



## Classificação da COVID-19 em Radiografias do Tórax Utilizando Redes Neurais Profundas e Padrões Binários Locais

COVID-19 X-Ray Imaging Classification Using Deep Neural Network and Local Binary Patterns

Clasificación da COVID-19 en Imágenes de Rayos-X Mediante Redes Neuronales Profundas y Patrones Binarios Locales

João Victor Gomes Martins<sup>1</sup>, Mateus Pereira Gregório<sup>1</sup>, Matheus de Freitas Oliveira Baffa<sup>2</sup>,  
Alessandra Martins Coelho<sup>3</sup>

### RESUMO

**Descritores:**  
Aprendizado Profundo;  
Coronavírus; Radiografia

**Objetivos:** O trabalho é desenvolver um algoritmo de classificação de imagens de raios-x do tórax para auxiliar na detecção de pacientes infectados pelo SARS-COV-2. **Métodos:** O método proposto neste trabalho consiste em realizar um pré-processamento das imagens, destacando as características texturais, a fim de criar um vetor descritor baseado em padrões locais binários. A detecção de padrões e a criação do modelo de classificação é realizada utilizando uma Rede Neural Totalmente Conectada. **Resultados:** Os experimentos para avaliar o método foram realizados seguindo o protocolo da validação cruzada k-fold. Foram obtidos uma taxa de acerto médio de 96.52% e uma sensibilidade de 94%. **Conclusão:** Conclui-se que o método proposto neste trabalho tem importante impacto para auxiliar os radiologistas na detecção de pacientes com COVID-19, com alto grau de confiança, podendo atuar como uma segunda avaliação de um exame por imagem.

### ABSTRACT

**Keywords:** Coronavirus;  
Deep Learning;  
Radiography

**Objectives:** The goal of this work is to develop an algorithm for classifying chest x-ray images to assist in the detection of patients infected with SARS-COV-2. **Methods:** The method proposed in this work consists of pre-processing the images, highlighting textural features, in order to create a descriptor vector based on local binary patterns. The patterns detection and the classification model creation is carried out using a Fully-Connected Neural Network. **Results:** The experiments to evaluate the method were performed following the k-fold cross-validation protocol. An average accuracy rate of 96.52% and a sensitivity of 94% were obtained. **Conclusion:** It is concluded that the method proposed in this work has an important impact to assist radiologists in the detection of patients with COVID-19, with a high degree of confidence, and can act as a second evaluation of an imaging exam.

### RESUMEN

**Descriptores:**  
Aprendizaje Profundo;  
Coronavirus; Radiografía

**Objetivo:** El objetivo de este trabajo es desarrollar un algoritmo para clasificar las imágenes de rayos X de tórax para ayudar en la detección de pacientes infectados con SARS-COV-2. **Métodos:** El método propuesto en este trabajo consiste en preprocesar las imágenes, resaltando los rasgos texturales, para crear un vector descriptor basado en patrones binarios locales. La detección de patrones y la creación del modelo de clasificación se lleva a cabo utilizando una Red Neural Totalmente Conectada. **Resultados:** Los experimentos para evaluar el método se realizaron siguiendo el protocolo de validación cruzada de k veces. Se obtuvo una tasa de precisión promedio del 96,52% y una sensibilidad del 94%. **Conclusión:** Se concluye que el método propuesto en este trabajo tiene un impacto importante para ayudar a los radiólogos en la detección de pacientes con COVID-19, con un alto grado de confianza, y puede actuar como una segunda evaluación de un examen de imagen.

<sup>1</sup> Discente do curso Bacharelado em Ciência da Computação do Instituto Federal do Sudeste de Minas Gerais – IF Sudeste MG, Rio Pomba MG, Brasil.

<sup>2</sup> Doutorando do Programa de Pós-Graduação em Bioengenharia da Universidade de São Paulo USP, São Paulo (SP), Brasil.

<sup>3</sup> Professora Titular do Departamento Acadêmico da Ciências da Computação do Instituto Federal do Sudeste de Minas Gerais – IF Sudeste MG, Rio Pomba MG, Brasil.

