

IDENTIFICAÇÃO DE IMAGENS DE RAIOS-X COM REDES NEURAIAS CONVOLUCIONAIS PARA DETECÇÃO DE PNEUMONIA CAUSADA POR COVID-19

David Santos Sobral¹

Graduando em Engenharia Eletrônica
IFSP Campus São Paulo

Tamires Flores dos Santos²

Graduanda em Engenharia Eletrônica
IFSP Campus São Paulo

Miguel Angelo de Abreu de Sousa³

Doutor em Engenharia Elétrica
IFSP Campus São Paulo

RESUMO

No início de 2020, o mundo foi atingido por uma pandemia de COVID-19 (Sars-Cov-2), que, segundo *Our World in Data*, até o momento infectou 672 milhões de pessoas e causou 6,85 milhões de mortes. Um dos métodos comumente utilizados para diagnóstico de COVID-19 é o RT-PCR que possui desvantagens como alto custo e lentidão no resultado. Como alternativa, tornam-se viáveis os algoritmos, baseados em aprendizado de máquina, de rápida classificação da presença ou não de COVID-19 em imagens de raios-x pulmonares em pacientes com pneumonia. Neste trabalho, diferentes modelos de rede neural convolucional foram propostos a fim de se obter alto desempenho no conjunto de teste com 1909 imagens de raios-x contendo ou não COVID-19 em casos de pneumonia. Em vista dos resultados obtidos, dois modelos atingiram precisão de aproximadamente 94% na fase de teste, para estes foi desenvolvida uma interface usuário-máquina para classificação de imagens de raios-x pulmonares com o intuito de auxiliar o profissional da saúde na realização do diagnóstico. Tal interface possibilita alterar o limiar de ativação do último neurônio da rede para que o especialista possua maior controle do sistema proposto.

Palavras-chave Covid-19; Redes Neurais Convolucionais; Raios-x de Tórax; Inteligência Artificial.

INTRODUÇÃO:

No início de 2020, o mundo foi atingido por uma pandemia de COVID-19 (Sars-Cov-2), que até o momento infectou um total de 672 milhões de pessoas e causou 6,85 milhões de mortes. Este surto, iniciado na cidade de Wuhan, China, assolou a Europa em março de 2020, colapsando o sistema de saúde italiano e ocasionando 12.399 mortes apenas no mês de março daquele ano. No Brasil, o pico de mortes confirmadas, em 2020, ocorreu entre os meses de Maio e Agosto, totalizando 30.435 mortes apenas no mês de Junho [1]. Durante o mesmo período, diversos países de diferentes continentes registraram casos de COVID-19 em seus territórios e fecharam suas fronteiras. Medidas preventivas, como *lockdown* e alto índice de testagem, aplicados precocemente ajudaram países a diminuir o número de mortes, infecções e colapso do sistema de saúde.

O método comumente utilizado para diagnóstico de COVID-19 é a transcrição reversa de reação em cadeia da polimerase (do inglês, *reverse transcription polymerase chain reaction*, RT-PCR), que possui alta especificidade, porém é lento na produção de resultados e possui alto custo financeiro [2]. No ano de 2022 os custos para realização destes exames variavam entre R\$200 e R\$400, conforme a revista Valor Investe [18].

Em contrapartida, raios-x de tórax são amplamente disponibilizados e de fácil acesso por instituições hospitalares, sendo seu custo inferior ao do exame RT-PCR, variando entre R\$37 e R\$70 dependendo do número de incidências, segundo a instituição Pro Exame [19]. Imagens de raio-x são frequentemente utilizadas por profissionais da saúde para a detecção de pneumonia, uma vez que essas imagens podem ser consideradas cruciais em diagnósticos médicos por conter informações importantes sobre a situação do paciente [11].

