitar *overfitting*.

CNN menos profunda com treinamento do zero

A arquitetura empregada na abordagem sem transferência de aprendizado é mais profunda do que o modelo utilizado por Duran-Lopez et al.⁽⁵⁾, mas menos profunda do que o modelo proposto por Ozturk et al.⁽⁶⁾. O modelo utilizado foi proposto no trabalho de Toni Esteves¹ e foi escolhido por ser uma arquitetura intermediária entre os trabalhos supracitados, estabelecendo assim um melhor equilíbrio entre *overfitting* e *underfitting*. A CNN empregada tem a seguinte arquitetura: camada de entrada que aceita imagens 224 x 224; dez camadas convolucionais; quatro camadas de agrupamento (*pooling*), uma camada *flatten*, uma camada de *dropout* e duas camadas totalmente conectadas (FC). A figura 1 mostra a arquitetura do modelo.

Todas as camadas de *pooling* usam *Max pooling*, as camadas convolucionais utilizam a função de ativação *ReLU* e as camadas totalmente conectadas também utilizam *ReLU*, exceto a última, que usa a função de ativação

Softmax. Foi empregado o otimizador Adam com taxa de aprendizado igual a 0,001.

CNN profunda treinada com transferência de aprendizado

Para os modelos de CNN treinados com transferência de aprendizado, dois modelos frequentemente utilizados em trabalhos relacionados foram selecionados: ResNet50V2 e VGG16. Foi reproduzida a estrutura especificada por Narin et al.⁽⁸⁾. Esse processo envolve excluir o topo de cada modelo, adicionar uma camada de *pooling* médio global bidimensional e uma camada totalmente conectada com 1024 neurônios com função de ativação *ReLU*. São conduzidos experimentos de classificação binária e multiclasse, para os quais foram respectivamente selecionadas uma camada totalmente conectada com 2 e uma com 3 neurônios com ativações *Softmax*. Foi utilizado também o otimizador Adam e a taxa de aprendizado 0,0001.

Para transferência de aprendizado, foram empregados os pesos desses modelos treinados no ImageNet⁽¹⁶⁾. Por fim, ambos os modelos foram treinados com apenas o último bloco de camadas de convolução e as camadas totalmente conectadas descongelados.

Base de Dados

Neste estudo foram construídos dois conjuntos de dados, um para a realização dos experimentos de classificação binária (classes Covid-19 e sem Covid-19) e outro para a classificação multiclasse (classes Covid-19, Pneumonia e Normal).

O conjunto de dados utilizado para a classificação binária é composto por 963 imagens de raio-x de pacientes com Pneumonia, sendo que 476 imagens de raio-x pertencem à classe Pneumonia causada por Covid-19, enquanto 487 pertencem à classe Pneumonia causada por outros tipos de doenças. As instâncias da classe Covid-19 foram obtidas do repositório *Covid-19 Image Data Collection*⁽¹⁷⁾. Como essa base é desbalanceada, para compor as 476 instâncias da classe sem Covid-19, 277 imagens de pneumonia viral ou bacteriana não causada por Covid-19 foram adicionadas do repositório *Chest X-Ray Images (Pneumonia)*⁽¹⁸⁾.

O conjunto de dados para a classificação multiclasse utiliza as imagens do conjunto de dados para a classificação binária, acrescidas de 476 imagens de pulmões saudáveis do repositório *Chest X-Ray Images (Pneumonia)*⁽¹⁸⁾. A distribuição entre as classes ficou da seguinte maneira: 476 instâncias da classe Covid-19, 487 da classe Pneumonia e 476 da classe Normal.

Por fim, foi utilizada a opção de validação *holdout*, isto é, cada conjunto de dados foi dividido em três partições: 1/8 para validação, 1/8 para teste e 6/8 para treino. Como




Figura 1 – Representação do modelo de CNN treinado sem transferência de aprendizado

¹ medium.com/@estevestoni/deep-learning-e-covid-19-utilizando-de-imagens-de-raio-x-63296b5dc77a

pode haver várias instâncias de um mesmo paciente, especialmente nos dados obtidos do repositório *Covid-19 Image Data Collection*⁽¹⁷⁾, a estratificação foi orientada aos identificadores anonimizados de pacientes, de modo a não permitir que instâncias de um mesmo paciente ocorram em mais de uma partição de dados. Portanto, pacientes presentes na base de treino, por exemplo, terão todas as suas instâncias apenas na base de treino. Dessa forma, nós eliminamos um possível viés na avaliação dos resultados dos experimentos.