## INTRODUÇÃO

A infecção por coronavírus é uma doença causada pelo vírus SARS-COV-2, popularmente conhecido como coronavírus, que originou-se em *Wuhan*, na China, em dezembro de 2019. Acredita-se que o vírus tenha uma origem zoonótica, pois os primeiros casos confirmados tinham ligações principalmente ao Mercado Atacadista de Frutos do Mar de *Huinan*, local onde também vendiam-se animais vivos<sup>(1)</sup>. As investigações sobre as formas de transmissão do coronavírus ainda estão em andamento, mas é amplamente confirmado a disseminação comunitária, de pessoa para pessoa, por gotículas respiratórias ou por contato<sup>(2)</sup>.

Os pacientes diagnosticados com essa doença possuem um quadro clínico que varia de infecções assintomáticas a quadros de infecção respiratória grave<sup>(3)</sup>. Segundo a Organização Mundial da Saúde (OMS), cerca de 80% dos pacientes com infecções por coronavírus podem ser assintomáticos, enquanto 20% dos casos podem necessitar de atendimento hospitalar, sendo que, 5% desses casos, poderá ainda haver a necessidade de tratamento para insuficiência respiratória<sup>(4)</sup>.

Devido ao aumento exponencial dos casos e da sua alta capacidade de transmissão, o coronavírus se tornou um surto emergencial de saúde pública e de interesse internacional. Em 11 de março, a doença foi caracterizada como pandemia pela Organização Mundial da Saúde (OMS), devido a presença de casos positivos em diferentes continentes<sup>(5)</sup>.

O número de casos confirmados crescem a cada dia, já ultrapassando os 8 milhões de infectados mundialmente no primeiro semestre de 2020. A taxa de letalidade reportada é de aproximadamente 6,7% e já somam mais de 450 mil mortes no mundo<sup>(6)</sup>. No Brasil já são mais de cinco milhões de casos, com mais de 149 mil mortes em todo o país, até o terceiro bimestre de 2020<sup>(3)</sup>.

Os sintomas mais comuns de infecções por coronavírus são febre, tosse seca e cansaço. Segundo a Organização Mundial da Saúde (OMS,2020), a maioria dos infectados, cerca de 80%, se recuperam da doença sem precisar de tratamento hospitalar, enquanto cerca de um a cada cinco pessoas que contraem infecções por coronavírus ficam gravemente doentes, necessitando tratamento especializado.

Os pacientes que apresentam sintomas característicos da doença são submetidos a exames biológicos. Esses exames são compostos pela coleta de material respiratório, através da aspiração de vias aéreas ou indução de escarro, o qual é submetido à exames de biologia molecular, a fim de verificar a presença do RNA viral. Além deste, os testes complementares, também conhecidos como testes rápidos, realizam a coleta de sangue e verificam a presença de anticorpos ou do RNA viral<sup>(7)</sup>.

Os testes laboratoriais, são caros e muitas vezes inacessíveis em determinadas regiões no Brasil, tornando difícil a sua aplicação em massa para a obtenção de dados precisos da situação pandêmica, bem como dificultando a tomada de decisão através de políticas públicas para conter os avanços da doença.

Mediante a esse contexto, as imagens médicas têm sido utilizadas para rápida análise do estado clínico do paciente. Através da visualização dos pulmões, os médicos podem verificar a presença da pneumonia e saber o estágio de desenvolvimento da doença. No âmbito do coronavírus, as imagens mais recomendadas são as imagens de Radiografia do Tórax e a Tomografia Computadorizada (*Computed tomography* - CT)<sup>(8)</sup>.

O diagnóstico utilizando as imagens de Raios-X tem como objetivo encontrar sinais de anormalidades em relação ao padrão de pacientes saudáveis. Tais anormalidades são identificadas no exame como uma região com efeitos irregulares e bilaterais, opacas e com aspecto de vidro fosco. Embora sejam exames fáceis de serem obtidos, devido a sua alta disponibilidade, os achados clínicos podem ser similares à outros tipos de pneumonia, dificultando a diferenciação de pacientes com outras pneumonias virais<sup>(9)</sup>. Com resultado rápido, o Raio-X se torna um importante exame para auxiliar no diagnóstico de infecções por coronavírus, devido a facilidade de obtenção e baixo custo em relação aos outros exames. Além disso, existe um déficit no Brasil em radiologistas especializados em radiografias do tórax, o que gera a necessidade de outros médicos realizarem o diagnóstico das imagens<sup>(10)</sup>.

