

INTELIGÊNCIA ARTIFICIAL NA TRIAGEM DE LESÕES CUTÂNEAS: O USO DE CNNs PARA O PRÉ-DIAGNÓSTICO DE CÂNCER DE PELE

Paola Kroll Souza, Bruna Arisa Saito, Maria Clara Dalla Vecchia Nunes de Oliveira, Daniela Santos Silva, Wagner dos Santos Clementino de Jesus.

Fundação Vale Paraibana de Ensino/Colégio Técnico "Antônio Teixeira Fernandes", Avenida Paraibuna, 75, Centro - 12245-020 - São José dos Campos-SP, Brasil, paolasouzakroll@gmail.com, brunaarisasaito@gmail.com, mariacnoli.08@gmail.com, danielass@univap.br, wagner@univap.br.

Resumo

A crescente demanda por ferramentas que auxiliem nos diagnósticos de câncer de pele e a superlotação de policlínicas, o câncer de pele permanece como o mais prevalente no Brasil e no mundo. O diagnóstico e o acesso a análises específicas são cruciais para a identificação e tratamento eficazes, juntamente com a qualidade dos serviços públicos de saúde, é mínima. Diante disso, o presente artigo tem como objetivo fazer o uso de técnicas computacionais, como as Redes Neurais Convolucionais (CNNs), para a detecção do câncer de pele, identificar a possibilidade de ser benigno ou maligno, em que por meio das imagens adicionadas mensalmente ocorre um novo treinamento com o modelo, gerando um aumento na taxa de acurácia, e acelerar o atendimento, gerando uma diminuição da superlotação em clínicas médicas que atrasam atendimentos e possíveis diagnósticos pelos médicos especializados.

Palavras-chave: Câncer de pele. Pré-diagnóstico. Redes Neurais Convolucionais.

Curso: Técnico em Informática.

Introdução

O câncer de pele é a doença mais frequente no mundo, estão previstos 704 mil novos casos de câncer no Brasil por ano no período de 2023 a 2025 de acordo com o Instituto Nacional de Câncer (INCA, 2023). Ocorre pelo crescimento anômalo dos queratinócitos, estas células se dispõem formando camadas e a partir das afetadas, são definidos os tipos de câncer. Os principais tipos de câncer de pele são melanoma (originado nos melanócitos, mais grave pelo alto risco metastático) e não melanoma - surge em células basais ou escamosas, e se subdivide em carcinoma basocelular e carcinoma de células escamosas (Costa, 2012).

No que diz respeito à disseminação do câncer de pele, pode alastrar-se para diferentes partes do corpo do ser, com concentração em partes mais evidenciadas ao sol (Costa *et al.*, 2013). O diagnóstico antecipado e tratamento adequado pode contribuir com a diminuição da incidência de casos de câncer de pele, em conjunto com a prevenção por meio dos cuidados quanto ao contato com os raios solares ultravioleta (Brasil, Ministério da Saúde, 2022).

A identificação desses tipos de carcinomas é difícil, visto que suas designações são específicas e requerem o teste ABCDE (observação de assimetrias, bordas irregulares, coloração variável, diâmetro e evolução) como método inicial e a biópsia da pele, caso haja suspeitas baseadas em evidências (Bühning, 2020). Entretanto, o acesso a tais análises e qualidade de serviços públicos da saúde é baixa, isto é, a sobrecarga de clínicas torna os atendimentos médicos insuficiente, sendo o reconhecimento de possíveis patologias escassas (Palmeira *et al.*, 2022).

Este projeto tem como objetivo o desenvolvimento de um software voltado para o apoio ao diagnóstico em dermatologia. A solução proposta visa realizar a triagem inicial e a detecção de câncer de pele, classificando lesões como benignas ou malignas. Para isso, serão empregadas técnicas de aprendizado de máquina, com ênfase em Redes Neurais Convolucionais (CNNs), a fim de analisar imagens dermatológicas. Adicionalmente, o sistema permitirá o armazenamento e a gestão de dados de pacientes, facilitando o acesso e a edição de anamneses pelos profissionais de saúde. A arquitetura do sistema utilizará o banco de dados MySQL e será implementada com as linguagens de programação

C# e Python, visando a construção de uma ferramenta robusta e eficiente para auxiliar na prática clínica.