A detecção de pneumonia causada por COVID-19 também pode ser realizada por meio de raio-x aliado a um sistema de inteligência artificial (IA). Diversos artigos foram publicados pela comunidade científica global em busca de um modelo de inteligência artificial capaz de detectar sintomas de Sars-Cov-2 por meio de imagens médicas, para auxílio a diagnósticos. Em Prottoy, Saha et. al. (2020), os autores utilizaram uma rede neural chamada *EMCNet* capaz de detectar pneumonia causada por COVID-19 a partir de dados extraídos de imagens de raio-x

do tórax, atingindo 98,91% de acurácia e 100% de precisão. Neste modelo, o *EMCNet* é composto por redes neurais convolucionais, algoritmos de aprendizado de máquina e classificadores binários [2]. Em Sekeroglu e Ozsahin (2020), realizou-se 38 experimentos com redes neurais convolucionais (RNC), 10 experimentos com 5 modelos de aprendizado de máquina e 14 redes neurais pré-treinadas por meio de transferência de aprendizado. A mediana da acurácia dos testes resultou em 98.50%, constatando que uma RNC sem pré-processamento é capaz de detectar COVID-19 mesmo tendo sido treinada em uma base de dados desbalanceada, isto é, que contém 4292 casos de pneumonia e 1583 casos saudáveis [3].

No trabalho desenvolvido por Cheng Jin et. Al. (2020), os autores fizeram uso de Rede Neural Convolucional Profunda para classificar imagens de Tomografia Computadorizada do tórax (CT) em mais de duas classes, sendo elas: COVID-19, influenza A/B, pneumonia não viral e não pneumonia [4]. No trabalho desenvolvido por Bassi e Attux, separou-se as imagens de raio-x em três categorias, sendo elas, COVID-19, pneumonia e normal. A partir desta classificação, utilizou-se um algoritmo baseado em uma rede neural convolucional densa que conseguiu atingir 100% de acurácia nos testes realizados. Também utilizou-se a técnica de *Layer-wise Relevance Propagation* (LRP) para evidenciar o funcionamento do algoritmo, gerando mapas de calor nas imagens [5].

O presente trabalho propõe modelos de rede neural convolucional contendo entre 11 e 13 camadas capazes de classificar imagens de raio-x pulmonar contendo pneumonia com presença de COVID-19 e pneumonia sem presença de COVID-19. Em seguida, apresenta-se uma sugestão de software visual para interface humano-máquina capaz de controlar o limiar de ativação para a classificação, com impacto na sensibilidade e na especificidade do modelo (classificação de verdadeiros negativos/positivos e falsos negativos/positivos). Esta alteração é realizada por meio de uma barra de escala interativa, com resolução de 0,1 para controle do limiar e permite ao profissional de saúde maior controle sobre o sistema de diagnósticos.

METODOLOGIA:**Base de dados**

Neste estudo, foram utilizadas 9544 imagens de raio-x pulmonares, com 5500 são classificadas como pneumonia com presença de COVID-19 e 4044 como pneumonia sem presença de COVID-19, disponibilizadas por El-Shafai et. al. (2020). Inicialmente, todas as imagens foram transformadas de seu tamanho original para 28x28 pixels, visando otimizar o processamento realizado pela rede neural [8].

Além da transformação dimensional, a base de dados foi submetida à transformação em escala de cinza, onde as informações de cores foram removidas, mantendo apenas a informação de luminescência, ou seja, a claridade do pixel [15].

Figura 1. Representação de raio-x pulmonares contidos na base de dados utilizada, com três exemplos de Não-COVID (Primeira linha) e COVID (Segunda Linha).



Fonte: El-Shafai et. al. [7].

Parâmetros de avaliação

Sempre que um modelo de detecção automática é criado, é necessário validá-lo para medir seu desempenho, para isso existem 2 fatores importantes: a sensibilidade e a especificidade. Utilizando como exemplo a detecção de pneumonia causada por COVID-19, a sensibilidade pode ser classificada como a habilidade do modelo em classificar corretamente os pacientes que estão infectados com a doença. A especificidade é classificada como a habilidade do modelo em classificar corretamente os pacientes que não possuem a doença [6].

Uma outra maneira de validar os resultados produzidos pelo modelo computacional, é por intermédio da avaliação de falsos positivos (FP), falsos negativos (FN), verdadeiros positivos (VP) e verdadeiros negativos (VN), onde:

- Falsos positivos são resultados da classificação do modelo em positivo para pacientes que não estão enfermos
- Falsos negativos são a classificação em negativo para pacientes que estão contaminados pela enfermidade
- Verdadeiros positivos são resultados da classificação correta de pacientes infectados
- Verdadeiros negativos são resultados da classificação correta de pacientes sadios.