O problema de diagnóstico de exames por imagens é comumente abordado na literatura da Visão Computacional, quando aplicada à saúde como pode ser visto em Souza et al.<sup>(11)</sup> e em Baffa e Lattari<sup>(12)</sup>. Nestes trabalhos, sistemas de auxílio ao diagnóstico são desenvolvidos, a fim de detectar padrões e gerar novas informações acerca dos elementos que compõem a imagem.

Aplicado ao problema do diagnóstico do novo coronavírus, os sistemas de Visão Computacional têm sido desenvolvidos para auxiliar no diagnóstico de imagens de Raios-X e de CT. Por exemplo, Narin et al.<sup>(13)</sup> desenvolveram um método de classificação de radiografias utilizando Redes Neurais Convolutivas. O método proposto pelos autores obteve uma acurácia de 98%.

Ao detectar padrões da doença, torna-se possível a análise de um Raio-X para detecção de infecções por coronavírus. A utilização de métodos de sistemas de Visão Computacional permite um diagnóstico rápido e com alta eficiência, permitindo diagnosticar infecções por coronavírus em fases iniciais, evitando assim a disseminação da doença rapidamente. Dessa forma, no presente trabalho, é implementado um método de classificação de imagens de Raios-X para a detecção de padrões visuais. Para isso, foram utilizados 400 exames de Raios-X, sendo 200 exames de pacientes saudáveis e 200 exames de infectados por coronavírus. Estas imagens foram posteriormente utilizadas no treinamento e validação do classificador proposto.

Ressalta-se as contribuições do presente trabalho:

- a avaliação da textura como característica de classificação do Raio-X Torácico;
- a utilização de técnicas de reconhecimento de padrões baseado em Aprendizado Profundo;
- desenvolvimento de um método baseado em *Local*

*Binary Patterns* e Redes Neurais Profundas, para o auxílio do diagnóstico de infecções por coronavírus usando radiografias de pacientes infectados e saudáveis;

### Trabalhos Relacionados

Recentemente, alguns autores abordaram o problema de classificação de imagens de Raios-X envolvendo o novo coronavírus. Nesta seção serão abordados os trabalhos mais atuais de classificação binária, entre pacientes doentes e saudáveis.

Em Narin et al.<sup>(13)</sup> foram feitas diversas comparações de métodos computacionais para auxiliar no diagnóstico automatizado de infecções por coronavírus a partir de uma classificação entre pacientes doentes e saudáveis. Os autores utilizaram três subarquitecturas de Redes Neurais Convolutivas, sendo elas o *ResNET50*, o *InceptionV3* e o *Inception-ResNetV2*. Foi utilizada uma base de dados com 100 imagens, sendo 50 pessoas com infecções por coronavírus e 50 saudáveis. Os autores obtiveram, com a *ResNet50*, 98% de acurácia e 96% de sensibilidade.

Tuncer et al.<sup>(14)</sup>, apresentaram um sistema de Visão Computacional para auxiliar no diagnóstico automatizado de infecções por coronavírus classificando os pacientes entre doentes e saudáveis. Para obter os melhores resultados, os autores utilizaram a extração de características com o Padrão Binário Local Residual Exemplar (*ResExLBP*) e a Máquina de Vetor de Suporte (*Support Vector Machine - SVM*) como classificador. A base de dados utilizada continha 321 imagens, sendo 87 de pacientes com infecções por coronavírus e 234 saudáveis. Os autores obtiveram um total de 100% de acurácia e 98,8% de sensibilidade. Embora os resultados tenham sido promissores, os autores não mostraram a utilização de técnicas para lidar com o problema de *overfitting* do modelo, também não foi especificado o valor de especificidade do método. Além disso, destaca-se o desbalanceamento entre o número de amostras de cada classe na base, não sendo retratado um método de balanceamento ou a utilização de métricas para bases desbalanceadas.

