

XXVII Brazilian Congress in Biomedical Engineering
October 26-30 2020 Vitoria (Brazil)



CBEB2020

XXVII Congresso Brasileiro
de Engenharia Biomédica

Técnicas de Seleção de Atributos para Classificação de Imagens Radiográficas

C.A. Costa JR¹, G. M. Pereira¹, P.M. Souza¹, C.M. Oliveira², L.V. Moura², A.M. Marques da Silva² e A.C. Patrocínio¹

¹Universidade Federal de Uberlândia/Engenharia Biomédica, Faculdade de Engenharia Elétrica, Uberlândia, Brasil

²Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS), Laboratório de Computação em Imagens Médicas, Porto Alegre, Brasil

Abstract— The outbreak of the infectious disease COVID-19 caused by the corona virus was declared a global pandemic by the World Health Organization and leads to Severe Acute Respiratory Syndrome. In this work, the authors considered using tools and methods of analysis in chest X-ray images with and without a diagnosis of COVID-19, looking for possible ways to aid in the detection of the disease. Three groups with 166 radiographic images each were used, where one is formed by radiographs of patients positive for COVID-19 and the remaining two, negative for COVID-19. After extracting attributes from the images, the Friedman hypothesis test was applied to select the attributes with the greatest statistical relevance to undergo the clustering technique. The Haralick technique was not significant and, for this reason, they were not used in the next stage. The texture descriptors using the wavelet, showed that 75% of the tested attributes showed a significant difference. Using only one of the attributes in K-means, the rate of 74.3% for the Vertical Standard Deviation was obtained as the best result. By combining all 12 attributes, a hit rate of 73.1% was obtained. Using 4 attributes, namely: Vertical Standard Deviation, Horizontal Standard Deviation, Number of Pixels Greater than the Peak Value and Smallest Pixel the result remained at 73.1%. The technique of extracting attributes of Haralick, unlike the other two, did not show a significant difference that justifies its use in a technique that considers separation of groups.

Keywords— Covid-19, Haralick, Wavelet, Texture, Intensity, Descriptors, Clusters, K-means

I. INTRODUCTION

O mundo está testemunhando em 2020 uma repentina crise global em saúde. O surto da doença infecciosa COVID-19, causada pelo coronavírus da Síndrome Respiratória Aguda Grave 2 (SARS-CoV-2), foi declarada como uma pandemia global pela Organização Mundial da Saúde (OMS) devido ao número crescente de pessoas afetadas em vários países e em todos os continentes [1].

Os sistemas de saúde tiveram o desafio de não colapsar em todo o mundo, principalmente devido à escassez de suprimentos médicos, bem como de profissionais que trabalham na área da saúde. Devido ao longo período de incubação da COVID-19 e sua alta contagiosidade, identificar os casos precoces e isolá-los da população saudável tornou-se

de extrema importância, principalmente com a ausência de vacinas e protocolos terapêuticos [1, 2].

A detecção de ácido nucleico viral usando Reação em Cadeia da Polimerase com Transcrição Reversa (RT-PCR) foi considerado o método padrão-ouro de diagnóstico para casos COVID-19 [3]. No entanto, foi relatado que os testes de RT-PCR tem o processo de diagnóstico demorado e sofrem com uma alta taxa de falsos negativos, principalmente devido a erros de coleta de laboratório e amostra [3, 4]. Essas limitações tornam o RT-PCR desfavorável na prática clínica diária, em meio a um cenário pandêmico [5].

Em contrapartida, o diagnóstico por imagem surge como um grande candidato para ajudar na triagem de casos COVID-19. Podem-se discriminar pacientes acometidos pelos sintomas da COVID-19 de outras condições, pelo fato de que a maioria dos pacientes com COVID-19, manifestando sintomas, apresentam anormalidades nas imagens médicas de tórax [6]. Nesse contexto, a radiografia de tórax e a tomografia computadorizada (TC) tem sido amplamente utilizadas na linha de frente de hospitais para auxiliar na detecção e no prognóstico dos pacientes com COVID-19 [6, 7]. A literatura recente em radiologia para COVID-19 girou em torno da TC devido à sua maior sensibilidade. No entanto, existem várias vantagens de promover o uso de imagens de radiografia torácica para a avaliação de casos desta doença. A radiografia é mais barata, mais fácil de executar, os equipamentos de raios-X são muito mais disponíveis que os scanners de TC, especialmente nos países em desenvolvimento. Além disso, com a ajuda de equipamentos de raios-X portáteis, a imagem pode ser realizada em ambientes com baixo risco de infecção e transmissão [7, 8].

