

Um Método Baseado em *Radiomics* e MLP para Diagnóstico Automático de COVID-19 a partir de Raio-X de Tórax

Emanuel L. C. de Sousa Filho¹, Paulo G. S. Magno¹, Camyla J. P. Santos¹,
Giovanni L. F. da Silva¹, João O. B. Diniz², Darlan B. P. Quintanilha³

¹Centro Universitário Unidade de Ensino Superior Dom Bosco - UNDB
Caixa Postal 65075-441 - São Luís - MA - Brasil

²Instituto Federal do Maranhão - IFMA
Caixa Postal 65940-000 - Grajaú - MA - Brasil

³Universidade Federal do Maranhão - UFMA
Caixa Postal 65085-580 - São Luís - MA - Brasil

{emanuel.filho08, pgs.magno, cjansensantos}@gmail.com
giovanni.silva@undb.edu.br
joao.bandeira@ifma.edu.br
darlan.quintanilha@ufma.br

Abstract. *The identification of COVID-19 is a crucial factor for the treatment and cure of patients. With the advancement of technology, it became possible to develop computational methods capable of helping specialists in the task of analyzing medical images. Therefore, the present work aims to develop an automatic method of diagnosing COVID-19 through chest X-ray images using a Radiomics approach and the Multi-Layer Perceptron algorithm. The proposed method was evaluated in two public image databases, obtaining an accuracy of 96.8%, precision of 97.1%, recall of 96.4% and specificity of 97.9%, with this, demonstrating the effectiveness in the automatic diagnosis of COVID-19 by image.*

Resumo. *A identificação da COVID-19 é um fator crucial para o tratamento e cura dos pacientes. Com o avanço da tecnologia, tornou-se possível o desenvolvimento de métodos computacionais capazes de auxiliar os especialistas na tarefa de análise de imagens médicas. Portanto, o presente trabalho tem como objetivo desenvolver um método automático de diagnóstico da COVID-19 por meio de imagens de raio-X do tórax usando uma abordagem Radiomics e o algoritmo Multi-Layer Perceptron. O método proposto foi avaliado em duas bases de imagens públicas, obtendo uma acurácia de 96,8%, precisão de 97,1%, recall de 96,4% e especificidade de 97,9%, com isso, demonstrando a eficácia no diagnóstico automático da COVID-19 por imagem.*

1. Introdução

No final de 2019, vários casos de pneumonia desconhecida foram relatados em Wuhan, China [Tan et al. 2020]. Em dezembro, a Organização Mundial da Saúde (OMS) declarou que era uma crise de saúde global [Zhu et al. 2020]. Inicialmente, a transmissão do vírus era restrita a morcegos. No entanto, a transmissão de humano para humano começou

e, desde então, esse vírus fatal se espalhou rapidamente pelo mundo [Chan et al. 2020]. O vírus é denominado síndrome respiratória aguda grave 2 (SARS-CoV-2) e a doença é chamada de coronavírus (COVID-19). O COVID-19 foi relatado como a causa desses vários casos de pneumonia [Bernheim et al. 2020].

Vários estudos foram desenvolvidos para investigar as características particulares da doença. Um dos principais mecanismos considerados para auxiliar os especialistas é a avaliação de imagens de radiografia de tórax [El-Din Hemdan et al. 2020]. Como o procedimento de imagem limita a exposição do paciente a altas doses de radiação, os resultados da radiografia torácica exibem apenas um leve contraste para distinguir os tecidos moles [Kroft et al. 2019]. Assim, muitos métodos computacionais têm sido propostos para auxiliar especialistas a classificar estas imagens de raio-X.

Uma das formas de interpretação de imagens é a extração de características quantitativas relevantes, que resultam na conversão de imagens em dados e na utilização desses dados para tomadas de decisão. Uma das técnicas de conversão dessas imagens em características é chamada de *Radiomics* [dos S. Neto et al. 2018]. O conceito de *Radiomics* define que imagens biomédicas apresentam informações que detalham a fisiopatologia. Desta maneira, a extração de informação das imagens pode revelar o diagnóstico final da patologia [Mayerhoefer et al. 2020]. E, para interpretação de dados extraídos de imagens (como os *Radiomics*), técnicas de Aprendizado de Máquina vêm sendo utilizadas de forma efetiva, alcançando resultados considerados estado da arte em vários domínios de imagens [dos S. Neto et al. 2018].