Ozturk et al.<sup>(15)</sup> realizaram comparações de sistemas de Visão Computacional para auxiliar no diagnóstico automatizado de infecções por coronavírus. Os autores utilizaram a subarquitectura de Redes Neurais Convolutivas *DarkNet-19*. Para a classificação binária foi utilizada uma base de dados com 627 imagens, sendo 127 com infecções por coronavírus e 500 saudáveis. Os autores obtiveram um total de 98,08% de acurácia e 95,13% de sensibilidade.

Na primeira parte do trabalho de VanBerlo e Ross<sup>(16)</sup>, foi desenvolvido um sistema de Visão Computacional para classificação binária entre pacientes doentes e saudáveis. Os autores utilizaram a subarquitectura de Redes Neurais Convolutivas chamada *Residual Neural Network* (*ResNET*). Foi utilizada uma base de dados com 1076 imagens, sendo 76 com infecções por coronavírus e 1000 contendo imagens sem doença ou com pneumonias. Os autores obtiveram um total de 92% de acurácia e 87,5% de sensibilidade.

Barstugan et al.<sup>(17)</sup> desenvolveram um sistema de Visão Computacional para auxiliar no diagnóstico do novo

coronavírus. Foram analisadas 618 imagens, com 219 provenientes de pacientes doentes diagnosticados com infecções por coronavírus, 224 de pacientes com pneumonia e 175 de pacientes saudáveis. Os autores utilizaram cinco métodos de extração de características (*Grey Level Co-occurrence Matrix (GLCM)*, *Local Directional Pattern (LDP)*, *Grey Level Run Length Matrix (GLRLM)* e *Grey-Level Size Zone Matrix (GLSZM)*). Concluíram que o *GLSZM* foi o melhor método de extração de características, obtendo um total de 98,71% de acurácia e 97,56% de sensibilidade.

No trabalho de Butt et al.<sup>(18)</sup> foi realizado um estudo que comparou vários modelos de Redes Neurais Convolutivas para classificar amostras de exames de pacientes saudáveis e pacientes com coronavírus. Os autores analisaram 528 imagens, com 189 provenientes de pacientes doentes com infecções por coronavírus, 194 provenientes de pneumonia e 145 pacientes saudáveis. Como resultado conseguiram obter um total de 92,2% de acurácia e 98,2% de sensibilidade.

Em Wang et al.<sup>(19)</sup>, foi proposta uma Rede Neural Convolutiva personalizada, com o propósito de ser uma rede colaborativa de código aberto para obtenção de diagnóstico do coronavírus. Foi utilizada uma base de dados com 13.975 imagens. Os autores conseguiram obter um total de 93,3% de acurácia e 91,0% de sensibilidade.

No trabalho de Wang et al.<sup>(20)</sup> foi desenvolvido um sistema de Visão Computacional utilizando Rede Neural Convolutiva para o diagnóstico do coronavírus. A base de dados utilizada continha 217 imagens com a finalidade de treinamento da rede. Os autores conseguiram obter um total 82,9% de acurácia e 84% de sensibilidade.

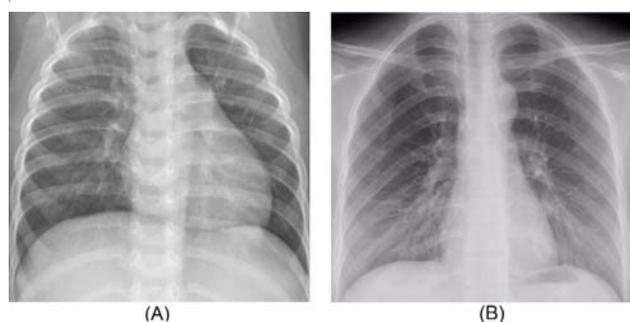
Grande parte dos trabalhos abordados na literatura trazem diferentes subarquitecturas e aplicações de Redes Neurais Convolutivas para resolver o problema do diagnóstico de infecções por coronavírus. Neste trabalho, entretanto, propomos a criação de um classificador baseado em uma Rede Neural Profunda Totalmente Conectada. Esta, detecta padrões baseados em textura, extraídas de uma base de dados visual de radiografias do tórax.

