

Classificação de imagens médicas pulmonares para auxílio à conclusão diagnóstica da Covid-19

Lavinia Beghini de Castro¹, Silvana Terezinha Faceroli²

¹IF Sudeste MG – Campus Juiz de Fora

²Núcleo de Informática – IF Sudeste MG – Campus Juiz de Fora

lavinia.beghini@gmail.com, silvana.faceroli@ifsudestemg.edu.br

Abstract. *The COVID-19 pandemic has brought several challenges, including rapid diagnosis. For this purpose, CT scans are the most indicated. Due to the overload of professionals specialized in analyzing these images, artificial intelligence serves as a support in this time of crisis. This article aims to use artificial intelligence techniques for the identification of COVID-19 in CT scans. Image processing methods such as GrabCut, the HOG image descriptor and Artificial Neural Networks were used. As a result, an accuracy of 0.8 was obtained. Due to the processing carried out on the tomographic images, the research is relevant to the point that it can be used to identify other diseases.*

Resumo. *A pandemia de COVID-19 trouxe diversos desafios, dentre eles o diagnóstico rápido. Para este fim, tomografias são as mais indicadas. Devido a sobrecarga de profissionais especializados em analisar essas imagens, a Inteligência artificial serve como um apoio neste momento de crise. O objetivo deste trabalho é utilizar técnicas de Inteligência artificial para a identificação de COVID-19 em imagens de tomografia. Para isso, foram utilizados métodos de processamento de imagens como o GrabCut, o descritor de imagem HOG e Redes Neurais Artificiais. Como resultado, obteve-se uma precisão de 0,8. Devido aos processamentos feitos nas imagens tomográficas, a pesquisa tem relevância a ponto de poder ser utilizada para identificação de outras doenças.*

1. Introdução

Um surto de pneumonia, de origem desconhecida, foi relatado em Wuhan, na China, em dezembro de 2019. As análises de células epiteliais das vias respiratórias humanas levaram ao isolamento de um novo vírus denominado coronavírus de síndrome respiratória aguda grave 2 (SARS-CoV-2) [Ciotti et al. 2020]. A alta disseminação do vírus, aliado ao grande número de mortes causadas por esta doença, fez com que a OMS (Organização Mundial da Saúde) declarasse uma pandemia em 12 de março de 2020. Até o presente momento, de acordo com dados disponibilizados por tal organização, o número total de casos relatados globalmente excede 180 milhões e o número total de mortes está em torno de 4 milhões. Além disso, começaram a surgir variantes do vírus. Essas variantes são preocupantes devido às mutações virais, que levaram a um aumento da transmissibilidade e mais possibilidade de reinfeção [Freitas, Giovanetti and Alcantara 2021]. Desta forma, se torna evidente a importância da vacinação e do rastreamento e isolamento de infectados, reduzindo a circulação do vírus. Neste contexto, a comprovação da doença em pacientes infectados é uma ferramenta essencial.

Testes de diagnósticos precisos e acessíveis devem ser um dos pilares mais importantes das políticas de medidas de controle sanitário em momentos de surtos de doenças infecciosas, possibilitando a compreensão dos acontecimentos e minimizando a propagação [Adati et al. 2021]. A detecção de RNA viral baseada em *reverse-transcriptase polymerase chain reaction* (RT-PCR) é um dos exames mais utilizados na detecção da COVID-19 [Carter et al. 2020]. Este teste deve ser feito preferencialmente na primeira semana da doença, no máximo até o 14º dia, quando a carga viral é mais alta. Tem a possibilidade de dar falso negativo por fatores pré-analíticos (tais como coleta inadequada, contendo pouco material do paciente, além da conservação e transportes inadequados da amostra) ou analíticos (tais como possível mutação viral, presença de inibidores de PCR na amostra ou carga viral abaixo do limite de detecção do teste). Além disso, é um exame com valor aquisitivo alto para a maioria da população e nem sempre está disponível em todas as unidades de saúde. Os testes rápidos são mais acessíveis e mais simples [Pan et al. 2020]. São testes baseados na sensibilização de antígenos/anticorpos conjugados ao ouro coloidal que capturam imunoglobulinas e proteínas específicas do SARS-CoV-2 presentes no soro, plasma ou sangue dos indivíduos infectados, formando um complexo antígeno-anticorpo que migra por capilaridade ao longo da membrana de nitrocelulose. Por outro lado, apresentam um índice significativo de falsos negativos pois detectam a doença apenas no estágio agudo, com alta concentração do vírus. Os testes sorológicos são baseados na detecção de anticorpos IgM e IgG e podem fornecer uma estimativa da resposta imune do paciente [Meesala et al. 2020]. Mas deve ser utilizado apenas como exame complementar. Desta forma, é importante o desenvolvimento de pesquisas que possam indicar outras possibilidades de exames que, aliados aos já utilizados, tragam uma forma mais segura de diagnóstico da COVID-19.