Assim, o presente trabalho tem como objetivo desenvolver um método baseado em Aprendizado de Máquina aplicado ao diagnóstico de COVID-19 utilizando uma abordagem *Radiomics* em imagens de raio-X de tórax. Como principais contribuições do trabalho, pode-se destacar:

- Um método robusto usando os conceitos de *Radiomics* para classificação de imagens de tórax em COVID-19 ou não COVID-19;
- Método completamente automático baseado em Aprendizado de Máquina utilizando características *Radiomics* e *Multi-Layer Perceptron*;
- Uma ferramenta de auxílio a diagnóstico que servirá como opinião auxiliar ao especialista.

Este trabalho está dividido da seguinte forma, a Seção 2 aborda os trabalhos relacionados ao tema de pesquisa. A descrição dos materiais e o método proposto são apresentados na Seção 3. Os experimentos e resultados para validar a pesquisa são relatados e discutidos na Seção 4. Finalmente, as conclusões e trabalhos futuros são abordados na Seção 5.

2. Trabalhos Relacionados

A literatura apresenta vários trabalhos relacionados a COVID-19 e imagens de raio-X de tórax. A seguir, são apresentados os trabalhos considerados estado da arte neste domínio de problema.

No trabalho recente de [Narin et al. 2020], modelos baseados em redes neurais convolucionais (ResNet50, Inception-v3 e Inception-ResNetV2) foram aplicados para detectar pacientes infectados com COVID-19; obteve-se uma acurácia máxima de

98%. [Apostolopoulos and Mpesiana 2020] também utilizou diferentes modelos de Aprendizado Profundo pré-treinados; alcançando uma acurácia de 98,75% e *recall* de 92,85% usando duas classes (COVID-19 vs. condições normais).

Em [El-Din Hemdan et al. 2020] e [Zhang et al. 2020] também apresentaram resultados significativos para a detecção baseada em raio-X de tórax de pacientes com COVID-19. Em ambos os estudos, vários modelos de rede neural convolucional (CNN) foram usados para verificar o desempenho da detecção de COVID-19. No [El-Din Hemdan et al. 2020], obteve-se uma acurácia de 90% para as classes normal e COVID-19. No [Zhang et al. 2020], alcançou um sensibilidade de 96% para casos de COVID-19 e 70,65% para casos normais.

O trabalho proposto por [Pereira et al. 2020] utilizou imagens de raio-X de tórax para distinguir casos de pneumonia causada por COVID-19 daqueles causados por outros tipos de doenças, bem como de pulmões saudáveis. Para tanto, os autores utilizaram descritores de textura conhecidos para extrair características e um modelo CNN pré-treinado. Eles alcançaram uma pontuação F1 de 65% usando uma abordagem multiclasse e uma pontuação F1 de 89% para a identificação de COVID-19. Em um estudo de [Ozturk et al. 2020], também foi desenvolvido um modelo (DarkCovidNet) para classificação binária e multiclasse. O modelo obteve acurácia de 98,08% para classe binária e 87,02% para classificação multiclasse.

Em [Wu et al. 2021], os autores propuseram um método baseado em características de textura usando a transformada de Wavelet e o classificador *Random Forest*, obtendo uma acurácia de 72,2%. Por outro lado, [Bakheet and Al-Hamadi 2021] desenvolveram um método usando características de textura extraídas da *Gray Level Co-occurrence Matrix* (GLCM) e o classificador Campos Aleatórios Condicionais Dinâmicos Latente (LDCRFs), alcançando uma acurácia de 95,88%.