Assim, a sensibilidade também pode ser descrita como a capacidade de classificar corretamente os verdadeiros positivos, enquanto a especificidade é determinada pela capacidade de classificação correta dos verdadeiros negativos. Por exemplo, um modelo que possui, por exemplo, uma sensibilidade de 0.85, classifica corretamente 85% pacientes que possuem a doença, mas 15% dos diagnósticos são de falsos positivos. Em outro exemplo, um modelo que possui especificidade de 0.90, classifica 90% dos pacientes que não possuem a doença, mas 10% dos casos são diagnosticados como falso negativo [6].

Escolha do modelo de rede neural

Para classificar as imagens entre COVID e Não-COVID, foram utilizadas redes neurais convolucionais (RNC), propostas inicialmente por LeCun et. al. em 1989 [8]. A RNC, inspirada no funcionamento do sistema nervoso humano que controla o córtex visual, é caracterizada como um algoritmo de aprendizado profundo que, utilizando uma imagem como entrada de dados, é capaz de atribuir pesos a diversos aspectos ou objetos da imagem (por meio de técnicas de aprendizagem de máquina, como *backpropagation*), sendo capaz de diferenciar características na própria imagem ou entre imagens distintas [13]. Além da alta performance na análise de imagens quando comparada a outras técnicas computacionais, a RNC apresenta baixos requisitos de pré-processamentos e alta capacidade de aprendizagem na regulação de seus filtros/camadas [9].

Para obtenção de uma RNC, utilizou-se 10 modelos diferentes visando a obtenção do melhor índice dentre 3 medidas nos treinamentos: Acurácia, Sensibilidade e Especificidade, as quais foram determinantes para a escolha do modelo. Os 10 modelos utilizados na etapa de treinamento diferem entre si em algumas características, tais como: número de camadas (convolucionais e densas), número de neurônios na(s) camada(s) densa(s), número filtros nas camadas convolucionais, função de *backpropagation* (perda) e dimensão de *kernels* em cada camada. Os modelos propostos, assim como a variação dos hiperparâmetros, foram escolhidos com base nos experimentos realizados em Sekeroglu B. et. al. (2020) [3], e são evidenciados na Tabela 1.

Função Binary Focal Loss

A função de erro *Focal Loss* (FL) possui por objetivo solucionar problemas em que as bases de dados estão desbalanceadas e/ou classes com diferentes dificuldades de classificação, e foram introduzidas primeiramente por Tsung-Yi et. al. para tarefas de visão computacional [10]. Para controle do desbalanceamento e dificuldade de classificação adicionam-se parâmetros à função *Cross Entropy* (CE) tradicional. A função CE não atribui pesos diferentes para diferentes classes. Portanto, em bases de dados desbalanceadas torna-se relevante o uso da função FL.

Evidenciam-se as funções CE e FL com a *Equação 1* e *Equação 2*, respectivamente:

$$CE(p, y) = \begin{cases} -\log(p), & \text{para } y = 1 \\ -\log(1 - p), & \text{para } y = 0 \end{cases} \quad (\text{Eq. 1})^*$$

$$FL(p, y, \alpha, \gamma) = \begin{cases} -\alpha(1 - p)^\gamma \log(p), & \text{para } y = 1 \\ -\alpha(1 - p)^\gamma \log(1 - p), & \text{para } y = 0 \end{cases} \quad (\text{Eq. 2})^*$$

* As funções CE e FL foram adaptadas para classificação binária.

** Considerar: p = valor previsto pela rede; y = valor desejado/verdadeiro; α = parâmetro de ponderação; γ = parâmetro de modulação.

Tabela 1. Modelos da fase de treinamento para escolha da RNC utilizada.