Métricas de Avaliação

Todos os modelos são avaliados com a partição de teste após a conclusão da fase de treinamento. Para avaliar o desempenho dos modelos foram utilizadas as métricas de acurácia (AC), precisão (PR), sensibilidade (SE) e F1-score. Dados os valores de falsos positivos (FP), verdadeiros positivos (TP), falsos negativos (FN) e verdadeiros negativos (TN), as métricas são definidas da seguinte forma:

- Acurácia: Relação entre as instâncias classificadas corretamente e o total de instâncias.

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

- Precisão: mede a precisão do modelo em relação aos casos que foram considerados positivos.

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

- Sensibilidade: proporção de casos positivos reais que são identificados corretamente.

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

- F1-score: média ponderada entre Precisão e Sensibilidade.

$$F1 = 2 * \frac{SE * PR}{SE + PR} \quad (4)$$

RESULTADOS E DISCUSSÃO

Os experimentos desenvolvidos neste trabalho estão divididos em duas séries: classificação binária e classificação multiclasse. As duas abordagens de uso de CNN—treinamento sem transferência de aprendizado e uso de redes pré-treinadas—são investigadas nas duas séries de experimentos. Os resultados são apresentados e discutidos nesta seção.

Resultados Bi-Classe

Embora duas abordagens tenham sido investigadas, é importante lembrar que dois modelos de CNN foram empregados na abordagem de treinamento com transferência de aprendizado: VGG16 e ResNet50V2. Como ambos os modelos foram treinados com parada antecipada, os melhores resultados para classificação bi-classe foram obtidos nas épocas 36 e 19 para VGG16 e ResNet50V2, respectivamente. A Tabela 1 mostra a comparação dos resultados obtidos pelas três redes: rede

Tabela 1 – Comparação entre os modelos de CNN investigados ao resolver o problema de classificação de pneumonia por Covid-19 vs outras pneumonias

Modelo	Acurácia	Precisão	Sensibilidade	F1-Score
VGG16	82,11%	79,37%	84,75%	81,97%
ResNet50V2	80,49%	76,92%	84,75%	80,65%
Rede Neural Treinada do Zero	85,37%	83,60%	86,44%	85%