## MATERIAIS E MÉTODOS

Para o desenvolvimento deste trabalho, foram utilizados dois computadores, ambos com as mesmas bases de dados e versões dos programas. O primeiro computador tem como configuração um processador *Intel Core I3* de sexta geração, 4GB de RAM DDR3, 1TB de armazenamento e gráficos integrados *Intel HD Graphics 520*. O segundo tem um processador *Intel Core I5* de sexta geração, 8GB de RAM DDR4, SSD de 240gb e *NVIDIA Geforce 920 MX* com 2GB de VRAM. O ambiente de desenvolvimento e testes foi composto pelo *Anaconda Navigator* (versão 1.9.12), que possui diversas ferramentas de desenvolvimento. Para este trabalho, foi utilizado o *Spyder* (versão 4.0.1), que possibilita um desenvolvimento na linguagem de programação *Python* (versão 3.7) de maneira rápida e prática. Além disso, foram utilizadas as bibliotecas de Visão Computacional *Mahotas* (versão 1.4.3)

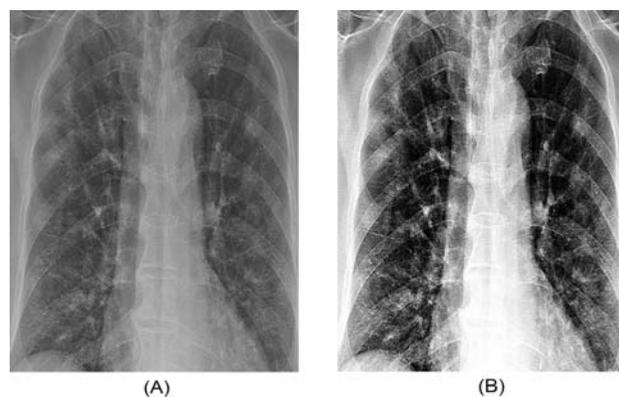
e *OpenCV* (versão 4.3), além da biblioteca de Aprendizado de Máquina *TensorFlow* (versão 1.15).

A Base de Dados utilizada foi a *COVID-19 Radiography Database*, que foi desenvolvida por pesquisadores da Universidade de Qatar (Doha), Universidade de Dhaka (Bangladesh) e colaboradores do Paquistão e da Malásia [21]. Trata-se de um banco de imagens de Raios-X do tórax, com 219 imagens de casos positivos de infecções por coronavírus, 1341 de pacientes saudáveis e 1345 de pacientes com casos de Pneumonia Viral. Como se trata de um problema de classificação binária, utilizamos apenas as imagens de pacientes saudáveis e de pacientes com infecções por coronavírus. Para resolver o problema de desbalanceamento da base de dados, evitando que o classificador favoreça a classe com mais imagens, foram usadas a mesma quantidade de imagens de pacientes saudáveis e com infecções por coronavírus.



**Figura 1** - Exemplo de imagens de Raios-X normal (Figura A) e com infecções por coronavírus (Figura B). Fonte: Tawsifur<sup>(21)</sup>.

As imagens foram lidas em escala de cinza pelo programa criado, usando a biblioteca *OpenCV*, em Python. Após serem lidas e alocadas em um vetor, foi aplicada a equalização de histogramas nas imagens, a fim de balancear a intensidade de pixel da imagem, deixando-a mais nítida, menos opaca e realçando as características texturais para futura observação.



**Figura 2** - Imagem original (a) e imagem pós processamento (b). Fonte: autor.

Na Visão Computacional, o conceito de detecção de características se refere aos métodos que têm como objetivo detectar informações de cada pixel de determinada imagem. Característica é qualquer parte da imagem que seja de interesse da aplicação.

Computacionalmente, existem diversas características importantes em uma imagem como a cor, a textura, o contorno, dentre outras.