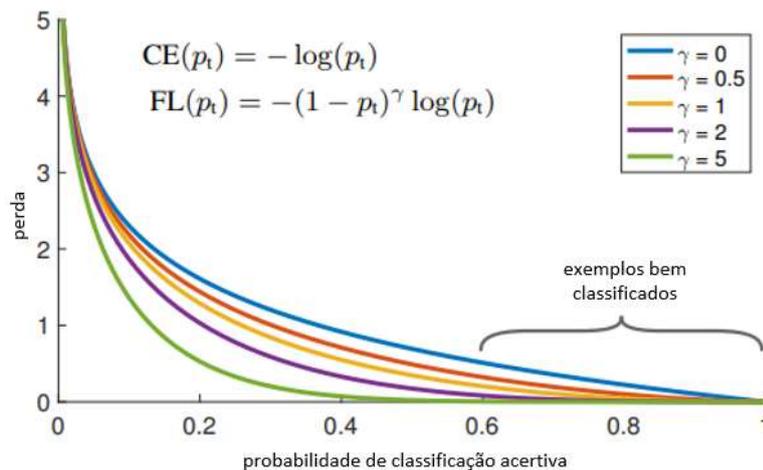
Modelo	Nº de Camadas	Nº de Cama. Conv.	Filtros por Cama. Conv.*	Dimen. dos Kernels	Nº de Cama. Densas	Neurônios por Camada Densa*	Função de Perda
1	11	3	64, 64, 32	(3,3)	2	256, 1	Binary Crossentropy
2	11	4	64, 64, 32, 32	(3,3)	2	256, 1	Binary Crossentropy
3	12	5	64, 64, 32, 32, 16	(2,2)	2	256, 1	Binary Crossentropy
4	13	5	64, 64, 32, 32, 16	(2,2)	3	128, 128, 1	Binary Crossentropy
5	13	5	128, 64, 32, 32, 16	(2,2)	3	256, 128, 1	Binary Crossentropy
6	11	3	64, 64, 32	(3,3)	2	256, 1	Focal Loss
7	11	4	64, 64, 32, 32	(3,3)	2	256, 1	Focal Loss
8	12	5	64, 64, 32, 32, 16	(2,2)	2	256, 1	Focal Loss
9	13	5	64, 64, 32, 32, 16	(2,2)	3	128, 128, 1	Focal Loss
10	13	5	128, 64, 32, 32, 16	(2,2)	3	256, 128, 1	Focal Loss

Fonte: Autores.

* Para todos os modelos: N° de camadas de max pooling = 3; Dimensão de pool size por camada Max Pooling = (2,2);

Ao utilizar-se a função FL para correção de pesos da rede, pondera-se o cálculo por meio do parâmetro α , o qual permite melhor controle entre exemplos positivos e negativos presentes na base de dados. Já com a variável γ , pode-se ponderar diferentemente o erro em exemplos difíceis ou fáceis de serem classificados, presentes na base de dados. Isto é feito, como visto a *Figura 1*, pela variação que permite maior ou menor valor de perda aplicada aos pesos, dependendo da distância entre o valor desejado e o valor previsto pela rede, alterando diretamente o limite de exemplos bem classificados.

Figura 2. Variação de γ para controle do valor de perda para classificação de exemplos fáceis ou difíceis, considerando $y = 1$.



Fonte: adaptado de Tsung-Yi et. al. [10]

Neste trabalho, focou-se na variação do parâmetro de ponderação α , devido ao desbalanceamento entre exemplos positivos e negativos presentes na base de dados utilizada: 1456 exemplos excedentes para valores positivos, como citado na subseção Base de dados.

RESULTADOS E DISCUSSÃO:

Após o treinamento de cada modelo proposto, citado na *Tabela 1*, obtiveram-se os resultados de acurácia, sensibilidade e especificidade, presentes na *Tabela 2*. A coluna da acurácia foi usada como determinante para escolha dos modelos para as próximas etapas.

Tabela 2. Resultados do treinamento inicial dos modelos propostos.

Modelo	Acurácia	Sensibilidade	Especificidade
1	0,8764	0,9188	0,8240
2	0,8726	0,8886	0,8495
3	0,8722	0,8975	0,8376
4	0,8722	0,9004	0,8343
5	0,8680	0,9202	0,8066
6	0,8793	0,8994	0,8513
7	0,8730	0,9315	0,8065
8	0,8780	0,9349	0,8129
9	0,8701	0,9198	0,8108
10	0,8764	0,9089	0,8340

Fonte: Autores.

Os números de acurácia e modelos em negrito destacam os modelos escolhidos para a próxima etapa, visto que atingiram os maiores níveis sobre o conjunto de teste, sendo estes: 1, 2, 6 e 8.