O trabalho proposto por [Sitaula and Hossain 2021] propôs uma modificação da rede neural convolucional VGG-16 para classificar casos de COVID-19 e não COVID-19 em imagens de raio-X de tórax. O método inseriu módulos de atenção na VGG-16 para melhorar os resultados e performance da rede. Como melhor resultado, os autores alcançaram 87,49% de acurácia. Por sua vez, [Kumar et al. 2022] desenvolveram uma rede neural convolucional chamada de SARS-Net. Os autores verificaram que o modelo alcançou uma precisão de 97,60% e um *recall* de 92,90% no conjunto de validação.

Pode-se observar que, em sua maioria, os autores propõem métodos baseados em Aprendizado Profundo, estas abordagens são comumente utilizadas por fazerem de forma automática a extração de características. Todavia, estas técnicas necessitam de alto poder computacional e muitas das vezes as características extraídas ficam omissas para o especialista. Ao utilizar uma abordagem Radiomics para extração de características juntamente com Aprendizado de Máquina para classificação destas, o método se torna mais rápido, além do fato das características serem conhecidas e representativas, podendo ser entendido qual peculiaridade da imagem foi extraída.

3. Materiais e Método

O método proposto está dividido em cinco etapas, conforme ilustrado na Figura 1. Em resumo, a primeira etapa descreve os materiais usados como as bases de imagens de raio-X do tórax. A segunda etapa consiste na etapa de pré-processamento para padronização

das imagens. Em seguida, na terceira etapa, as características de textura são extraídas. Após esta etapa, a classificação é realizada usando o algoritmo *Multi-Layer Perceptron*. Por fim, os resultados são avaliados.

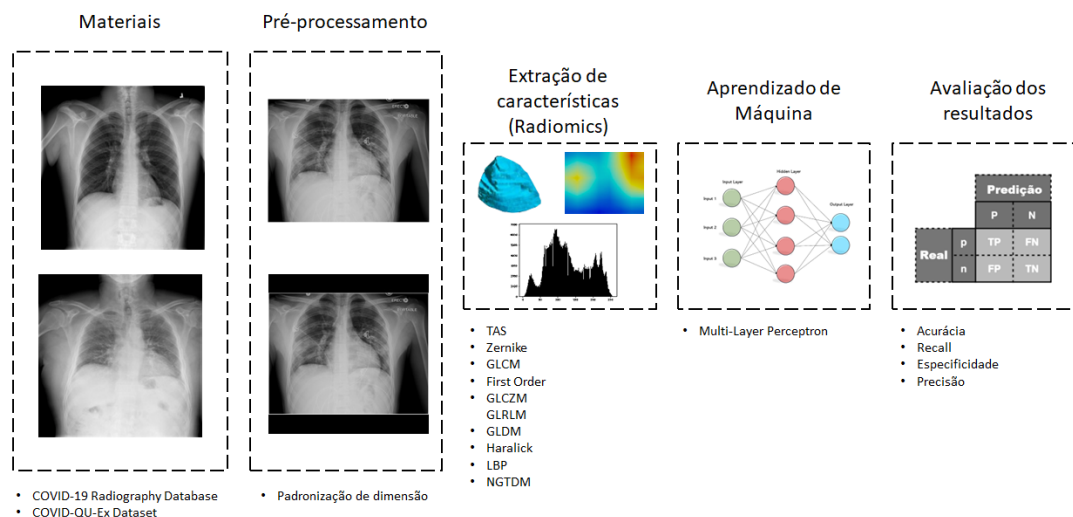


Figura 1. Fluxo das etapas do método proposto.

3.1. Materiais

As bases de dados utilizadas neste trabalho foram a *COVID-19 Radiography Database*¹ e a *COVID-QU-Ex Dataset*², ambas disponíveis na Internet. A primeira base contém um total de 13.808 imagens com resoluções variadas, das quais 3.616 imagens referem-se a raio-X infectados por COVID-19 e 10.192 referem-se a imagens de pulmões saudáveis. A segunda base contempla 22.657 imagens com resolução padronizada em 256 x 256, sendo 11.956 de raio-X com COVID-19 e 10.701 imagens de pulmões saudáveis.

