



Radiômica baseada em Deep Learning: Extrair Informações de Imagens Médicas

Luís Vinícius de Moura¹, Ana Maria Marques da Silva² (orientador)

¹Escola Politécnica, PUCRS, ²Escola Politécnica, PUCRS/

Resumo

O diagnóstico médico refere-se à determinação da origem e etiologia de uma condição médica. Para tal, são utilizadas diversas informações clínicas e demográficas juntamente com imagens médicas. O diagnóstico acurado de uma condição está ligado a experiência do médico, bem como sujeito a subjetividade do mesmo. As imagens possuem informações que vão além dos aspectos visuais. A técnica de radiômica permite a extração de grandes quantidades de atributos, utilizando técnicas matemáticas, que descrevem o objeto de interesse de forma estatística. Devido a esse volume de dados, algoritmos de *machine learning* (ML) e *deep learning* (DL) têm sido estudados com a intuito de auxiliar na análise médica. O objetivo deste estudo é extrair atributos radiômicos de imagens médicas e implementar diferentes algoritmos de ML e DL avaliando sua capacidade de classificação de doenças. Foram utilizadas 1850 imagens RGB por dermatoscópio de lesões de pele do *International Skin Imaging Collaboration* (ISIC), sendo 950 lesões benignas e 900 lesões malignas, com suas respectivas segmentações e informações clínicas. As imagens foram divididas em seus três canais de cores: *Red* (R), *Green* (G) e *Blue* (B) e analisadas independentemente para avaliar a relevância das informações contidas em cada canal. Utilizando a biblioteca *Pyradiomics* do *Python* foram extraídas 95 atributos radiômicos de cada canal. Após normalizar os dados entre 0 e 1, utilizou-se o algoritmo *Random Forest Classifier* (RFC) juntamente com *Recursive Feature Elimination and Cross-validated* para reduzir a quantidade de informações necessárias, selecionando os atributos que melhor descrevem as duas classes (benigno e maligno). Para cada canal R, G e B, foram selecionados respectivamente 11, 62 e 66 atributos. O modelo de ML RFC foi treinado com estes dados e validado com o método *K-Folds* ($K = 5$), obtendo acurácias de, respectivamente, 86%, 86% e 87% para R, G e B. O canal R mostrou-se mais otimizado, pois necessita de menos atributos radiômicos para obter a mesma acurácia que os restantes, reduzindo a necessidade de poder e tempo computacional. Isso pode estar associado ao aumento da dilatação dos vasos sanguíneos na lesão, trauma ou neovascularização, assim como à cor avermelhada da pele saudável que alguns grupos étnicos. Portanto, a cor vermelha se torna mais representativa na diferenciação entre lesões benignas e malignas.

Palavras-chave: Classificação; imagens multicanais; lesão de pele; inteligência artificial.