Os modelos 6 e 8 foram treinados com a função *Binary Focal Loss*, possibilitando a variação de α para verificar-se o melhor valor em relação aos resultados de um novo treinamento, desta vez utilizou-se a coluna da sensibilidade como determinante. Utilizou-se então uma variação entre 0,25 e 10, gerando os resultados presentes na *Tabela 3*.

Encontrado o valor ideal de α (entre a variação de 0,25 e 10) para os modelos 6 e 8, partiu-se para a etapa final para a geração da curva ROC de cada modelo, assim como a área sob a curva (AUC), para definição do melhor modelo [14]. As curvas ROC de cada modelo encontram-se na *Figura 2*, já a área sob a curva na *Tabela 4*.

Com base na *Figura 2* e na *Tabela 4*, nota-se que os modelos 1 e 6 atingiram valores bem próximos, mesmo sendo treinados com diferentes funções de perda, apresentando bons resultados na classificação do conjunto de teste, indicando que a função *Focal Loss* pode ser mais explorada com novos testes envolvendo a variável γ para possíveis melhores resultados.

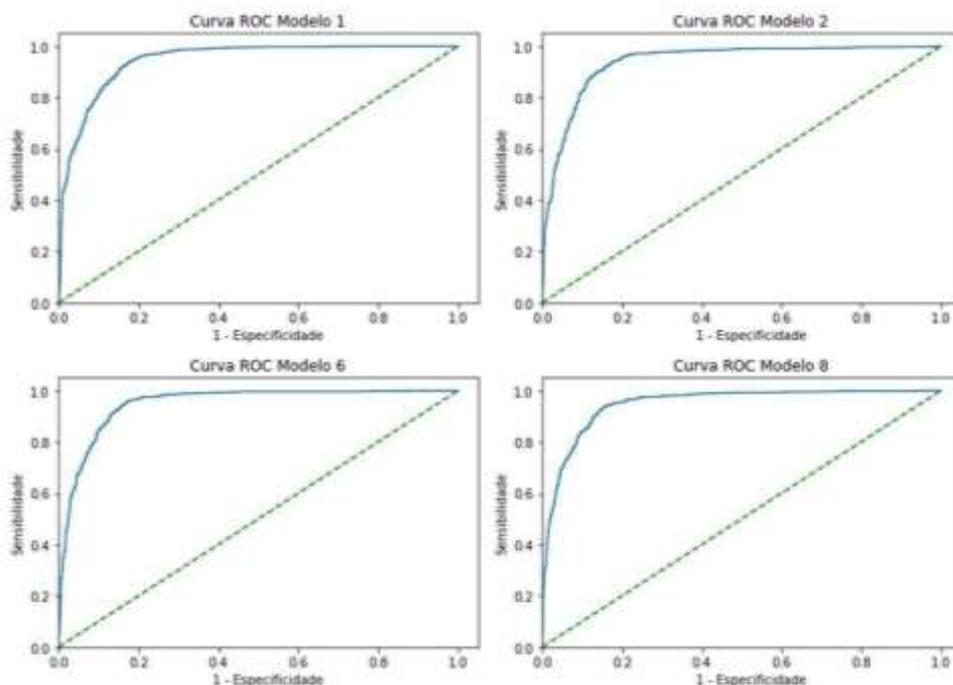
Tabela 3. Resultados do treinamento com a variação de α .

Modelo	α (<i>pos_weight</i>)	Acurácia	Sensibilidade	Especificidade
6	0,25	0,8378	0,8215	0,8695
6	0,5	0,8650	0,8696	0,8579
6	0,6	0,8718	0,9039	0,8296
6	0,7	0,8625	0,8675	0,8547
6	0,8	0,8738	0,9013	0,8369
6	0,9	0,8705	0,8753	0,8630
6	1	0,8793	0,8994	0,8513
6	1,1	0,8709	0,8944	0,8385
6	1,2	0,8680	0,8905	0,8367
6	1,3	0,8734	0,9121	0,8246
6	1,4	0,8659	0,8884	0,8345
6	1,5	0,8713	0,9021	0,8307
6	2	0,8801	0,9089	0,8420
6	3	0,8743	0,9061	0,8325
6	5	0,8655	0,9218	0,8005
6	10	0,8697	0,9618	0,7798
8	0,25	0,8361	0,8294	0,8481
8	0,5	0,8575	0,8747	0,8325
8	0,6	0,8516	0,8557	0,8451
8	0,7	0,8596	0,8674	0,8475
8	0,8	0,8525	0,8559	0,8470
8	0,9	0,8630	0,8748	0,8452
8	1	0,8780	0,9349	0,8129
8	1,1	0,8801	0,9206	0,8297
8	1,2	0,8738	0,8973	0,8416