Pesquisas recentes apontam a importância da utilização de exames de imagens médicas de tórax na identificação de pacientes com esta doença. O trabalho desenvolvido por Khan *et al.* (2020) concluiu que a radiografia de tórax é uma importante forma de investigação inicial em pacientes com COVID-19, além de desempenhar um papel de destaque durante o tratamento da doença. Na pesquisa realizada por Borakati et al. (2020), foi apresentada uma análise de tomografias computadorizadas e radiografias de tórax para avaliar a precisão diagnóstica destes exames em casos de pacientes confirmados com COVID-19. Concluiu-se que a tomografia apresentou melhor desempenho, podendo ser utilizada na avaliação inicial do paciente com suspeita da doença.

Porém, como informa de Henderson (2022), por uma convergência de fatores, incluindo o aumento da demanda por estudos de imagem e esgotamento de recursos relacionados ao COVID, está exacerbando a escassez global de radiologistas. Na Itália, o grande número de pacientes afetados requisitando hospitalização foi devastador para os departamentos de radiologia [Laghi and Grassi 2020].

Nesse cenário, para mitigar a situação, o uso de Inteligência Artificial e *Machine Learning* pode proporcionar ferramentas para ajudar a diminuir essa sobrecarga, já que em várias aplicações o desempenho de detecções automáticas baseadas em *machine learning* se importante no auxílio a radiologistas [Wang and Summers 2012]. Estudos recentes apontam para a possibilidade de utilização de inteligência artificial na identificação de pacientes com COVID-19 a partir de imagens médicas de tórax. O trabalho apresentado por Bai et al. (2020) teve por objetivo validar um sistema de inteligência computacional para diferenciar a pneumonia causada pelo SARS-CoV-2 da

pneumonia com outras causas. De acordo com as métricas apresentadas, os autores concluíram que a assistência da inteligência artificial melhorou o desempenho dos radiologistas na identificação de pacientes com COVID-19. No mesmo viés, a pesquisa apresentada por Li et al. (2020) utilizou técnicas de inteligência artificial, baseadas em Deep Learning, para auxílio ao diagnóstico de COVID-19. Os resultados permitiram concluir que o modelo proposto pode detectar pacientes infectados pelo SARS-CoV-2 com precisão, bem como diferenciar a pneumonia causada por esta doença de outras condições pulmonares.

1.1. Objetivos

O objetivo geral deste trabalho é analisar o desempenho de algoritmos, utilizando técnicas de visão computacional em imagens pulmonares, para a identificação de pacientes com COVID-19.

1.2. Objetivos específicos

- Analisar qual o melhor tipo de imagem pulmonar para a identificação de pacientes com COVID-19;
- Mapear as técnicas de processamento de imagens mais significativas para a identificação de características específicas em imagens pulmonares de pacientes com COVID-19;
- Investigar a utilização de redes neurais artificiais para a aplicação proposta;
- Sistematizar os resultados das métricas de desempenho dos algoritmos desenvolvidos a fim de identificar as técnicas mais promissoras.

2. Bases teóricas

2.1. Exames de imagem

Exames de imagem de tórax são raios-x ou escaneamentos que produzem uma imagem dos órgãos e estruturas no tórax [Slam et al. 2021]. Essas imagens podem ser:

- Raios-X (radiografias): usam radiação para produzir uma imagem 2D.
- Tomografias computadorizadas: usam um computador para mesclar imagens de raio-X em duas dimensões e convertê-las em uma imagem em três dimensões.
- Ultrassonografias: usam ondas sonoras de alta frequência para produzir uma imagem.

As pesquisas mostradas em Islam et.al (2021) fazem uma comparação da precisão diagnóstica em tomografias de tórax, raio-X e ultrassom em pessoas com suspeita de COVID-19. A tabela 1 apresenta os resultados obtidos:

Tabela 1. Comparação entre precisão de exames de imagem

Exame	Análise Correta	Falso positivo
Tomografia	87.9%	20%
Raio-X	80.6%	28.5%

Ultrassom	86.4%	45%
-----------	-------	-----

Os resultados mostraram que tomografias tiveram o melhor desempenho dentre os resultados, em comparação com os outros exames. Porém, houve um número significativo de casos em que foi diagnosticada COVID-19 em pacientes sem a doença. Essa evidência aponta que a tomografia é melhor para descartar a doença do que diagnosticá-la.

2.1.1. Tomografia

Tomografias computadorizada são compostas por imagens 2D transversais de seções finas do corpo (*slices*), criando uma representação em três dimensões das estruturas dentro do corpo. Para obter a imagens, nos scanners de tomografia, um gerador de raios-x rotativo envia vários feixes para o objeto de vários ângulos [Afshar 2021].

2.2. Características do exame de imagem

O trabalho desenvolvido por Khan et al. (2020) teve por objetivo identificar os padrões mais comuns de alterações pulmonares em radiografias de tórax de pacientes COVID-19 positivos, confirmados através do teste RT-PCR. Verificou-se uma diferenciação nestes exames em zonas periféricas e inferiores, além de uma tendência ao envolvimento pulmonar bilateral, com predominância de opacidade em vidro fosco.