Metodologia


Este estudo utilizou o Skin Cancer Dataset da Universidade de Harvard, disponibilizado na plataforma Kaggle. A base de dados compreende aproximadamente 10.015 imagens dermatoscópicas, categorizadas em 7 tipos de câncer de pele (Kabir, 2022). Ressalta-se que o trabalho não envolveu o uso de material humano ou animal, dispensando a necessidade de aprovação de um Comitê de Ética.

Para o desenvolvimento do software, foram empregadas as linguagens de programação C# e Python. A escolha do C# foi fundamentada em sua natureza orientada a objetos e sua capacidade multiplataforma, utilizando o Visual Studio com .NET como ambiente de desenvolvimento (Tavares; Dionysio; Santos Júnior, 2013). O Python foi utilizado com o ambiente virtual da Anaconda, que se trata de um gerenciador de pacotes e ambientes voltado para a área de Data Science com suporte às linguagens Python e R, no treinamento da IA, essencial para o processamento de dados e implementação de algoritmos de aprendizado de máquina (Rizzo; Canato, 2020).

A detecção e classificação das lesões dermatológicas foram realizadas por meio de Redes Neurais Convolucionais (CNNs). A arquitetura de uma CNN é organizada em camadas, incluindo as camadas de convolução, que atuam como filtros para extrair características abstratas das imagens, como bordas e texturas (Cunha, 2020). A rede neural específica utilizada neste trabalho foi estruturada com quatro neurônios de entrada, quatro camadas ocultas e três neurônios de saída, garantindo um fluxo de processamento contínuo para a análise e classificação das imagens.

A convolução, ilustrada na Figura 1, consiste em uma operação matemática entre duas funções que resulta em uma terceira, a qual indica o grau de modificação da primeira função em relação à segunda (Rizwan, 2018).

Figura 1 – Representação de uma Rede Neuronal Convolucional.



Fonte: Alves, 2018.

Para a implementação do modelo, utilizamos a biblioteca TensorFlow, dividindo o conjunto de dados em 80% para treinamento e 20% para teste, pelo aprendizado supervisionado para treinamento. Esse método exige um conjunto de dados rotulados, divididos em uma base para o modelo aprender os padrões e outra para testar seu desempenho. Após o treinamento, o modelo estará apto a prever com precisão a classe de novos dados. (Pires; Coelho, 2021). A técnica de classificação para a pré-diagnose utiliza uma função de ativação, responsável por relacionar o estado interno e atual de ativação com a definição do próximo estado, conduzindo a rede neural à determinação do resultado. (Fleck *et al.*, 2021).


A função de ativação, ReLU (Rectified Linear Unit) ou unidade linear retificada, demonstrada em sua forma matemática na Equação 1 é considerada uma rede neural com camadas ocultas que gera resultados nos intervalos entre $[0, \infty]$. Sua utilização compreende-se que todos os neurônios não são ativados no mesmo momento, tornando a rede neuronal mais efetiva, assim o neurônio é desativado quando a saída da transformação linear é zero, conforme apresentado na Equação 1 (Cunha, 2022).

$$f(x) = \max(0, x) \quad (1)$$

Resultados

O Gráfico 1 apresenta a evolução da acurácia e da perda ao longo de 8 épocas de treinamento e validação. Observa-se um aumento discreto da acurácia de treino, estabilizando entre 0,74 e 0,77, enquanto a de validação varia entre 0,62 e 0,69. A perda de treino reduz progressivamente até 0,59, indicando bom ajuste aos dados, mas a perda de validação se mantém elevada, entre 0,81 e 1,0, o que sugere ocorrência de sobreajuste (overfitting).

Gráfico 1 – Representação Gráfica da Acurácia e Perda do Modelo.



Fonte: Autores, 2025.

A Figura 2 corresponde a um sistema de apoio ao pré-diagnóstico dermatológico que apresenta a imagem de uma lesão cutânea e o resultado da análise. O paciente é identificado por nome e CPF, e o sistema prevê por exemplo a lesão como Nevo (pinta comum, não cancerígena) – dentre os variados tipos testados - com confiança de 62%. O médico responsável está vinculado ao banco de dados. Há ainda opções para enviar arquivos e gerar a anamnese em forma de pdf. A interface serve de apoio à triagem, mas exige confirmação por um profissional de saúde antes de qualquer diagnóstico.

Figura 2 – Interface do Pré-diagnóstico com Exemplo.



PRÉ-DIAGNÓSTICO

Paciente: Ana Silva
CPF: 12345678901

Resultado:
Lesão prevista: Nevo (pinta comum)
(Probabilidade baixa de carcinoma)
Confiança: 62%

Médico responsável:
Dr(a). Lucas Dias - CRM: 123456789

Enviar Arquivo Gerar e Baixar Anamnese

Fonte: Autores, 2025.