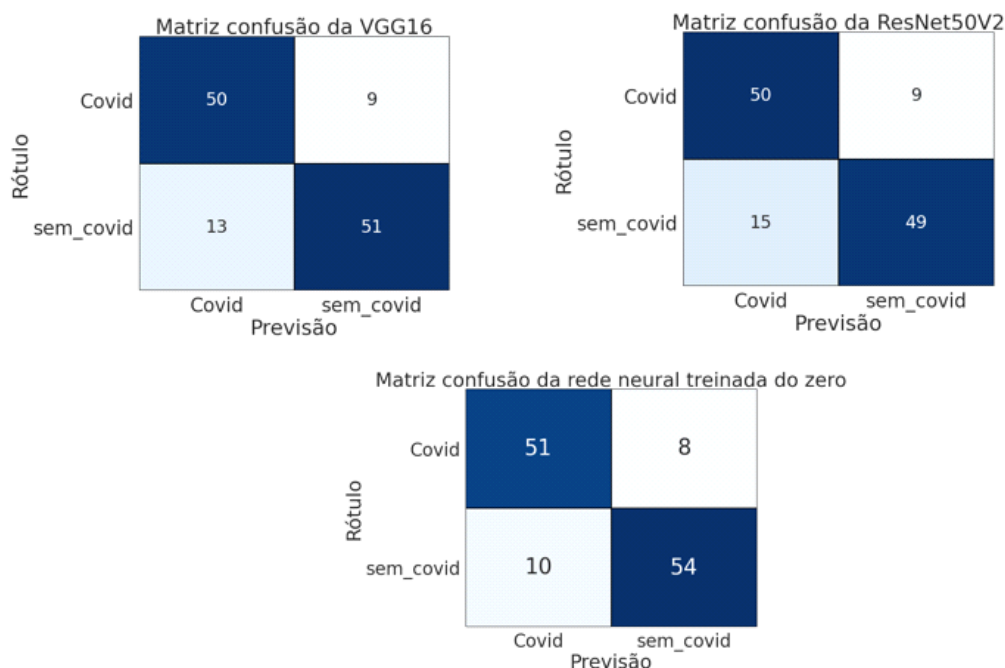


Figura 2 – Matrizes de confusão Bi-Classe.

treinada do zero (abordagem 1), VGG16 e ResNet50V2 (ambas na abordagem 2). Os valores das quatro métricas de avaliação descritas na seção anterior são exibidos nessa tabela. Além disso, o melhor valor obtido para cada métrica está em destaque em negrito.

Os resultados resumidos na tabela 1 mostram que os modelos treinados com transferência de aprendizado não foram melhores do que a rede neural treinada do zero. Esses resultados não eram esperados, pois a literatura de CNN mostra que normalmente transferência de aprendizado ajuda a melhorar a capacidade de classificação de CNNs em problemas com poucas instâncias de treinamento. A razão para esse desempenho inferior da abordagem que utiliza transferência de aprendizado pode estar no fato de não ter sido realizado um ajuste fino das redes para o processo de transferência de aprendizado. Ao compararmos os resultados obtidos pelos modelos pré-treinados, os resultados da VGG16 são equivalentes ou superiores aos resultados da ResNet50V2.

Também é importante analisar a distribuição de erros obtida pelos modelos investigados, pois, em situações reais, o ideal é que a taxa de falso negativo (instâncias de Covid-19 classificadas como sem Covid-19) seja reduzida. A figura 2 mostra as matrizes de confusão geradas por cada um dos três modelos de CNN testados. Essas matrizes mostram que os três modelos apresentam desempenho bastante semelhante quando o foco é voltado para a análise de falsos negativos. Nesse caso, dentre as 59 instâncias de Covid-19 presentes na base de teste, VGG16 e ResNet50V2 classificaram 9 instâncias incorretamente,

enquanto a rede treinada do zero classificou 8 instâncias incorretamente.

Resultados de Classificação Multi-classe

Nesta segunda série de experimentos, os dois modelos, VGG16 e ResNet50V2, foram novamente usados para fazer transferência de aprendizado. Os resultados apresentados aqui foram obtidos com o modelo da VGG16 treinado até a época 21 e o modelo ResNet50V2 treinado até a época 13, como consequência da etapa de parada antecipada. A Tabela 2 mostra os resultados obtidos pelos três modelos de CNN no problema de classificação multi-classe. A melhor taxa de acurácia está em negrito.

Essa tabela mostra que, considerando apenas as métricas avaliadas para a classe Covid-19, a VGG16 obteve melhores resultados no geral, exceto na precisão e sensibilidade, pois a rede treinada do zero obteve taxa maior. Entretanto, as diferenças entre as três redes não são tão elevadas. Novamente, a nossa expectativa era obter significativa superioridade da abordagem que usa transferência de aprendizado. A razão para a pequena diferença de resultados entre a rede treinada do zero e os modelos pré-treinados é provavelmente a falta de mais ajustes dos parâmetros das redes utilizadas para transferência de aprendizado.

Ao analisarmos as matrizes de confusão exibidas na figura 3, é possível verificarmos que a rede treinada do zero confunde mais a classe Covid-19 com a classe Outras Pneumonias, pois, dentre as 59 instâncias da classe Covid-19, 10 foram classificadas como pertencentes à classe

Tabela 2 – Comparação entre os modelos de CNN investigados ao resolver o problema de classificação de Pneumonia por Covid-19 vs outras Pneumonias vs classe normal. Siglas: AC - acurácia; PR - precisão; SE - sensibilidade; e F1 - F1 score.