Essa opacidade em vidro fosco evidencia-se por uma opacidade turva que não obscurece totalmente as estruturas bronquiais ou vasos pulmonares, visíveis em imagens de tomografia computadorizada de alta resolução [Park et al. 2007], como mostrado na Figura 1:




Figura 1. Opacidade em vidro fosco visto em tomografia pulmonar - Fonte Própria (2022)

2.3. Formatos de Imagem

Formatos de imagem são uma forma padronizada de armazenar as informações de uma imagem em um arquivo de computador. Os formatos mais encontrados são apresentados na Tabela 2:

Tabela 2. Principais formatos de imagem

Formato	Extensão
Joint Photographic Experts Group	.jpg
portable networks graphics	.png

O maior ponto positivo do JPEG é sua capacidade de comprimir significativamente imagens grandes, porém essa compressão apresenta muita perda de dados, o que degrada a imagem.

Já o PNG se propõe a ser um formato flexível que comprime imagens sem muita perda de dados, e transparência variável [Wiggins et al. 2001].

2.3.1. Formatos de Imagens médicas

Uma imagem médica é uma representação de uma estrutura interna ou função de uma região anatômica na forma de uma matriz. Alguns dos formatos mais encontrados são encontrados na Tabela 3:

Tabela 3. Principais formatos de imagens médicas

Formato	Extensão
Nifti	.nii
Dicom	.dcm

O formato Dicom é o padrão preferível, por conta de sua grande flexibilidade para seguir o desenvolvimento tecnológico e avanços médicos [Larobina and Murino 2014].

2.4. Processamento de imagem

De acordo com o Petrou e Petrou (2010), o processamento de imagens foi desenvolvido em resposta a três maiores problemas com imagens:

- Digitalização de imagem para facilitar transmissão, impressão e arquivamento;
- Melhoramento e restauração da imagem para permitir a interpretação;
- Segmentação da imagem e descrição como um estado inicial de visão de máquina;

Nesse sentido, o processamento da imagem antes de sua classificação é uma etapa importante de forma a garantir o melhor desempenho da inteligência artificial.

2.4.1. Corte

O corte de imagens é uma operação comum utilizada para melhorar a qualidade visual de imagens. O objetivo é remover áreas indesejadas e melhorar a composição geral da imagem, destacando uma Região de Interesse (ROI) [Yan et al. 2013]. A funcionalidade do ROI é importante em aplicações médicas onde certas partes da imagem são de maior importância diagnóstica do que outras. Nesse caso, essas regiões precisam ser destacadas em qualidade superior ao plano de fundo [Doukas and Maglogiannis 2007].

2.4.2. Binarização

O método de binarização converte uma imagem em escala de cinza (de 0 até 255 níveis de cinza), mostrado na Figura 2(a), em imagens preto e branco (0 e 1), como mostrado na Figura 2(b).




Figura 2. Método de binarização – Fonte Própria (2022)

Uma imagem binarizada de alta qualidade pode dar mais precisão em reconhecimentos de imagem comparado à imagem original, pois diminui o ruído. Porém a dificuldade maior é definir qual tipo de binarização é mais apropriado para todas as imagens.

Os algoritmos são divididos em duas categorias:

- Global, que usam um limiar único para a imagem toda
- Local, onde o limiar é calculado pixel a pixel ou região a região

Os algoritmos globais são melhores para calcular o valor do limiar em uma imagem em escala de cinza, mas não dão bons resultados para imagens coloridas com iluminação intensa. Nesses casos, o melhor seria algoritmos de binarização locais.

2.4.2.1. Método do Limiar Fixo (Global)

No método do limiar fixo, um valor é usado para atribuir 0 e 1 para todas as posições de pixel na imagem. O processo desse método pode ser descrito com a função a seguir:

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) \geq T \\ 0 & \text{se não} \end{cases}$$

Onde T é o limiar global.

2.4.3. GrabCut

O problema de uma segmentação de plano de fundo eficiente em imagens estáticas é de grande importância para o contexto de processamento de imagens [Rother et al. 2004]. Assim como definido no artigo de Pereira et al. (2022), a técnica do GrabCut tem justamente esse propósito: é um método de segmentação em cortes de grafos. O funcionamento se baseia nos seguintes passos:

1. É informado as coordenadas da Região de Interesse (ROI)
2. A região é fragmentada para cada pixel da imagem em um grafo
3. São inseridos vértices de origem e destino, onde o vértice de origem é o objeto a ser segmentado e o de destino é o fundo da imagem

Na Figura 3 podemos observar o resultado da técnica:

A Região de Interesse destacada para o uso do GrabCut pode tanto ser um retângulo, quanto uma máscara. Essa máscara é definida por uma matriz de 0 e 1 de mesmas dimensões da imagem, onde o que for marcado em 0 será necessariamente eliminado, e 1, necessariamente mantido. A partir desses valores, o algoritmo define as bordas do objeto selecionado e remove o fundo.



Figura 3. Exemplo do funcionamento do GrabCut – Fonte [Histogram of Oriented Gradients — skimage v0.12.3 docs (s.d.)]

2.5. Técnicas de Extração de Características

Uma questão importante na aplicação da Inteligência Artificial é encontrar uma representação adequada de dados multivariados. A Extração de Características pode ser utilizada, neste contexto, para reduzir a complexidade e dar uma representação mais simples, proporcionando uma transformação nas características originais da imagem para gerar outras características que são mais significativas [Khalid 2014].