8	1,3	0,8697	0,9042	0,8250
8	1,4	0,8730	0,9047	0,8314
8	1,5	0,8738	0,9243	0,8141
8	2	0,8667	0,8971	0,8263
8	3	0,8730	0,9006	0,8360
8	5	0,8755	0,9040	0,8376
8	10	0,8709	0,9014	0,8306

Fonte: Autores.

Figura 3. Curva ROC de cada modelo proposto.



Fonte: Autores.

Uma vez terminada a etapa de treinamento e encontrados os melhores modelos dentre os propostos empiricamente neste trabalho, ressalta-se a importância da interação entre o especialista da área da saúde e o modelo classificador de imagens.

Tabela 4. Resultados da área sob a curva de cada modelo.

Modelo	Valor da AUC (curva ROC)
1	0,94759
2	0,93927
6	0,94306
8	0,93795

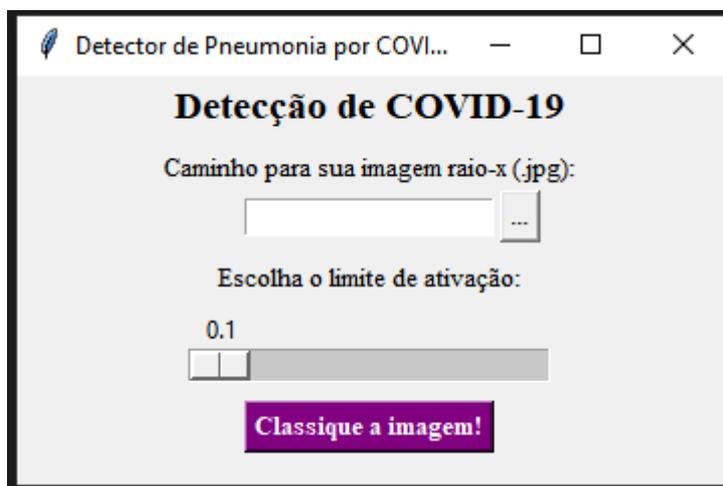
Fonte: Autores.

Interação Usuário-Máquina

Como uma sugestão de modelo visual para uso do algoritmo, desenvolveu-se uma interface usuário-máquina para classificação das imagens. Por meio da linguagem de programação *Python*, utiliza-se a biblioteca *tkinter* que é aceita em diversos sistemas operacionais (OS), como MacOS, Windows e Linux, pois sua principal função é prover ferramentas visuais para a criação de interfaces entre usuário e máquina, com a disponibilidade de botões, janelas, espaços para preenchimento, opções de cores, entre outros [12].

A fim de utilizar-se de uma imagem para predição e um limiar de ativação controlado pelo usuário, foi criada uma interface capaz de receber as duas informações, carregar os pesos de treinamento anteriormente realizado, processar a imagem e produzir um resultado entre Negativo ou Positivo para a presença de Pneumonia causada por COVID-19.

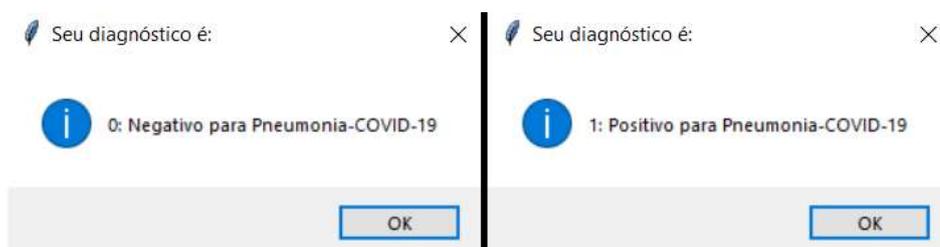
Figura 4. Modelo final realizado com *Python* e *tkinter*.