Modelo	AC	Covid19			Pneumonia			Normal		
		PR(%)	SE(%)	F1(%)	PR(%)	SE(%)	F1(%)	PR(%)	SE(%)	F1(%)
VGG16	87,91	81,82	91,53	86,40	87,72	78,12	82,64	94,92	94,92	94,92
ResNet 50V2	85,71	77,14	91,53	83,72	88,24	70,31	78,26	93,44	96,61	95,00
Rede Treinada do Zero	86,26	87,5	83,05	85,21	79,10	82,81	80,91	93,22	93,22	93,22

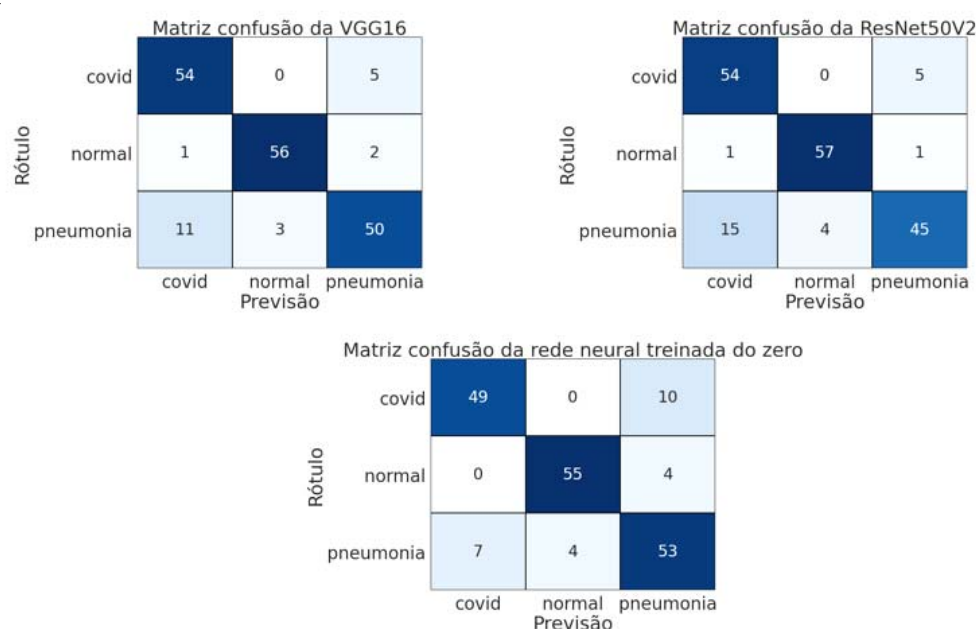


Figura 3 – Matrizes de confusão Multi-Classe.

Outras Pneumonias. Nos dois outros modelos, apenas 5 instâncias foram confundidas. Os três modelos cometeram menos erros para as instâncias da classe Normal. Por fim, a classe Outras Pneumonias foi, em geral, a classe com maiores erros. Esses erros foram majoritariamente decorrentes da classificação das instâncias de Outras Pneumonias como pertencentes à classe Covid-19. Esse resultado já era esperado, uma vez que as instâncias de Covid-19 também são exemplos de casos de Pneumonia.

CONCLUSÃO

Este trabalho apresenta um estudo experimental que usa CNN para detectar Covid-19 em imagens de raio-x. Duas abordagens de treino de CNN foram investigadas: treinamento do zero e transferência de aprendizado. Além disso, o problema de classificação foi tratado como um problema bi-classe: Pneumonia por Covid-19 vs sem Covid-19; e como um problema multi-classe no qual as

classes consideradas foram: Covid-19, Pneumonia e a classe normal. Os resultados dos experimentos indicaram superioridade do modelo treinado do zero no cenário de classificação binária, enquanto no cenário de múltiplas classes, os modelos pré-treinados foram ligeiramente superiores. Porém, os modelos empregados no cenário de transferência de aprendizado precisam de ajuste mais fino de seus parâmetros. Essa será a próxima etapa deste trabalho.

