

## TREINAMENTO E AVALIAÇÃO DE UM MODELO MULTILAYER PERCEPTRON NO TRATAMENTO DE INCERTEZA NO DIAGNÓSTICO AUXILIADO POR COMPUTADOR DE COVID-19<sup>1</sup>

Kalyl Henings<sup>2</sup>, Gilmário Barbosa do Santos<sup>3</sup>

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

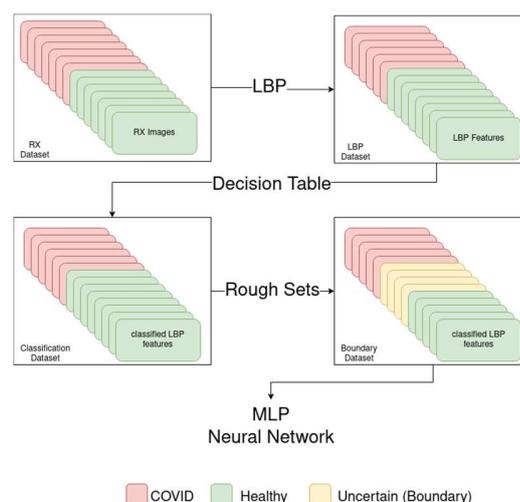
<sup>2</sup> Acadêmico do Curso de Ciências da Computação – CCT – Bolsista PROIP

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

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 fim de classificá-las em dois grupos: os de pacientes acometidos e dos não acometidos pela doença, com o objetivo de auxiliar no processo de diagnose médica.

Num estágio inicial do projeto, foram conduzidas análises dos recursos e materiais fundamentais: repositórios de dados contendo radiografias de tórax que são autenticadas e de acesso gratuito; ferramentas de código aberto para a implementação da rede neural de perceptron multicamada (MLP) e avaliação de incertezas usando conjuntos aproximados; além de bibliotecas para a extração de características de imagens. Investigações foram realizadas para selecionar o descritor mais apropriado a ser utilizado na categorização de imagens médicas, com a exibição dos resultados alcançados por diferentes descritores que foram experimentados.

Na etapa subsequente, a atenção foi direcionada para: estabelecer a configuração do sistema, conduzir experimentos com os conjuntos de dados resultantes da identificação da incerteza (reconhecida como casos de fronteira pela teoria de conjuntos aproximados) e realizar a avaliação dos resultados obtidos.



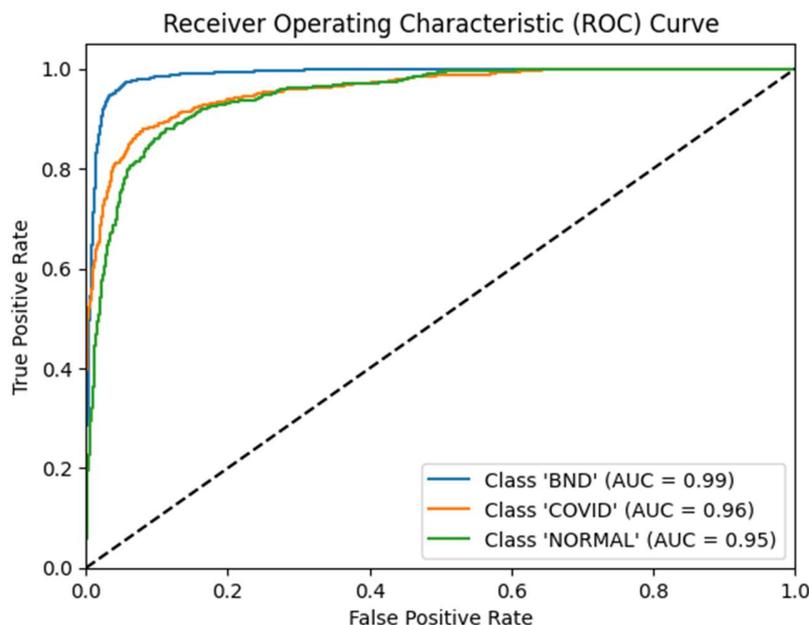
**Figura 1.** Processo utilizado nos experimentos

Com esse objetivo, utilizou-se uma ferramenta de tratamento de incerteza, que tomava os descritores das bases e realizava a análise com *rough sets*, e a partir dessa análise, foram extraídos

os casos incertos do restante dos casos de pulmões saudáveis e acometidos com COVID. No entanto, a base escolhida se mostrou pequena para a realização dos experimentos, então foi feita uma composição com uma segunda base para aumentar o número de imagens por classe.

Com essa base aumentada, foi possível encontrar um número significativo de casos incertos, e assim foram montadas bases com 3 classes (casos saudáveis, de COVID e incertos) para treinamento, testes e extração de métricas do modelo. Após a fase de testes do processo, estabeleceu-se o fluxo de trabalho descrito na Figura 1, e então foi feita uma série de experimentos distintos em diversas etapas do processo, a fim de obterem-se os melhores resultados possíveis dentro da metodologia utilizada.

Um desses experimentos foi encontrar os melhores hiperparâmetros para serem usados no modelo com o tipo de dado sendo utilizado. Para tanto, foi utilizada uma técnica de busca exaustiva chamada *grid search*, onde foi provido a base que obteve as melhores métricas de classificação sem *fine tuning*, os hiperparâmetros padrão da biblioteca e uma lista de hiperparâmetros a serem testados.



**Figura 2.** Curva ROC para as 3 classes do modelo com hiperparâmetros otimizados

Os resultados encontrados foram animadores, com a precisão geral do modelo ficando em torno de 88.02%, e conseguindo fazer uma excelente distinção dos casos de incerteza dos demais casos. A Figura 2 exibe as curvas ROC obtidas na fase de testes da rede treinada, as AUCs designam as áreas sob as respectivas curvas ROC, exibindo valores próximos à unidade, o que demonstra a excelência dos resultados obtidos.

**Palavras-chave:** machine learning, processamento de imagens médicas, COVID-19, tratamento de incerteza, rough sets