

Classificação de Lesões Benignas e Malignas na Pele via Redes Neurais Convolucionais

Juliana M. Souza¹, Wallace Casaca²

Instituto de Biociências, Letras e Ciências Exatas (IBILCE)/UNESP, São José do Rio Preto, SP

Diferentes tipos de células compõem o corpo humano, incluindo o melanócito, responsável pela pigmentação da pele. Células dessa natureza podem gerar lesões benignas, como é o caso das pintas de tonalidade marrom, as quais são frequentes nos seres humanos, e malignas, como os melanomas. Mundialmente, são diagnosticados por ano 232.100 casos de melanoma cutâneo, o que corresponde a 1,7% da totalidade dos casos de cânceres malignos recém descobertos, e dentre estes, estima-se que 55.550 pacientes morrem [3].

Em regiões de clima tropical como o Brasil, a incidência de raios UV é elevada, sendo fundamental que a população se mantenha alerta aos sintomas da doença, visando preveni-la, diagnosticá-la, e tratá-la precocemente. A partir deste cenário, é possível aplicar técnicas de Aprendizado de Máquina e Inteligência Artificial para realizar o pré-diagnóstico desta e outras enfermidades, acelerando o processo de descoberta e aumentando as chances de cura ou sobrevivência [4].

Posto o contexto acima, este trabalho teve como objetivo classificar lesões da pele entre benignas ou malignas utilizando um algoritmo baseado em Redes Neurais Convolucionais (do inglês, *CNN - Convolutional Neural Networks*). Mais precisamente, foi empregado um *dataset* aberto composto por milhares de imagens extraídas da pele humana de modo a treinar e validar uma abordagem computacional do tipo CNN [4]. Após a etapa de treinamento, foi gerado um classificador capaz de discriminar imagens de pele arbitrarias entre duas classes: melanoma maligno ou não maligno.

Para o treinamento, validação e teste do modelo de CNN implementado, foi utilizado o repositório aberto *Melanoma Cancer Image Dataset* [1], composto por 13.879 imagens de pele, sendo 6.590 rotuladas como tumores malignos e 7.289 como benignos. Na sequência, as imagens foram agrupadas em dois subconjuntos, um abrangendo 80% das imagens do *dataset*, usado para fins de treinamento da rede, e outro constituído pelas 20% imagens remanescentes, para a fase de teste.

Considerando o design da rede implementada, foram adotadas: (a) camada de convolução de entrada, com 32 filtros de tamanho 3×3 , e função de ativação ReLU; (b) duas camadas de convolução internas, com 64 filtros 3×3 e função de ativação ReLU, seguidas por camadas de *max pooling* para redução da dimensionalidade; (c) camada de saída totalmente densa, com função de ativação *softmax* para classificação em duas categorias. Para o treinamento, utilizou-se o otimizador *Adam* e função de perda *categorical_crossentropy*.

Após a aplicação do classificador obtido no subconjunto de teste, o mesmo obteve precisão final de 87,39%, escore este bastante satisfatório, inclusive acima de modelos apresentados recentemente na literatura, cujo escore médio é de 80% conforme discutido e comparado em [4]. Ainda para fins comparativo, em [2] os autores fizeram uso de uma CNN em um conjunto de imagens pré-processadas de lesões benignas e malignas da pele, obtendo uma eficácia final para o modelo da ordem de 81%.

¹juliana.marques@unesp.br

²wallace.casaca@unesp.br

A Figura 1(a) apresenta a matriz de confusão, incluindo os falsos positivos (rótulo predito 0 e verdadeiro 1) e falsos negativos (rótulo predito 1 e verdadeiro 0), enquanto a Figura 1(b)-(c) apresentam a evolução da função de perda e *Precisão* para as primeiras iterações durante o treinamento e validação. A partir da diagonal da matriz de confusão, tanto os verdadeiros positivos como negativos são capturados em maior número do que os falsos negativos e positivos. Com relação à convergência do modelo, há um decaimento acentuado conforme as etapas de treinamento e validação vão progredindo, ao passo que a precisão aumenta na mesma taxa de incremento. O resultado obtido destaca o potencial das redes CNNs na detecção precoce do melanoma e na classificação de lesões de pele.




Figura 1: (a) Matriz de confusão, (b) plot da função de perda, e (c) métrica de avaliação *Precisão*.

Agradecimentos

Os autores agradecem à FAPESP (#2023/14427-8), CNPq (#316228/2021-4) e CAPES (código de financiamento: 01) pelo suporte à pesquisa realizada.

Referências

- [1] B. Mittal. **Melanoma Cancer Image Dataset**. Online. Acessado em 25/03/2024, <https://www.kaggle.com/datasets/bhaveshmittal/melanoma-cancer-dataset/data>. 2024.
- [2] E. Nasr-Esfahani, S. Samavi, N. Karimi, S. M. R. Soroushmehr, M. H. Jafari, K. Ward e K. Najarian. “Melanoma detection by analysis of clinical images using convolutional neural network”. Em: **2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. IEEE. 2016, pp. 1373–1376.
- [3] D. Schadendorf, A. Van Akkooi, C. Berking, K. G. Griewank, R. Gutzmer, A. Hauschild, A. Stang, A. Roesch e S. Ugurel. “Melanoma”. Em: **The Lancet** 392.10151 (2018), pp. 971–984.
- [4] S. R. Waheed, S. M. Saadi, M. S. M. Rahim, N. M. Suaib, F. H. Najjar, M. M. Adnan e A. A. Salim. “Melanoma skin cancer classification based on CNN deep learning algorithms”. Em: **Malaysian Journal of Fundamental and Applied Sciences** 19.3 (2023), pp. 299–305.