2.5.1. Histograma

O histograma é uma função que mostra a frequência de níveis de cinza em uma imagem, onde *bin* representa esse valor. Esses *bins* variam de 0 a 255 em imagens em escala de cinza [Carvalho and Faceroli 2020].

2.5.2. Histograma Orientado ao Gradiente (HOG)

O descritor de Histograma Orientado ao Gradiente (HOG) foca na estrutura ou formato de um objeto. É melhor que qualquer descritor de borda por usar a magnitude e o ângulo do gradiente para computar as características [Tyagi 2021].

Este funciona da seguinte forma:

1. Aplica-se uma normalização de intensidade
2. Aplica-se um filtro de suavização
3. Aplica-se um mapa de bordas
4. Agrupa-se os pixels em células, que podem ter tamanhos variados (Figura 4)
5. Normaliza-se as células
6. Combina-se as células em blocos únicos, o que gera um descritor (Figura 5)

O processo termina quando todos os blocos estiverem combinados [Carvalho and Faceroli 2020].




Figura 4. Exemplo de agrupamento de pixel no HOG – Fonte [Singh 2019]

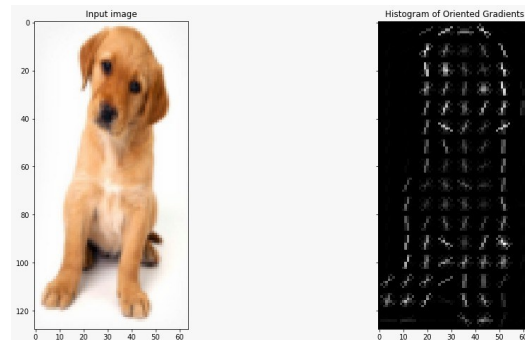


Figura 5. Resultado do HOG – Fonte [Singh 2019]

2.6. Modelos de Classificação

Classificação é uma técnica em *machine learning* usada para classificar membros associados por instâncias de dados. Há várias técnicas de classificação que podem ser usadas com esse propósito. Cada técnica tem seus próprios méritos, deméritos e problemas de implementação. A seleção da técnica depende do objetivo do problema tratado [Soofi and Awan 2017].

2.6.1. Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são estruturas computacionais sofisticadas, inspirada nos cérebros humanos, em que milhares de neurônios interconectados processam informações em paralelo.

Uma rede neural artificial, como demonstrado na Figura 6, é composta de uma camada externa de entrada, onde inserimos os dados a serem processados, uma ou mais camadas internas escondidas, e uma camada de saída final.

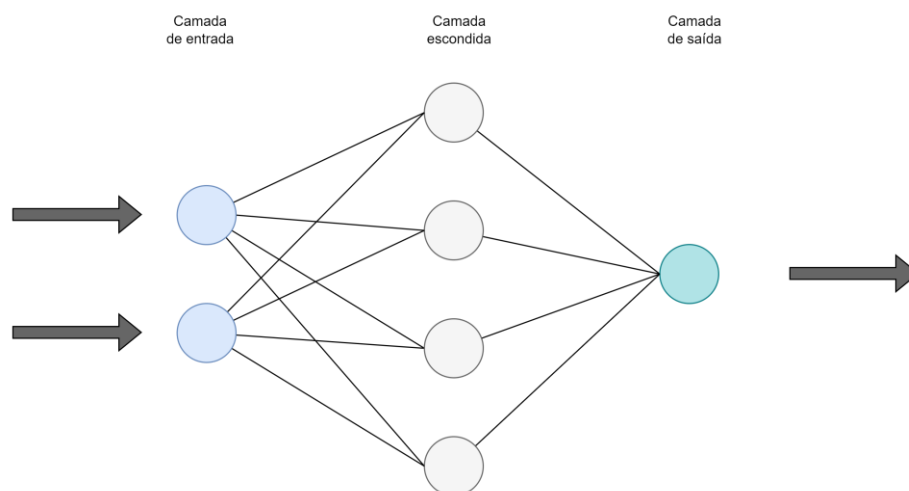


Figura 6. Demonstração simplificada de uma RNA – Fonte Própria

Cada camada contém um ou mais neurônios, que seriam as unidades de processamento, onde ocorrerão os cálculos definidos pela configuração da rede. Cada neurônio terá um resultado, que pode ser definido como o somatório dos valores da camada anterior, multiplicado pelos respectivos pesos de cada neurônio daquela camada, e somado um valor de limiar. O resultado dessa equação é então passado para uma função, que terá responsabilidade de introduzir uma não-linearidade à rede neural, chamada função de ativação. Ao final disso, temos os resultados de cada neurônio da camada, e os cálculos seguem para a próxima [Wang 2003]. A Figura 7 demonstra esse processo:

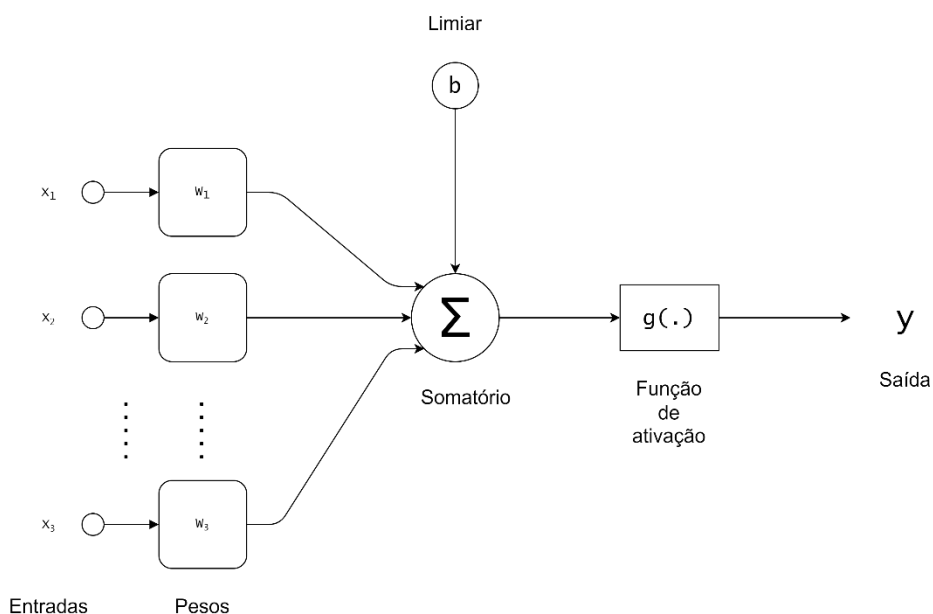


Figura 7. Demonstração detalhada de uma RNA – Fonte Própria

2.6.1.1. MLP

Uma das estratégias de classificação redes neurais mais utilizada é a MLP (*Multi Layer Perceptron*), que consiste em uma ou mais camadas de múltiplos neurônios, onde

cada camada de neurônios é alimentada pela anterior. Esta utiliza uma técnica de treinamento chamada de *backpropagation*, caracterizada pela tentativa de classificação, medição do erro, e volta recalibrando seus pesos para mais próximo do acerto [Ramchoun et al. 2016].

2.7. Matriz de Confusão

Uma matriz de confusão é uma ferramenta estatística para medir a performance de um modelo de classificação em *machine learning* onde a saída pode ser de uma ou mais classes. É uma tabela composta por 2 colunas e 2 linhas, sendo o eixo y os valores positivos e negativos obtidos e o x os valores reais.

A partir de uma matriz de confusão, pode-se extrair a precisão, acurácia e a sensibilidade. Para o cálculo da precisão, divide-se o total de positivos pela soma da mesma com o total de falsos positivos. Em seguida, para o cálculo da acurácia, deve-se somar o total de positivos com o total de negativos e dividir pela soma de tudo. E finalmente, para o cálculo da sensibilidade, deve-se somar o total de previsões positivas dividido pela soma da mesma mais o total de falsos negativos. [Narkhede 2018]

3. Materiais e Métodos

3.1. Banco de Dados

O banco de dados escolhido foi o COVID-CT-MD. Ele foi desenvolvido com o propósito de auxiliar estudos de *machine learning* e *deep learning* na classificação de imagens tomográficas.

Contém 169 casos de COVID-19, 60 casos de pessoas com Pneumonia comum e 76 casos de pacientes controle, todas em formato DICOM. Cada um dos casos de COVID foi diagnosticado por três radiologistas diferentes. Os seguintes critérios foram considerados por estes:

1. Achados nas imagens, como:
 - a. Opacidade em vidro fosco
 - b. Envolvimento pulmonar bilateral e multifocal
 - c. Distribuição periférica
 - d. Maior distribuição nos lobos inferiores
2. Achados clínicos
3. Epidemiologia, que se refere se o participante vem de uma área de risco ou teve contato com um paciente positivado para COVID-19

Se o participante é identificado de acordo com todos os três critérios, ele é classificado como COVID-19. Senão, é classificado como Pneumonia comum ou Normal.

Um subgrupo de 54 casos de COVID-19 e 25 de Pneumonia comum foram analisados de forma minuciosa, identificando e categorizando cada parte da tomografia (slices) com evidência de infecção.

Além da classificação por slice, dados clínicos foram coletados dos pacientes:

- Idade
- Gênero

- Peso
- Características clínicas (sintomas, motivo do exame, histórico do paciente)
- Histórico de cirurgia
- Acompanhamento (depois do exame)
- Resultado do teste RT-PCR, quando disponível

3.2. Metodologia

A metodologia utilizada para o desenvolvimento do trabalho pode ser visualizada no fluxograma a seguir:

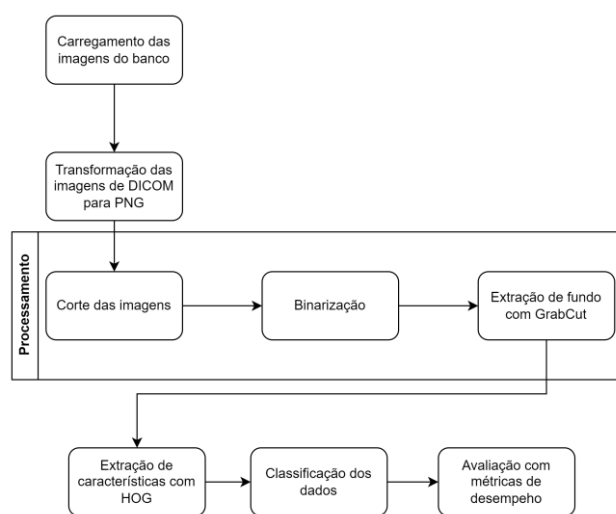


Figura 8. Fluxograma da metodologia aplicada – Fonte Própria

Em propósito de favorecer a visualização das imagens e transformações em cima destas, o formato das imagens foi trocado de DICOM para PNG. Foi selecionado uma única tomografia com 148 *slices* para o estudo.

Para fazer o corte das imagens, foi definido uma técnica específica para tomografias baseando-se no comportamento destas. Como mostra a Figura 9, a média dos valores linha a linha da imagem mantém o comportamento de dois picos iniciais, indicando o início do corpo humano, tendo um decrescimento no meio, por conta da escuridão da área do pulmão, voltando a crescer novamente quando a área do pulmão termina.

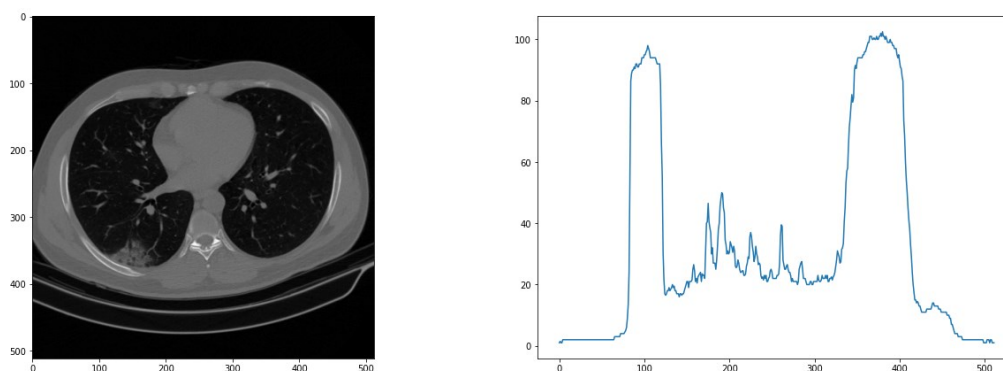


Figura 9. Tomografia juntamente a seu gráfico de valores de média – Fonte Própria

Tanto no início quanto no final da figura, temos uma área de fundo. Porém, esse valor nunca é fixo, pois o início do corpo da pessoa varia não só de paciente para paciente, mas de *slice* para *slice*.

Para construir o algoritmo, primeiramente, a imagem é dividida na metade, como demonstrado na Figura 10:




Figura 10. Tomografia repartida em duas metades – Fonte Própria

Em seguida, são calculados os valores dos picos da imagem, sempre cima do valor da média de toda a imagem, para pegar os picos mais altos. Após isso, é pego o menor valor do posicionamento do pico da imagem de cima, e o maior valor do posicionamento do pico da imagem de baixo, que representam os extremos.




Figura 11. Gráfico de média da imagem juntamente aos picos – Fonte Própria

Na Figura 11 podemos ver, destacado em linhas azuis, onde a imagem será cortada, de acordo com os valores dos picos calculados pelo algoritmo, visto na Figura 12:




Figura 12. Tomografia com indicação das linhas de corte – Fonte Própria

Para a criação de uma máscara precisa no pulmão, foram utilizadas duas binarizações:

- binarização para zero inversa, onde o limiar é a média da imagem
- binarização binária, com o desvio padrão da binarização para zero inversa

A partir da definição da máscara com o processo de binarização, podemos aplicar a técnica de GrabCut, que retorna somente a área dos pulmões.

Em seguida, todas as imagens foram transformadas para a mesma escala, afim de permitir o processo de classificação. A escala escolhida foi a da menor das imagens dentro do espaço amostral.

Nas imagens geradas na etapa de extração de fundo, foi utilizado o HOG como extrator de características, com a possibilidade de 16 orientações, células de tamanho 2x2 e 1 célula por bloco.

Para classificar os dados, foi utilizada uma RNA MultiLayer Perceptron. Foram separados 80% dos dados para treinamento, e 20% para teste. O modelo foi configurado com a função de ativação *relu* e solver *adam*, os padrões sugeridos pela biblioteca. Os testes foram feitos com 1 e 2 camadas, variando o número de neurônios nas camadas em 2, 3, 4, 5, 10, 15 e 20.