Achados radiológicos como opacidades do espaço aéreo pulmonar e/ou opacidades em vidro fosco, distribuídas nas zonas bilateral, periférica e inferior do pulmão são as aparências radiológicas comumente relatadas com a COVID-19. No entanto, essas manifestações são muito semelhantes a vários tipos de pneumonias virais e outras inflamações e doenças pulmonares infecciosas. Por isso, é difícil para os radiologistas discriminarem a COVID-19 de outros tipos de pneumonia [9, 10].

Diante desta problemática, diversos estudos vem sendo desenvolvidos no intuito de criar ferramentas que auxiliem os profissionais no diagnóstico desta doença em questão, usando a classificação de radiografias por utilização de redes

neurais e análises em *deep learning* Estudos desenvolvidos por [11, 12] fazem uso destas técnicas. Além disso, em [13], o autor revisa e discute as ferramentas que poderiam ser usadas em radiografias para classificação da Covid-19. Assim, neste trabalho, os autores consideraram utilizar ferramentas e métodos de análise em imagens radiográficas de tórax com e sem COVID-19, e compará-las na tentativa de encontrar aspectos inerentes à manifestação da doença, que possam ser indicativos, a nível pulmonar, de possíveis vertentes de auxílio a detecção da doença.

II. METODOLOGIA

Para este trabalho foram usados dois bancos de imagens de raios X de tórax, sendo um com imagens de pacientes com Covid-19 e outro com imagens de pacientes que não apresentavam a doença. Foram usadas 166 imagens de pacientes diagnosticados com Covid-19, disponíveis no repositório do *github*, compondo assim o primeiro grupo, aqui chamado de *Com Covid* [14]. E dois grupos de 166 imagens de pacientes, provenientes do banco CheXpert [15], que não apresentaram a doença, denominados neste estudo de grupos *Sem Covid* e *Sem Covid2*, respectivamente.

Todas as imagens dos bancos acima citados, passaram pelas etapas de pós-processamento, primeiramente, onde foram feitas a extração de atributos de textura e intensidade. Logo após foram aplicadas análises estatística e posterior classificação utilizando o algoritmo *k-means*, que serão descritos a seguir:

A. Extração de atributos

Neste trabalho foram usados atributos de textura e intensidade. Uma das técnicas utilizada para a extração de atributos de textura proposta por Haralick [16], onde são utilizadas matrizes de co-ocorrências de níveis de cinza, que são descritores estatísticos que a distribuição e a relação de dos pixels, por tons de cinza, em uma imagem e considera as interações espaciais entre pixels [17]. Esta técnica assume que as informações no contexto de textura de uma determinada imagem estão contidas na relação espacial geral ou "média" que os tons de cinza da imagem [18].

Foram extraídos 14 descritores usando a técnica de Haralick, sendo eles: Energia, Contraste, Correlação, Variância, Homogeneidade, Média da Soma, Variância da Soma, Entropia da Soma, Entropia, Variância da Diferença, Entropia da Diferença, Medida de Informação de Correlação 1 (MIC I), Medida de Informação de Correlação 2 (MIC II) e Máximo de Coeficiente de Relação [19].

Outra técnica utilizada para a extração de atributos de textura foi a *Transformada Wavelet* (TW), nela o sinal pode ser decomposto em diferentes escalas tanto no domínio do

tempo quanto no domínio da frequência. Como sugere o nome a transformada decompõe o sinal em ondas, ou seja, conjuntos apropriados de bases de funções [20]. A fim de conseguir obter informações da imagem por meio da TW foi criada uma análise multirresolução onde é possível ter aproximação e detalhes do sinal [21].