3.2. Pré-processamento

Esta etapa tem como objetivo padronizar as resoluções das imagens de ambas as bases de dados utilizadas para a resolução 256 x 256. Para isso, as imagens com resoluções diferentes tiveram o maior eixo reduzido para 256 e o menor eixo foi reduzido de forma proporcional para manter a proporção original entre os eixos. Em seguida, as imagens foram centralizadas em um quadrado preto de resolução 256 x 256 para obter a padronização em todas as imagens.

3.3. Extração de características

Radiomics incorpora várias disciplinas importantes, incluindo Radiologia (por exemplo, interpretação de imagens), Visão Computacional (por exemplo, extração quantitativa de recursos) e Aprendizado de Máquina (por exemplo, avaliação de classificadores). Um objetivo central é a identificação de indicadores quantitativos de imagem que predizem resultados clínicos importantes, incluindo prognóstico e resposta ou resistência a um

¹<https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>

²<https://www.kaggle.com/datasets/anasmohammedtahir/covidqu>

tratamento específico. Para analisar de forma abrangente as imagens de raio-X, várias características *Radiomics* foram extraídas das imagens.

O conjunto de descritores de Haralick [Haralick et al. 1973] é formado por 13 descritores texturais derivados da *Gray Level Co-occurrence Matrix* (GLCM). Estes descritores descrevem a correlação de intensidade entre dois *pixels* em uma imagem a uma determinada distância d na direção atribuída. O GLCM oferece não apenas o relacionamento inter-pixel, mas também as dependências espaciais e a periodicidade do nível de cinza.

O *Zernike Moments* [Imada 2013] trata-se de uma técnica de definição de contornos de uma imagem, invariante em relação à rotação, que opera pela determinação de um ponto central ao redor do qual se traça um círculo. Considerando-se os *pixels* dentro desse círculo, de raio definido como parâmetro do algoritmo, o processo de detecção de contornos é executado, excluindo-se os demais *pixels*. O *Zernike Moments* contém 25 descritores.

TAS [Hamilton et al. 2007] é uma técnica consiste na transformação da imagem original em uma imagem binária, na qual seus *pixels* são mapeados ou para branco ou para preto. Em seguida, é calculado um conjunto de 9 valores baseados na relação de um *pixel* branco e outros *pixels* brancos (ou não) a ele adjacentes. A diferença entre os 9 valores reside na quantidade de *pixels* brancos encontrados no entorno do *pixel* central. O primeiro valor leva em consideração um *pixel* branco central e 9 *pixels* pretos; para os valores seguintes, o número de *pixels* pretos vai diminuindo até que todos os *pixels* do entorno sejam brancos. O TAS contém 54 descritores.

Os métodos estatísticos analisam a distribuição espacial dos valores de cinza calculando as características locais em cada ponto da imagem e derivando um conjunto de estatísticas da distribuição das características locais. *First Order Statistics* [Zwanenburg et al. 2020] descrevem a distribuição de intensidades do *pixel* dentro da região da imagem definida pela máscara por meio de métricas básicas e comumente usadas como energia, entropia, média, mínimo, máximo, entre outros, totalizando 18 descritores estatísticos.

O *Gray Level Co-occurrence Matrix* (GLCM) é um método estatístico para descrição de texturas. A GLCM armazena a probabilidade de que dois valores de intensidade de cinza estejam envolvidos por uma determinada relação espacial. A partir desta matriz de probabilidades, diferentes medidas estatísticas são extraídas a fim de caracterizar a textura presente na imagem. A partir da matriz de co-ocorrência, pode-se extrair várias medidas relacionadas a características de uma textura. Além da GLCM, foram analisados descritores extraídos de *Gray Level Run Length Matrix* (GLRLM), *Gray Level Size Zone Matrix* (GLSZM), *Neighbouring Gray Tone Difference Matrix* (NGTDM) e o *Gray Level Dependence Matrix* (GLDM) [Zwanenburg et al. 2020]. Neste estudo, foram extraídos 75 descritores das matrizes, sendo 24 com GLCM, 16 com GLRLM e 16 com GLSZM, 5 com NGTDM e 14 com GLDM.