4. Resultados

A máscara gerada pelo processo de binarização tem as seguintes características, apontadas na Figura 13:




Figura 13. Comparação da imagem original com a binarização – Fonte Própria

A máscara consegue marcar exatamente o espaço do pulmão, o que é um ótimo insumo para o algoritmo de GrabCut, como visto na Figura 14, onde a remoção do fundo foi bem-sucedida:




Figura 14. Comparação da imagem original com a remoção de fundo – Fonte Própria

Logo após, a imagem foi reescalada, e em cima desta, foram calculados seus descritores HOG, como demonstrado nas Figuras 15 e 16:




Figura 15. Imagem reescalada – Fonte Própria




Figura 16. Descritores HOG – Fonte Própria

Tendo todos os descritores das imagens calculados, podemos ver os melhores resultados das classificações nas tabelas 4 e 5 a seguir, separadas por quantidade de camadas escondidas:

Tabela 4. Resultados da Classificação com 1 camada escondida

Número de neurônios	Acurácia (%)	VP	FP	VN	FN
2	73	33	0	12	0
3	73	33	0	12	0
5	73	33	0	12	0
10	73	33	0	12	0

Tabela 5. Resultados da Classificação com 2 camadas escondidas

Número de neurônios	Acurácia (%)	VP	FP	VN	FN
10	80	26	7	2	10
15	80	29	4	5	7
20	80	26	7	2	10

5. Conclusões

A pandemia de COVID-19 certamente deixará marcas nessa e nas próximas gerações. Porém é inegável o quanto a ciência teve de evoluir e se adaptar em tão pouco tempo por conta dos novos desafios propostos.

Este trabalho é fruto deste cenário, contribuindo para achados com relevância não apenas para o auxílio à mitigação da doença, mas também deixando um legado de contribuição que servirá para patologias relacionadas, tais como pneumonias e câncer de pulmão.

6. Referências

- ADATI, M.C., et al. Monitoramento pós-mercado dos testes rápidos para COVID-19: enfrentamento da pandemia. *Vigilância Sanitária em Debate: Sociedade, Ciência & Tecnologia (Health Surveillance under Debate: Society, Science & Technology) – Visa em Debate*, 2021.
- Afshar, P., Heidarian, S., Enshaei, N., Naderkhani, F., Rafiee, M. J., Oikonomou, A., Fard, F. B., Samimi, K., Plataniotis, K. N., & Mohammadi, A. (2021). COVID-CT-MD, COVID-19 computed tomography scan dataset applicable in machine learning and deep learning. *Scientific Data*, 8(1), 121. <https://doi.org/10.1038/s41597-021-00900-3>
- BAI, Harrison X. et al. Artificial intelligence augmentation of radiologist performance in distinguishing COVID-19 from pneumonia of other origin at chest CT. *Radiology*, v. 296, n. 3, p. E156-E165, 2020.
- BORAKATI, A. et al. Diagnostic accuracy of X-ray versus CT in COVID-19: a propensity-matched database study. *BMJ Open* 2020; 10: e042946.
- CARTER, L.J.; GARNER, L.V.; SMOOT, J.W.; LI, Y.; ZHOU, Q.; SAVESON, C.J. Assay techniques and test development for COVID-19 diagnosis. *ACS Cent Sci*. 2020;6(5):591-605. <https://doi.org/10.1021/acscentsci.0c00501>.
- Carvalho, V. F., & Faceroli, S. T. (2020). ANÁLISE DE PERFORMANCE DE TÉCNICAS DE MACHINE LEARNING APLICADAS À IMAGENS DE RESSONÂNCIA MAGNÉTICA EM PACIENTES COM TRANSTORNO DO ESPECTRO AUTISTA.
- CIOTTI, M.; CICCOTZI, M.; TERRINONI, A.; JIANG, W.; WANG, C.; BERNARDINI, S. The COVID-19 pandemic. *Critical Reviews in Clinical Laboratory Sciences*, 57:6, 365-388, DOI: 10.1080/10408363.2020.1783198.
- Doukas, C., & Maglogiannis, I. (2007). Region of interest coding techniques for medical image compression. *IEEE Engineering in Medicine and Biology Magazine: The Quarterly Magazine of the Engineering in Medicine & Biology Society*, 26(5), 29–35. <https://doi.org/10.1109/emb.2007.901793>
- FREITAS, A.R.R.; GIOVANETTI, M.; ALCANTARA, L.C.J. Variantes emergentes do SARS-CoV-2 e suas implicações na saúde coletiva. *Inter American Journal of Medicine and Health*, v. 4, 2021.
- Henderson, M. (2022, maio 10). Radiology facing a global shortage. *Rсна.org*. <https://www.rsna.org/news/2022/may/Global-Radiologist-Shortage>