Fonte: Autores.

Após clicar no botão para reconhecer a imagem, o usuário se depara com uma mensagem apresentando o resultado da classificação, e pode alterar o limiar de ativação a fim de verificar seu impacto na classificação do raio-x. Isto permite ao profissional da saúde, responsável pelo diagnóstico do paciente, acompanhar e julgar a coerência e a performance do modelo proposto.

Figura 5. Notificação de resultado negativo (à esq.) e positivo (à dir.), após processamento da imagem.



Fonte: Autores.

Ao alterar o limiar de ativação para classificação do resultado, é possível estabelecer um filtro entre o que é considerado positivo e negativo, alterando as atribuições de verdadeiros negativos e positivos e falsos negativos e positivos de acordo com as características do paciente, tais como: idade, doenças crônicas, uso de substâncias tóxicas etc.

CONCLUSÃO:

Com base nos resultados obtidos, é evidente que um modelo construído com técnicas de inteligência artificial próprias para análise de imagens, como redes neurais convolucionais, é capaz de atingir altos níveis de precisão em um conjunto de teste com amostras da Presença de COVID-19 ou Não Presença de COVID-19 em pneumonia. Além de um alto índice de precisão alcançado na etapa de testes, uma interface interativa, como a apresentada neste trabalho, é importante para que profissionais de saúde possam utilizar com maior segurança a tecnologia de apoio ao diagnóstico.

A combinação de algoritmos de aprendizado de máquina com a área da saúde possibilita novas ferramentas para auxílio no diagnóstico, tornando-o mais robusto e possibilitando diagnósticos mais rápidos, com menor invasão médica como os testes PCR, o que resulta em melhor conforto aos pacientes e menores custos financeiros para administrações hospitalares, visto que os gastos gerados na produção de exames raio-x são inferiores aos da elaboração de exames RT-PCR.

Em análise dos dados obtidos, os modelos 1 e 6, treinados com *Binary Crossentropy* e *Binary Focal Loss*, respectivamente, atingiram praticamente os

mesmos valores de 94% de precisão sobre o conjunto de teste, evidenciando a necessidade de maior exploração sobre as possibilidades de controle das variáveis da função *Binary Focal Loss* como a variação do parâmetro γ , capaz de ponderar casos difíceis para classificação, em conjunto com a variável α que foi explorada neste trabalho.

Dada a relevância na utilização desta tecnologia em diagnósticos mais precisos, algoritmos de IA aliados a interfaces usuário-máquina tendem a ser mais utilizados no futuro para maior auxílio de profissionais da área da saúde, possibilitando maiores avanços em áreas como a telemedicina.

REFERÊNCIAS

- [1] MATHIEU, Edouard et al. Coronavirus Pandemic (COVID-19). [S. l.], 2020. Disponível em: <https://ourworldindata.org/coronavirus>. Acesso em: 8 fev. 2023.
- [2] Prottoy Saha, Muhammad Sheikh Sadi, Md. Milon Islam, EMCNet: Automated COVID-19 diagnosis from X-ray images using convolutional neural network and ensemble of machine learning classifiers.
- [3] Sekeroglu B, Ozsahin I. Detection of COVID-19 from Chest X-Ray Images Using Convolutional Neural Networks. *SLAS TECHNOLOGY: Translating Life Sciences Innovation*. 2020.
- [4] Jin, C., Chen, W., Cao, Y. et al. Development and evaluation of an artificial intelligence system for COVID-19 diagnosis. *Nat Commun* 11, 5088 (2020).
- [5] Pedro R. A. S. Bassi, Romis Attux. A deep convolutional neural network for COVID-19 detection using chest X-rays. Springer Link. 2021.
- [6] Swift A, Heale R, Twycross A. What are sensitivity and specificity? *Evid Based Nurs* 2020;23:2–4. doi:10.1136/ebnurs-2019-103225.
- [7] El-Shafai, Walid; Abd El-Samie, Fathi (2020), "Extensive COVID-19 X-Ray and CT Chest Images Dataset", Mendeley Data, V3, doi: 10.17632/8h65ywd2jr.3
- [8] Y. LeCun et al., "Backpropagation Applied to Handwritten Zip Code Recognition," in *Neural Computation*, vol. 1, no. 4, pp. 541-551, Dec. 1989, doi: 10.1162/neco.1989.1.4.541.
- [9] Data Science Academy. *Deep Learning Book*, 2022. Disponível em: <<https://www.deeplearningbook.com.br/>>. Acesso em: 10 Janeiro. 2022.
- [10] LIN, Tsung-Yi et al. Focal loss for dense object detection. In: *Proceedings of the IEEE international conference on computer vision*. 2017. p. 2980-2988.
- [11] ScienceDirect. JAIN, Govardhan et al. A deep learning approach to detect Covid-19 coronavirus with X-ray images. *Biocybernetics and biomedical engineering*, v. 40, n. 4, p. 1391-1405, 2020. Disponível em: <<https://doi.org/10.1016/j.bbe.2020.08.008>>. Acesso em: 28 Novembro. 2022.
- [12] Lundh, F. (1999). An introduction to tkinter. URL: [Www. Pythonware. Com/Library/Tkinter/Introduction/Index](http://www.pythonware.com/Library/Tkinter/Introduction/Index). Htm.
- [13] SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes Perceptron Multicamadas: Processo de treinamento do Perceptron Multicamadas. In: *REDES Neurais Artificiais Para Engenharia E Ciências Aplicadas: Curso Prático*. [S. l.]: Artliber, 2010. cap. 5, p. 94-119.