Discussão

O modelo aplicado no diagnóstico de doenças dermatológicas obteve resultados experimentais esperados, ainda necessitando de ajustes e testes com outros modelos. Nesta CNN, foi identificado uma acurácia variável de 75% a 77% de forma geral, indicando desempenho adequado para a tarefa proposta. Segundo (Musthafa et al., 2024) comparando o modelo com as abordagens tradicionais, MobileNet (83,1%), ResNet (90,51%) e o DenseNet201 (93,24%), o modelo de CNN testado alcançou uma precisão de 97,858% na classificação de sete tipos de câncer de pele do conjunto de dados HAM10000. Em relação aos resultados foi demonstrado um desempenho superior em métricas como precisão, recall e F1-score. Relevando que arquiteturas CNN otimizadas são altamente eficazes na detecção de câncer de pele, pois conseguem extrair características discriminativas complexas de

imagens dermatoscópicas que seriam difíceis de identificar manualmente por médicos especialistas (Musthafa *et al.*, 2024).

Para pesquisas futuras, sugere-se a utilização de módulos explicativos, como os heatmaps Grad-CAM, para melhorar a clareza das decisões, atendendo à necessidade de "interpretabilidade em modelos de deep learning" (Tiwari *et al.*, 2025).

Conclusão

Em síntese, esta pesquisa mostra que a aplicação de redes neurais convolucionais (CNNs) no diagnóstico dermatológico atende as expectativas e à detecção de benigno ou maligno quanto a imagens. A criação do sistema, como descrito e desenvolvido, surge como ferramenta para reduzir a sobrecarga nas clínicas, otimizar exames e aumentar a eficiência nos serviços de saúde com a pré-diagnose de câncer de pele. Além disso, contribui para a triagem precoce de casos graves, agilizando encaminhamentos e favorecendo melhores desfechos clínicos. Assim, a rede neuronal não substitui o médico, ou seu diagnóstico, mas funciona como suporte estratégico, agregando valor ao processo diagnóstico e fortalecendo a integração entre inteligência artificial e prática médica.

Referências

- ALVES, Gisely. Entendendo Redes Convolucionais (CNNs). 2018.
- BRASIL. Ministério da Saúde. Departamento de Ciência e Tecnologia. Protocolo de Diretrizes Terapêuticas do Melanoma Cutâneo, 2022.
- BÜHRING, C.A.Z. et al. Subtipos de câncer de pele. *RevInt*, 8, 2020.
- COSTA, C.C. et al. Carcinoma Basocelular. *Rev. Goiana Med.*, 2013.
- COSTA, C.S. Epidemiologia do câncer de pele. *Rev. Diagnóstico & Tratamento*, 2012.
- CUNHA, C.H.O. Redes ReLU aplicadas à sintonia. Dissertação, UFSC, 2022.
- CUNHA, Leonardo Cardoso da. Redes neurais convolucionais e segmentação de imagens – uma revisão bibliográfica. Ouro Preto, 2020.
- FLECK, L. et al. Redes neurais artificiais. *Rev. Inovação e Tecnologia*, 2016.
- INCA. Estimativa 2023: câncer no Brasil. 2022.
- KABIR, Farjana. Skin Cancer Dataset. Kaggle, 2022.
- MUSTHAFA, M. M. et al. Enhanced skin cancer diagnosis using optimized CNN architecture and checkpoints for automated dermatological lesion classification. *BMC Medical Imaging*, 2024.
- PALMEIRA, N.C. et al. Acesso a serviços de saúde. *Rev. Saúde Pública*, 2022.
- PIRES, G.A.; COELHO, F.G.F. Identificação de desvios por redes neurais. *An. CBIC*, 2021.
- RIZWAN, Muhammad. Convolutional Neural Networks – In a Nut Shell. *engMRK*, 2018.
- RIZZO, Igor Vilela; CANATO, Robson Leandro Carvalho. Inteligência artificial: funções de ativação. *Revista Prospectus*, v. 2, n. 2, p. 51-65, ago./fev. 2020.
- TAVARES, N.S. et al. Introdução a C#. Clube de Autores, 2013.

*A Ciência do **NANO** e seu impacto transformador no **MACRO***

TIWARI, A. K. et al. Automatic melanoma and non-melanoma skin cancer diagnosis using advanced adaptive fine-tuned convolution neural networks. Discover Oncology, 2025.