



Universidade: presente!

UFRGS
PROPEAQ



XXXI SIC

21. 25. OUTUBRO • CAMPUS DO VALE

Evento	Salão UFRGS 2019: SIC - XXXI SALÃO DE INICIAÇÃO CIENTÍFICA DA UFRGS
Ano	2019
Local	Campus do Vale - UFRGS
Título	Classificação de Lesões Dermatológicas Utilizando Redes Neurais Convolucionais
Autor	PAULO GAMARRA LESSA PINTO
Orientador	JACOB SCHARCANSKI

Classificação de Lesões Dermatológicas Utilizando Redes Neurais Convolucionais

Autor: Paulo Gamarra Lessa Pinto
Orientador: Jacob Scharcanski
Universidade Federal do Rio Grande do Sul

A captura de lesões dermatológicas usando dermatoscopia é um método onde lesões de pele são analisados com o auxílio de um dermatoscópio para diagnosticar doenças, como o câncer de pele. Neste trabalho é apresentado um método baseado em redes neurais convolucionais para a classificação de imagens dermatoscópicas de lesões de pele, com o objetivo de dar suporte à profissionais da saúde. Para o treino e avaliação dos modelos apresentados, foi utilizado o dataset “Human Against Machine with 10000 training images” (HAM10000) da International Skin Imaging Collaboration (ISIC). O dataset é composto por 10015 imagens dermatoscópicas pertencentes à uma das 7 classes: Ceratose actínica, carcinoma basocelular, ceratose benigna, dermatofibroma, nevo melanocítico, melanoma, ou lesão vascular. O número de amostras por classe varia de 115 a 6705, o que representa um desbalanceamento significativo. Na metodologia utilizada, o HAM10000 foi dividido em um conjunto de treino, com 80% das amostras, e um conjunto de teste, com 20% das amostras, com a mesma representatividade das classes nos dois conjuntos. Foi feita a análise do desempenho da classificação para diferentes configurações de *Fine-Tuning* da rede ResNet50 treinada no dataset ImageNet. O *Fine-Tuning* é uma técnica que consiste em utilizar uma rede já treinada em outro dataset e atualizar apenas os pesos das últimas camadas da rede, o que acelera a convergência do treino e evita *overfitting*. Todos os modelos foram treinados utilizando o otimizador Adam com *learning rate* de 0,001 para atualização dos pesos. Para definir o número de iterações do laço de treino, foi utilizada a técnica de *early stopping*, na qual o laço é interrompido quando o desempenho do modelo não melhora em N iterações (foi utilizado $N = 16$). Para normalização, foram utilizadas camadas de *drop-out*. Na metodologia proposta, primeiramente foram avaliados diferentes tratamentos das imagens de treino em uma arquitetura com 2 camadas densas acopladas à ResNet50. O melhor resultado foi obtido com transformações aleatórias nas imagens (rotações, deslocamentos e *zoom*), que obteve 85,88% de taxa de acerto, comparado a 84,33% sem as transformações. Os testes com as amostras balanceadas obtiveram 85,4% de taxa de acerto, mostrando que o desbalanceamento do dataset não afeta negativamente no desempenho do modelo e não precisa ser eliminado. Na sequência, foram testadas diferentes configurações de camadas de classificação do modelo. Os resultados mostraram que a eliminação de uma camada densa leva a uma melhora de desempenho, levando o modelo final a obter 86,44% de taxa de acerto. Para comparação do modelo final com o estado da arte foi computada a área sob a curva ROC para cada classe, dando uma média de 0,9709, o que representa um aumento de desempenho em relação a média de 0,9487 da literatura. Além disso, o modelo obteve 63% de precisão e 74% de especificidade para a classe melanoma (tipo de câncer de pele mais letal), que quando comparado aos 63% de precisão e 40% de especificidade da literatura, apresenta uma melhora significativa na segunda métrica. Em termos de trabalhos futuros, seria interessante a visualização de quais features o modelo utiliza na classificação das imagens, além de testes em outros datasets de imagens dermatoscópicas.