Nesta técnica o sinal é dividido em 4 coeficientes: aproximação, horizontal, vertical e diagonal. Como atributo de textura foram utilizadas a média e o desvio padrão de cada atributo.

Além dos descritores de textura supracitados, também foram utilizados atributos de intensidade descritos a seguir: Média do valor dos pixels, Moda excluindo o fundo (pixels maior que zero), Menor Pixel (também excluindo o fundo), Maior Pixel (excluindo o maior valor da escala), Percentual da Moda em Relação ao Maior Pixel, Diferença da Média com o Menor Pixel, Diferença da Média com o Maior Pixel, Quantidade de Pixels Maior que o Valor de Pico e Quantidade de níveis de cinza da imagem.

Todas as intervenções para extração de atributos foram realizadas no software *Matlab*, utilizando suas próprias bibliotecas para a execução. Após a extração de todos os atributos em todas as imagens selecionadas, os seus valores puros foram submetidos a um teste estatístico para identificar quais destes apresentaram diferença estatisticamente significativa.

B. Testes Estatísticos

A análise estatística abordou os três grupos anteriormente citados, com 166 imagens cada. Em um primeiro momento foi realizado o teste de normalidade para o conjunto das amostras de cada variável extraída, para cada um dos grupos. Isto possibilitou escolha e pertinência do teste de hipóteses que seria adotado. Em segundo momento, foi usado o teste de Friedman para análise de significância destes três grupos, por se tratar de um conjunto de dados heterogêneo, independente e não paramétrico, e que possibilita analisar de forma direta o quanto as oscilações numéricas encontradas podem indicar um comportamento que não é ao acaso [22, 23].

Este teste estatístico foi aplicado de forma a averiguar se os grupos utilizados no estudo apresentaram valores estatisticamente similares entre si ou não, com relação aos dados quantitativos coletados de cada atributo, extraídos em pós-processamento. Foi utilizado o software de análise estatística *BioEstat*, na versão 5.3, para entrada de dados e testes de hipótese e significância. Todos os testes consideraram α de 0,05.

C. Técnica de Clusterização K-means

Como o próprio nome sugere, uma técnica de *clusterização* consiste em dividir os dados ou população em grupos distintos conforme a semelhança dos dados apresentados, ou seja, agrupar os *clusters* conforme a semelhança apresentada.

O agrupamento *K-means* [24] é um método comumente utilizado para subdividir automaticamente um conjunto de dados em n grupos. O algoritmo é que determinou o número de 2 de centroides e posteriormente seguiu refinando-os de forma iterativa. Primeiramente cada dado foi atribuído a um centroide com a menor distância d_i , posteriormente os centroides foram ajustados para que seu valor seja a média dos dados próximos à ele [25].

III. RESULTADOS

A metodologia descrita anteriormente foi aplicada nas 498 imagens dos bancos utilizados, sendo assim, para cada imagem foram extraídos 31 atributos. Nas Tabelas de 1 a 3, a seguir, são apresentadas as médias e os desvios padrão dos valores obtidos em cada banco.

Tabela 1 Atributos de Textura Haralick

Item	Com Covid ($\bar{X} \pm \sigma$)	Sem Covid ($\bar{X} \pm \sigma$)	Sem Covid2 ($\bar{X} \pm \sigma$)
Energia	0,176 ± 0,03	0,194 ± 0,03	0,173 ± 0,04
Contraste	0,067 ± 0,03	0,056 ± 0,01	0,061 ± 0,01
Correlação	0,986 ± 0,001	0,988 ± 0,001	0,989 ± 0,001
Variância	26,31 ± 7,03	27,55 ± 4,95	26,48 ± 7,03
Homogeneidade	0,970 ± 0,01	0,974 ± 0,00	0,972 ± 0,00
Média da Soma	9,619 ± 1,46	9,940 ± 1,04	9,550 ± 1,51
Variância da Soma	105,8 ± 28,2	110,7 ± 19,8	106,4 ± 28,2
Entropia da Soma	1,948 ± 0,19	1,897 ± 0,15	1,995 ± 0,22
Entropia	2,876 ± 0,30	2,797 ± 0,22	2,942 ± 0,34
Variância da Diferença	0,068 ± 0,02	0,058 ± 0,001	0,062 ± 0,01
Entropia da Diferença	0,215 ± 0,08	0,203 ± 0,02	0,211 ± 0,05
MIC I	-0,86 ± 0,05	-0,86 ± 0,01	-0,86 ± 0,02
MIC II	0,992 ± 0,001	0,992 ± 0,001	0,993 ± 0,001
Máximo de Coeficiente de Relação	0,211 ± 0,03	0,227 ± 0,04	0,207 ± 0,05