[14] MANDREKAR, Jayawant N. Receiver operating characteristic curve in diagnostic test assessment. *Journal of Thoracic Oncology*, v. 5, n. 9, p. 1315-1316, 2010.

[15] BUI, Hieu Minh et al. Using grayscale images for object recognition with convolutional-recursive neural network. In: 2016 IEEE Sixth International Conference on Communications and Electronics (ICCE). IEEE, 2016. p. 321-325.

[16] CALISTO, Francisco Maria; NUNES, Nuno; NASCIMENTO, Jacinto C. BreastScreening: on the use of multi-modality in medical imaging diagnosis. In: Proceedings of the international conference on advanced visual interfaces. 2020. p. 1-5.

[17] TSCHANDL, Philipp et al. Human-computer collaboration for skin cancer recognition. *Nature Medicine*, v. 26, n. 8, p. 1229-1234, 2020.

[18] PCR, antígeno... Qual teste de covid-19 fazer? Saiba preços, diferenças e indicações de cada um. [S. l.], 14 jan. 2022. Disponível em: <https://valorinveste.globo.com/mercados/brasil-e-politica/noticia/2022/01/14/qual-teste-de-covid-19-fazer-saiba-precos-diferencas-e-indicacoes-de-cada-um.ghtml>. Acesso em: 31 jan. 2023.

[19] CAETANO, Simone; PRO EXAME. Tabela de preços. [S. l.], 2018. Disponível em: <https://proexame.com/tabela-preco/>. Acesso em: 31 jan. 2023.

X-RAY IMAGES IDENTIFICATION WITH CONVOLUTIONAL NEURAL NETWORKS FOR DETECTION OF PNEUMONIA CAUSED BY COVID-19

ABSTRACT

In early 2020, the world was hit by a COVID-19 (Sars-Cov-2) pandemic, which, according to Our World in Data, has so far infected 672 million people and caused 6.85 million deaths. One of the commonly used methods for diagnosing COVID-19 is RT-PCR, which, like other tests, has disadvantages such as high cost and slow results. As an alternative, algorithms, based on machine learning, for fast classification of the presence or absence of COVID-19 in lung x-ray images in patients with pneumonia become viable. In this article, different convolutional neural network models were proposed to obtain a good performance in the test set containing 1909 chest x-ray images with or without the presence of COVID-19 in cases of pneumonia. In the results obtained, two models achieved accuracy of approximately 94% in the test phase, for which a user-machine interface was developed for classifying chest x-ray images to assist health professionals in carrying out a patient's diagnosis. The elaborated interface makes it possible to change the activation threshold of the last neuron in the network, so the health professional has greater control of the proposed system to aid diagnosis.

Keywords: Covid-19, Convolutional Neural Networks, Chest X-ray, Artificial Intelligence.