

EXTRAÇÃO DE FEATURES E CLASSIFICAÇÃO DE IMAGENS RX COM MULTILAYER PERCEPTRON NO DIAGNÓSTICO DE COVID-19¹

Kalyl Henings², Gilmário Barbosa do Santos³, Luciano Wayand de Abreu⁴

¹ Vinculado ao projeto “*Rough Sets e Multilayer Perceptron no Tratamento de Incertezas em Imagens de RX no Diagnóstico de COVID-19*”

² Acadêmico do Curso de Ciências da Computação – CCT – Bolsista PROIP

³ Orientador, Departamento de Ciências da Computação – CCT – gilmario.santos@udesc.br

⁴ Acadêmico do Curso de Ciências da Computação – CCT – Bolsista PROIP

Em vista da pandemia do novo Coronavírus (COVID-19), decretada pela OMS em 11 de março de 2020, o projeto focou esforços em contribuir para a detecção de casos através da análise por *machine learning*, em conjunto com a técnica de *rough sets* para tratamento das incertezas, de radiografias de tórax.

A incerteza pode ser caracterizada pela determinação de casos que apresentam um mesmo quadro clínico (representado por descritores extraídos de imagens de RX), porém são diagnosticados diferentemente um do outro. Em termos simples, a incerteza ocorreria quando dois pacientes com o mesmo quadro clínico recebessem diagnósticos diferentes (sadio e enfermo, por exemplo).

O projeto foi dividido em duas frentes (A e B). A frente de trabalho aqui relatada (frente-A) foi desenvolvida pelo bolsista Kalyl Hennings e teve como objetivo principal a avaliação de três diferentes descritores de imagens de RX sob um modelo de rede neural multicamadas (MLP).

Para tanto, primeiramente, uma base de dados foi escolhida. Prezou-se por uma base livre para uso, com um bom número de casos e separada em classes. A base escolhida foi a *COVID-19 Radiography Database* contabilizando 3616 radiografias de pulmões acometidos por COVID-19 e 10192 de pulmões saudáveis. A fim de equilibrar o conjunto de dados, foram utilizadas todas as radiografias de COVID e um número igual de radiografias de pulmões saudáveis, totalizando 7232 imagens.

Descritores numéricos foram extraídos das imagens por meio de três métodos de extração de features: transformação da imagem em um vetor de pixels (“linearização”); Local Binary Patterns (LBP) e Histogram of Oriented Gradients (HOG). Após escolhida a base de dados e os extratores utilizados, prosseguiu-se para a construção dos datasets com duas categorias de casos (COVID e NORMAL) utilizados no treinamento e teste de uma rede MLP (pacote Python `sklearn.neural_network.MLPClassifier`), auferindo-se a acurácia dos resultados para cada dataset.



Figura 1. Processo utilizado no desenvolvimento da frente-A de trabalho.

Os experimentos rodaram em uma estação como a seguinte configuração: Ubuntu 22.04.1, CPU: AMD Ryzen 7 3800X (16) @ 3.900G; GPU: NVIDIA Quadro P2200; RAM: 15928MiB. Para auferir a qualidade dos descritores foram comparados seus resultados por meio das métricas acurácia e curva ROC.

Os resultados obtidos apresentam o descritor HOG com 95,15% de acurácia, o LBP com 85,07% de acurácia, e a linearização com 47,3% de acurácia. Portanto, o HoG e o LBP se destacam, cabendo ao HoG a posição de maior destaque dentre os três tipos de descritores testados. Abaixo consta o gráfico da curva ROC para o descritor HoG.

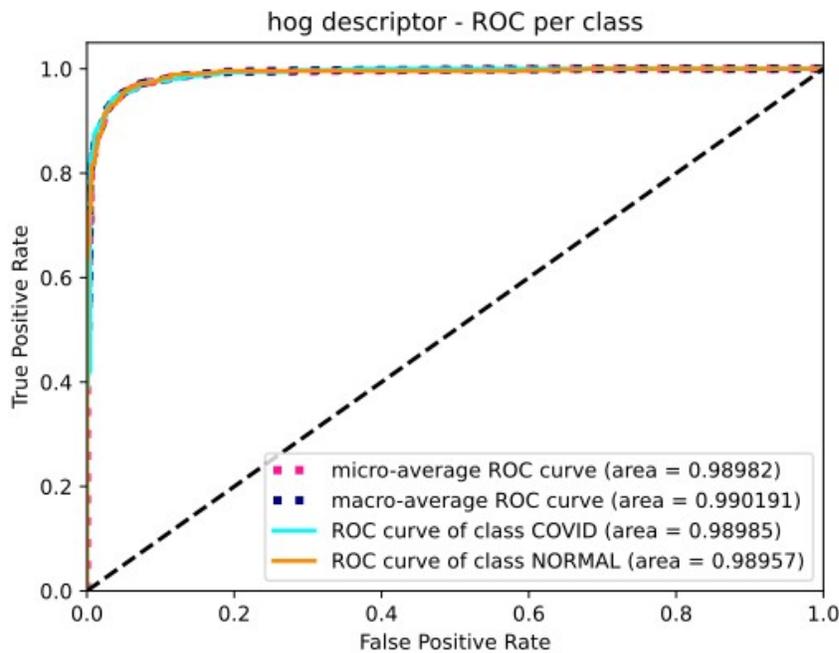


Figura 2. Curva ROC para o melhor descritor HOG

Palavras-chave: Machine learning, Rede Neural, Extração de Features, COVID-19