

Desenvolvimento de uma Arquitetura de Rede Neural Convolutiva para a Classificação de Tipos de Câncer de Pele

Roney Nogueira de Sousa¹, Ana Júlia Lopes de Brito²

¹Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE) — Campus Fortaleza
Av. Treze de Maio, 2081 — Benfica, Fortaleza—CE, 60040-531

²Universidade Federal do Ceará (UFC) — Campus do Porangabussu
R. Alexandre Baraúna, 994 — Rodolfo Teófilo, Fortaleza—CE, 60430-160

{nogueiraroney453, julialopes130703}@gmail.com

Abstract. *In this study, we introduced a convolutional neural network to assist in the diagnosis of skin cancer through images of skin lesions. We used a public database, incorporating data augmentation techniques to address the variability of skin characteristics. After 25 training epochs, we achieved promising results, with an accuracy of 92.91%, AUC of 92.59%, precision of 75.76%, and F1-Score of 71.01%.*

Resumo. *Neste estudo, introduzimos uma rede neural convolutiva para auxiliar no diagnóstico de câncer de pele via imagens de lesões cutâneas. Utilizamos uma base de dados pública, incorporando técnicas de aumento de dados para lidar com a variabilidade das características da pele. Após 25 épocas de treinamento, obtivemos resultados promissores, com uma acurácia de 92,91%, AUC de 92,59%, precisão de 75,76% e F1-Score de 71,01%.*

1. Introdução

O Brasil enfrenta uma alta incidência de câncer de pele, sendo o tipo mais comum. Apesar do melanoma representar menos de 5% dos casos, contribui com mais de 70% das mortes associadas ao câncer de pele, devido à sua rápida progressão e propensão a metástases [Jain et al. 2015, Esteva et al. 2017]. A confirmação do diagnóstico ocorre por meio de biópsias, mas, devido ao aumento de casos, buscam-se métodos menos invasivos desde os anos 80. A precisão do diagnóstico visual são aproximadamente 60%, mas aumenta para 75–84% com a utilização de dermatoscopia [Sommer 2008, Vestergaard et al. 2008].

A detecção de câncer de pele por métodos computacionais é desafiadora devido à variabilidade de características da pele como tonalidade, tamanho e forma. As imagens também podem sofrer interferências de pelos, marcas de nascença ou lesões benignas de baixo contraste [Vieira 2022].

Este estudo apresenta uma arquitetura de Rede Neural Convolutiva (RNC) para diagnosticar câncer de pele. Utilizando a base de dados pública "Skin Cancer ISIC"¹ os experimentos revelam uma acurácia de 92,91% para a RNC proposta.

2. Materiais e Método

A presente seção visa mostrar a metodologia adotada no presente estudo.

¹"<https://www.kaggle.com/datasets/nodoubttome/skin-cancer9-classesisic>"

2.1. Base de Dados

A base de dados utilizada consiste em 2.357 imagens de doenças oncológicas malignas e benignas, originadas da *The International Skin Imaging Collaboration* (ISIC). As imagens são categorizadas em classes como Ceratoses, Carcinomas, Dermatofibroma, Melanoma, Nevo, e Lesão Vascular.

2.2. Preparação de Dados

Para lidar com a variabilidade de peles, o conjunto de treinamento foi expandido utilizando de *Data Augmentation*. Foram aplicadas transformações como *zoom* e espelhamento horizontal, totalizando 21.241 amostras. Esse processo foi exclusivo para o treinamento, evitando distorções no conjunto de testes. O quantitativo de dados pós-*Data Augmentation* está na Tabela 1.

Tabela 1. Quantidade de Imagens na Base de Dados Após o *Data Augmentation*

Classe	Quantidade Original	Quantidade Atual
Ceratose Actínica	130	1177
Carcinoma Basocelular	392	3490
Dermatofibroma	111	1005
Melanoma	454	3983
Nevo	373	3369
Ceratose Benigna Pigmentada	478	4137
Ceratose Seborreica	80	819
Carcinoma de Células Escamosas	197	1827
Lesão Vascular	142	1434

A base de dados foi dividida usando 80% para treinamento e 20% para teste. No conjunto de treinamento, 20% foram separados para o conjunto de validação.

2.3. RNC Proposta para a Classificação de Câncer de Pele




Figura 1. Arquitetura da Rede Neural Convolutacional Proposta

A RNC proposta tem uma arquitetura com convoluções organizadas em quatro blocos, iniciando com camadas menores e progressivamente mais complexas. A transição

para camadas densas permite aprender relações complexas, seguidas por *Batch Normalization* e técnicas de *Dropout* para evitar *overfitting*. A camada de saída densa usa *softmax* para classificação multiclasse. A Figura 1 representa a arquitetura da RNC proposta.

A RNC foi treinada por 100 épocas, avaliando regularmente o conjunto de validação e, em seguida, testada. As 100 épocas permitem ao modelo aprender padrões complexos. A *callback Early Stopping* foi usada para evitar *overfitting*, monitorando o *F1-Score*, e encerrando o treinamento após 25 épocas consecutivas sem melhoria.