Tabela 2 Atributos de Textura Wavelet

Item	Com Covid	Sem Covid	Sem Covid2
------	-----------	-----------	------------

	($\bar{X} \pm \sigma$)	($\bar{X} \pm \sigma$)	($\bar{X} \pm \sigma$)
Média - Aproximação	273,2 ± 48,1	282,9 ± 34,1	270,0 ± 48,7
Média - Horizontal	0,003 ± 0,03	-0,005 ± 0,02	-0,02 ± 0,02
Média - Vertical	0,004 ± 0,04	-0,02 ± 0,02	-0,01 ± 0,02
Média - Diagonal	0,001 ± 0,006	-0,0001 ± 0,001	-0,0005 ± 0,001
Desv Padrão - Aproximação	106,6 ± 22,4	105,2 ± 18,2	115,5 ± 21,3
Desv Padrão - Horizontal	3,310 ± 2,03	2,471 ± 0,82	2,733 ± 0,85
Desv Padrão - Vertical	3,122 ± 1,66	2,270 ± 0,74	2,555 ± 0,86
Desv Padrão - Diagonal	1,242 ± 0,95	0,776 ± 0,18	0,969 ± 0,33

Tabela 3 Atributos de Intensidade

Item	Com Covid ($\bar{X} \pm \sigma$)	Sem Covid ($\bar{X} \pm \sigma$)	Sem Covid2 ($\bar{X} \pm \sigma$)
Média Pixels	136,9 ± 24,1	142,2 ± 17,0	135,7 ± 24,5
Moda < 0	134,1 ± 88,2	127,3 ± 82,8	94,48 ± 94,9
Menor Pixel < 0	6,801 ± 14,9	4,469 ± 5,86	2,090 ± 2,41
Maior Pixel < 255	250,2 ± 10,7	239,2 ± 10,0	245,3 ± 14,1
Porcentagem Moda Em relação ao max da escala	0,526 ± 0,34	0,499 ± 0,32	0,370 ± 0,37
Dif Média Menor Valor Pixel < 0	130,1 ± 25,1	137,7 ± 14,3	133,6 ± 23,6
Dif Média Maior Valor Pixel < 255	113,3 ± 24,6	97,07 ± 18,9	109,6 ± 27,6
Qtde Pixels > valor de pico	16973 ± 2128	51649 ± 3382	62563 ± 3890
Qtde de níveis da imagem	243,4 ± 19,6	234,8 ± 11,6	243,2 ± 14,7

Os dados citados, foram submetidos a testes estatísticos que mostraram quais dados apresentaram diferença significativa, como apresenta a Fig. 1.

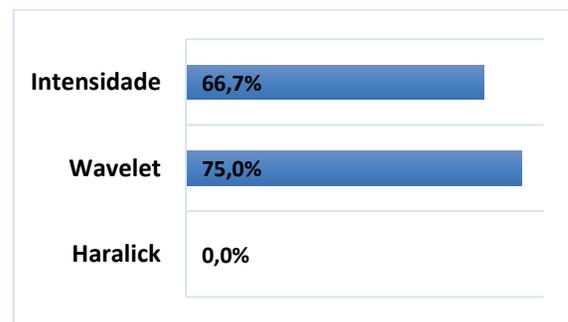


Fig. 1 Percentual de Atributos com Diferença Significativa

A partir da Fig. 1, temos que todos os descritores de Haralick foram descartados nesta etapa do trabalho por não apresentarem diferença. Já 6 dos 8 atributos de textura usando a Wavelet, sendo eles: Média Horizontal, Média Vertical, Média Diagonal, Desvio Padrão Aproximação, Desvio Padrão Horizontal e Desvio Padrão Vertical e 6 dos 9 atributos de intensidade, sendo eles: Menor Pixel, Maior Pixel, Diferença da Média com o Menor Pixel, Diferença da Média com o Maior Pixel, Quantidade de Pixels Maior que o Valor de Pico e Quantidade de níveis de cinza da imagem apresentaram diferença e foram utilizados para *clusterização* das imagens.