Como extrator de características, foi usado o Padrão Binário Local (*Local Binary Patterns - LBP*)<sup>(22)</sup>, que é um método não paramétrico, computacionalmente eficiente e robusto, usado para descrever a estrutura espacial local da imagem, mostrando alta capacidade de distinguir características de textura<sup>(23)</sup>. A escolha pela utilização do LBP se deu pelo fato do padrão observado nas imagens de Raios-X se assemelhar a uma textura com padrão de vidro fosco. Desta forma, neste trabalho foi avaliado o desempenho da textura, descrita pelo LBP, como característica descritiva para classificação de infecções por coronavírus nas imagens de Raio-X.

Por fim, os valores extraídos pelo LBP de uma imagem são alocados em um vetor descritor junto da sua classificação, sendo 0 para pacientes saudáveis e 1 para pacientes doentes. Tal vetor é utilizado como parâmetro de entrada na Rede Neural em etapas posteriores no método de classificação a fim de detectar padrões visuais referentes à textura.

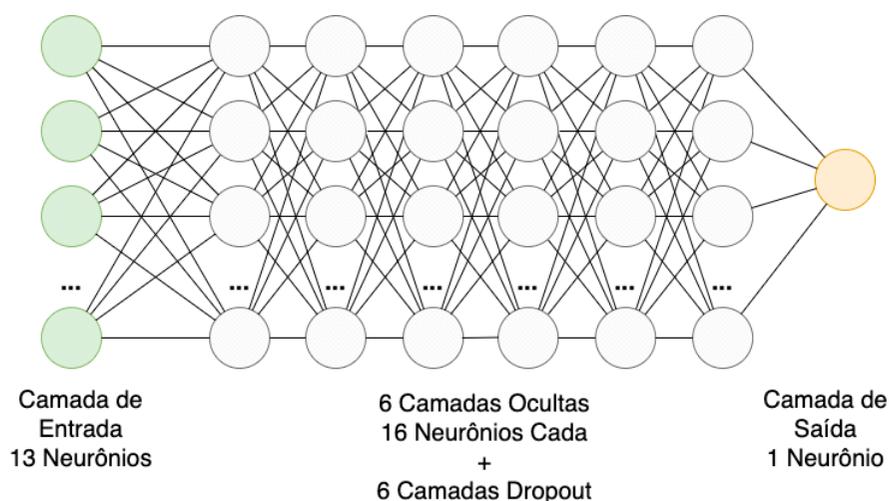
Neste trabalho, a Rede Neural Totalmente Conectada (*Fully-Connected Neural Network - FCNN*) foi utilizada como classificador. Esta rede possui uma arquitetura de Rede Neural Artificial, seguindo os padrões propostos pela abordagem do Aprendizado Profundo. É uma rede altamente eficaz na classificação de imagens, pois é capaz de detectar padrões em bases de dados, devido as suas conexões entre a saída de um neurônio com todas as entradas de todos os neurônios, formando uma rede de informações consistentes<sup>(24)</sup>.

A FCNN (Figura 3) proposta é composta por uma camada de entrada, com 13 neurônios, e seis camadas internas com 16 neurônios cada. Nas camadas internas da Rede Neural foram utilizadas a função de ativação ReLU (*Rectifier Linear Unit*), em conjunto com o algoritmo de otimização Adam. Na última camada, por se tratar de uma classificação binária, foi utilizada a função de ativação *Sigmoid*. Todas as camadas FCNN foram seguidas por uma camada de *Dropout*, com uma taxa de desligamento de 20%. O tamanho do lote (*Batch Size*) é um termo usado em Aprendizado de Máquina e refere-se ao número de exemplos de treinamento usados em uma iteração, que neste caso foi de tamanho 32.

## RESULTADOS E DISCUSSÃO

No experimento foi utilizada a Validação Cruzada no método *k-fold* de tamanho  $k=10$ . Isto significa que a base de dados foi dividida em 10 grupos, com 10 iterações. O modelo utiliza nove grupos ( $k-1$ ) para treinamento e um grupo para validação, escolhido de forma aleatória a cada iteração. O método é repetido até que todos os grupos tenham passado no grupo de validação e todos tenham um percentual de erro. No final, torna-se possível o cálculo do erro médio do modelo.