3.4. Reconhecimento de Padrões

Para a construção do modelo preditivo, utilizou-se o algoritmo *Multi-Layer Perceptron* (MLP) [Sonawane and Patil 2014]. A escolha pelo MLP deve-se ao fato do algoritmo possuir um grande poder de representação de conhecimentos através da criação de

relações ponderadas entre as entradas do sistema [Sonawane and Patil 2014]. Como hiperparâmetros utilizados, destacam-se a taxa de aprendizado igual a 0,01, número de épocas igual a 500, número de neurônios na camada oculta igual a 100, função de ativação ReLU e o otimizador Adam.

3.5. Avaliação dos Resultados

As métricas de avaliação utilizadas no método proposto foram a acurácia, precisão, *recall* e especificidade. Os cálculos para estas métricas foram baseados nas seguintes fórmulas:

$$acurácia = \frac{VP + VN}{VP + FP + FN + VN} \quad (1)$$

$$precisão = \frac{VP}{VP + FP} \quad (2)$$

$$recall = \frac{VP}{VP + FN} \quad (3)$$

$$especificidade = \frac{VN}{VN + FP} \quad (4)$$

no qual, VP equivale aos verdadeiros positivos, VN aos verdadeiros negativos, FP aos falsos positivos e FN aos falsos negativos.

4. Resultados e Discussão

Esta seção apresenta e discute os resultados obtidos com o método proposto para o diagnóstico de COVID-19 em imagens de raio-X. Para avaliação, as base de dados descritas na Seção 3.1 foram divididas em dois conjuntos: treinamento e teste. Um total de 36.411 imagens foram analisadas, sendo 15.519 imagens de pacientes com COVID-19 e 20.892 imagens de pacientes saudáveis. A Tabela 1 apresenta a proporção de imagens nos conjuntos de treino e teste.

Tabela 1. Divisão da base de dados nos conjuntos de treinamento e teste.

Base de dados	Pacientes com COVID-19	Pacientes saudáveis	Total
Treinamento	12.447	16.681	29.128
Teste	3.072	4.211	7.283
Total	15.519	20.892	36.411

Após a etapa de extração de características de textura, descrita na Seção 3.3, foram extraídas 195 características para cada imagem presente na base de dados. Em seguida, todas as características foram normalizadas e submetidas ao algoritmo MLP na etapa de reconhecimento de padrões. A Tabela 2 apresenta os resultados obtidos pelo método proposto usando todas as características de textura e cada descritor de forma individual, incluindo a acurácia (Acc), precisão (Prec), *recall* (Rec) e especificidade (Esp) no conjunto de teste.

Analisando a Tabela 2, percebe-se a importância de todos os descritores de textura juntos para o diagnóstico de pacientes com COVID-19. Ao compararmos as métricas de avaliação, os ganhos foram em torno de 6% em média comparados aos resultados obtidos

Tabela 2. Resultados obtidos no conjunto de teste por cada grupo de descritores de textura.

Descritores de textura	Quantidade	Acc (%)	Prec (%)	Rec (%)	Esp (%)
TAS	54	87,9	84,5	87,2	88,4
Zernike	25	61,3	55,4	55,4	75,3
GLCM	24	89,0	84,9	90,0	88,4
First Order	18	87,2	84,7	85,1	88,8
GLDM	14	90,3	88,9	88,1	91,9
GLSZM	16	85,8	84,7	81,0	89,3
GLRLM	16	89,9	87,2	89,1	90,4
Haralick features	13	90,4	88,6	88,6	91,7
LBP	10	85,6	86,1	78,5	90,8
NGTDM	5	80,7	76,1	79,2	81,8
Todos	195	96,8	97,1	96,4	97,9

usando apenas as características de Haralick, que foi o descritor com o segundo melhor resultado, mostrando a eficácia da abordagem *Radiomics* no contexto do diagnóstico de COVID-19 em imagens de raio-X.