AGRADECIMENTOS

Esta pesquisa, realizada no âmbito do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), conforme previsto no Artigo 48 do Decreto nº 6.008 / 2006 (SUFRAMA), foi financiada pela Samsung Eletrônica da Amazônia Ltda., nos termos da Lei Federal nº 8.387 / 1991, através do convênio 001/2020, firmado com a Universidade Federal do Amazonas e a FAEPI, Brasil.

REFERÊNCIAS

1. Souza CDF, Paiva JPS, Leal TC, Silva LF, Santos LG. Spatiotemporal evolution of case fatality rates of COVID-19 in Brazil, 2020. *Jornal Brasileiro de Pneumologia*; 46(4). Epub June 17, 2020.
2. Shi F, Wang J, Shi J, Wu Z, Wang Q, Tang Z, et al. Review of artificial intelligence techniques in imaging data acquisition, segmentation and diagnosis for covid-19. *IEEE reviews in biomedical engineering*. 2020 Apr 16.
3. Levy J, Zieve D, Conaway B [Internet]. Imaging and radiology [cited 2020 Oct 08]. Available from: <https://medlineplus.gov/ency/article/007451.htm>.
4. Pereira RM, Bertolini D, Teixeira LO, Silla Jr CN, Costa YM. COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios. *Computer Methods and Programs in Biomedicine*. 2020 May 8:105532.
5. Duran-Lopez L, Dominguez-Morales JP, Corral-Jaime J, Vicente-Diaz S, Linares-Barranco A. COVID-XNet: A Custom Deep Learning System to Diagnose and Locate COVID-19 in Chest X-ray Images. *Applied Sciences*. 2020 Jan;10(16):5683.
6. Ozturk T, Talo M, Yildirim EA, Baloglu UB, Yildirim O, Acharya UR. Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*. 2020 Apr 28:103792.
7. Hemdan EE, Shouman MA, Karar ME. Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images. *arXiv preprint arXiv:2003.11055*. 2020 Mar 24
8. Narin A, Kaya C, Pamuk Z. Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. *arXiv preprint arXiv:2003.10849*. 2020 Mar 24.
9. Redmon J, Farhadi A. YOLO9000: Better, Faster, Stronger. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, p. 7263-7271
10. Ouchicha C, Ammor O, Meknassi M. CVDNet: A Novel Deep Learning Architecture for Detection of Coronavirus (Covid-19) from Chest X-Ray Images. *Chaos, Solitons & Fractals*. 2020 Sep 4:110245.
11. Apostolopoulos ID, Mpesiana TA. Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*. 2020 Apr 3:1.
12. Rahimzadeh M, Attar A. A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. *Informatics in Medicine Unlocked*. 2020 May 26:100360.
13. Wang L, Wong A. COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images. *arXiv preprint arXiv:2003.09871*. 2020 Mar 22.
14. Kumar P, Gangal A, Kumari S. WisdomNet: Prognosis of COVID-19 with Slender Prospect of False Negative Cases and Vaticinating the Probability of Maturation to ARDS using Posteroanterior Chest X-Rays. *J Pure Appl Microbiol*. 2020;14(suppl 1):869-78.
15. Ahsan MM, E Alam T, Trafalis T, Huebner P. Deep MLP-CNN Model Using Mixed-Data to Distinguish between COVID-19 and Non-COVID-19 Patients. *Symmetry*. 2020 Sep;12(9):1526.
16. Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, Huang Z, Karpathy A, Khosla A, Bernstein M, Berg AC. Imagenet large scale visual recognition challenge. *International journal of computer vision*. 2015 Dec 1;115(3):211-52.
17. Cohen JP, Morrison P, Dao L, Roth K, Duong TQ, Ghassemi M. Covid-19 image data collection: Prospective predictions are the future. *arXiv preprint arXiv:2006.11988*. 2020 Jun 22.
18. Wang X, Peng Y, Lu L, Lu Z, Bagheri M, Summers RM. Chestx-ray8: Hospital-scale chest x-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases. *Proceedings of the IEEE conference on computer vision and pattern recognition 2017* (pp. 2097-2106).