Todos os atributos foram testados no *K-means* individualmente para a decisão de qual combinação poderia ser mais eficaz para a separação dos grupos pelo algoritmo. Nas Fig. 2 e 3 mostram a taxa de acerto obtida por cada atributo.

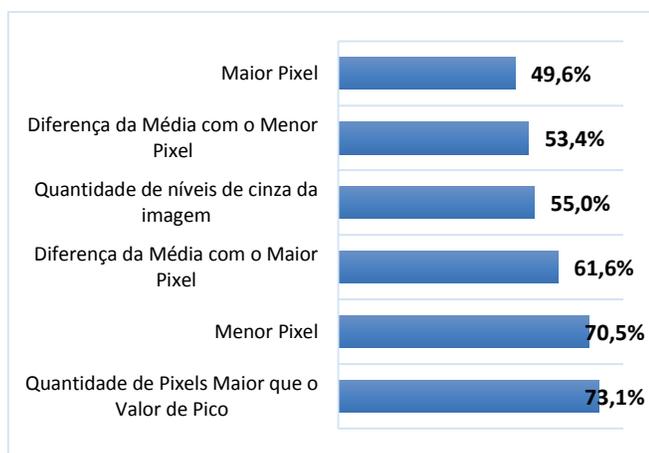


Fig. 2 Percentual de Acerto dos Atributos de Intensidade

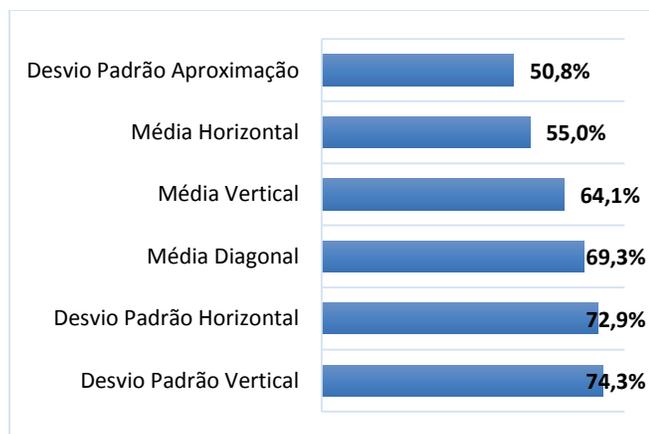


Fig. 3 Percentual de Acerto dos Atributos de Textura Wavelet

Após a obtenção da taxa de acerto individual dos atributos, foram feitos testes utilizando apenas os grupos (Wavelet

e Intensidade) cujos resultados apresentaram os melhores resultados. Primeiramente, utilizou-se os 4 melhores atributos dentre os dois grupos, com taxa de acerto maior que 70,0%. Posteriormente, considerando que o atributo de Média Diagonal demonstrou comportamento próximo a 70,0%, procedeu-se pela inclusão deste no grupo de atributos a serem testados, formando a classe de 5 atributos. Seguindo com os testes, foi calculado o percentual de acerto para todos os atributos dos dois grupos, Intensidade e Wavelet, em conjunto e separadamente. Os resultados estão apresentados na Fig. 4.