4.1. Estudo de Caso

A Figura 2 (a) ilustra um caso de erro na predição de um paciente saudável, por outro lado, a Figura 2 (b) apresenta um exemplo de erro na predição de um paciente com COVID-19. Ao observar a Figura 2, nota-se que em (a) o paciente apresenta alguns artefatos aparentes (bronquíolos, derrame pleural ou espessamento dos septos interlobulares) dentro da região do parênquima, o que possivelmente fez com que o modelo preditivo classificasse esta imagem como um paciente com COVID-19. Contudo, de acordo com o especialista, tais artefatos não são capazes de classificá-lo em um paciente com COVID-19. Por outro lado, em (b), a região do parênquima do paciente não possui aparição de preenchimento pulmonar, levando o modelo preditivo a classificá-lo como normal.



(a)



(b)

Figura 2. Casos de erros nas predições do modelo preditivo. (a) Erro em paciente saudável e (b) erro em paciente com COVID-19.

5. Conclusão

O presente trabalho apresentou um método automático para o diagnóstico de COVID-19 em imagens de raio-X usando a abordagem *Radiomics* e o algoritmo de aprendizado de máquina MLP. Os melhores resultados foram obtidos utilizando todos os descritores de textura juntos, alcançando uma acurácia de 96,8%, precisão de 97,1%, *recall* de 96,4% e especificidade de 97,9%, com isso demonstrando a importância do *Radiomics* no diagnóstico da COVID-19 por imagens.

Como trabalhos futuros, pretende-se incorporar a etapa de seleção de características para uma análise minuciosa dos descritores de textura utilizados. Além disso, aplicar técnicas de interpretabilidade do modelo preditivo com o objetivo de entender a importância de cada característica utilizada na predição. Por fim, investigar uma possível etapa de segmentação dos pulmões antes da extração de características e comparar os resultados obtidos.

Referências

- Apostolopoulos, I. D. and Mpesiana, T. A. (2020). Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, page 1.
- Bakheet, S. and Al-Hamadi, A. (2021). Automatic detection of covid-19 using pruned glcm-based texture features and ldcrf classification. *Computers in Biology and Medicine*, 137:104781.
- Bernheim, A., Mei, X., Huang, M., Yang, Y., Fayad, Z. A., Zhang, N., Diao, K., Lin, B., Zhu, X., Li, K., et al. (2020). Chest ct findings in coronavirus disease-19 (covid-19): relationship to duration of infection. *Radiology*, page 200463.
- Chan, J. F.-W., Yuan, S., Kok, K.-H., To, K. K.-W., Chu, H., Yang, J., Xing, F., Liu, J., Yip, C. C.-Y., Poon, R. W.-S., et al. (2020). A familial cluster of pneumonia associated with the 2019 novel coronavirus indicating person-to-person transmission: a study of a family cluster. *The Lancet*, 395(10223):514–523.
- dos S. Neto, A. C., Diniz, J. O. B., Diniz, P. H. B., Cavalcante, A. B., Silva, A. C., and de Paiva, A. C. (2018). Classificação do câncer de pulmão de células não pequenas usando índice de diversidade filogenética e índices de forma em uma abordagem radiomics. In *Anais do XVIII Simpósio Brasileiro de Computação Aplicada à Saúde*, Porto Alegre, RS, Brasil. SBC.
- El-Din Hemdan, E., Shouman, M. A., and Karar, M. E. (2020). Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images. *arXiv*, pages arXiv–2003.
- Hamilton, N. A., Pantelic, R. S., Hanson, K., and Teasdale, R. D. (2007). Fast automated cell phenotype image classification. *BMC bioinformatics*, 8(1):1–8.
- Haralick, R. M., Shanmugam, K., and Dinstein, I. H. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6):610–621.
- Imada, R. (2013). *Os Momentos de Zernike no Reconhecimento de Contornos de Edifícios*. Anais do Congresso de Matemática Aplicada e Computacional.