Para avaliação foram utilizadas três métricas (acurácia, sensibilidade e especificidade), com o objetivo de obter melhor qualidade no diagnóstico. Os acertos para a



**Figura 3** - Arquitetura da Rede Neural Totalmente Conectada proposta. Fonte autor.

**Tabela 1** - Resultados obtidos ao longo dos 10 experimentos da validação cruzada.

<i>k-fold</i>	Acurácia	Sensibilidade	Especificidade
1	93,10%	90%	94,73%
2	100%	100%	100%
3	96,55%	93,33%	100%
4	96,55%	100%	91,66%
5	100%	100%	100%
6	100%	100%	100%
7	93,10%	83,33%	100%
8	93,10%	86,66%	100%
9	96,42%	93,33%	100%
10	96,42%	93,33%	100%
<b>Média</b>	<b>96,52%</b>	<b>94%</b>	<b>98,64%</b>

avaliação das métricas são definidos por Verdadeiro Positivo (VP), que são imagens de pacientes doentes que foram classificados como doentes e por Verdadeiro Negativo (VN), que são imagens de pacientes saudáveis, classificados como saudáveis. Além disso, tem-se os erros, que são definidos por Falso Positivo (FP), onde imagens de pacientes saudáveis são classificados como Doentes e o Falso Negativo (FN), onde imagens de pacientes doentes são classificados como saudáveis. A partir da extração dos valores de VP, VN, FP e FN a acurácia, a sensibilidade e a especificidade foram calculadas a fim de descrever a eficiência do modelo de classificação.

Ao final do experimento foram obtidos resultados excelentes, demonstrando a eficiência do uso da característica textural LBP em representar imagens de Raios-X de pacientes com infecções por coronavírus e pacientes saudáveis. Na Tabela 1 são apresentados os resultados obtidos ao longo dos 10 experimentos, seguindo a Validação Cruzada. O valor médio obtido de acurácia foi de 96,52%, 94% de sensibilidade e 98,64% de especificidade.

Nota-se em uma grande maioria dos trabalhos relacionados, a utilização de redes neurais convolutivas para detecção de padrões e classificação de imagens de Raio-X de pacientes. Neste trabalho foi desenvolvido um método de classificação baseado na extração de características texturais, seguindo a abordagem tradicional

de extração de características, construtor de um vetor descritor e detecção de padrões. O método proposto obteve uma acurácia média de 96,52%, o que o torna bem competitivo se comparado aos métodos de outros trabalhos.

## CONCLUSÃO

Neste trabalho é proposto o desenvolvimento do método de classificação baseado na detecção de padrões utilizando LBP, um descritor visual de textura usado para classificação em visão computacional, para detecção de infecções por coronavírus através de imagens de Raios-X torácico. O presente trabalho contribui para a possibilidade de um diagnóstico de baixo custo, rápido e automático de infecções por coronavírus. Apesar do tratamento adequado não ser determinado exclusivamente a partir de uma imagem de Raios-X, uma triagem de prováveis infectados seria muito importante para a aplicação imediata da quarentena. Além disso, a vantagem de detecção automática de infecções por coronavírus através das imagens médicas implica na redução de exposição da equipe médica e de enfermagem ao surto. Em trabalhos futuros, espera-se verificar a eficiência do vetor descritor supracitado em outras arquiteturas de Redes Neurais Profundas e da implementação desta em um serviço oferecido à rede de saúde.