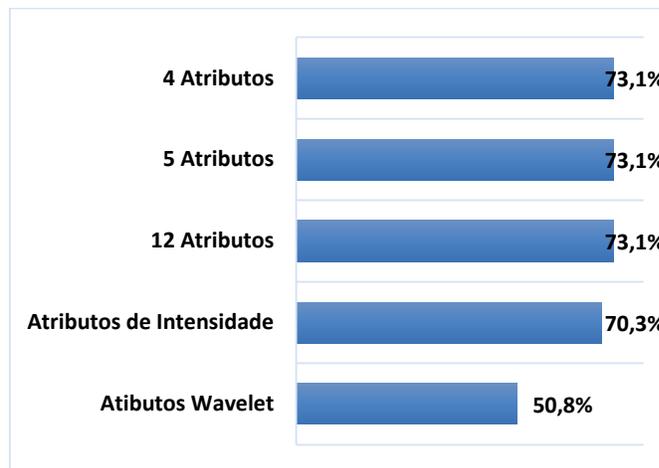


Fig. 4 Percentual de Acerto dos Atributos de Textura Wavelet

IV. DISCUSSÃO

Com base na extração de atributos não se pode verificar quais dados apresentariam diferença significativas. Por esta razão, foram feitos os testes estatísticos para averiguar e selecionar quais seriam os atributos utilizados no algoritmo de *clusterização*, com base na sua relevância estatística.

Sendo assim, após os testes, notou-se que todos os descritores de textura utilizando a técnica de Haralick não se mostraram significativos e, por esta razão, não foram utilizados na etapa seguinte.

Enquanto isso, os descritores de textura usando a *wavelet*, mostraram que 75% dos atributos testados neste trabalho apresentaram diferença significativa. Dentre todos os atributos de intensidade, 66% apresentaram diferenças entre os grupos de dados.

Partindo para a técnica de *clusterização K-means*, o resultado obtido para a separação das imagens no grupo *Com Covid-19* e *Sem Covid-19*, utilizando apenas um dos atributos, obteve como melhor resultado a taxa de 74,3% para o Desvio Padrão Vertical. Já quando a subdivisão foi feita agrupando todos os descritores Wavelet e Intensidade, o

resultado obtido foi de 50,8% e 70,3%, respectivamente. Este se mostrou um achado diferente do que traz a literatura [26], que recomenda a combinação de dois ou mais atributos para que seja realizada a classificação.

Realizando uma combinação entre todos os 12 atributos, o resultado teve um aumento de 2,8 p.p., ou seja, teve uma taxa de acerto de 73,1% se comparado ao melhor resultado usando grupos de dados.

Ao reduzir a quantidade de dados para inserção no *K-means* para 4 atributos, sendo eles: Desvio Padrão Vertical, Desvio Padrão Horizontal, Quantidade de Pixels Maior que o Valor de Pico e Menor Pixel o resultado permaneceu em 73,1%.

V. CONCLUSÃO

A partir dos resultados obtido por este trabalho ficou claro que para o grupo de imagens aqui utilizado, a técnica de extração de atributos de Haralick não apresenta uma diferença significativa que justifique sua utilização em uma técnica que considere separação de grupos.

Enquanto isso os atributos significantes extraídos a partir da Wavelet e de Intensidade apresentaram uma taxa de acerto de 73,1% usando o *K-means*.

O *K-means* utilizado neste trabalho representa também uma técnica de seleção de atributos para a utilização de um classificador mais robusto que está sendo implementado como etapa posterior a esta, no estudo de radiografia de tórax de pacientes com Covid-19