- Kroft, L. J., van der Velden, L., Girón, I. H., Roelofs, J. J., de Roos, A., and Geleijns, J. (2019). Added value of ultra-low-dose computed tomography, dose equivalent to chest x-ray radiography, for diagnosing chest pathology. *Journal of thoracic imaging*, 34(3):179.
- Kumar, A., Tripathi, A. R., Satapathy, S. C., and Zhang, Y.-D. (2022). Sars-net: Covid-19 detection from chest x-rays by combining graph convolutional network and convolutional neural network. *Pattern Recognition*, 122:108255.
- Mayerhoefer, M. E., Materka, A., Langs, G., Häggström, I., Szczypiński, P., Gibbs, P., and Cook, G. (2020). Introduction to radiomics. *Journal of Nuclear Medicine*, 61(4):488–495.
- Narin, A., Kaya, C., and Pamuk, Z. (2020). Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. *arXiv preprint arXiv:2003.10849*.
- Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., and Acharya, U. R. (2020). Automated detection of covid-19 cases using deep neural networks with x-ray images. *Computers in Biology and Medicine*, 121:103792.
- Pereira, R. M., Bertolini, D., Teixeira, L. O., Silla, C. N., and Costa, Y. M. (2020). Covid-19 identification in chest x-ray images on flat and hierarchical classification scenarios. *Computer Methods and Programs in Biomedicine*, 194:105532.
- Sitaula, C. and Hossain, M. B. (2021). Attention-based vgg-16 model for covid-19 chest x-ray image classification. *Applied Intelligence*, 51(5):2850–2863.
- Sonawane, J. S. and Patil, D. (2014). Prediction of heart disease using multilayer perceptron neural network. In *International conference on information communication and embedded systems (ICICES2014)*, pages 1–6. IEEE.
- Tan, W., Zhao, X., Ma, X., Wang, W., Niu, P., Xu, W., Gao, G. F., and Wu, G. (2020). A novel coronavirus genome identified in a cluster of pneumonia cases—wuhan, china 2019- 2020. *China CDC Weekly*, 2(4):61–62.
- Wu, Z., Li, L., Jin, R., Liang, L., Hu, Z., Tao, L., Han, Y., Feng, W., Zhou, D., Li, W., et al. (2021). Texture feature-based machine learning classifier could assist in the diagnosis of covid-19. *European journal of radiology*, 137:109602.
- Zhang, J., Xie, Y., Li, Y., Shen, C., and Xia, Y. (2020). Covid-19 screening on chest x-ray images using deep learning based anomaly detection. *arXiv preprint arXiv:2003.12338*.
- Zhu, N., Zhang, D., Wang, W., Li, X., Yang, B., Song, J., Zhao, X., Huang, B., Shi, W., Lu, R., et al. (2020). China novel coronavirus investigating and research team. a novel coronavirus from patients with pneumonia in china, 2019. *N Engl J Med*, 382(8):727–733.
- Zwanenburg, A., Vallières, M., Abdallah, M. A., Aerts, H. J. W. L., Andrearczyk, V., Apte, A., Ashrafinia, S., Bakas, S., Beukinga, R. J., Boellaard, R., Bogowicz, M., Boldrini, L., Buvat, I., Cook, G. J. R., Davatzikos, C., Depeursinge, A., Desserot, M.-C., Dinapoli, N., Dinh, C. V., Echegaray, S., Naqa, I. E., Fedorov, A. Y., Gatta, R., Gillies, R. J., Goh, V., Götz, M., Guckenberger, M., Ha, S. M., Hatt, M., Isensee,

F., Lambin, P., Leger, S., Leijenaar, R. T., Lenkiewicz, J., Lippert, F., Losnegård, A., Maier-Hein, K. H., Morin, O., Müller, H., Napel, S., Nioche, C., Orhac, F., Pati, S., Pfaehler, E. A., Rahmim, A., Rao, A. U., Scherer, J., Siddique, M. M., Sijtsema, N. M., Fernandez, J. S., Spezi, E., Steenbakkers, R. J., Tanadini-Lang, S., Thorwarth, D., Troost, E. G., Upadhaya, T., Valentini, V., van Dijk, L. V., van Griethuysen, J., van Velden, F. H., Whybra, P., Richter, C., and Löck, S. (2020). The image biomarker standardization initiative: Standardized quantitative radiomics for high-throughput image-based phenotyping. *Radiology*, 295(2):328–338.