- Histogram of Oriented Gradients — skimage v0.12.3 docs. ([s.d.]). Hubwiz.com. Recuperado 19 de julho de 2022, de http://man.hubwiz.com/docset/Scikit-image.docset/Contents/Resources/Documents/auto_examples/features_detection/plot_hog.html
- Islam, N., Ebrahimzadeh, S., Salameh, J.-P., Kazi, S., Fabiano, N., Treanor, L., Absi, M., Hallgrimson, Z., Leeftang, M. M., Hooft, L., van der Pol, C. B., Prager, R., Hare, S. S., Dennie, C., Spijker, R., Deeks, J. J., Dinnes, J., Jenniskens, K., Korevaar, D. A., ... Cochrane COVID-19 Diagnostic Test Accuracy Group. (2021). Thoracic imaging tests for the diagnosis of COVID-19. *Cochrane Database of Systematic Reviews*, 3(3), CD013639. <https://doi.org/10.1002/14651858.CD013639.pub4>
- Khalid, S., Khalil, T., & Nasreen, S. (2014). A survey of feature selection and feature extraction techniques in machine learning. 2014 Science and Information Conference, 372–378.
- KHAN, Nasir et al. Chest X-ray findings in COVID-19: A Pictorial Review. *Journal of Rawalpindi Medical College*, v. 24, n. Supp-1, p. 44-49, 2020.
- Laghi, A., & Grassi, R. (2020). Italian radiology's response to the COVID-19 outbreak. *Journal of the American College of Radiology: JACR*, 17(6), 699–700. <https://doi.org/10.1016/j.jacr.2020.04.012>
- Larobina, M., & Murino, L. (2014). Medical image file formats. *Journal of Digital Imaging*, 27(2), 200–206. <https://doi.org/10.1007/s10278-013-9657-9>
- LI, Lin et al. Using artificial intelligence to detect COVID-19 and community-acquired pneumonia based on pulmonary CT: evaluation of the diagnostic accuracy. *Radiology*, v. 296, n. 2, p. E65-E71, 2020.
- Meesala, N., Harsha, G., Kandikatla, P., Karteekvarma, P. V., Nadakuditi, S. R., & Kakaraparthi, S. K. (2020). Measuring the impact of COVID-19 on mental health as a preliminary procedure in primary care provision: A cross-sectional study using COVID-19 anxiety scale. *Journal of Family Medicine and Primary Care*, 9(11), 5554–5558. https://doi.org/10.4103/jfmpe.jfmpe_1244_20
- Narkhede, S. (2018, maio 9). *Understanding confusion matrix*. Towards Data Science. <https://towardsdatascience.com/understanding-confusion-matrix-a9ad42dcfd62>
- PAN, Y; LI, X; YANG, G; FAN, G; TANG, Y; ZHAO, Y. Serological immunochromatography approach in diagnosis with SARS-CoV-2 infected COVID-19 patients. *J Infect.* 2020;81(1):e28-e32. <https://doi.org/10.1016/j.jinf.2020.03.051>.
- Park, C. M., Goo, J. M., Lee, H. J., Lee, C. H., Chun, E. J., & Im, J.-G. (2007). Nodular ground-glass opacity at thin-section CT: histologic correlation and evaluation of change at follow-up. *Radiographics: A Review Publication of the Radiological Society of North America, Inc*, 27(2), 391–408. <https://doi.org/10.1148/rg.272065061>
- Pereira, V. P., Faceroli, S. T., Rodrigues, M. C. B. P., & Amaral, F. S. (2022). DETECÇÃO E CONTAGEM DE BOBINAS EM VAGÕES PLATAFORMA: UMA ABORDAGEM UTILIZANDO TÉCNICAS DE VISÃO COMPUTACIONAL.
- Petrou, M., & Petrou, C. (2010). *Image processing: The fundamentals* (2o ed). Wiley-Blackwell.

- Ramchoun, H., Amine, M., Idrissi, J., Ghanou, Y., & Ettaouil, M. (2016). Multilayer Perceptron: Architecture Optimization and Training. *International journal of interactive multimedia and artificial intelligence*, 4(1), 26. <https://doi.org/10.9781/ijimai.2016.415>
- Rother, C., Kolmogorov, V., & Blake, A. (2004). GrabCut: Interactive foreground extraction using iterated graph cuts. *ACM Transactions on Graphics*, 23(3), 309–314. <https://doi.org/10.1145/1015706.1015720>
- Singh, A. (2019, setembro 4). *Feature engineering for images: A valuable introduction to the HOG feature descriptor*. Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2019/09/feature-engineering-images-introduction-hog-feature-descriptor/>
- Soofi, A. A., & Awan, A. (2017). Classification Techniques in Machine Learning: Applications and Issues. *Journal of basic & applied sciences*, 13, 459–465. <https://doi.org/10.6000/1927-5129.2017.13.76>
- Tyagi, M. (2021, julho 4). HOG (histogram of Oriented Gradients): An overview. Towards Data Science. <https://towardsdatascience.com/hog-histogram-of-oriented-gradients-67ecd887675f>
- Wang, S., & Summers, R. M. (2012). Machine learning and radiology. *Medical Image Analysis*, 16(5), 933–951. <https://doi.org/10.1016/j.media.2012.02.005>
- Wang, S.-C. (2003). Artificial Neural Network. *Em Interdisciplinary Computing in Java Programming* (p. 81–100). Springer US.
- Wiggins, R. H., 3rd, Davidson, H. C., Harnsberger, H. R., Lauman, J. R., & Goede, P. A. (2001). Image file formats: past, present, and future. *Radiographics: A Review Publication of the Radiological Society of North America*, 21(3), 789–798. <https://doi.org/10.1148/radiographics.21.3.g01ma25789>
- Yan, J., Lin, S., Kang, S. B., & Tang, X. (2013). Learning the change for automatic image cropping. 2013 IEEE Conference on Computer Vision and Pattern Recognition.