REFERÊNCIAS

1. Na Z, Dingyu Z, et al (2020) A novel coronavirus from patients with pneumonia in china, 2019. New England Journal of Medicine.
2. Qun L, Xuhua G et al (2020) Early transmission dynamics in wuhan, china, of novel coronavirus–infected pneumo-nia. New England Journal of Medicine.
3. Tao A, Zhenlu Y et al (2020) Correlation of chest ct and rt-pcr testing in coronavirus disease 2019 (covid-19) in china: a report of 1014 cases. Radiology p. 200642.
4. Yicheng F, Huangqi Z, et al (2020) Sensitivity of chest ct for covid-19: comparison to rt-pcr. Radiology p. 200432.
5. Chatterjee S et al (2020) Exploration of Interpretability Techniques for Deep COVID-19 Classification using Chest X-ray Images. arXiv preprint arXiv 2006:2570.
6. Ali N, Ceren K and Ziyet P (2020) Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. arXiv preprint arXiv 2003:10849.
7. Jeffrey P (2020) Chest ct findings in 2019 novel coronavirus (2019-ncov) infections from wuhan, china: key points for the radiologist.
8. Jacobi A, Chung M, Bernheim A, and Eber C (2020) Portable chest x-ray in coronavirus disease-19 (covid-19): A pic-torial review. Clinical Imaging.
9. Ho Y, Hiu Y, et al (2020) Frequency and distribution of chest radiographic findings in covid-19 positive patients. Ra-diology, p. 201160.
10. Wang L, Wong A, and Qui Lin Z (2020) Covid-net: A tailored deep convolutional neural network design for detec-tion of covid-19 cases from chest x-ray images. arXiv preprint arXiv:2003: 9871.
11. Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., & Acharya, U. R. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. Computers in Biology and Medicine, 103792.
12. Hemdan, E. E. D., Shouman, M. A., & Karar, M. E. (2020). Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images. arXiv preprint arXiv:2003.11055.
13. Shi, F., Wang, J., Shi, J., Wu, Z., Wang, Q., Tang, Z., ... & Shen, D. (2020). Review of artificial intelligence techniques in imaging data acquisition, segmentation and diagnosis for covid-19. IEEE reviews in biomedical engineering.
14. Cohen J, Morrison P, Dao L (2020) COVID-19 image data collection. arXiv preprint arXiv 2003:11597.
15. Wang, X et al (2017) .Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases. In: IEEE CVPR.
16. Haralick R, Shanmugan K (1973) Its' Hak. Textural features for image classification. IEEE Transactions on systems, man, and cybernetics, pp. 610-621.
17. Porebski, A, Vandenbroucke N, Macaire L (2008) Haralick feature extraction from LBP images for color texture classification. In: 2008 First Workshops on Image Processing Theory, Tools and Applications IEEE pp. 1-8.
18. Aksoy S, Haralick R (1998) Textural features for image database retrieval. In: Proceedings. IEEE Workshop on Content-Based Access of Image and Video Libraries (Cat. No. 98EX173). IEEE pp. 45-49.
19. Gelzinis A, Verikas A, Bacauskiene M (2007) Increasing the discrimination power of the co-occurrence matrix-based features. Pattern Recognition, pp. 2367-2372.
20. Carneiro P, et al (2019). Proposta de metodologia para realce de contraste em imagens de mamas densas utilizando decomposição multiescala com transformada discreta wavelet.
21. Mallat S (1989) A theory for multiresolution signal decomposition: the wavelet representation. IEEE transactions on pattern analysis and machine intelligence, pp. 674-693.
22. Zimmerman W, Zumbo B (1993) Relative power of the Wilcoxon test, the Friedman test, and repeated-measures ANOVA on ranks. The Journal of Experimental Education, pp. 75-86.
23. Ishitaki T, Oda T; Barolli L (2016) A neural network based user identification for Tor networks: Data analysis using Friedman test. In: 2016 30th International Conference on Advanced Information Networking and Applications Workshops IEEE pp. 7-13.
24. Macqueen J (1967) et al. Some methods for classification and analysis of multivariate observations. In: Proceedings of the fifth Berkeley symposium on mathematical statistics and probability pp.281-297.
25. Wagstaff K et al (2001) Constrained k-means clustering with background knowledge. In: Icml pp. 577-584.
26. Carneiro, P et al (2015). Classificação mamográfica por densidade de mamária utilizando atributos de intensidade e textura.

Enter the information of the corresponding author:

Author: Carlos Alberto da Costa Junior
Institute: Faculdade de Engenharia Elétrica
Street: Av João Naves de Ávila 2121
City: Uberlândia/MG
Country: Brasil
Email: carlosjunior@ufu.br

Author: Gabrielle Macedo Pereira
Institute: Faculdade de Engenharia Elétrica
Street: Av João Naves de Ávila 2121
City: Uberlândia/MG
Country: Brasil
Email: gabriellem@ufu.br

Author: Pedro
Institute: Faculdade de Engenharia Elétrica
Street: Av João Naves de Ávila 2121
City: Uberlândia/MG
Country: Brasil
Email: profpedromois@gmail.com

Author: Ana Cláudia Patrocínio
Institute: Faculdade de Engenharia Elétrica
Street: Av João Naves de Ávila 2121
City: Uberlândia/MG
Country: Brasil
Email: ana.patrocinio@ufu.br