

# Detecção da Covid-19 por meio de Redes Neurais Convolucionais

Paula A. Kikuchi<sup>1</sup>

UEMS, Dourados, MS

Josimar J. Campos<sup>2</sup>

Mapfre Brasil, São Paulo, SP

Diante de todo impacto do coronavírus, alguns trabalhos buscando a detecção da Covid-19 por meio de imagens foram publicados. Em alguns deles, utilizou-se redes neurais para a classificação de imagens em três grupos de pacientes: saudáveis, pneumonia e pneumonia por Covid-19. Neste trabalho essa classificação também é utilizada, com o mesmo conjunto de dados dos artigos [4, 7].

Redes Neurais Convolucionais [CNNs] são um tipo de rede especializada em processamento de dados que tem uma topologia do tipo grade, como séries temporais (grade em uma dimensão) e dados de imagem (grade em duas dimensões) [2].

As imagens utilizadas neste trabalho são oriundas da plataforma Kaggle [1], em que o conjunto de treino é constituído de 460 imagens de raios-x de pacientes com Covid-19, 1266 sem doença pulmonar (normal), e 3418 com pneumonia (total de 5144 arquivos). O conjunto de teste é constituído de 116 imagens com Covid-19, 317 com pulmão normal, e 855 com pneumonia, totalizando 1288 imagens.

Na implementação utilizamos um conjunto de validação igual a 20% do conjunto de treino. Foram desenvolvidas uma rede convolucional simples, uma com *dropout*, e uma com *dropout* e *data augmentation*. Foram feitas 5 repetições para cada rede, trocando a semente aleatória inicial de cada uma, a fim de manter a equidade da amostra de dados e inicialização das repetições. Os resultados obtidos são apresentados a seguir:

- Rede convolucional simples: primeira camada de convolução com 32 filtros, dimensão do *kernel* igual a 3, e função de ativação ReLu. Camada densa com dimensão de saída de 32. Total de parâmetros: 31.361.027.

O número médio de épocas atingidos foi 14 ( $\pm 4,64$ ) de 25. Os valores das acurácias estão na Tabela 1, concluímos que há uma variação significativa nos valores, evidenciando a ocorrência de *overfitting*. Porém a acurácia no conjunto de validação foi muito satisfatória.

- Rede convolucional com *dropout*: primeira camada de convolução com 32 filtros, dimensão do *kernel* igual a 3, e função de ativação ReLu. Camada densa com dimensão de saída igual a 32. *Dropout* igual a 0,1. Total de parâmetros: 31.361.027.

Foi obtida uma média de  $15,4 \pm 3,65$  épocas de 25. Quando usamos a técnica de *dropout* obtemos uma generalização um pouco melhor dos dados, visto que há desligamento de pesos e o modelo é treinado com menos conexões dando vantagem computacional e menor tempo de treinamento. Pelos valores de acurácia na Tabela 1, podemos concluir que não há uma grande mudança nos valores, indicando que não há *overfitting* e o modelo obtido pode ser generalizado para qualquer

---

<sup>1</sup>paula.kikuchi@uems.br

<sup>2</sup>jjcampos@mapfre.com.br

conjunto de imagens.

- Rede convolucional com *dropout* e *data augmentation*: primeira camada de convolução com 32 filtros, dimensão do *kernel* igual a 3, e função de ativação ReLu. Camada densa com dimensão de saída igual a 32. Dropout igual a 0,1. Total de parâmetros: 31.361.027.

Os resultados obtidos para acurácia constam na Tabela 1. O número de épocas obtido foi 15 de 25. Comparando com a rede simples e com *dropout*, temos um valor menor da acurácia e mesmo que não haja *overfitting* o resultado não foi satisfatório.

A Tabela 1 mostra resumidamente as acurácias obtidas para cada rede.

Tabela 1: Acurácia dos tipos de rede.

Rede Convolucional	Treino	Validação	Teste
Simple	0,98664 ± 0,02	0,95884 ± 0,02	0,94410 ± 0,01
Com <i>dropout</i>	0,96766 ± 0,02	0,94280 ± 0,01	0,93974 ± 0,01
Com <i>dropout</i> e <i>data augmentation</i>	0,82406 ± 0,06	0,86166 ± 0,05	0,86272 ± 0,05

Nota-se a melhor acurácia no conjunto de teste pela rede simples, sendo que o resultado obtido pelo segundo modelo (com *dropout*) também mostrou-se satisfatório e com uma diferença de acurácia em relação a simples estatisticamente insignificante.

Neste trabalho utilizou-se apenas 1 camada convolucional. Destaca-se que em [5] foram utilizadas 9, em [6] foram 13, em [3] um total de 48, e 4 em [7]. Tendo em visto o número significativamente maior em outros trabalhos, conclui-se que, para os dados analisados, obtivemos ótimos resultados.

E comparando nosso resultado com o obtido em [7], vemos que, apesar do modelo simples ter três camadas de convoluções a menos, conclui-se que o resultado é melhor, já que em [7] se obtém uma acurácia de 100% em apenas uma repetição de três, sendo sua média final de 89,6%. Concluímos que, de forma geral, comparando com os resultados obtidos na literatura, obtivemos uma acurácia muito boa, tendo em vista que foi utilizada apenas uma camada de convolução.

## Referências

- [1] **Chest X-ray (Covid-19 & Pneumonia)**. Online. Acessado em 08/02/2024, [www.kaggle.com/datasets/prashant268/chest-xray-covid19-pneumonia](http://www.kaggle.com/datasets/prashant268/chest-xray-covid19-pneumonia).
- [2] I. Goodfellow, Y. Bengio e A. Courville. **Deep learning**. MIT press, 2016.
- [3] G. Jain, D. Mittal, D. Thakur e M. K. Mittal. “A deep learning approach to detect Covid-19 coronavirus with X-Ray images”. Em: **Biocybernetics and biomedical engineering** 40.4 (2020), pp. 1391–1405.
- [4] R. Jain, M. Gupta, S. Taneja e D. J. Hemanth. “Deep learning based detection and analysis of COVID-19 on chest X-ray images”. Em: **Applied Intelligence** 51 (2021), pp. 1690–1700.
- [5] C. Ouchicha, O. Ammor e M. Mekkassi. “CVDNet: A novel deep learning architecture for detection of coronavirus (Covid-19) from chest x-ray images”. Em: **Chaos, Solitons & Fractals** 140 (2020), p. 110245.
- [6] H. Panwar, P. K. Gupta, M. K. Siddiqui, R. Morales-Menendez e V. Singh. “Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet”. Em: **Chaos, Solitons & Fractals** 138 (2020), p. 109944.
- [7] P. Rici, S. O. S. Santos e A. L. C. Ottoni. “Análise da seleção de hiperparâmetros de Data Augmentation na detecção de Covid-19 em imagens de raio-x com Deep Learning”. Em: **Anais do 15 Congresso Brasileiro de Inteligência Computacional**. Joinville, SC: SBIC, 2021, pp. 1–7.