## REFERÊNCIAS

1. Vital Surveillances. "The epidemiological characteristics of an outbreak of 2019 novel coronavirus diseases (COVID-19)—China, 2020". In: *China CDC Weekly* 2.8(2020), pp. 113–122.
2. Superintendência Estadual de Comunicação Social do Espírito Santo (SECOM). Covid-19 informação. Disponível em: <https://coronavirus.es.gov.br/>. 2020.
3. Ministério Da Saúde. Painel Coronavírus. Disponível em: <https://covid.saude.gov.br/>. 2020
4. Organização Mundial da Saúde. QA on coronavirus. Disponível em: <https://www.who.int/emergencies/diseases/novelcoronavirus-2019/question-and-answers-hub/q-a-detail/q-a-coronaviruses/>. Acesso em: 19/06/2020. 2020.
5. Catrin Sohrabi et al. "World Health Organization declares global emergency: A review of the 2019 novel coronavirus (COVID-19)". In: *International Journal of Surgery* (2020).
6. Organização Mundial da Saúde. WHO Coronavirus Disease (COVID-19) Dashboard. Disponível em: <https://covid19.who.int/>. Acesso em: 19/06/2020. 2020.
7. Yi-Wei Tang et al. "Laboratory diagnosis of COVID-19: current issues and challenges". In: *Journal of clinical microbiology* 58.6 (2020).
8. American College of Radiology. ACR Recommendations for the use of Chest Radiography and Computed Tomography (CT) for Suspected COVID-19 Infection. Disponível em: <https://www.acr.org/Advocacy-and-Economics/ACRPosition-Statements/Recommendations-for-ChestRadiography-and-CT-for-Suspected-COVID19-Infection>. 2020
9. Wei-jie Guan et al. "Clinical characteristics of 2019 novel coronavirus infection in China". In: *MedRxiv* (2020).
10. Instituto Israelita Albert Einstein de Ensino e Pesquisa. Achados de Imagem da COVID19 na TC de Tórax . Disponível em: <https://ensino.einstein.br/achadosdeimagemdacovid> "19natcdetorap3210/p. 2020.
11. Jefferson Alves de Sousa et al. "Texture based on geostatistic for glaucoma diagnosis from fundus eye image". In: *Multimedia Tools and Applications* 76.18 (2017), pp. 19173–19190.
12. Matheus de Freitas Oliveira Baffa and Lucas Grassano Lattari. "Convolutional neural networks for static and dynamic breast infrared imaging classification". In: 2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). IEEE. 2018, pp. 174–181.
13. Ali Narin, Ceren Kaya, and Ziynet Pamuk. "Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks". In: *arXiv preprint arXiv:2003.10849* (2020).
14. Turker Tuncer, Sengul Dogan, and Fatih Ozyurt. "An automated Residual Exemplar Local Binary Pattern and iterative ReliefF based corona detection method using lung X-ray image". In: *Chemometrics and Intelligent Laboratory Systems* (2020), p. 104054.
15. Tulin Ozturk et al. "Automated detection of COVID19 cases using deep neural networks with X-ray images". In: *Computers in Biology and Medicine* (2020), p. 103792.
16. Blake VanBerlo and Matt Ross. "Investigation of Explainable Predictions of COVID-19 Infection from Chest X-rays with Machine Learning". In: *Artificial Intelligence Lab* (2020).
17. Mucahid Barstugan, Umut Ozkaya, and Saban Ozturk. "Coronavirus (covid-19) classification using ct images by machine learning methods". In: *arXiv preprint arXiv:2003.09424* (2020).
18. Charmaine Butt et al. "Deep learning system to screen coronavirus disease 2019 pneumonia". In: *Applied Intelligence* (2020), p. 1.
19. Linda Wang and Alexander Wong. "Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images". In: *arXiv preprint arXiv:2003.09871* (2020).
20. Shuai Wang et al. "A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID19)". In: *MedRxiv* (2020).
21. Tawsifur Rahman. COVID-19 Radiography Database. Disponível em: <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database?/>. Acesso em: 15/05/2020. 2020.
22. Dong-Chen He and Li Wang. "Texture unit, texture spectrum, and texture analysis". In: *IEEE transactions on Geoscience and Remote Sensing* 28.4 (1990), pp. 509–512.
23. Timo Ojala, Matti Pietikainen, and David Harwood. "A comparative study of texture measures with classification based on featured distributions". In: *Pattern recognition* 29.1 (1996), pp. 51–59.
24. K-Y Hsu, H-Y Li, and Demetri Psaltis. "Holographic implementation of a fully connected neural network". In: *Proceedings of the IEEE* 78.10 (1990), pp. 1637–1645.