A RNC foi implementada em *Python* [Van Rossum and Drake 2009] usando *Keras* [Chollet et al. 2015], com visualização facilitada pela *Visualkeras* [Gavrikov 2020] e os gráficos foram feitos com *Matplotlib* [Hunter 2007].

3. Resultados e Discussões

Os resultados do treinamento e validação do modelo proposto são apresentados na Figura 2. O gráfico apresenta métricas como acurácia, precisão, *loss*, *F1-Score* e área sob a curva ROC (AUC). A arquitetura convergiu rapidamente durante o treinamento, alcançando estabilidade com apenas 25 épocas.




Figura 2. Resultados obtidos no conjunto de treinamento

As métricas que a RNC alcançou no conjunto de testes constam na Tabela 2.

Tabela 2. Resultados Obtidos no Conjunto de Testes

Métrica	RNC proposta neste trabalho
Acurácia	92,91
Precisão	75,76
AUC	92,59
<i>F1-Score</i>	71,01

O modelo teve bom desempenho no teste, com destaque para 92,91% de acurácia. O *F1-Score* revela equilíbrio na minimização de falsos resultados, crucial em aplicações médicas. Em geral, o modelo demonstra eficácia em prever novos dados.

A matriz de confusão na Figura 3 revela desafios na classificação das classes “*melanoma*”, “*nevus*” e “*Pigmented Benign Keratosis*” devido a suas semelhanças. No entanto, o modelo demonstrou capacidade de classificação para outras classes na base, indicando uma adaptação da arquitetura na identificação de padrões dessas classes.

4. Conclusão

Este estudo propõe uma RNC para auxiliar no diagnóstico de vários tipos de câncer de pele, reconhecendo a rapidez de um diagnóstico como melhoria para a eficácia do trata-

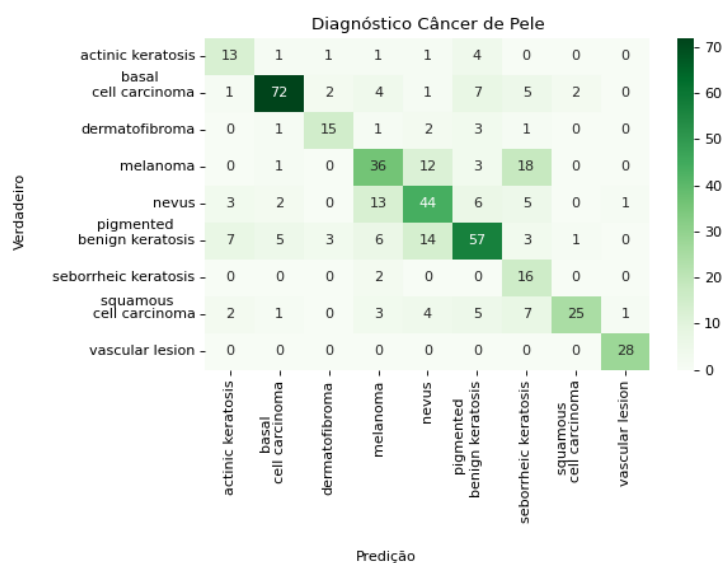


Figura 3. Matriz de Confusão da Arquitetura Proposta

mento. A metodologia envolveu o treinamento e análise do desempenho do modelo em um conjunto de dados público, inicialmente com 2.357 amostras, ampliado para 21.241.

Os resultados destacam a eficácia da arquitetura, dada a sua capacidade de generalização e desempenho robusto, sem sinais de *overfitting*. As métricas validam a habilidade do modelo em discernir entre as classes consistentemente.

Referências

- Chollet, F. et al. (2015). Keras. <https://github.com/fchollet/keras>.
- Esteva, A., Kuprel, B., et al. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639):115–118.
- Gavrikov, P. (2020). Visualkeras. <https://github.com/paulgavrikov/visualkeras>.
- Hunter, J. D. (2007). Matplotlib: A 2d graphics environment. *Computing in Science & Engineering*, 9(3):90–95.
- Jain, S., Pise, N., et al. (2015). Computer aided melanoma skin cancer detection using image processing. *Procedia Computer Science*, 48:735–740.
- Sommer, C. (2008). Skin biopsy as a diagnostic tool. *Current opinion in neurology*, 21(5):563–568.
- Van Rossum, G. and Drake, F. L. (2009). *Python 3 Reference Manual*. CreateSpace, Scotts Valley, CA.
- Vestergaard, M., Macaskill, P., Holt, P., and Menzies, S. (2008). Dermoscopy compared with naked eye examination for the diagnosis of primary melanoma: a meta-analysis of studies performed in a clinical setting. *British Journal of Dermatology*, 159(3):669–676.
- Vieira, E. Q. (2022). Comparação entre diferentes modelos de redes neurais convolucionais para classificação de melanoma. *Universidade de Brasília*.